

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

MELISSA LA BANCA FREITAS

**ESTUDO E CLASSIFICAÇÃO DE GESTOS DE SINALIZAÇÃO CIRÚRGICA POR
MEIO DE ELETROMIOGRAFIA DE SUPERFÍCIE**

PONTA GROSSA

2022

MELISSA LA BANCA FREITAS

**ESTUDO E CLASSIFICAÇÃO DE GESTOS DE SINALIZAÇÃO CIRÚRGICA POR
MEIO DE ELETROMIOGRAFIA DE SUPERFÍCIE**

**STUDY AND CLASSIFICATION OF SURGICAL SIGNALING GESTURES USING
SURFACE ELECTROMYOGRAPHY**

Dissertação apresentada como requisito para obtenção do título de Mestre em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná (UTFPR).

Orientador(a): Prof. Dr. Sergio Luiz Stevan Junior.

Coorientador(a): Prof. Dr. José Jair Alves Mendes Junior.

PONTA GROSSA

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.



MELISSA LA BANCA FREITAS

**ESTUDO E CLASSIFICAÇÃO DE GESTOS DE SINALIZAÇÃO CIRÚRGICA POR MEIO DE
ELETROMIOGRAFIA DE SUPERFÍCIE**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestra Em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Controle E Processamento De Energia.

Data de aprovação: 11 de Novembro de 2022

Dr. Sergio Luiz Stevan Junior, Doutorado - Universidade Tecnológica Federal do Paraná
Dr. Carmelo Jose Albanez Bastos Filho, Doutorado - Universidade de Pernambuco (Upe)
Dr. Hugo Valadares Siqueira, Doutorado - Universidade Tecnológica Federal do Paraná
Jose Jair Alves Mendes Junior, - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 11/11/2022.

Dedico este trabalho a Deus,
à minha família, e, em especial,
ao meu marido por sempre
me apoiar e me auxiliar.

AGRADECIMENTOS

Agradeço a Deus, em primeiro lugar, pois sem Ele nada disso seria possível.

À minha família, por sempre me apoiar e me ajudar a não desistir. Agradeço, especialmente, ao meu marido por ter sido meu suporte por todos esses anos de pandemia e Mestrado, por me ajudar a programar, por me apoiar, por acreditar em mim e não me deixar desistir.

Ao meu orientador, Prof. Dr. Sergio Luiz Stevan Jr., por dar um norte, me auxiliar, e, principalmente, por não ter desistido de mim quando eu mesma queria. Ao meu coorientador, Prof. Dr. José Jair Alves Mendes Jr., por me dar todo o suporte necessário em diversos momentos difíceis, principalmente na etapa final, definitivamente não teria conseguido sem a sua ajuda. Aos demais professores que contribuíram direta ou indiretamente para a realização do presente trabalho e para a minha formação.

Aos meus colegas e amigos, que mesmo longe por causa da pandemia do COVID-19, estiveram perto de mim em diversos momentos de maneira online, dando apoio e o suporte psicológico que eu precisava.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES pelo apoio financeiro (Código de Financiamento 001).

Agradeço, por fim, a todas as pessoas que confiaram no meu trabalho, se disponibilizando como voluntários para realizar a coleta dos dados, afinal, sem estes dados nada disso seria possível.

O sucesso é ir de fracasso em
fracasso sem perder o entusiasmo.
(Autor desconhecido).

RESUMO

A sinalização cirúrgica é uma linguagem específica baseada no conjunto de gestos adotados em ambiente cirúrgico para facilitar a comunicação em manobras realizadas durante os procedimentos. Através da sinalização, o cirurgião transmite a informação ao instrumentador de qual instrumento precisa, reduzindo o tempo total da cirurgia e os erros causados por falhas na comunicação verbal. Com o avanço da tecnologia, sistemas de telecirurgia e cirurgia robótica estão cada vez mais presentes, sendo necessário que estes procedimentos cirúrgicos estejam adequados frente ao avanço da tecnologia. Neste sentido, o presente trabalho tem como objetivo apresentar uma análise de viabilidade do uso de sinais de eletromiografia de superfície (sEMG) e ferramentas de reconhecimento de padrões para classificar gestos de sinalização cirúrgica, visando auxiliar procedimentos cirúrgicos. A aquisição foi feita utilizando a *armband* comercial Myo™. A base de dados foi adquirida por meio de 10 voluntários ao realizar 14 gestos de sinalização cirúrgica referentes à solicitação de instrumentos (compressa, fio em carretel, fio solto, pinça Backhaus, pinça hemostática, pinça hemostática Kelly, afastador de Farabeuf, bisturi, porta agulha, válvula Doyen, pinça Allis, pinça anatômica, pinça dente de rato e tesoura) em 30 aquisições. Foram extraídas dezessete características do domínio do tempo e duas do domínio da frequência. A seleção dos grupos de características foi feita com base em trabalhos que também utilizam a classificação de gestos envolvendo a mão e o punho e que apresentaram bons resultados na classificação. A classificação dos 14 gestos foi feita utilizando os algoritmos LDA (Análise dos Discriminantes Lineares), QDA (Análise dos Discriminantes Quadráticos), KNN (K-Vizinhos Próximos), RF (Florestas Aleatórias), SVM (Máquina de Vetores de Suporte) e MLP (Perceptron de Múltiplas Camadas) e *Ensemble* (combinação de classificadores). A avaliação dos resultados foi feita de três maneiras diferentes: analisando os classificadores com relação ao seu acerto geral; para os diferentes 14 gestos; e para os indivíduos. O sistema proposto é viável caso haja uma calibração antes do uso para cada indivíduo e ajuste dos gestos utilizados, pois foi obtida uma taxa de acerto de mais de 90% para os indivíduos com os melhores resultados, além de 100% de taxa de acerto para os 10 indivíduos em um determinado gesto.

Palavras-chave: eletromiografia; instrumentos e aparelhos cirúrgicos; classificação; processamento de sinais.

ABSTRACT

Hand Signals in surgery are a specific language based on the set of gestures adopted in a surgical environment to facilitate communication for procedures handling. Through the signaling, the surgeon transmits the information to the scrub nurse which instrument he needs, thus reducing the total time of the surgery and the errors caused by failures in verbal communication. With the advancement of technology, telesurgery systems and robotic surgery are increasingly present, and these surgical procedures need to be adequate in the face of technological advances. In this sense, the present work aims to present a feasibility analysis of the use of surface electromyography (sEMG) signals and pattern recognition tools to classify surgical signaling gestures, aiming to assist surgical procedures. The acquisition was made using the commercial Myo™ armband. The composition of the database involved the acquisition of data from 10 volunteers when performing 14 hand signals referring to the request for instruments (compress, thread on spool, untied thread, Backhaus forceps, hemostatic forceps, Kelly hemostat forceps, Farabeuf retractor, scalpel, needle holder, Doyen valve, Allis forceps, anatomical forceps, rat tooth forceps and scissors) in 30 acquisitions. Seventeen features were extracted from the time domain and two from the frequency domain. The selection of groups of characteristics was based on studies that also use the classification of gestures involving the hand and wrist and that presented good results in the classification. The classification of the 14 gestures was performed using the algorithms LDA (Linear Discriminant Analysis), QDA (Quadratic Discriminant Analysis), KNN (K-Nearest Neighbor), RF (Random Forests), SVM (Support Vector Machine), MLP (Multilayer Perceptron), and Ensemble (combination of classifiers). The proposed system is viable if there is a calibration before use for each individual and adjustment of the gestures used, as an accuracy of more than 90% was obtained for individuals with the best results, in addition to a 100% of accuracy hit rate for the 10 individuals in a given gesture.

Keywords: electromyography; surgical instruments and devices; classification; signal processing.

LISTA DE FIGURAS

Figura 1 - Disposição geral do instrumental na mesa de cirurgia	32
Figura 2 - Esquema geral para montagem da mesa principal de acordo com a sequência de uso e funções: 1) diérese, 2) prensão, 3) hemostasia, 4) exposição, 5) especiais e 6) síntese.	32
Figura 3 - Exemplo de sinal EMG adquirido do músculo flexor radial do carpo durante a execução de um gesto envolvendo o antebraço, a mão e o punho. .	37
Figura 4 - 1) Exemplo de sinal EMG adquirido durante a execução de um gesto envolvendo a mão e o punho, 2) exemplo de determinação do <i>onset</i> e <i>offset</i> do sinal EMG apresentado com base em um <i>threshold</i>	42
Figura 5 - <i>Armband</i> comercial Myo™ usada para realizar a aquisição, com destaque aos seus oito canais.....	57
Figura 6 - Fluxo de dados: 1) aquisição através da <i>armband</i> e transmissão via <i>bluetooth</i> ao <i>smartphone</i> , 2) salvamento no <i>smartphone</i> , 3) transmissão via USB, 4) processamento no computador com o <i>software</i> MATLAB™	58
Figura 7 - Fluxograma da metodologia de trabalho adotada.....	59
Figura 8 - <i>Armband</i> comercial Myo™ usada para realizar a aquisição posicionada no antebraço	60
Figura 9 - Gestos realizados durante a aquisição	61
Figura 10 - Exemplo de sinal adquirido em um canal 1) mais ruidoso e 2) menos ruidoso, seus histogramas e desvios-padrão (Dp) 3) e 4), respectivamente	64
Figura 11 - Fluxograma da técnica de segmentação utilizada no presente trabalho	66
Figura 12 - Exemplos de funcionamento do <i>Ensemble</i> : 1) três classificadores apontaram o mesmo gesto, 2) dois classificadores apontaram o mesmo gesto e 3) cada classificador apontou um gesto diferente	72
Figura 13 – Funcionamento da análise por indivíduos, usando: 1) 1 para treinamento, 9 para teste, 2) 9 para treinamento, 1 para teste e 3) 1 – 90% para treinamento e 10% para teste, A) separando os dados do indivíduo 1, B) separando os dados do indivíduo 2, J) separando os dados do indivíduo 10 ..	72
Figura 14 – Taxas de acerto para os seis classificadores e treze grupos de características	74
Figura 15 - Acerto médio por grupo de característica	75
Figura 16 - Acerto médio dos classificadores para o grupo 13	75
Figura 17 - Matriz de confusão para o <i>Ensemble</i> manual.....	77
Figura 18 - Matriz de confusão para o classificador SVM.....	77
Figura 19 - Resultados da etapa de teste do classificador <i>Ensemble</i> treinado com os dados de um indivíduo e testado com os demais nove	80
Figura 20 - Resultados da etapa de teste do classificador <i>Ensemble</i> treinado com os dados de nove indivíduos e testado com os dados do indivíduo restante	81
Figura 21 - Resultados da etapa de teste do classificador <i>Ensemble</i> treinado 90% dos dados de um indivíduo e testado com 10% dos dados deste mesmo indivíduo	82
Figura 22 - Matrizes de confusão para os indivíduos que apresentaram os melhores resultados: 1) indivíduo 5 e 2) indivíduo 8	83

LISTA DE QUADROS

Quadro 1 - Comparativo dos trabalhos apresentados no Estado da Arte, relacionados ao reconhecimento de padrões (gestos) por EMG.....	26
Quadro 2 - Comparativo dos trabalhos apresentados no Estado da Arte, relacionados à instrumentação cirúrgica.....	27
Quadro 3 - Sinalização cirúrgica para os instrumentos adotados no presente trabalho	33
Quadro 4 - Características do sinal EMG usadas no presente trabalho.....	45
Quadro 5 - Algoritmo do classificador LDA.....	48
Quadro 6 - Algoritmo do classificador QDA	49
Quadro 7 - Algoritmo do classificador KNN.....	50
Quadro 8 - Algoritmo do classificador RF.....	51
Quadro 9 - Algoritmo do classificador MLP.....	55
Quadro 10 - Parâmetros usados na segmentação	63
Quadro 11 - Parâmetros usados para as características.....	68
Quadro 12 - Divisão dos grupos de características escolhidos	68
Quadro 13 - Critérios de parametrização para os classificadores utilizados	69
Quadro 14 - Gestos que apresentaram os melhores resultados de classificação para o <i>Ensemble</i> e o SVM.....	78
Quadro 15 - Gestos que apresentaram os piores resultados de classificação para o <i>Ensemble</i> e o SVM.....	79
Quadro 16 - Gestos que apresentaram os melhores resultados de classificação para a análise de acordo com os indivíduos	84

LISTA DE TABELAS

Tabela 1 - Taxa de acerto média dos classificadores	73
Tabela 2 - Taxa de acerto e tempo de execução para os métodos de <i>Ensemble</i> manual e automático.....	76

LISTA DE ABREVIATURAS E SIGLAS

AAC	<i>Average Amplitude Change</i>
ANN	<i>Artificial Neural Network</i>
AR	<i>Autoregressive Coefficients</i>
ASLR	<i>Automatic Sign Language Recognition</i>
BR-MC	<i>Binary Relevance + multiclass</i>
C1	Grupo de características 1
C2	Grupo de características 2
C3	Grupo de características 3
C4	Grupo de características 4
C5	Grupo de características 5
C6	Grupo de características 6
C7	Grupo de características 7
C8	Grupo de características 8
C9	Grupo de características 9
C10	Grupo de características 10
C11	Grupo de características 11
C12	Grupo de características 12
C13	Grupo de características 13
CC	<i>Cepstrum Coefficients</i>
CC-MC	<i>Classifier Chain + multiclass</i>
CNN	<i>Convolutional Neural Network</i>
DASDV	<i>Difference Absolute Standard Deviation Value</i>
DCNN	<i>Deep Convolutional Neural Network</i>
DT	<i>Decision Tree</i>
ELM	<i>Extreme Learning Machine</i>
EMG	Eletromiografia
FE	<i>Finger Extension</i>
FF	<i>Finger Flexion</i>
H.Close	<i>Hand Close</i>
HIST	<i>Histogram</i>
HL	<i>Hang Loose</i>
HN	<i>Horn</i>
HO	<i>Hand Open</i>
H.Open	<i>Hand Open</i>
IAV	<i>Integral Absolute Value</i>
ICA	<i>Independent Component Analysis</i>
IE	<i>Index Extension</i>
IEMG	<i>Integrated EMG</i>
IMU	<i>Inertial Measurement Unit</i>
ISL	<i>Indian Sign Language</i>
KNN	<i>k-Nearest Neighbors</i>
LDA	<i>Linear Discriminant Analysis</i>
LIS	<i>Lingua Italiana dei Segni</i>
LP-MC	<i>Label Power set + multiclass</i>
LS	<i>2nd Moment (L-SCALE)</i>
LSTM	<i>Long Short-Term Memory Neural Network</i>
MAV	<i>Mean Absolute Value</i>
ME	<i>Middle Extension</i>

MFL	<i>Maximal Fractal Length</i>
MHW	<i>Multiple Hamming Windows</i>
MLP	<i>Multilayer Perceptron</i>
MNP	<i>Mean Power</i>
MSR	<i>Mean Square Root</i>
MTW	<i>Multiple Trapezoidal Windows</i>
MYOP	<i>Myopulse percentagem rate</i>
NB	<i>Näive Bayes</i>
NN	<i>Neural Network</i>
OK	<i>Ok</i>
PC	<i>Peace</i>
PCA	<i>Principal Component Analysis</i>
PE	<i>Permutation Entropy ou Pinky Extension</i>
PG	<i>Power Grip</i>
PSL	<i>Persian Sign Language</i>
QDA	<i>Quadratic Discriminant Analysis</i>
RA	<i>Right Angle</i>
RBF-NN	<i>Radial Basis Function Neural Network</i>
RD	<i>Radial Deviation</i>
RE	<i>Ring Extension</i>
RF	<i>Random Forests</i>
R.Flex	<i>Wrist Radial Flexion</i>
RMS	<i>Root Mean Square</i>
RNN	<i>Recurrent Neural Network</i>
SampEn	<i>Sample Entropy</i>
sEMG	<i>Eletromiografia de superfície</i>
SSC	<i>Slope Sign Change</i>
SVM	<i>Support Vector Machine</i>
SVMLin	<i>Support Vector Machine with Linear Discrimination</i>
SVMRBF	<i>Support Vector Machine with Radial Basis Function Discrimination</i>
SWSS	<i>Soft Wrist-worn Sensor System</i>
TA	<i>Taxa de assertividade</i>
TE	<i>Thumb Extension</i>
TTP	<i>Total Power</i>
TU	<i>Thumb Up</i>
UD	<i>Ulnar Deviation</i>
U.Flex	<i>Wrist Ulnar Flexion</i>
UTFPR	<i>Universidade Tecnológica Federal do Paraná</i>
VAR	<i>Variance</i>
WAMP	<i>Willison Amplitude</i>
WE	<i>Wrist Extension</i>
W.Ext	<i>Wrist Extension</i>
WF	<i>Wrist Flexion</i>
W.Flex	<i>Wrist Flexion</i>
WL	<i>Waveform Length ou Wrist Flexion</i>
W.Pron	<i>Wrist Pronation</i>
W.Sup	<i>Wrist Supination</i>
ZC	<i>Zero Crossing</i>

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Objetivos	15
1.1.1	Objetivo Geral.....	15
1.1.2	Objetivos específicos.....	16
1.2	Justificativa.....	16
1.3	Hipótese	17
1.4	Organização.....	17
2	ESTADO DA ARTE.....	19
3	REVISÃO DE LITERATURA	30
3.1	Instrumentação e Sinalização Cirúrgica.....	30
3.1.1	Sinalização cirúrgica.....	33
3.2	Eletromiografia	36
3.3	Instrumentação do Sinal de Eletromiografia	38
3.3.1	Aquisição	38
3.3.2	Condicionamento.....	40
3.3.3	Segmentação	41
3.3.4	Extração de Características	43
3.3.5	Classificação	47
4	MATERIAIS E MÉTODOS	57
4.1	Materiais.....	57
4.2	Metodologia	59
4.3	Metodologia Experimental.....	59
4.4	Metodologia de Análise	62
4.4.1	Segmentação	62
4.4.2	Normalização dos dados	67
4.4.3	Extração de Características/Atributos do sinal	67
4.4.4	Classificação de padrões	69
5	RESULTADOS E DISCUSSÃO	73
5.1	Análise Geral dos Classificadores.....	73
5.2	Análise de Acordo com o <i>Ensemble</i>.....	74
5.3	Análise de Acordo com os Gestos	76
5.4	Análise de Acordo com os Indivíduos.....	80
5.4.1	Treinamento com dados de um indivíduo e teste com dados dos demais nove	80

5.4.2	Treinamento com dados de nove indivíduos e teste com dados do indivíduo restante	81
5.4.3	Treinamento e teste com cada indivíduo separadamente	82
6	CONCLUSÃO	86
	REFERÊNCIAS.....	89
	APÊNDICE A - Termo de Consentimento Livre e Esclarecido	99

1 INTRODUÇÃO

Dentro do ambiente cirúrgico devem estar presentes diversos elementos para realizar os procedimentos com segurança e eficácia. Uma equipe capacitada, assim como uma sala de cirurgia organizada, pode reduzir consideravelmente os riscos ao paciente e garantir uma melhor qualidade de vida. Além disso, uma boa comunicação entre o cirurgião e a sua equipe é um fator essencial para uma intervenção cirúrgica com sucesso (JACOB *et al.*, 2012; NEMITZ, 2019).

Neste sentido, entra a questão da comunicação entre o cirurgião e o instrumentador, que é o membro da equipe responsável por organizar a bandeja de instrumentos e fornecer estes ao cirurgião quando solicitado. Para evitar erros e falhas de comunicação, a solicitação dos instrumentos é feita de maneira verbal e através de sinalização cirúrgica, em que o cirurgião executa gestos com a mão que representam determinados instrumentos (NEMITZ, 2019; PHILLIPS, 2019).

Porém, nem sempre há um instrumentador com agenda disponível para auxiliar na cirurgia, fazendo com o que o procedimento cirúrgico deva ser remarcado ou adiado. Por essa razão, tem-se estudado a inserção de ferramentas tecnológicas para auxiliar no processo de instrumentação cirúrgica, como o auxílio de robôs instrumentadores tanto em cirurgias presenciais quanto em telecirurgias. A inserção desses robôs traz a necessidade de sistemas que auxiliem no reconhecimento dos gestos e solicitações efetuados pelo cirurgião (ANGELINI; PAPASPYROPOULOS, 2000; BRADLEY, 1995; CHOI; OSKOUIAN; TUBBS, 2018).

Sob essa perspectiva, a presente dissertação apresenta o desenvolvimento de um sistema para fazer a aquisição de gestos de sinalização cirúrgica por meio de um dispositivo vestível para aquisição de eletromiografia de superfície (sEMG) e a classificação desses gestos através de ferramentas computacionais.

1.1 Objetivos

Os objetivos da presente dissertação estão apresentados a seguir.

1.1.1 Objetivo Geral

O presente trabalho tem por objetivo geral apresentar uma análise de viabilidade do uso de sinais de eletromiografia de superfície (sEMG) e ferramentas de

reconhecimento de padrões para classificar gestos de sinalização cirúrgica, visando auxiliar procedimentos cirúrgicos.

1.1.2 Objetivos específicos

Para o cumprimento do objetivo geral do trabalho, são listados a seguir os seguintes objetivos específicos:

- Definir e delimitar um conjunto de gestos de sinalização, habitualmente utilizados em instrumentação cirúrgica;
- Definir um protocolo experimental para a aquisição dos sinais de sEMG durante a execução de gestos de sinalização cirúrgica utilizando uma *armband* comercial;
- Realizar a aquisição dos sinais de sEMG seguindo o protocolo definido;
- Construir uma base de dados com base na aquisição dos sinais referente ao conjunto de dados definido;
- Realizar a segmentação e normalização dos sinais de acordo com cada indivíduo;
- Selecionar grupos de características do sinal EMG para inserir como entrada de classificadores;
- Utilizar seis classificadores diferentes e um método de combinação destes para análise dos padrões nos dados adquiridos oriundos dos gestos definidos no protocolo experimental;
- Realizar a apresentação dos resultados com base nos diferentes grupos de características, classificadores, gestos e voluntários.

1.2 Justificativa

A utilização de sistemas de reconhecimento de gestos de sinalização cirúrgica pode diminuir a dependência do instrumentador, o que é uma vantagem não apenas por causa da disponibilidade dele, mas também pelo fato de que a presença do instrumentador normalmente implica em custos adicionais ao procedimento cirúrgico. Outro fator importante é que em sistemas de telecirurgia ou cirurgia robótica, a presença de mais um robô para auxiliar pode diminuir a chance de erros durante o procedimento, pois estes não apresentam características humanas como cansaço, desatenção e fadiga.

Entretanto, a maioria dos sistemas de reconhecimento de gestos de sinalização cirúrgica têm envolvido a classificação por meio de imagens e vídeos, os quais requerem algumas atenções: é necessário se ter uma boa condição de iluminação no local, a maioria dos instrumentos cirúrgicos é metálica, então esses acabam refletindo mais a luz e podem dificultar o sistema de classificação de instrumentos. Em outra perspectiva, o uso de sistemas de reconhecimento de voz pode apresentar falhas provenientes dos ruídos gerados pelas máquinas de monitoramento.

Por essa razão utilizar, em conjunto com os sistemas citados anteriormente, um sistema vestível para fazer o reconhecimento de gestos através de sEMG pode ajudar a aumentar a robustez do sistema de reconhecimento de gestos. A inserção do sistema de sEMG faz com que o reconhecimento se dê independentemente de condições de iluminação do local, do posicionamento dos dispositivos no ambiente, ou de outros ruídos inerentes ao ambiente, aumentando a segurança ao paciente e trazendo mais eficiência ao procedimento cirúrgico. Entretanto, é importante que esse sistema vestível traga o mínimo de desconforto ao cirurgião, pois há cirurgias que são extremamente longas, e o desconforto pode interferir em sua concentração, acelerando o processo de fadiga.

1.3 Hipótese

O presente trabalho busca avaliar a seguinte hipótese: É possível desenvolver um sistema de reconhecimento de padrões com alta taxa de acerto para gestos de sinalização cirúrgica, baseados em dados coletados exclusivamente por sEMG?

1.4 Organização

O presente trabalho está organizado em outros capítulos além da introdução.

O Capítulo 2 proporciona o estado da arte acerca do tema da presente dissertação, apontando os principais trabalhos existentes que tratam sobre instrumentação cirúrgica e o reconhecimento de sinalização cirúrgica.

O Capítulo 3 apresenta uma revisão de literatura contendo os principais conceitos relacionados ao tema do presente trabalho, abrangendo a instrumentação cirúrgica, eletromiografia e procedimentos empregados no estudo do sinal de eletromiografia.

O Capítulo 4 aborda como a metodologia do presente trabalho foi desenvolvida, explicitando quais os materiais utilizados e as etapas de desenvolvimento, envolvendo aquisição do sinal de eletromiografia de superfície e montagem da base de dados, o processo de segmentação de dados adotado, a extração de características e classificação.

O Capítulo 5 demonstra os resultados obtidos com relação à classificação dos gestos de sinalização cirúrgica, levantando também a discussão acerca destes resultados.

Por fim, o Capítulo 6 apresenta quais são as considerações finais sobre o presente trabalho, além das perspectivas de trabalhos futuros.

2 ESTADO DA ARTE

O reconhecimento de padrões de gestos através de eletromiografia tem sido abordado em diversas pesquisas nos últimos anos. Alguns estudos envolvem o reconhecimento de gestos de línguas de sinais, enquanto outros envolvem a classificação de gestos performados usando a mão e o punho para o controle de próteses (DONG *et al.*, 2021; KHOMAMI; SHAMEKHI, 2021; SCHORSCH *et al.*, 2008; SERNANI *et al.*, 2021).

No caso apresentado por Li *et al.* (2020) buscou-se fazer o desenvolvimento de um modelo avançado de reconhecimento de gestos através de um classificador utilizando redes neurais (LSTM – *Long Short-Term Memory Neural Network*), utilizando como sistema de aquisição a *armband* comercial Myo™. Foi feita a classificação de quatro diferentes gestos envolvendo a mão e o punho: pedra, tesoura, papel e ok. Chegou-se a uma taxa de acerto de 95,75% com o sistema de classificação LSTM desenvolvido.

Com o objetivo de avaliar a influência da segmentação, extração de características e classificação para o processamento do sinal de EMG, os autores Mendes Junior *et al.* (2020b) realizaram a classificação dos 26 gestos do alfabeto de Libras (Língua Brasileira de Sinais). Para a análise, utilizou-se os classificadores KNN (*k-Nearest Neighbors*), LDA (*Linear Discriminant Analysis*), NB (*Náive Bayes*), MLP (*Multilayer Perceptron*), QDA (*Quadratic Discriminant Analysis*), RF (*Random Forests*), ELM (*Extreme Learning Machine*), SVMLin (*Support Vector Machine with Linear Discrimination*), SVMRBF (*Support Vector Machine with Radial Basis Function Discrimination*). Também foram avaliados vários grupos diferentes de características e formas de segmentação e chegou-se como melhor resultado que a melhor taxa de acerto encontrada foi de aproximadamente 99% para o classificador RF, com segmentos de 1,75s e taxa de *overlap* de 12,5% (essa taxa é a quantidade de amostras que são sobrepostas entre segmentos consecutivos no processo de segmentação).

Realizando uma fusão de sensores de EMG e pressão, no estudo desenvolvido por Dong *et al.* (2021) apresentou-se um sistema de sensor flexível para uso no punho (SWSS – *Soft Wrist-worn Sensor System*). Foram utilizados quatro canais para coletar os sinais EMG para dois casos diferentes. O primeiro deles avalia a execução de seis gestos: extensão do punho (WF – *Wrist Flexion*), extensão do punho (WE – *Wrist*

Extension), flexão dos dedos (FF – *Finger Flexion*), extensão dos dedos (FE – *Finger Extension*), desvio radial (RD – *Radial Deviation*) e desvio ulnar (UD – *Ulnar Deviation*). O segundo envolve a execução de gestos relacionados aos números de 0 a 9 de linguagem de sinais. A classificação dos gestos foi feita com o uso dos classificadores LDA e SVM. Chegou-se a uma taxa de acerto média de 83,67% e 86,8% com relação ao primeiro grupo de gestos para os classificadores LDA e SVM, respectivamente. Os resultados para o segundo grupo apresentaram uma taxa média de acerto de 84,71% para o LDA e 88,53% para o QDA.

Visando classificar 100 gestos presentes na Linguagem Indiana de Sinais (ISL – *Indian Sign Language*), Gupta e Kumar (2021) utilizaram um sistema de aquisição de EMG em conjunto com sensores inerciais para coletar os sinais de ambos os antebraços. Foram utilizados 6 canais de sEMG e 4 unidades de medição inerciais, sendo a comunicação *wireless* realizada pelo sistema Delsys Trigno. Foram utilizadas as seguintes técnicas de classificação: classificação plana (*Flat Classification*), classificação baseada em árvore para multiclasse (*Tree-based categorization + final multiclass*), classificação por relevância binária para multiclasse (BR-MC – *Binary Relevance + multiclass*), cadeia classificadora para multiclasse (CC-MC – *Classifier Chain + multiclass*) e *Label Power set + multiclass* (LP-MC). Como resultados, obteve-se que a menor taxa de erro foi obtida para o classificador LP-MC com o valor de 2,73%.

Com o objetivo de desenvolver um sistema de reconhecimento de gestos da Linguagem Persa de Sinais (PSL – *Persian Sign Language*) de baixo custo, Khomami e Shamekhi (2021) utilizaram 4 canais bipolares de sEMG e uma IMU com 6 eixos para realizar a aquisição dos sinais de 10 voluntários. Foram utilizados 20 sinais comuns na PSL para fazer a classificação com os métodos LDA, SVMLinear, SVMRBF, KNN e DT (*Decision Trees*). Como resultados, obteve-se que a maior taxa de acerto obtida foi de 96,13% para o classificador KNN.

No estudo apresentado por Raurale, McAllister e Rincon (2021) utilizou-se a *armband Myo™* para classificar 8 gestos diferentes envolvendo a mão e o punho. Estes gestos foram: pronação do punho (W.Pron – *Wrist Pronation*), supinação do punho (W.Sup – *Wrist Supination*), extensão do punho (W.Ext – *Wrist Extension*), flexão do punho (W.Flex – *Wrist Flexion*), flexão ulnar do punho (U.Flex – *Wrist Ulnar Flexion*), flexão radial do punho (R.Flex – *Wrist Radial Flexion*), mão fechada (H.Close – *Hand close*) e mão aberta (H.Open – *Hand Open*). Foram utilizadas as técnicas de

redução de dimensionalidade LDA, PCA (*Principal Component Analysis*) e ICA (*Independent Component Analysis*) para os classificadores DT, MLP, SVM polinomial e RBF-NN (*Radial Basis Function Neural Network*). Como melhor resultado, chegou-se a uma taxa média de acerto de 91,7% para o classificador RBF-NN.

Também utilizando a *armband* Myo™, Sernani *et al.* (2021) realizaram a classificação de 26 gestos do alfabeto da Linguagem Italiana de Sinais (LIS – *Lingua Italiana dei Segni*). Para tal, utilizou-se o classificador LSTM, um tipo de rede neural recorrente (RNN – *Recurrent Neural Network*) para uma base de dados formada tanto pelos dados dos eletrodos de sEMG, quanto pelos valores medidos pela unidade inercial (IMU – *Inertial Measurement Unit*). Com o sistema proposto, chegou-se a uma taxa de acerto de 97%.

Com um sistema composto por 8 canais para fazer a aquisição do sinal de sEMG, Botros, Phinyomark e Scheme (2022) realizaram a classificação de 17 diferentes gestos envolvendo os dedos e o punho. Estes gestos foram divididos em três grupos: gestos envolvendo apenas um dedo (TE – *Thumb Extension*, IE – *Index Extension*, ME – *Middle Extension*, RE – *Ring Extension* e PE – *Pinky Extension*), gestos envolvendo múltiplos dedos (TU – *Thumb Up*, RA – *Right Angle*, PC – *Peace*, OK, HN – *Horn*, HL – *Hang Loose*) e gestos envolvendo o punho (PG – *Power Grip*, HO – *Hand Open*, WE – *Wrist Extension*, WL – *Wrist Flexion*, UD – *Ulnar Deviation* e RD – *Radial Deviation*). Foram usados os classificadores LDA e SVM e chegou-se à taxa média de acerto de 91,2% para os gestos envolvendo os dedos e 94,7% para gestos convencionais envolvendo o a mão e o punho.

Para realizar a classificação de 12 sinais presentes na Língua Colombiana de Sinais, Pereira-Montiel *et al.* (2022) utilizaram um sistema de 4 canais para realizar a aquisição de sinais de sEMG e acelerômetros para captar o movimento. Seu objetivo era o desenvolvimento de um sistema automático de reconhecimento de linguagem de sinais (ASLR – *Automatic Sign Language Recognition*). Para tal, utilizou-se o classificador SVM e analisou-se a taxa de acerto para o uso dos sinais de sEMG e/ou do acelerômetro, assim como o uso das características RMS (*Root Mean Square*) e PE (*Permutation Entropy*) em conjunto ou usadas de maneira individual. Como resultados, chegou-se a uma taxa de acerto de 96,66% ao usar apenas a característica RMS e os dados do acelerômetro e de sEMG.

Nesta linha, os trabalhos de reconhecimento de gestos dependem não apenas do conjunto de gestos a serem analisados, da quantidade e posicionamento dos

eletrodos empregados, mas também das diferentes estratégias de processamento de sinais e de dados, a serem estudadas, moldadas e avaliadas. Porém, o desafio do presente trabalho não é o reconhecimento de gestos de sEMG de forma geral como apresentado nos exemplos anteriores, e sim focando em aplicações envolvendo instrumentação cirúrgica.

A instrumentação cirúrgica é habitualmente realizada por auxiliares humanos, os quais inserem custos adicionais às cirurgias e podem inserir falhas no processo, seja por problemas de comunicação, seja pelas extensas jornadas que estes profissionais costumeiramente se propõem. Neste aspecto, o auxílio de ferramentas tecnológicas e/ou assistivas podem promover uma melhor execução dos procedimentos cirúrgicos, seja no âmbito de robotização, seja no âmbito de telecirurgias.

Buscando reduzir potenciais erros no repasse do instrumental ao cirurgião e aumentar a segurança no ambiente cirúrgico, nos trabalhos desenvolvidos por Jacob *et al.* (2012) e Jacob, Li e Wachs (2011, 2012, 2013) apresentou-se a criação de um robô instrumentador, chamado *Gestonurse*. Este robô teve como função realizar o reconhecimento do gesto realizado pelo cirurgião e repassar ao mesmo o instrumento requisitado. O reconhecimento foi feito através de classificação por imagens (usando o sensor Kinect), utilizando os números de 1 a 5 como gestos referentes aos instrumentos bisturi, tesoura, retrator, fórceps e hemostato, respectivamente. Os resultados apresentados por Jacob, Li e Wachs (2011) e Jacob *et al.* (2012) mostraram que aproximadamente 95% dos gestos foram reconhecidos corretamente, porém comparando-se ao desempenho de tarefas humanas o sistema apresentou 0,83 s de lentidão em comparação à atividade realizada por pessoas. Já no trabalho de Jacob, Li e Wachs (2012), chegou-se a uma taxa de acerto na classificação de 97% e percebeu-se que o sistema multimodal utilizado foi mais rápido que o sistema unimodal utilizado anteriormente. No estudo realizado pelos mesmos autores, Jacob, Li e Wachs (2013), o *Gestonurse* foi aperfeiçoado, acrescentando a ele um sistema de reconhecimento de fala e mais cinco gestos (utilizando os mesmos 5 números, porém com divisão entre gestos estáticos e dinâmicos), além de criar trajetórias de movimentação do robô planejadas e executadas para evitar colisões com o usuário. Neste caso, o treinamento ocasionou uma queda de 12,92% no tempo de conclusão da tarefa e 95,96% dos gestos foram reconhecimentos corretamente, além das

colisões com o usuário terem sido completamente evitadas ao usar o novo algoritmo de prevenção de obstáculos ativo.

No estudo apresentado por Perez-Vidal *et al.* (2012), desenvolveu-se um robô instrumentador para auxiliar o instrumentador e o cirurgião, apelidado de *Quirubot*. Ele é composto de um sistema de reconhecimento de fala para reconhecer qual o instrumento solicitado pelo cirurgião e de um sistema de reconhecimento de imagem para poder detectar o instrumento (com o uso de câmera), pegá-lo e alcançá-lo ao instrumentador. Também foi realizada uma modificação no robô para que ele possa manipular uma garra eletromagnética, facilitando a preensão dos instrumentos. Como resultados, o *Quirubot* é capaz de identificar até 27 instrumentos cirúrgicos e reconhecer mais de 82 instruções faladas.

Visando reduzir o tempo de cirurgia e o potencial de infecção, no trabalho desenvolvido por Esfahani *et al.* (2017) focou-se no desenvolvimento de um sistema de reconhecimento de gestos com as mãos através de *deep learning*. Este método é um modelo de detecção preciso, porém com alta complexidade, o que aumenta consideravelmente o custo computacional. Por essa razão, no estudo foram aplicadas algumas mudanças na estrutura para reduzir a complexidade do sistema de classificação. Com isso, realizou-se a classificação de 10 diferentes gestos através de imagens provindas de um banco de dados e avaliou-se a eficácia do sistema proposto. Neste caso, não se utilizou uma câmera, apenas as imagens fornecidas pelo *dataset*. Em comparação a outro estudo (MARIN; DOMINIO; ZANUTTIGH, 2014), a taxa média de acerto na classificação foi maior (91,28 para Marin, Dominio e Zanuttigh (2014) e 94,86 para o estudo atual), o que implica em maior precisão e menor complexidade em comparação com métodos existentes.

No caso apresentado por Zhou e Wachs (2017) o foco não foi no reconhecimento de gestos performados pelo cirurgião, e sim no reconhecimento dos instrumentos posicionados na bandeja de instrumentos pelo robô instrumentador. Isso porque muitas vezes os instrumentos são posicionados de forma desordenada, obstruída e por serem metálicos exibem luz especular, o que dificulta bastante o processo de reconhecimento dos instrumentos de maneira visual. Recorreu-se a uma abordagem combinada de visão computacional híbrida e manipulação robótica, em que os instrumentos são primeiro segmentados e a pose é estimada, depois o robô pega os instrumentos e os apresenta a um sensor ótico para que estes possam ser reconhecidos e então entregues. Foram conduzidos experimentos para avaliar o

sistema proposto e chegou-se a uma taxa de 95,6% de acerto no reconhecimento de instrumentos.

Tendo como objetivo reduzir as falhas ocasionadas na cirurgia como fornecimento de instrumentais errados e atrasos, no estudo desenvolvido por Le e Pham (2018) foi apresentado um sistema de visão computacional que identifica os símbolos das mãos e as posições dos instrumentos cirúrgicos usando um sensor Kinect na sala de cirurgia. Foram reconhecidos 5 gestos representados por pares de números e determinados instrumentos: 30 – bisturi, 31 – tesoura, 32 – retrator, 33 – fórceps e 34 – hemostato. Esses pares de números foram executados em sequência. Por exemplo, para representar o instrumento bisturi, o usuário deveria fazer o gesto referente ao número 3 e, em seguida, o gesto referente ao número 0. Por serem pares de números. O sistema desenvolvido classifica o gesto desenvolvido pelo cirurgião e detecta a posição e direção do instrumento em uma mesa para direcionar um robô para pegá-lo corretamente. Com os resultados obtidos, chegou-se à conclusão de que o sistema é viável, pois ele foi capaz de detectar símbolos com base no número de dedos e conseguiu identificar o centro e o ângulo de rotação dos instrumentos necessários.

Com o foco não na classificação de sinalização cirúrgica, e sim na classificação de diferentes instrumentos cirúrgicos, Murillo, Arenas e Moreno (2018) desenvolveram um algoritmo de classificação de imagens de objetos com base em redes neurais convolucionais (CNN – *Convolutional Neural Networks*) estruturadas no sistema de árvores de decisão (DT). Com o sistema proposto, os autores chegaram a 70% de taxa de acerto na classificação de 10 diferentes instrumentos (cabo de bisturi 4, sonda, agulha de dissecação curva, fórceps Splinter, cabo de bisturi 7, pinça de jacaré Hartman, pinça Kelly curvada, tesoura de operação sem corte, prendedor de toalha Backhaus e sonda de ponta dupla) e de 96% de taxa de acerto na classificação de 5 diferentes instrumentos (agulha de dissecação curva, fórceps Splinter, sonda, tesoura de operação sem corte e prendedor de toalha Backhaus).

Levando em consideração a contaminação proveniente de instrumentos que auxiliam nos sistemas de cirurgia digital (ou telecirurgias) como câmeras, acelerômetros e outros sensores, Bieck, Fuchs e Neumuth (2019) propuseram um sistema vestível para auxiliar nestes processos. Para tal, utilizou-se a *armband* comercial Myo™ para captar os sinais EMG provenientes do antebraço durante a execução de gestos de manuseio dos seguintes instrumentos cirúrgicos: braçadeira

reta, fórceps, perfurador, *Bone Punch* e *sharp spoon*). A classificação dos gestos foi feita por meio de redes neurais artificiais (ANN – *Artificial Neural Network*) e árvores de decisão (DT). Como resultados, obteve-se uma taxa de acerto de classificação de 95,2% e 70,1% das redes neurais artificiais para dados adquiridos de um e seis voluntários, respectivamente. Já no caso das árvores de decisão, chegou-se a uma taxa de acerto de 95,3% para um voluntário e 71,2% de acerto para seis voluntários.

No trabalho apresentado por Qi *et al.* (2021) buscou-se fazer o reconhecimento de gestos de números (de 1 a 10), para melhorar a interação homem-máquina em sistemas de telecirurgia robótica. Para tal, utilizou-se o conceito de fusão de sensores com EMG (utilizando também a *armband* comercial Myo™) e de informações de profundidade e classificou-se os gestos utilizando redes neurais convolucionais profundas (DCNN – *Deep Convolutional Neural Networks*) e outros classificadores para fazer a comparação. Foram coletados dados de 10 voluntários, sendo 5 homens e 5 mulheres. Como resultado, obteve-se uma taxa de acerto de 88,47% para a DCNN, 80,37% para a RNN, 74,39% para SVM, 69,78% para KNN e 79,49% para NN (*Neural Network*).

Por fim, Luongo *et al.* (2021) fizeram o reconhecimento de gestos de sutura para sistemas de cirurgias auxiliadas por robôs através de vídeos. Utilizou-se o conceito de visão computacional através do método de aprendizagem profunda (*deep-learning*) com o classificador LSTM para realizar a classificação dos gestos. Foram usados dois conjuntos de dados diferentes: um para identificar a presença de um gesto (com 2395 vídeos) e outro para classificar o tipo de gesto (com 511 vídeos). Chegou-se como resultados à taxa de acerto de classificação da presença de gestos de 88% e do tipo de gesto de 87% com o método adotado.

O Quadro 1 apresenta um comparativo entre os trabalhos citados que estão relacionados ao reconhecimento de padrões (gestos) por EMG, com destaque à quantidade de eletrodos utilizada, técnica de classificação abordada e resultados obtidos. Já o Quadro 2 apresenta um comparativo entre os trabalhos relacionados à instrumentação cirúrgica, com destaque ao objetivo dos trabalhos, técnicas utilizadas, quais os gestos e/ou instrumentos classificados e os resultados obtidos.

Quadro 1 - Comparativo dos trabalhos apresentados no Estado da Arte, relacionados ao reconhecimento de padrões (gestos) por EMG

Trabalho	Quantidade de canais	Técnicas de classificação	Gestos	Resultados
Li <i>et al.</i> (2020)	8	LSTM	4 gestos (pedra, papel, tesoura e ok)	Taxa de acerto: 95,75%
Mendes Junior <i>et al.</i> (2020a)	8	KNN, LDA, NB, MLP, QDA, RF, ELM, SVMLin, SVMRBF	26 gestos do alfabeto de Libras	Maior taxa de acerto: 99% para o classificador RF
Dong <i>et al.</i> (2021)	4	LDA, SVM	- G1: 6 gestos (WF, WE, FF, FE, RD e UD) - G2: 10 gestos (números de 0 a 9)	Maiores taxas de acerto: 86,8% para o grupo 1 e 88,53% para o grupo 2
Gupta, Kumar (2021)	6	Flat, Tree-MC, BR-MC, CC-MC, LP-MC	100 gestos da ISL	Menor taxa de erro: - LP-MC: 2,73%
Khomami, Shamekhi (2021)	4	LDA, SVMLin, SVMRBF, KNN, DT	20 sinais da PSL	Maior taxa de acerto: 96,13% para o classificador KNN
Raurale, Mcallister, Rincon (2021)	8	DT, MLP, SVM, RBF-NN	8 gestos (W.Pron, W.Sup, W.Ext, W.Flex, U.Flex, R.Flex, H.Close, H.Open)	Maior taxa média de acerto: 91,7% para RBF-NN
Sernani <i>et al.</i> (2021)	8	LSTM	26 gestos do alfabeto da LIS	Taxa de acerto: 97%
Botros, Phinyomark, Scheme (2022)	8	LDA, SVM	17 gestos envolvendo os dedos e o punho	Maior taxa de acerto: 94,7% para gestos com o punho
Pereira-Montiel <i>et al.</i> (2022)	4	SVM	12 sinais da Língua Colombiana de Sinais	Taxa de acerto: 96,66% usando RMS

Fonte: Autoria própria (2023)

Quadro 2 - Comparativo dos trabalhos apresentados no Estado da Arte, relacionados à instrumentação cirúrgica

Trabalho	Objetivo	Técnicas	Gestos/ Instrumentos	Resultados
Jacob, Li e Wachs (2011)	Desenvolvimento de Robô instrumentador	- Classificação por imagem - Sensor Kinect	- 5 gestos - Números de 1 a 5 representando instrumentos	- Acerto: 95% - 0,83 s mais lento em comparação à atividade humana
Jacob <i>et al.</i> (2012)	Desenvolvimento de Robô instrumentador	- Classificação por imagem - Sensor Kinect	- 5 gestos - Números de 1 a 5 representando instrumentos	- Acerto: 95% - 0,83 s mais lento em comparação à atividade humana
Jacob, Li e Wachs (2012)	Aperfeiçoamento do Robô instrumentador	- Classificação por imagem - Sensor Kinect - Sistema multimodal de classificação	- 5 gestos - Números de 1 a 5 representando instrumentos	- Acerto: 97%
Jacob, Li e Wachs (2013)	Aperfeiçoamento do desenvolvimento de Robô instrumentador	- Classificação por imagem e fala - Sensor Kinect e microfone - Sistema para evitar colisão	- 10 gestos - Números de 1 a 5 (estáticos e dinâmicos) representando instrumentos	- Acerto: 95,96% - Queda de 12,92% no tempo de conclusão da tarefa - Colisões evitadas
Perez-Vidal <i>et al.</i> (2012)	Desenvolvimento de robô instrumentador	- Classificação do instrumento por imagem - Classificação da solicitação por fala - Câmera e microfone	-	- Identificação de até 27 instrumentos - Reconhecimento de mais de 82 instruções faladas
Esfahani <i>et al.</i> (2017)	Reconhecimento de gestos	- <i>Deep Learning</i> - Classificação por imagem - <i>Dataset</i> com imagens	- 10 gestos	- Acerto: 94,86%
Zhou e Wachs (2017)	Reconhecimento de instrumentos posicionados na bandeja	- Visão computacional híbrida - Manipulação robótica - Sensor ótico	-	- Acerto: 95,6%

Trabalho	Objetivo	Técnicas	Gestos/ Instrumentos	Resultados
Le e Pham (2018)	Reconhecimento de gestos e das posições dos instrumentos	- Classificação por imagem - Sensor Kinect	- 5 gestos - Números 30, 31, 32, 33 e 34 representando instrumentos	- O sistema é viável
Murillo, Arenas e Moreno (2018)	Reconhecimento de instrumentos cirúrgicos	- Classificação por imagem - Classificador CNN estruturado com DT	- 10 instrumentos - 5 instrumentos	- Acerto: 70% para 10 instrumentos e 96% para 5 instrumentos
(BIECK; FUCHS; NEUMUTH, 2019)	Reconhecimento de gestos de manuseio de instrumentos	- EMG: <i>Armband Myo™</i> - Classificador ANN - Classificador DT	- 5 instrumentos	Acertos: - 1 voluntário: 95,2% (ANN) e 95,3% (DT) - 5 voluntários: 70,1% (ANN) e 71,2% (DT)
Qi et al. (2021)	Reconhecimento de gestos	- EMG: <i>Armband Myo™</i> - Informações de profundidade - Diversos classificadores	- 10 gestos representando os números de 1 a 10	- Acerto: 88,47% (DCNN), 80,37% (RNN), 74,39% (SVM), 69,78% (k-NN), 79,49 (NN)
Luongo et al. (2021)	Reconhecimento de gestos de sutura	- Visão computacional - <i>Deep Learning</i> - Classificador LTSM - <i>Datasets</i> com vídeos	-	Acerto: 88% para detecção da presença de gesto, 87% para o tipo de gesto

Fonte: Autoria própria (2023)

Avaliando esses trabalhos aqui apresentados, pode-se notar que o uso de sEMG visando o auxílio no processo de instrumentação cirúrgica não é muito presente, normalmente os processos envolvem mais a classificação através de imagens. Nos casos apresentados, quando se utilizou sEMG, foi visando mais o reconhecimento de gestos de números ou de manuseio de instrumentos, do que da

sinalização cirúrgica em si. Outro fato evidente é de que no trabalho apresentado por Bieck, Fuchs e Neumuth (2019), a diferença das taxas de acerto de classificação para um 1 voluntário e para 5 voluntários é bem clara, demonstrando que o aumento do número de voluntários pode acarretar um resultado mais baixo. Isso se deve ao fato de que os sinais de sEMG variam bastante de acordo com cada voluntário.

3 REVISÃO DE LITERATURA

No presente capítulo são abordados os conceitos de instrumentação cirúrgica, além de conceitos sobre eletromiografia e quais são os procedimentos comuns empregados ao trabalhar com o sinal de eletromiografia.

3.1 Instrumentação e Sinalização Cirúrgica

A instrumentação cirúrgica é a área da saúde relacionada à manipulação dos instrumentos utilizados durante intervenções cirúrgicas, exames, tratamentos e curativos. Ela é uma das mais importantes áreas dentro dos procedimentos cirúrgicos, pois estes instrumentos podem ser considerados como uma extensão das mãos do cirurgião (NEMITZ, 2019; PINHEIRO, 2018; SOUZA; HOFFMAN; COUTINHO, 2014).

Dependendo do tipo de cirurgia realizado (cirurgia cardiotorácica, plástica, neurocirurgia) são empregados diferentes tipos de instrumentos e, por essa razão, existe um elevado número de instrumentos existentes (PHILLIPS, 2019).

De modo geralista, os instrumentos podem ser divididos em diferentes categorias, de acordo com as suas funções, sendo as principais (CARVALHO *et al.*, 2019; MORIYA; VICENTE; TAZIMA, 2011; NEMITZ, 2019; PHILLIPS, 2019):

- Instrumentos de diérese (corte e dissecação): usados para realizar cortes e incisões e promover uma via de acesso através do tecido, permitindo a exposição dos órgãos. Exemplos de instrumentos de diérese incluem bisturis e diferentes tipos de tesouras, como tesoura para fios, de Metzenbaum, de Potts, entre outras. Esse tipo de instrumento é aplicado em instrumentação microcirúrgica, vascular ou de rinoplastia;
- Instrumentos de fixação e oclusão: usados para comprimir vasos e outras estruturas tubulares, impedindo o fluxo de sangue e outros fluidos. Alguns exemplos de instrumentos são: pinça hemostática, pinça Kelly, pinça intestinal Doyen;
- Instrumentos de prensão: normalmente em formato de pinças, são projetados para agarrar e manipular tecidos do corpo. Frequentemente usados para estabilizar o tecido que deve ser suturado, reparado ou dissecado. Alguns exemplos de pinças usadas são: pinça Allis, Babcock e Kocher;

- Sondas, cânulas e dilatadores: usados para expandir túneis, examinar ou criar uma passagem anatômica para tornar possível a injeção, amostragem ou descompressão de tecidos. Exemplos de dilatadores incluem o Hanks, Van Buren, Bakes, entre outros;
- Instrumentos de retração e exposição: projetados para reter ou afastar bordas de feridas, órgãos, vasos, nervos e outros tecidos, fornecendo um visual claro no local da cirurgia. São geralmente chamados de afastadores. Como exemplo, pode-se citar os afastadores: Farabeuf, Gosset e Balfour;
- Instrumentos de aspiração: usados para remover sangue, fluido e detritos dos locais operatórios. Há diversas pontas diferentes usadas para aspiração, citando-se como exemplo as pontas Yankauer, Frazier, Poole e Baron;
- Instrumentos de síntese: usados para ligar, reparar e aproximar tecidos durante um procedimento cirúrgico. Exemplos incluem dispositivos de grampeamento, como grampeadores de pele, grampos de ligadura, fios, agulhas e porta-agulhas diferentes;
- Instrumentos de visualização: permitem a visualização de uma estrutura ou cavidade. Como exemplos, pode-se citar o espéculo nasal, endoscópios estriados e flexíveis e a câmera endoscópica;
- Acessórios, instrumentos diversos, especiais: são instrumentos que não se enquadram em nenhuma das outras categorias, mas tem uma função específica e fazem parte de um determinado procedimento cirúrgico. Exemplos incluem martelos, dobradores de placas, compactadores, aquecedores de lentes, etc.

Dentro do centro cirúrgico, cabe ao instrumentador organizar estes instrumentos sobre a mesa de cirurgia, além de conhecer os instrumentos por seus nomes e funções e entregar estes ao cirurgião quando ele o solicitar. Por essa razão, existem padrões comumente usados para a exposição dos instrumentos na mesa de cirurgia, dividindo-a setorialmente de acordo com o procedimento. Essa disposição é feita de acordo com as etapas do procedimento cirúrgico. Por exemplo, Moriya, Vicente e Tazima (2011) apresentam um exemplo de mesa de cirurgia em que a mesma é dividida em quatro quadrantes para comportar os instrumentos de diérese,


síntese, hemostasia e os instrumentos auxiliares de acordo com a Figura 1. Já em Pinheiro (2018) é apresentado um esquema geral, com destaque à divisão da mesa entre instrumentos de diérese, preensão, hemostasia, exposição, especiais e síntese, de acordo com a Figura 2.

Figura 1 - Disposição geral do instrumental na mesa de cirurgia



Fonte: UFRGS (2022), adaptado

Figura 2 - Esquema geral para montagem da mesa principal de acordo com a sequência de uso e funções: 1) diérese, 2) preensão, 3) hemostasia, 4) exposição, 5) especiais e 6) síntese.



Fonte: Alencar (2017), adaptado

Ao ser solicitado, o instrumentador deve passar os instrumentos ao cirurgião de forma técnica e precisa, para que o cirurgião não necessite ficar ajustando o

instrumento ao recebê-lo. Por exemplo, o bisturi deve ser passado com a lâmina voltada para cima, evitando cortes no cirurgião ou no instrumentador (PINHEIRO, 2018). O contato visual direto entre o cirurgião e o instrumentador também pode evitar lesões acidentais causadas por objetos cortantes (PEZZELLA, 1996).



Com relação à solicitação do instrumento realizada pelo cirurgião, existem duas formas comumente empregadas: o cirurgião faz um pedido verbal solicitando o instrumento através de seu nome oficial ou através de sinalização cirúrgica baseada em gestos (CARVALHO *et al.*, 2019).











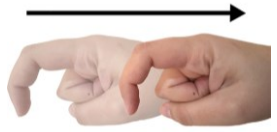

3.1.1 Sinalização cirúrgica





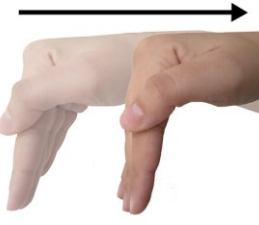



A sinalização cirúrgica consiste em uma linguagem específica baseada no conjunto de gestos adotados em ambiente cirúrgico para facilitar a comunicação em manobras realizadas durante os procedimentos. Através da sinalização, o cirurgião transmite a informação de qual material precisa, reduzindo assim o tempo total da cirurgia (SOUZA; HOFFMAN; COUTINHO, 2014). Desta forma, é especialmente importante quando há um aumento no nível de ruído na sala de cirurgia, ou quando há alguma dificuldade de verbalização, aumentando a concentração e melhorando a comunicação durante o procedimento (PEZZELLA, 1996).

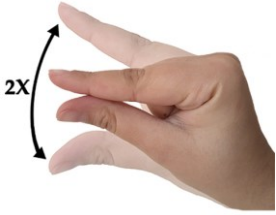

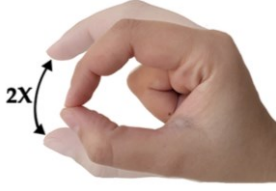



Por existirem muitos instrumentos cirúrgicos diferentes, nem todos possuem uma sinalização específica. Porém, os principais instrumentos possuem sinalizações que são comumente usadas em ambiente cirúrgico. O Quadro 3 apresenta os gestos adotados para o presente trabalho, em conjunto com a forma e descrição da de sinalização, assim como a foto de como é feita a entrega do determinado instrumento. Estes foram escolhidos pois são mais presentes na literatura e por serem gestos que podem ser executados usando apenas uma mão (CARVALHO *et al.*, 2019; COSTA NETO *et al.*, 2011; GÓES JR. *et al.*, [s.d.]; SOUZA; HOFFMAN; COUTINHO, 2014).

Quadro 3 - Sinalização cirúrgica para os instrumentos adotados no presente trabalho

Instrumento	Sinalização	Descrição	Imagem
Compressa	 Fonte: Autoria própria (2023)	Apresenta a mão espalmada, com os dedos juntos e a face palmar voltada para cima.	 Fonte: PolarFix (2022)

Instrumento	Sinalização	Descrição	Imagem
Fio em carretel	 <p>Fonte: Autoria própria (2023)</p>	A mão deve estar com a palma voltada para cima com os dedos semifletidos.	 <p>Fonte: 4MD Medical (2022)</p>
Fio solto	 <p>Fonte: Autoria própria (2023)</p>	A mão deve estar com a palma voltada para baixo com os dedos semifletidos.	 <p>Fonte: Pronto Veterinário (2022)</p>
Pinça Backhaus	 <p>Fonte: Autoria própria (2023)</p>	Os dedos anelar, médio e indicador devem ser fletidos, enquanto o polegar interpõe os dedos indicador e médio.	 <p>Fonte: Centermedical (2022)</p>
Pinça Hemostática	 <p>Fonte: Autoria própria (2023)</p>	Cruzar os dedos indicador e médio com a face palmar virada para baixo.	 <p>Fonte: Centermedical (2022b)</p>
Pinça Hemostática Kelly	 <p>Fonte: Autoria própria (2023)</p>	Fletir os dedos anelar e mínimo e manter os outros dedos estendidos.	 <p>Fonte: Centermedical (2022c)</p>
Afastador Farabeuf	 <p>Fonte: Autoria própria (2023)</p>	indicador semifletido e demais dedos fletidos, movimento semelhante ao manuseio do instrumento.	 <p>Fonte: Centermedical (2022d)</p>

Instrumento	Sinalização	Descrição	Imagem
Bisturi	 <p>Fonte: Autoria própria (2023)</p>	Manter os dedos da mão semifletidos e reunidos pelas pontas, fazendo um movimento pendular semelhante ao movimento realizado no manuseio do instrumento	 <p>Fonte: Mercado Livre (2022)</p>
Porta agulha	 <p>Fonte: Autoria própria (2023)</p>	Com os quatro últimos dedos semifletidos e o polegar parcialmente fletido no lado oposto, com pequenos movimentos de rotação.	 <p>Fonte: Centermedical (2022e)</p>
Válvula Doyen	 <p>Fonte: Autoria própria (2023)</p>	Movimentando a mão com os dedos juntos, estirados e em ângulo reto com relação ao resto da mão.	 <p>Fonte: Rhoss (2022)</p>
Pinça Allis	 <p>Fonte: Autoria própria (2023)</p>	Polegar e indicador semifletidos fazendo o movimento de abrir e fechar com o polegar prendendo o indicador) e os demais dedos permanecem fletidos.	 <p>Fonte: Centermedical (2022f)</p>

Instrumento	Sinalização	Descrição	Imagem
Pinça Anatômica	 <p>Fonte: Autoria própria (2023)</p>	<p>Polegar e indicador estendidos fazendo o movimento de aproximação e afastamento) e os demais dedos permanecem fletidos.</p>	 <p>Fonte: Centermedical (2022g)</p>
Pinça Dente de Rato	 <p>Fonte: Autoria própria (2023)</p>	<p>Polegar e indicador semifletidos fazendo o movimento de abrir e fechar com as pontas do indicador e polegar se tocando) e os demais dedos permanecem fletidos.</p>	 <p>Fonte: Centermedical (2022h)</p>
Tesoura	 <p>Fonte: Autoria própria (2023)</p>	<p>Manter os dedos indicador e médio estendidos e os demais fletidos sobre a palma da mão, realizando movimento semelhante ao funcionamento do instrumento.</p>	 <p>Fonte: Centermedical (2022i)</p>


3.2 Eletromiografia

A eletromiografia compreende o conjunto de técnicas para realizar a análise, detecção e uso dos sinais elétricos provenientes de variações e contrações musculares, chamados de sinais eletromiográficos (EMG) (NAJARIAN; SPLINTER, 2016). Estes sinais têm sua origem no cérebro, onde há estímulos nervosos que são transmitidos pelo sistema nervoso até as células musculares esqueléticas. Nessas células, há neurônios motores que conduzem o impulso nervoso até as fibras

musculares esqueléticas, gerando assim o sinal que é medido na eletromiografia (KAMEN; GABRIEL, 2010).

A eletromiografia está presente em diversas áreas e estudos, por exemplo: ergonomia através da análise, prevenção de riscos e desenvolvimento de *design* ergonômico (LIU *et al.*, 2016; NIU *et al.*, 2020); reabilitação pós-cirurgia e acidentes, envolvendo análises na fisioterapia e desenvolvimento de próteses e órteses (BOOSTANI; MORADI, 2003; DALLEY; VAROL; GOLDFARB, 2012; LIN; CHEN, 2018); pesquisas médicas nas áreas de ortopedia, cirurgia e neurologia funcional (BIECK; FUCHS; NEUMUTH, 2019; TAMURA *et al.*, 2016); esportes e análises de movimentos e biomecânica, treinamento e fadiga muscular (OLIVEIRA, 2019; SINGH, 2013); entre outros. Na Figura 3 ilustra-se um exemplo de sinal elétrico de EMG adquirido do músculo flexor radial do carpo durante a execução de um gesto envolvendo o antebraço, a mão e o punho.

Figura 3 - Exemplo de sinal EMG adquirido do músculo flexor radial do carpo durante a execução de um gesto envolvendo o antebraço, a mão e o punho.



Fonte: Autoria própria (2023)

É possível notar através da figura que o sinal de eletromiografia possui aparência ruidosa e de natureza estocástica, o que muitas vezes o torna um sinal de difícil interpretação (NAJARIAN; SPLINTER, 2016). Por essa razão, ao trabalhar com o sinal EMG é necessário estabelecer com cautela quais serão os procedimentos adotados, garantindo assim que o sinal estudado de fato refere-se à atividade muscular e não ao sinal proveniente de ruídos (KAMEN; GABRIEL, 2010).

Diversos fatores devem ser levados em conta ao realizar o estudo e instrumentação do sinal EMG, por exemplo: região muscular a ser avaliada de acordo com os movimentos escolhidos (KOCAK; YILMAZ, 2018; LIU, 2014; SANEI;

HOSSEINI-YAZDI, 2011); forma de aquisição dos dados (AL-QURAISHI *et al.*, 2014; MENDES *et al.*, 2015); processamento adotado (MENDES JUNIOR *et al.*, 2020a; ZECCA *et al.*, 2002), entre outros.

3.3 Instrumentação do Sinal de Eletromiografia

As etapas mais comuns presentes na instrumentação do sinal de eletromiografia são: aquisição, condicionamento, segmentação, extração de características e classificação.

3.3.1 Aquisição

A atividade bioelétrica proveniente da ação muscular é detectada com a ajuda de eletrodos de EMG feitos de materiais condutores como prata, ouro, platina e aço inoxidável. Estes eletrodos convertem em potencial elétrico, com a ajuda de um amplificador, o potencial iônico gerado pelos músculos. Por medir uma diferença de potencial, é necessário o posicionamento do eletrodo na região muscular a ser estudada e um outro eletrodo de referência, posicionado em uma região neutra (normalmente próxima a estruturas ósseas ou com pouca atividade muscular). Existem dois tipos de eletrodos usados na eletromiografia: os invasivos e os não-invasivos (FRIDLUND; CACIOPPO, 1986; NAJARIAN; SPLINTER, 2016).

Os eletrodos invasivos são inseridos através da pele diretamente no músculo a ser avaliado, e sua aplicação requer supervisão e certificação médica rigorosa (JAMAL, 2012). Eles podem ser de agulha ou de fio. Os eletrodos de agulha são bastante usados em procedimentos clínicos para avaliação neuromuscular. A qualidade de sinal dos eletrodos de agulha é comparativamente melhor aos outros tipos de eletrodo, pois como sua área de captação é baixa, é possível obter o sinal provenientes de contrações musculares de força relativamente baixa. Também é possível fazer o reposicionamento desses eletrodos dentro do músculo após a inserção deles na pele, permitindo um ajuste para melhor obtenção do sinal. Os eletrodos de fio são mais finos do que os eletrodos de agulha, sendo facilmente implantados e retirados dos músculos esqueléticos, além de serem considerados menos dolorosos do que os eletrodos de agulha (DE LUCA, 2006; JAMAL, 2012).

Os eletrodos não-invasivos, também chamados de eletrodos de superfície, são posicionados em cima da pele na região do músculo que se pretende avaliar.

Estes eletrodos são mais simples de serem aplicados, pois não requerem supervisão e certificação médica, além de gerarem um desconforto menor em comparação aos eletrodos invasivos (JAMAL, 2012). Uma das principais desvantagens do uso desse tipo de eletrodo é o fato de que ele só pode ser usado para medir a atividade de músculos superficiais, podendo ainda medir a ação de mais um músculo ao mesmo tempo, o que pode gerar maior susceptibilidade a ruídos e interferência (*crosstalk*) muscular. A área da eletromiografia que trabalha com os sinais provenientes de eletrodos não-invasivos é chamada de eletromiografia de superfície, abreviada por sEMG (CRISWELL; CRAM, 2011; FRIDLUND; CACIOPPO, 1986).

Os eletrodos de sEMG podem ser divididos de acordo com a sua composição entre eletrodos com gel ou eletrodos secos. Os eletrodos com gel (normalmente descartáveis) são amplamente utilizados na eletromiografia de superfície. O gel presente nos eletrodos é utilizado para manter um caminho condutivo entre a superfície metálica do eletrodo e a pele, atenuando os ruídos por artefatos de movimento. Já os eletrodos secos não possuem esse gel condutor, o que pode ocasionar uma alta impedância entre o eletrodo e a pele, também tendo maiores problemas com relação aos ruídos de artefatos de movimento. Diversos estudos que envolvem o desenvolvimento de um sistema próprio de aquisição utilizam os eletrodos descartáveis com gel (AL-QURAIISHI *et al.*, 2014; MENDES JUNIOR *et al.*, 2016; SHARMA; DUBEY, 2012), enquanto sistemas comerciais utilizam eletrodos secos (OYMOTION, 2022; THALMIC LABS, 2016).

Os eletrodos não-invasivos também podem ser divididos entre ativos ou passivos. Os eletrodos ativos possuem um circuito eletrônico externo contendo um pré-amplificador acoplado ao eletrodo, preparando o sinal adquirido para o processamento posterior, além de ajudar também a atenuar os ruídos de modo comum. Já os eletrodos passivos não possuem esse circuito eletrônico, fazendo com que todo o condicionamento e processamento do sinal precise ser realizado depois da aquisição dos sinais (JAMAL, 2012).

Outra forma de classificação dos eletrodos de superfície é com relação à sua configuração de aquisição, eles podem ser monopolares ou bipolares. No caso dos eletrodos monopolares, um eletrodo de superfície é posicionado na região a ser estudada (em uma fibra ou grupo muscular) e outro eletrodo de referência é posicionado em uma região neutra. Esse arranjo é usado às vezes em ambientes clínicos por causa da sua simplicidade técnica. Já no caso dos eletrodos bipolares,

duas superfícies são usadas (cada uma em uma extremidade do feixe muscular) para detectar dois valores de diferença de potencial, cada um com relação ao eletrodo de referência. O sinal adquirido é o resultado da diferença entre os sinais provenientes dos dois eletrodos. A qualidade do sinal provinda dos eletrodos bipolares é considerada maior, pois essa configuração ajuda a atenuar ruídos de corrente alternada, como os sinais de 60Hz originários da rede elétrica, e ruídos de corrente contínua, como potenciais de polarização na junção do eletrólito metálico (DE LUCA, 2006).

Para a análise de movimentos e gestos, quando há o interesse de avaliar o sinal EMG de diversos músculos ou grupos musculares, recomenda-se a utilização de múltiplos canais como nos casos apresentados por Dalley, Varol e Goldfarb (2012); Phinyomark, Phukpattanaront e Limsakul (2012); e Schorsch *et al.* (2008), de forma a se poder ponderar a contribuição de diferentes músculos em cada fase do movimento.

3.3.2 Condicionamento

Enquanto é realizada a aquisição do sinal EMG, é necessário fazer o seu condicionamento (também chamado de pré-processamento). Ele consiste em realizar a adequação do sinal para as etapas posteriores de processamento através de sua amplificação, filtragem e amostragem. As etapas de amplificação e amostragem são feitas por meio de *hardware* com a implementação de circuitos eletrônicos utilizando componentes que condicionam o sinal quando ele está sendo adquirido. Já no caso da filtragem, pode-se fazer através de *hardware*, como também com o uso de *softwares* de processamento (LA BANCA *et al.*, 2016; MOHAMAD; NOOR, 2014; TURCHIELLO; MARINO-NETO; MARQUES, 2014).

Na etapa de amplificação, normalmente utilizam-se circuitos contendo amplificadores (de preferência de instrumentação), em conjunto com os eletrodos durante a aquisição. Esses circuitos de amplificação devem ser projetados de forma que aconteça o mínimo de distorção no sinal EMG detectado pelos eletrodos.

A filtragem do sinal consiste na delimitação dele dentro de uma determinada faixa de frequência. No caso do sinal EMG, essa faixa está entre 0 e 500 Hz, sendo dominante na faixa entre 50 e 150 Hz (DE LUCA, 2002). Ela está direta ou indiretamente ligada à etapa de amplificação do sinal. Isso porque se for feita através de *hardware* o circuito de amplificação já é projetado também para realizar a filtragem do sinal, seguindo as larguras de banda típicas para cada tipo de eletrodo. Porém,

também pode-se filtrar o sinal após a aquisição, através de um *software* de processamento de sinais e instrumentação como o MATLAB™ ou LabVIEW™. Para realizar a delimitação da largura de banda comumente utiliza-se filtros dos tipos passa-alta e passa-baixa, ou ainda passa-banda. Além da delimitação da largura de banda, também é importante eliminar os ruídos provenientes da frequência de alimentação da rede de energia através de filtros do tipo rejeita-faixa (CLANCY; MORIN; MERLETTI, 2002; DE LUCA, 2002; MERLETTI; PARKER, 2004).

Como o sinal de sEMG amplificado e filtrado é um sinal analógico, é necessário que se faça sua conversão para o formato digital e assim ele possa ser processado posteriormente. Para isso, é feita a amostragem dele com um conversor analógico-digital. A taxa de amostragem utilizada pode interferir na qualidade sinal a ser analisado, por isso deve-se avaliar que um sinal com maior taxa de amostragem apresenta mais informações acerca dele, porém o custo computacional para processamento do mesmo é maior (PHINYOMARK; N. KHUSHABA; SCHEME, 2018). Por essa razão, há estudos que trabalham com uma taxa de amostragem mais baixa, como nos casos apresentados por (BIECK; FUCHS; NEUMUTH, 2019; MENDES JUNIOR *et al.*, 2020a). Nestes casos, utilizou-se uma *armband* comercial com taxa de amostragem de 200 Hz. Há também estudos que trabalham com uma taxa de amostragem mais alta, como nos casos apresentados por Mendes Junior *et al.* (2016) e Phinyomark, Phukpattanaront e Limsakul (2012).

3.3.3 Segmentação


A segmentação é o processo de separação do sinal de sEMG, depois de condicionado, em pequenas partes para extrair informações relativas aos momentos de atividade muscular. Esse processo é muito importante, pois o método utilizado pode interferir posteriormente no desempenho de sistema de classificação. O processo de segmentação está diretamente ligado ao protocolo adotado durante a aquisição (FARFÁN; POLITTI; FELICE, 2010; HAKONEN; PIITULAINEN; VISALA, 2015).

Existem diversas técnicas utilizadas para fazer a segmentação do sinal de sEMG, sendo que uma das formas mais comuns implica na necessidade de determinação do início e do fim do sinal de sEMG proveniente de alguma atividade muscular registrada dentro da aquisição. O início é chamado de *onset* e equivale ao momento em que ocorre contração muscular proveniente da execução de algum gesto

e o fim é chamado de *offset* e equivale ao momento em que não é registrada mais nenhuma atividade muscular significativa (normalmente quando se está em posição neutra) (FARFÁN; POLITTI; FELICE, 2010).

Encontrar esses dois fatores não é uma tarefa computacional simples devido ao fato de que as atividades musculares podem ter durações diferentes, dificultando a criação de um intervalo de tempo fixo, por exemplo. Por isso, uma das técnicas mais utilizadas consiste em realizar essa detecção com base em um limiar (*threshold*) em um sinal pré-processado (WIJANARKO; SETIJADI; MENGKO, 2014; WU *et al.*, 2019). Por exemplo, pode-se extrair o RMS e determinar o *onset* e *offset* do sinal com base em um limiar de maneira visual (JUBANY; ANGULO-BARROSO, 2016). A Figura 4 apresenta um exemplo de sinal sEMG adquirido durante a execução de um gesto envolvendo a mão e o punho (Figura 4-1), além da determinação do *onset* e *offset* utilizando um limiar escolhido com base no RMS do sinal (Figura 4-2). Nesta figura, pode-se observar que a maior parte do sinal referente à atividade muscular foi abrangida pelo *onset* e *offset* determinados.

Figura 4 - 1) Exemplo de sinal EMG adquirido durante a execução de um gesto envolvendo a mão e o punho, 2) exemplo de determinação do *onset* e *offset* do sinal EMG apresentado com base em um *threshold*



Fonte: Autoria própria (2023)

A determinação dos valores de *onset* e *offset* dos sinais é apenas a primeira etapa da segmentação. Depois disso, passa-se à separação, de fato, dos dados de acordo com esses momentos, determinando-se os comprimentos dos segmentos adotados. O tamanho desses comprimentos pode interferir na qualidade dos classificadores. Por exemplo, grandes segmentos aumentam a taxa de acerto de classificação, porém é necessário um maior tempo de processamento e coleta. Por essa razão, não existe um consenso sobre qual seria um tamanho ideal de segmentos (MENDES JUNIOR *et al.*, 2020a; OSKOEI; HU, 2008).

3.3.4 Extração de Características

Com os dados segmentados, passa-se para a etapa de extração de características ou atributos do sinal. Esta etapa tem por objetivo extrair as informações úteis do sinal EMG removendo suas partes indesejadas e interferências, melhorando os resultados de sistemas de classificação de movimentos. O processo de extração de características baseia-se na transformação sinais brutos de EMG em um vetor de características, calculadas com base em equações matemáticas (BOOSTANI; MORADI, 2003; NAZMI *et al.*, 2016).

As características podem ser divididas de acordo com os seus domínios, sendo do domínio do tempo, frequência, tempo-frequência ou espaciais (HAKONEN; PIITULAINEN; VISALA, 2015; OSKOEI; HU, 2007). As características no domínio do tempo avaliam a alteração de amplitude do sinal no decorrer do tempo. Elas são características de fácil implementação, uma vez que não é necessário realizar nenhuma transformação e são calculadas com base em séries temporais do sinal EMG bruto. Embora tenham como vantagem o menor custo computacional para sua obtenção, como desvantagem são consideradas mais sensíveis a interferências e artefatos de movimento (PHINYOMARK; PHUKPATTARANONT; LIMSAKUL, 2012). As características no domínio da frequência possuem como informação a densidade do espectro de potência, sendo normalmente computadas através de métodos paramétricos e periodogramas. Elas são mais utilizadas para estudar a fadiga muscular e realizar a análise de recrutamento de unidades motoras (NAZMI *et al.*, 2016; PHINYOMARK; PHUKPATTARANONT; LIMSAKUL, 2012). As características do domínio de tempo-frequência unem informações do domínio do tempo e frequência para obter informações de frequência variável em locais diferentes de tempo, fornecendo informações não-estacionárias abundantes dos sinais analisados (NAZMI

et al., 2016). Por fim, as características do domínio espacial estão voltadas à diferenciação entre postura e níveis de força fornecendo informações sobre as distribuições espaciais dos potenciais de ação das unidades motoras e sobre o compartilhamento de carga entre os músculos e grupos musculares (HAKONEN; PIITULAINEN; VISALA, 2015).

As características também podem ser divididas de acordo com as informações que elas fornecem: informação de energia com relação à potência e amplitude do sinal (por exemplo: IEMG – *Integrated EMG*, MAV – *Mean Absolute Value* e RMS), complexidade não-linear (por exemplo: WAMP – *Willison Amplitude*, AAC – *Average Amplitude Change*, DASDV – *Difference Absolute Standard Deviation Value*), frequência (por exemplo: ZC – *Zero Crossing*, MYOP – *Myopulse percentagem rate*, WAMP), modelagem de séries temporais (AR – *Autoregressive Coefficients*, CC – *Cepstrum Coefficients*), dependência do tempo (HIST – *Histogram*, MHW – *Multiple Hamming Windows*, MTW – *Multiple Trapezoidal Windows*), entre outros (PHINYOMARK; N. KHUSHABA; SCHEME, 2018; PHINYOMARK; PHUKPATTARANONT; LIMSAKUL, 2012).

São inúmeros os atributos que podem ser obtidos de um sinal, sendo que estas podem ser usadas tanto individualmente, quanto em grupo (FREITAS, 2018; MENDES JUNIOR, 2020). A escolha das características a serem usadas deve ser feita levando em conta a frequência de amostragem do sinal. Isso porque algumas delas apresentam um melhor desempenho no classificador quando foi usada uma frequência de amostragem mais alta, enquanto outras apresentam um maior desempenho com frequência de amostragem mais baixa, como pode ser visto no trabalho apresentado por Phinyomark, Khushaba e Scheme (2018).

Com relação à escolha das características para o presente trabalho, optou-se por selecionar dezenove delas, sendo dezessete no domínio do tempo e duas no domínio da frequência: AR, CC, DASDV, HIST, IAV (*Integral Absolute Value*), LD (*Log Detector*), LS (*L-Scale*), MAV, MFL (*Maximum Fractal Length*), MNP (*Mean Power*), MSR (*Mean Square Root*), RMS, SampEn (*Sample Entropy*), SSC (*Slope Sign Change*), TTP (*Total Power*), VAR (*Variance*), WAMP, WL (*Waveform Length*), ZC. Estas características foram escolhidas com base na revisão bibliográfica, ao cercar-se de estudos anteriores que realizam o reconhecimento de gestos visando, ou não, o controle de sistemas com base em sEMG. Nesses estudos algumas destas características foram divididas em grupos de poucos elementos (o que envolve um

menor custo computacional) e apresentaram bons resultados na classificação (BHATTACHARYA; SARKAR; BASAK, 2017; HUANG *et al.*, 2005; HUDGINS; PARKER; SCOTT, 1993; LIU; HUANG; WENG, 2007; MENDES JUNIOR, 2020; PHINYOMARK *et al.*, 2013; PHINYOMARK; N. KHUSHABA; SCHEME, 2018; TKACH; HUANG; KUIKEN, 2010). O Quadro 4 apresenta as características escolhidas, em conjunto com sua respectiva equação, função e referência.

Quadro 4 - Características do sinal EMG usadas no presente trabalho

Característica	Equação	Função	Referência
AR	$x_k = \sum_{i=1}^p a_i x_{k-1} + e_k$ <p>x_k = amostra atual, p = ordem do modelo, a_i = coeficientes AR, x_{k-1} = amostras passadas, e_k = ruído branco residual</p>	Contém informação sobre a localização de picos do sinal em seu espectro	Zardoshti-Kermani <i>et al.</i> (1995)
CC	$c_1 = -a_1$ $c_i = -a_1 - \sum_{i=1}^{i-1} \left(1 - \frac{n}{i}\right) a_i c_{i-1}$ <p>a_i = i-ésimo termo dos coeficientes autorregressivos, c_i = i-ésimo coeficiente cepstral, n = dimensionalidade do modelo</p>	Inverso da transformada de Fourier do logaritmo da magnitude do espectro de potência do sinal	Kang <i>et al.</i> (1995)
DASDV	$\sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (x_{i+1} + x_i)^2}$ <p>N = comprimento do sinal, x_n = sinal de EMG</p>	Valor absoluto do desvio padrão da diferença entre amostras adjacentes	Kim <i>et al.</i> (2011)
HIST	$HIST(x)$ <p>HIST = função de histograma para o sinal x</p>	Usado para medir com que frequência o sinal de sEMG alcança múltiplos níveis de amplitude	Zardoshti-Kermani <i>et al.</i> (1995)
IAV	$\frac{1}{N} \sum_{i=1}^N x_i $ <p>N = comprimento do sinal, x_n = sinal de EMG</p>	Relacionado à detecção do ponto de disparo do sinal EMG usado para controle de próteses	Zardoshti-Kermani <i>et al.</i> (1995)

Característica	Equação	Função	Referência
LD	$e^{\frac{1}{N} \sum_{i=1}^N \log(x_i)}$ <p>N = comprimento do sinal, x_n = sinal de EMG</p>	Fornecer uma estimativa da força de contração muscular	Zardoshti-Kermani <i>et al.</i> (1995)
LS	$r^{-1} \sum_{k=0}^{r-1} (-1)^k \binom{r-1}{k} EX_{r-k:r}$ <p>$r = 2$, $X_{k:n}$ = estatística de ordem k de uma amostra aleatória de tamanho n, E = valor esperado</p>	Função linear da estatística de ordem esperada, sendo o segundo momento das estatísticas dos Momentos-L	Phinyomark, Khushaba e Scheme (2018)
MAV	$\frac{1}{N} \sum_{i=1}^N x_i $ <p>N = comprimento do sinal, x_n = sinal de EMG</p>	Relacionado à detecção do ponto de disparo do sinal no controle de próteses	Hudgins, Parker e Scott (1993)
MFL	$\log_{10} \left(\sqrt{\sum_{i=1}^{N-1} (x_{i+1} - x_i)^2} \right)$ <p>N = comprimento do sinal, x_n = sinal de EMG</p>	Medição de ativação muscular de baixo nível	Arjunan <i>et al.</i> (2011)
MNP	$\frac{\sum_{i=1}^M P_i}{M}$ <p>M = índice máximo da banda de frequência, P = densidade de frequência após a transformada</p>	Potência média do espectro de potência do sinal EMG	Oskoei e Hu (2008)
MSR	$\frac{1}{N} \sum_{i=1}^N \sqrt{x_i}$ <p>N = comprimento do sinal, x_n = sinal de EMG</p>	Medição da quantidade total de ativação do sinal EMG	Phinyomark, Khushaba e Scheme (2018)
RMS	$\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$ <p>N = comprimento do sinal, x_n = sinal EMG</p>	Índice relacionado à força e contração muscular sem fadiga	Chan e Englehart (2003)
SampEn	$SampEn(x, m, r) = -\ln \left(\frac{A^m(r)}{B^m(r)} \right)$ <p>x = sinal de EMG, $B^m(r)$ = probabilidade de duas sequências se combinarem entre os m pontos, r = tolerância, $A^m(r)$ = dimensão embarcada de $m+1$</p>	Usada para medir a regularidade da série temporal	Richman e Moorman (2000)

Característica	Equação	Função	Referência
SSC	$\sum_{i=2}^{N-1} [f[(x_i - x_{i-1}) \times (x_i - x_{i+1})]]$ $f(x) = \begin{cases} 1, & \text{se } x \geq \text{limiar} \\ 0, & \text{caso contrário} \end{cases}$ <p>N = comprimento do sinal, x_n = sinal de EMG</p>	Número de vezes que o declive do sinal EMG passa de positivo para negativo e vice-versa	Hudgins, Parker e Scott (1993)
TTP	$\sum_{i=1}^M P_i$ <p>M = índice máximo da banda de frequência, P = densidade de frequência após a transformada</p>	Medição da energia do espectro de potência do sinal EMG	Biopac Systems (2010)
VAR	$\frac{1}{N-1} \sum_{i=1}^N x_i^2$ <p>N = comprimento do sinal, x_n = sinal de EMG</p>	Medição da potência do sinal	Zardoshti-Kermani <i>et al.</i> (1995)
WAMP	$\sum_{i=1}^{N-1} [f(x_i - x_{i+1})]$ $f(x) = \begin{cases} 1, & \text{se } x \geq \text{limiar} \\ 0, & \text{caso contrário} \end{cases}$	Fornecer informações de frequência do sinal EMG	Willison (1963)
WL	$\sum_{i=1}^{N-1} x_{i+1} - x_i $ <p>N = comprimento do sinal, x_n = sinal de EMG</p>	Referente à complexidade do sinal EMG	Hudgins, Parker e Scott (1993)
ZC	$\sum_{i=1}^{N-1} [sgn(x_i \times x_{i+1}) \cap x_i - x_{i+1} \geq \text{limiar}]$ $sgn(x) = \begin{cases} 1, & \text{se } x \geq \text{limiar} \\ 0, & \text{caso contrário} \end{cases}$ <p>N = comprimento do sinal, x_n = sinal de EMG</p>	Contabiliza o número de vezes que o sinal EMG cruza o nível de amplitude zero	Hudgins, Parker e Scott (1993)

Fonte: Autoria própria (2023)

3.3.5 Classificação

Depois da extração de características passa-se à etapa de classificação. Nesta etapa, podem ser utilizados diversos métodos para realizar o reconhecimento de gestos, tendo como entrada os vetores de características extraídas. Alguns dos tipos de classificadores mais utilizados são: classificadores baseados em funções de discriminantes (como LDA – Análise dos Discriminantes Lineares – e QDA – Análise dos Discriminantes Quadráticos), classificadores baseados em distância e

proximidade (KNN – *K-Nearest Neighbor*), classificadores baseados em máquinas de vetores suporte (SVM – *Support Vector Machines*), classificadores baseados em redes neurais artificiais (como MLP – *Multilayer Perceptron* – e ELM – *Extreme Learning Machine*) (DUDA; HART; STORK, 2001). Devido à grande variedade de classificadores, serão abordados aqui apenas as formas de classificação adotadas no presente trabalho: LDA, QDA, KNN, RF, SVM, MLP. Além da utilização dos classificadores de forma individual, também fez-se a combinação destes (método conhecido como *Ensemble*).

a) Análise dos Discriminantes Lineares (LDA – *Linear Discriminant Analysis*)

O método LDA é utilizado para maximizar a razão da variância entre as classes e minimizar a variância dentro de uma determinada classe, garantindo assim uma maior separabilidade entre elas. Desta forma, pode-se tanto realizar a classificação com este método, como ele também é utilizado para reduzir a dimensionalidade de uma amostra (BALAKRISHNAMA; GANAPATHIRAJU, 1998; FUKUNAGA, 1990; JAMES *et al.*, 2013). Este método busca fronteiras de decisão definidas por funções lineares para realizar a separação entre as classes. O Quadro 5 mostra as etapas necessárias para realizar o treinamento e execução do LDA:

Quadro 5 - Algoritmo do classificador LDA

<p>1: função LDA(X)</p> <p>2: Calcular a média (μ_i) e a probabilidade a priori ($P(\omega_i)$) para cada classe</p> <p>3: Calcular a matriz de covariância (Σ) para cada classe i:</p> $\Sigma_i = (\omega_i - \mu_i)(\omega_i - \mu_i)^T,$ <p>ω_i: dados pertencentes a cada classe i</p> <p>μ_i: vetor de médias de cada classe i</p> <p>4: Obter as funções de discriminantes para cada classe por meio de:</p> $f_i = -0,5 \sum_i^{-1} (x^T x + \mu_i^T \mu_i - 2\mu_i^T x) + \ln(P(\omega_i))$ <p>Σ_i: matriz de covariância para cada classe</p> <p>m: quantidade de dimensões</p> <p>x: vetor de dados que se deseja classificar</p> <p>$P(\omega_i)$: probabilidade a priori de cada classe</p> <p>5: Agrupar as funções discriminantes em uma matriz (W)</p> <p>6: Aplicar transformação linear dos dados (X) na matriz dos discriminantes (W)</p> <p>7: Atribuir a maior resultante da transformação linear como classe pertencente da amostra</p> <p>8: Fim da função</p>

Fonte: Mendes Junior (2020), adaptado

b) Análise dos Discriminantes Quadráticos (QDA – *Quadratic Discriminant Analysis*)

Assim como o método LDA, o método QDA é utilizado para maximizar a razão da variância entre as classes e minimizar a variância dentro de uma determinada classe, garantindo assim uma maior separabilidade entre essas classes. Pode-se tanto realizar a classificação com este método, como ele também é utilizado reduzir a dimensionalidade de uma amostra (BALAKRISHNAMA; GANAPATHIRAJU, 1998; FUKUNAGA, 1990; JAMES *et al.*, 2013). Este método busca fronteiras de decisão definidas por funções quadráticas para realizar a separação entre as classes, ao contrário do LDA que utiliza funções lineares. As etapas necessárias para realizar o treinamento e execução deste tipo de classificador são apresentadas no Quadro 6:

Quadro 6 - Algoritmo do classificador QDA

<p>1: função QDA(X)</p> <p>2: Calcular a média (μ_i) e a probabilidade a priori ($P(\omega_i)$) para cada classe;</p> <p>3: Calcular a matriz de covariância (Σ) para cada classe i:</p> $\Sigma_i = (\omega_i - \mu_i)(\omega_i - \mu_i)^T,$ <p>ω_i: dados pertencentes a cada classe i</p> <p>μ_i: vetor de médias de cada classe i</p> <p>4: Obter as funções de discriminantes para cada classe por meio de:</p> $f_i = -0,5 \sum_i^{-1} (x^T x + \mu_i^T \mu_i - 2\mu_i^T x) - 0,5m(\ln(2\pi)) - 0,5 \ln(\Sigma) + \ln(P(\omega_i))$ <p>Σ_i: matriz de covariância para cada classe</p> <p>m: quantidade de dimensões</p> <p>x: vetor de dados que se deseja classificar</p> <p>$P(\omega_i)$: probabilidade a priori de cada classe</p> <p>5: Agrupar as funções discriminantes em uma matriz (W)</p> <p>6: Aplicar transformação linear dos dados (X) na matriz dos discriminantes (W)</p> <p>7: Atribuir a maior resultante da transformação linear como classe pertencente da amostra</p> <p>8: Fim da função</p>
--

Fonte: Mendes Junior (2020), adaptado

c) K-Vizinhos próximos (KNN – *K-Nearest Neighbors*)

O método KNN é baseado na forma de aprendizado por analogia ao comparar uma determinada tupla (amostra) de teste com tuplas de treinamento semelhantes a ela, em que cada tupla representa um ponto n -dimensional. Ao receber uma tupla desconhecida, o classificador procura no espaço de padrões as k tuplas de

treinamento que estão mais próximas da desconhecida, sendo estas chamadas de k vizinhos mais próximos. A proximidade é definida em termos de uma métrica de distância, sendo que um dos métodos mais utilizados é o da distância Euclidiana (BRAMER, 2013; HAND; MANNILA; SMYTH, 2001).

Ao utilizar esse método de classificação, é necessário que se defina dois parâmetros principais: a forma do cálculo da distância entre os pontos e o número de vizinhos próximos a serem utilizados, sendo este segundo determinado de forma experimental. Para a implementação do classificador, normalmente inicia-se com 1 vizinho mais próximo e esse número vai sendo incrementado, avaliando se os resultados obtidos vão melhorando ou não. Para realizar o treinamento e execução deste método de classificação são necessárias as etapas apresentadas no Quadro 7.

Quadro 7 - Algoritmo do classificador KNN

<p>1: função KNN(X)</p> <p>2: Definir o valor de k-vizinhos próximos;</p> <p>3: Calcular para cada amostra de teste a distância Euclidiana por meio de:</p> $dist(x_1, x_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2},$ <p>x_{1i}: termo de x_1 pertencente ao atributo i</p> <p>x_{2i}: termo de x_2 pertencente ao atributo i</p> <p>4: Determinar o conjunto das k-amostras mais próximas da amostra de teste</p> <p>5: Fornecer o rótulo da amostra de teste para os rótulos com maior ocorrência nos k-vizinhos próximos</p> <p>6: Fim da função</p>
--

Fonte: Mendes Junior (2020), adaptado

d) Florestas Aleatórias (RF – *Random Forests*)

O método de classificação RF é baseado na combinação de outro classificador, o de árvores de decisão (BRUCE; BRUCE; GEDECK, 2020; HAN; KAMBER, 2012). As árvores de decisão são usadas para classificar um objeto ou uma instância em um conjunto predefinido de classes com base em seus valores de atributos. Quando usadas para a classificação de objetos ou instâncias, elas são particularmente chamadas de árvores de classificação. Para realizar a classificação, cada classe é considerada como sendo um nó da árvore. Em cada nó é feito um teste com base nos valores de atributos e de acordo com o resultado desse teste, direciona-se a informação para um próximo nó ou folha, sendo a folha é a representação final de cada classe. Para a realização desses testes, são utilizadas nas árvores de decisão

restrições de comandos, como as estruturas condicionais (*if-else*) (ROKACH; MAIMON, 2015).

O método RF é composto de diversas árvores de decisão. As árvores de decisão individuais são geradas usando uma seleção aleatória de atributos em cada nó para determinar a divisão. Mais formalmente, cada árvore depende dos valores de um vetor aleatório amostrado independentemente e com a mesma distribuição para todas as árvores da floresta. Durante a classificação, cada árvore vota e a classe mais popular é retornada (BRUCE; BRUCE; GEDECK, 2020). O Quadro 8 apresenta os passos de execução do classificador RF.

Quadro 8 - Algoritmo do classificador RF

<p>1: Função RF(X)</p> <p>2: Pegar uma subamostra de <i>bootstrap</i> dos dados</p> <p>3: Para a primeira divisão, amostrar $p < P$ variáveis ao acaso sem reposição</p> <p>4: Para cada uma das variáveis amostradas $X_{j(1)}, X_{j(2)}, \dots, X_{j(p)}$, aplicar o seguinte algoritmo de divisão:</p> <p style="padding-left: 20px;">a) Para cada valor $s_{j(k)}$ de $X_{j(k)}$:</p> <p style="padding-left: 40px;">i. Dividir os dados na partição A, com $X_{j(k)} < s_{j(k)}$ como sendo uma partição e os dados restantes em que $X_{j(k)} \geq s_{j(k)}$ como outra partição</p> <p style="padding-left: 40px;">ii. Medir a homogeneidade das classes dentro de cada subdivisão A</p> <p style="padding-left: 20px;">b) Selecionar o valor de $s_{j(k)}$ que produz a máxima homogeneidade de classe dentro da partição</p> <p>5: Selecionar a variável $X_{j(k)}$ e o valor separado $s_{j(k)}$ que produzem a máxima homogeneidade de classe dentro da partição</p> <p>6: Prosseguir para a próxima divisão e repetir as etapas anteriores, começando com a etapa 3</p> <p>7: Continuar com as divisões adicionais, seguindo o mesmo procedimento até que a árvore cresça</p> <p>8: Voltar para a etapa 2, pegar outra subamostra de <i>bootstrap</i> e reiniciar o processo novamente;</p> <p>9: Repetir o processo para todas as subamostras de <i>bootstrap</i></p> <p>10: Fim da função</p>
--

Fonte: Bruce, Bruce e Gedeck (2020), adaptado

e) Máquina de Vetores de Suporte (SVM – *Support Vector Machines*)

As Máquinas de Vetores Suporte (SVM) trabalham de forma supervisionada, sendo necessário, tal como a QDA, de um conjunto de treinamento e outro de teste.

Estes algoritmos baseiam-se em mapeamentos lineares, podendo serem usados em problemas não lineares, buscando um hiperplano ótimo de separação entre classes.

As bases da SVM podem ser resumidas em quatro parâmetros: a busca por um hiperplano de separação (as margens deste hiperplano são chamadas de vetores suporte); a otimização do hiperplano máximo que garanta a máxima distinção entre as classes; a otimização da margem de separação; e o uso de uma transformação de kernel (NOBLE, 2006).

O treinamento de uma SVM consiste na otimização de uma função que separe as classes corretamente, buscando generalidade para a solução do problema a ser resolvido. Restrições são necessárias para que a SVM não sofra influências de sobre-treinamento ou sub-treinamento. Usando como exemplo um problema de duas classes linearmente separáveis contendo um número n de atributos de entrada (x_n), a busca pelo hiperplano que possui menor erro de classificação pode ser expressada de acordo com a equação (1) (THEODORIDIS *et al.*, 2010):

$$x \cdot W_{SVM}^T + b = 0 \quad (1)$$

em que W são os valores de busca do SVM, contendo a mesma quantidade dos índices dos atributos de entrada e b sendo o valor de escalar de limiar. A saída y desse classificador pode ser expressa com:

$$y = \begin{cases} +1, & \text{se } W_1 \cdot x_1 + W_2 \cdot x_2 + b \geq 1 \\ -1, & \text{se } W_1 \cdot x_1 + W_2 \cdot x_2 + b < 1 \end{cases} \quad (2)$$

Logo, cada amostra se posicionará em um dos lados do hiperplano, podendo pertencer a um grupo ou a outro. Como o principal ponto é otimizar os valores de W , minimizando os vetores suporte, os quais são a própria margem, a função de otimização pode ser escrita como o seguinte problema:

$$\begin{aligned} \arg \max_{w,b} & \left\{ \frac{\|W_{SVM}\|^2}{2} \min_i [y_i (W_{SVM}^T \cdot x_i + b)] \right\}, \\ \text{sujeito a } & y_i (W_{SVM}^T \cdot x_i + b) \geq 1, n = 1, \dots, N \end{aligned} \quad (3)$$

Quando não se pode resolver o problema de forma linear, pode-se utilizar um fator de relaxamento (também chamado de folga), que admite um erro do limite de decisão. Além disso, um parâmetro C pode ser fornecido pelo usuário relacionado com a distância das margens, gerando a função custo tal que (THEODORIDIS *et al.*, 2010):

$$f(W_{SVM}) = \frac{\|W_{SVM}\|^2}{2} + C \sum_{i=1}^N \xi_i \quad (4)$$

$$\text{sujeito a } y_i(W_{SVM}^T \cdot x_i + b) \geq 1 - \xi, n = 1, \dots, N$$

$$\xi \geq 0, n = 1, \dots, N$$

Quando os dados não possuem distribuições linearmente separáveis, pode-se utilizar funções não-lineares para delimitar os hiperplanos de separação. Dessa forma, mapeia-se os dados em um espaço que possua uma alta dimensionalidade por meio de uma função não-linear (ϕ) (TAN; STEINBACH; KUMAR, 2009), a qual pode ser escrita como:

$$y_i(W_{SVM} \cdot \phi(x_i) + b) \geq 1 \quad (5)$$

Essas funções lineares são os chamados kernels e estes podem ser polinomiais, funções gaussianas, entre outros. Logo, escolhe-se estes hiperplanos de separação no espaço dimensional formado pelo espaço original. Estes parâmetros devem ser configurados para cada problema e cada caso (HAN; KAMBER, 2012).

Como as SVMs só resolvem problemas envolvendo duas classes, são necessárias estratégias para que possam ser aplicados em problemas de multi-classe. Na primeira estratégia, chamada *one-versus-one*, são construídas uma quantidade de classificadores de tal forma que cada classe possa competir com as demais classes individualmente, sendo a saída determinada por meio de voto majoritário. Na segunda estratégia, *one-versus-all*, são construídos classificadores para cada classe, sendo uma quantidade reduzida de classificadores, na qual se distingue uma classe das demais.

f) Rede Neural Perceptron Multicamadas (MLP – *Multilayer Perceptron*)

As redes neurais formam outra classe de classificadores, as quais são inspiradas no sistema nervoso dos organismos superiores. A base de processamento da rede neural, que é o neurônio artificial, é responsável por adquirir e manter a informação, na qual está inserida a capacidade de aprendizado e lhe conferirá generalização após o treinamento (HAYKIN, 1999; SILVA; SPATTI; FLAUZINO, 2010).

O modelo mais simples de redes neurais usadas para a classificação de padrões linearmente separáveis é o Perceptron, consistindo em um único neurônio com pesos sinápticos ajustáveis e *bias* (HAYKIN, 1999). De maneira mais formal, ele

é composto pelas entradas (x_i , sendo i a quantidade de entradas), pelos seus pesos sinápticos (w_{ki}), uma unidade de soma, um limiar de ativação (Θ) e uma função de ativação (g). Dessa forma, este pode ser expresso de acordo com a equação (6):

$$y = g \left(\sum_{i=1}^n w_{ki} \cdot x_i - \theta \right) \quad (6)$$

Assim como as entradas estão relacionadas com os dendritos celulares, os pesos sinápticos estão relacionados com as ligações entre as entradas e o corpo celular, sendo as entradas multiplicadas pelo seu respectivo conjunto de pesos sinápticos.

A partir de um conjunto de neurônios, pode-se construir arquiteturas e topologias de redes neurais mais complexas, como as Perceptron de Múltiplas Camadas (MLP – *Multilayer Perceptron*). A grande diferença entre a MLP e a Perceptron simples é a presença de uma camada escondida, ou seja, que não faça parte da camada de entrada ou de saída. Devido a sua grande flexibilidade, a MLP pode ser aplicada como um algoritmo de classificação (HAYKIN, 1999).

O ajuste dos pesos sinápticos de uma MLP na etapa de treinamento pode ser feito de diversas formas, como um problema de otimização. Uma das formas é a utilização do método do gradiente descendente, com a retropropagação do erro (chamado de *backpropagation*). Este processo busca encontrar um mínimo global ou local para a relação do erro entre a entrada e a saída, sendo baseada em duas etapas. A primeira é a apresentação do conjunto de treinamento na etapa de entrada até a geração de uma resposta de saída. Calcula-se o erro e em função da sua variação, os pesos sinápticos são ajustados. Os passos da execução do algoritmo do gradiente descendente da rede Perceptron de Múltiplas camadas são apresentados em detalhes no Quadro 9.

O algoritmo cessa a sua execução quando atinge a quantidade máxima de iterações (chamada de época de treinamento) ou quando o erro mínimo é atingido. Estes parâmetros devem ser escolhidos com cuidado de tal forma que não haja sobre-treinamento para o conjunto de dados.

A MLP é um classificador com diversos parâmetros a serem ajustados. Entre eles, pode-se citar a quantidade de camadas e de neurônios das camadas intermediárias e escolha da função de ativação, os valores dos erros para a parada e quantidade máxima de épocas durante o treinamento.

Quadro 9 - Algoritmo do classificador MLP

1: **Função MLP(X)**

- 2: Inicializar os pesos sinápticos da rede com valores aleatórios e pequenos
 3: Realizar a etapa *forward*, apresentando o vetor dos valores de entrada do treinamento e propagá-los até a camada de saída obtendo valor na saída
 4: Calcular o erro do sinal pela comparação entre o sinal obtido na saída com o desejado
 Pelo método do gradiente descendente, o gradiente local do erro da camada de saída pode ser obtido por

$$\delta_2 = (\mathbf{d} - \mathbf{Y}_2) \times g'(\mathbf{I}_2)$$

δ_2 : vetor/matriz do gradiente local do erro da camada de saída

d : vetor/matriz da saída desejada

$g'(\cdot)$: derivada da função de ativação

- 5: Por meio do gradiente, calcular os pesos sinápticos entre a camada escondida e a camada de saída por

$$\mathbf{W}_{2MLP} = \mathbf{W}_{2MLP} + \eta \times \delta_2 \times \mathbf{Y}_2$$

η : taxa de aprendizagem

- 6: Calcular o vetor/matriz gradiente do erro δ_1 entre a camada escondida e a camada de entrada por

$$\delta_1 = (\delta_2 \times \mathbf{W}_{2MLP}) \times g'(\mathbf{I}_1)$$

- 7: Ajustar os pesos sinápticos \mathbf{W}_1 entre a camada de entrada e a camada escondida por

$$\mathbf{W}_{1MLP} = \mathbf{W}_{1MLP} + \eta \times \delta_1 \times \mathbf{X}$$

- 8: Como critério de parada, calcula-se o valor do erro quadrático médio entre a saída desejada e a saída obtida

$$E_M = \frac{1}{p} \sum \left(\frac{1}{2} \sum (\mathbf{d} - \mathbf{Y}_2)^2 \right)$$

- 9: Repetir os passos 3 a 9 até se obter um valor de erro aceitável ou atingir o número máximo de épocas (definido previamente)

10: **Fim da função**

Fonte: Mendes Junior (2020), adaptado

g) *Ensemble*

O método de *Ensemble* consiste na combinação de diversos classificadores. A ideia desse método de classificação é combinar as previsões dos classificadores através de um sistema de votação para realizar a classificação de diferentes instâncias. Espera-se que o conjunto tenha coletivamente um nível mais alto de precisão preditiva do que qualquer um dos classificadores individuais, mas isso não é garantido (BRAMER, 2013). Neste método, os classificadores individuais são conhecidos como classificadores base. Se os classificadores base forem todos do mesmo tipo, diz-se que se tem um *Ensemble* homogêneo, caso contrário, é conhecido

como heterogêneo. Em um *Ensemble*, a combinação da saída de vários classificadores só é útil se eles discordarem sobre algumas entradas, pois classificadores diversificados levam a erros não correlacionados, melhorando a precisão do processo de classificação (ROKACH; MAIMON, 2015).

Durante o processo de classificação, é importante fazer o treinamento e validação do classificador antes de passar para a etapa de teste. Para tal, faz-se a separação dos dados de entrada em duas amostras principais: uma voltada ao treinamento e validação do classificador, e outra para a etapa de teste. Dentro da primeira amostra, faz-se a divisão em subamostras, sendo uma para treinamento e outra para validação. Os métodos mais comuns dessa divisão são: *holdout*, validação cruzada *k-fold* (*k-fold cross validation*) e *bootstrap* (HAN; KAMBER, 2012; KOHAVI, 1995). No presente trabalho, utilizou-se o método de validação cruzada *k-fold*.

Neste método de validação, realiza-se a divisão aleatória dos dados em k subconjuntos de mesmo tamanho. Destes subconjuntos, é selecionado um grupo para fazer o treinamento do classificador ($k-1$) e o resto fica separado para fazer a etapa de validação. Ele é chamado de *k-fold*, pois o processo é repetido k vezes, em que um dos subconjuntos k é usado como dado de verificação em cada iteração (CHANG; CHEN; LIU, 2015; KOHAVI, 1995).

Depois do treinamento e validação, passa-se para a etapa de teste do classificador, em que são usadas as amostras que não foram previamente apresentadas ao classificador. A taxa de acerto do classificador é medida durante a etapa de teste (HAN; KAMBER, 2012).

4 MATERIAIS E MÉTODOS

O presente capítulo abordará quais foram os materiais e métodos adotados para a realização do trabalho.

4.1 Materiais

A aquisição dos sinais de sEMG foi feita utilizando a *armband* comercial Myo™, desenvolvida pela empresa Thalmic Labs. Esta é um dispositivo vestível que possui 8 canais de aquisição de sinais de sEMG, além de uma unidade de medição inercial (IMU) de 9 eixos (giroscópio de 3 eixos, acelerômetro de 3 eixos e magnetômetro de 3 eixos) e um motor de vibração que é acionado quando determinados eventos ocorrem. Para seu funcionamento e controle, ela possui um processador ARM Cortex M4 (MK22FN1M) e os dados adquiridos são transmitidos via *bluetooth* (chip BLE NRF51822). A alimentação da *armband* é feita através de duas baterias de íons de lítio de 3,7 V – 260 mAh. São utilizados eletrodos do tipo bipolar e secos em conjunto com um amplificador operacional modelo ST78589. Sua taxa de amostragem é de 200 Hz e ela possui resolução de 8 bits (VISCONTI *et al.*, 2018). A Figura 5 apresenta a *armband* comercial Myo™ utilizada na aquisição, com seus canais destacados.

Figura 5 - *Armband* comercial Myo™ usada para realizar a aquisição, com destaque aos seus oito canais.



Fonte: A autoria própria (2023)

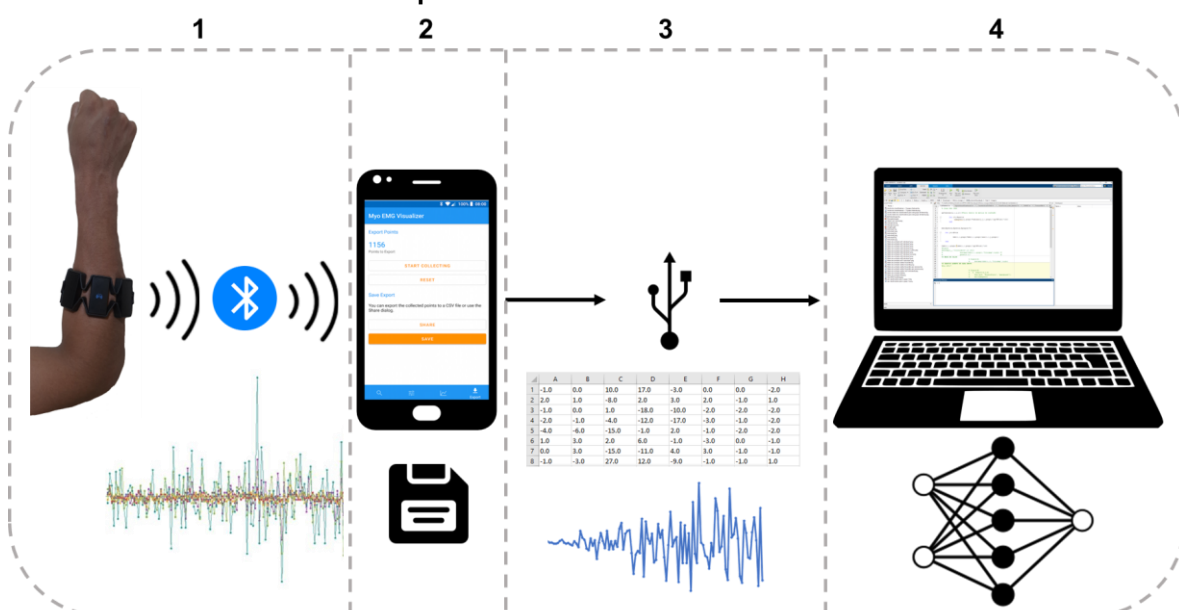
Para realizar a aquisição dos dados com a *armband*, utilizou-se um aplicativo de *smartphone Android* chamado *Myo EMG Visualizer 2.0* desenvolvido por Corti (2020). Este aplicativo fornece apenas a aquisição dos sinais de EMG, portanto, para o presente trabalho, não foram utilizados os sensores inerciais presentes na *armband*.

Porém, pode-se fazer a conexão direta da *armband* com o computador, sendo apenas necessário ter o *software* adequado para tal. Depois de adquirir os dados através do aplicativo utilizando um *smartphone*, passou-se os arquivos relativos às aquisições para o computador, para então realizar as etapas de processamento.

As demais etapas (segmentação, extração de características, classificação e obtenção dos resultados) foram realizadas através do *software* MATLAB™. Este *software* foi desenvolvido pela *MathWorks* inicialmente para realizar cálculos matriciais. Porém, atualmente ele é mais completo, sendo utilizado para realizar cálculos e simulações. Possui ferramentas de controle (por exemplo os recursos *Fuzzy* e *Sisotool*), processamento de imagens e sinais (através de *toolboxes*) e simulação (*Simulink*). Sua linguagem de programação é baseada em C e JavaScript, contando com diversas estruturas de programação semelhantes como estruturas condicionais (como *if-else*, *switch-case*), laços de repetição (*loop for*, *loop do while*) (CHAPMAN, 2016).

A Figura 6 ilustra o fluxo de dados com relação à aquisição e processamento adotados no presente trabalho. Os dados foram adquiridos com a *armband*, transmitidos ao *smartphone* via *bluetooth* (Figura 6-1), salvos no formato .csv no *smartphone* (Figura 6-2), transmitidos ao computador via USB (Figura 6-3) e processados através do *software* MATLAB™ no computador.

Figura 6 - Fluxo de dados: 1) aquisição através da *armband* e transmissão via *bluetooth* ao *smartphone*, 2) salvamento no *smartphone*, 3) transmissão via USB, 4) processamento no computador com o *software* MATLAB™

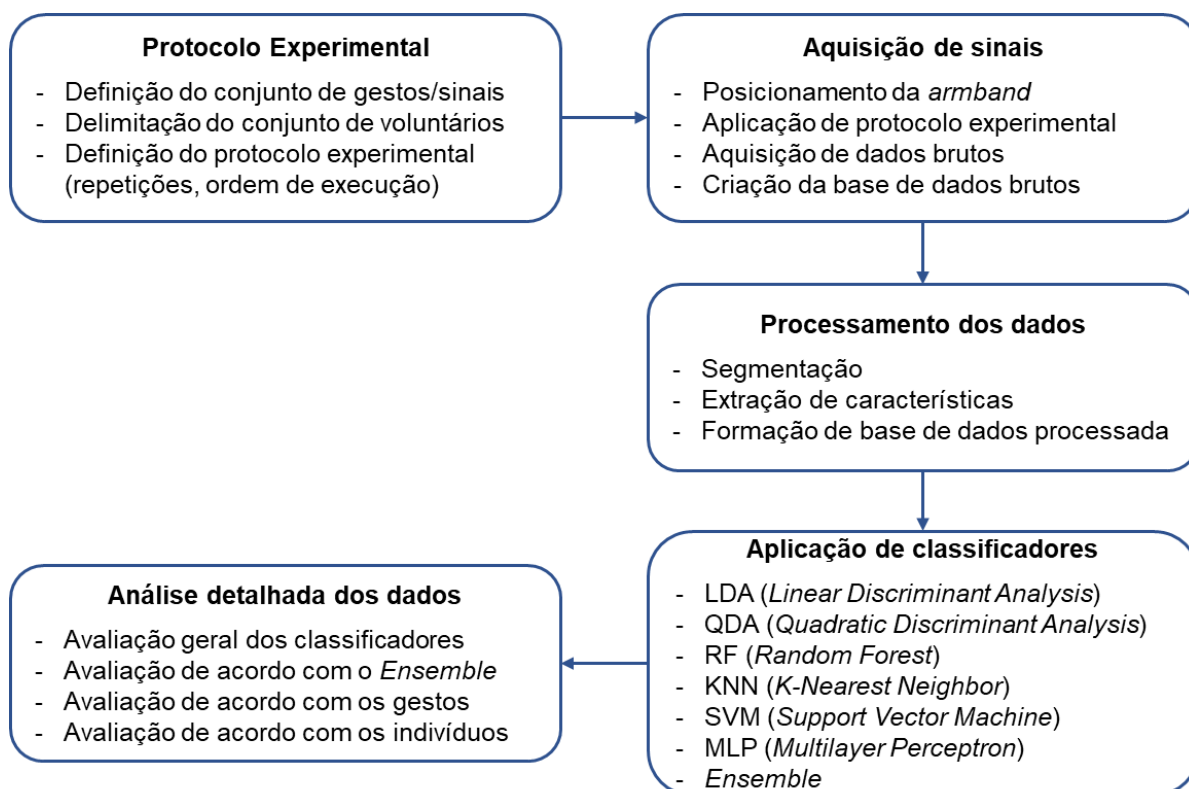


Fonte: Autoria própria (2023)

4.2 Metodologia

Para realizar o desenvolvimento do presente trabalho seguiu-se a metodologia apresentada na Figura 7. a qual foi subdividida em cinco etapas principais: definição do protocolo experimental, aquisição de sinais, processamento dos dados, aplicação de classificadores e análise detalhada dos dados.

Figura 7 - Fluxograma da metodologia de trabalho adotada.



Fonte: Autoria própria (2023)

4.3 Metodologia Experimental

Para realizar a aquisição dos dados, alocou-se o Myo™ no antebraço direito, tendo como referência um terço do comprimento do antebraço. O posicionamento dos canais foi feito de maneira que o quarto canal ficasse posicionado no músculo extensor ulnar do carpo. A Figura 8 apresenta a *armband* comercial Myo™ utilizada na aquisição, com seus canais destacados e seu o posicionamento no antebraço.

Figura 8 - Armband comercial Myo™ usada para realizar a aquisição posicionada no antebraço



Fonte: Autoria própria (2023)

Com relação aos voluntários, foram capturados dados de dez voluntários saudáveis (sete homens e três mulheres), com idade média de $27,0 \pm 2,2$ anos. É importante destacar que estes não trabalham na área da saúde, logo não possuíam familiaridade com os gestos executados até o momento da aquisição dos dados. Os procedimentos experimentais adotados estão de acordo com o Comitê de Ética em Pesquisa envolvendo Seres Humanos da UTFPR, sob o registro CAAE: 50088321.6.0000.5547, no qual os participantes assinaram um termo de aceitação da pesquisa, cujo modelo está presente no Anexo A.

Foram delimitados 14 gestos/sinais para este estudo, os quais estão enumerados e apresentados na Figura 9. Eles foram escolhidos por estarem mais presentes na literatura e por serem gestos executados com apenas com uma mão (CARVALHO *et al.*, 2019; COSTA NETO *et al.*, 2011; NEMITZ, 2019). São eles:

- compressa,
- fio em carretel,
- fio solto,
- pinça Backhaus,
- pinça hemostática,
- pinça hemostática Kelly,

- afastador Farabeuf,
- bisturi,
- porta agulha,
- válvula Doyen,
- pinça Allis,
- pinça anatômica,
- pinça dente de rato e
- tesoura.

Figura 9 - Gestos realizados durante a aquisição



Fonte: Autoria própria (2023)

Cada participante foi orientado a realizar os 14 gestos em sequência seguindo uma cadência de 30 batidas por minuto (bpm) guiada por um metrônomo. Entre os movimentos, o indivíduo deveria manter-se na posição neutra (sem realizar movimento algum). Optou-se por seguir este protocolo para se ter uma padronização

entre os dados de todos os indivíduos, a fim de se poder comparar os resultados de classificação posteriormente. Determinados gestos são estáticos e deveriam ser executados apenas uma vez (gestos 1 ao 6), enquanto os gestos dinâmicos foram executados de duas formas diferentes: os gestos 7 ao 10 foram executados apenas uma vez e os gestos 11 ao 14 foram executados duas vezes. Para evitar a fadiga muscular foram realizadas pausas de, aproximadamente, um minuto entre as aquisições.

Esta sequência de movimentos foi realizada 1 vez por aquisição e foram obtidas 30 aquisições por participante. O banco de dados totalizou-se com 420 gestos por participante, o que é equivalente a 4200 gestos para todos os participantes.

4.4 Metodologia de Análise

Para realizar a análise dos dados adquiridos, realizou-se a segmentação dos dados de acordo com os gestos realizados, extração de características para uso em diferentes grupos e classificação dos gestos utilizando classificadores individuais e combinação destes através do método *Ensemble*.

4.4.1 Segmentação

O processo segmentação dos dados foi realizado subdividindo-o em processos menores: preparação do sinal; determinação e avaliação dos limiares (*thresholds*) para detecção do *onset* e *offset* do sinal dos 14 gestos; e janelamento dos dados com base nos limiares encontrados. Optou-se por utilizar esse método, pois mesmo tendo um metrônomo para guiar a cadência dos movimentos, ao avaliar os sinais adquiridos de forma visual, percebeu-se que alguns voluntários executavam os gestos em tempos diferentes de outros voluntários, prejudicando assim um possível sistema baseado em valores de janela fixos para registrar a atividade muscular.

O algoritmo da segmentação foi desenvolvido de forma que realiza todo o processo automaticamente. Desta forma, não há necessidade de ajuste posterior ou inspeção visual. Para que o algoritmo possa iniciar sua execução, deve-se inserir alguns parâmetros: número de gestos executados dentro de uma aquisição (independentemente do tipo de gesto), número de voluntários, número de aquisições para cada voluntário, duração esperada de cada gesto, taxa de assertividade desejada e valor limite de amplitude para o limiar. Este valor de amplitude é fornecido

com base na unidade de medida na aquisição dos dados elevada ao quadrado. O Quadro 10 apresenta quais foram os parâmetros adotados no presente trabalho para o processo de segmentação:

Quadro 10 - Parâmetros usados na segmentação

Parâmetro	Valor
Número de gestos executados por aquisição	14
Número de voluntários	10
Número de aquisições por voluntário	30
Duração esperada de cada gesto	2 segundos
Taxa de assertividade mínima desejada	80%
Valor limite de amplitude para o limiar	500 u.aq. ²

Fonte: Autoria própria (2023)

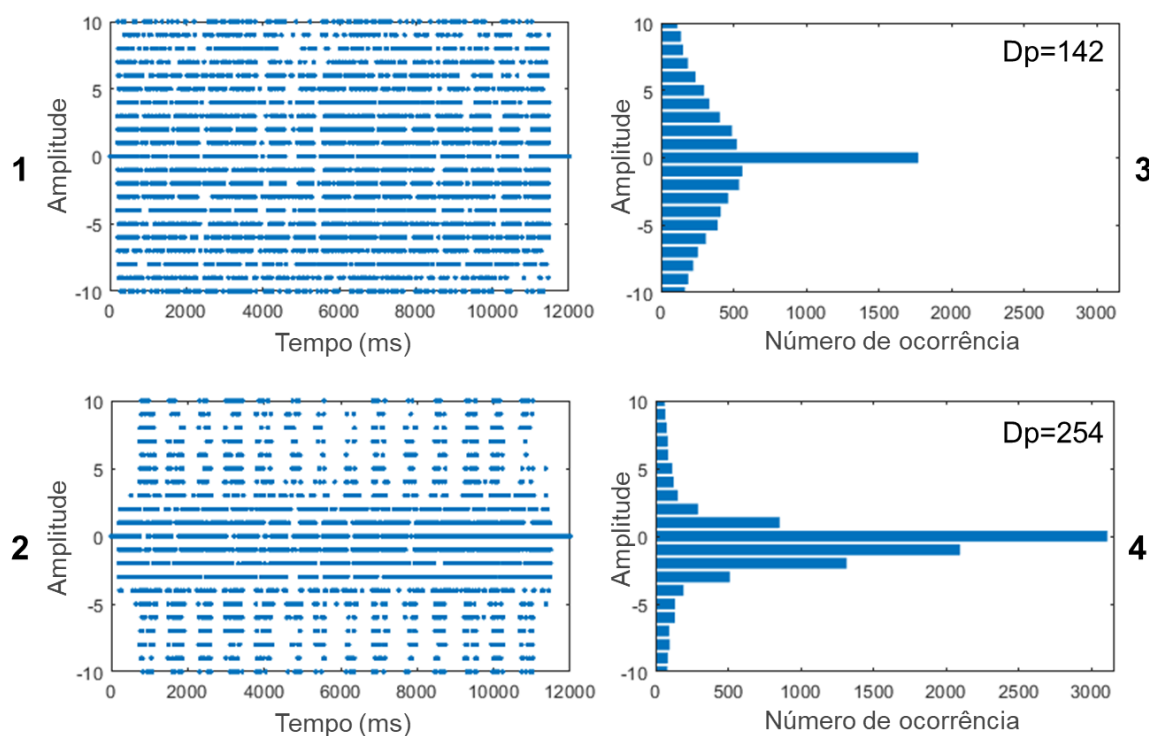
A preparação do sinal envolve a identificação dos canais que apresentaram menos ruídos para serem utilizados como base. Optou-se por utilizar quatro canais para se ter uma visualização mais completa do momento de início e fim de cada gesto, já que devido à posição dos canais e músculos, a duração da execução do gesto era diferente (em alguns canais era maior, em outros menor). Testou-se também a utilização do sinal proveniente de todos os oito canais, porém verificou-se que alguns destes apresentavam muito ruído por causa da baixa atividade muscular da região em que o canal ficou posicionado, dificultando o processo de segmentação.

Para identificar os canais mais relevantes, foi realizado um histograma de cada canal e selecionou-se os quatro canais que apresentaram maior valor de desvio padrão. Utilizou-se o desvio-padrão, pois ele demonstra o grau de dispersão de um conjunto de dados em torno do valor médio (MORETTIN; BUSSAB, 2017). No caso da análise aqui adotada, quanto maior o desvio-padrão, maior é a diferença no sinal de quanto há atividade muscular em comparação ao momento de repouso. Já um sinal mais ruidoso apresenta um desvio menor em torno da média, resultando em um valor de desvio-padrão menor. A Figura 10 ilustra a dispersão de dados descrita para um canal mais ruidoso (Figura 10-1), em comparação com um canal menos ruidoso

(Figura 10-2), além dos respectivos histogramas e valores de desvio-padrão (Figura 10-3 e Figura 10-4).

Depois de selecionar os quatro canais mais relevantes, somou-se o sinal destes para a obtenção de uma melhor representação da atividade muscular. Para melhorar a visualização dos momentos de atividade muscular, elevou-se o valor resultante ao quadrado, obtendo um resultado com números positivos apenas. Posteriormente, extraiu-se o valor RMS (apresentado na equação (7)) para uma janela móvel de 500 ms com o objetivo de atenuar a aparência ruidosa do sinal. Na equação apresentada, N representa o comprimento do sinal e x_i representa o sinal de EMG referente à soma dos quatro canais mais relevantes.

Figura 10 - Exemplo de sinal adquirido em um canal 1) mais ruidoso e 2) menos ruidoso, seus histogramas e desvios-padrão (Dp) 3) e 4), respectivamente



Fonte: Autoria própria (2023)

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (7)$$

Com base nesse sinal, foram testados diferentes valores de limiares dentro de um intervalo (começando com zero até o valor médio, sendo incrementado de 1 em 1 o valor da amplitude) para identificar os 14 gestos, com seus respectivos *onsets* e

offsets. Caso o algoritmo identificasse menos de 14, ele deveria aumentar o valor do limiar e testar novamente. Caso identificasse mais de 14, o algoritmo deveria realizar a integral desses gestos encontrados e selecionar os 14 que apresentassem maior valor, pois isso indica maior atividade muscular e maior a chance de ser um dos gestos desejados. Se o algoritmo não conseguisse identificar pelo menos 14 ao testar todos os valores de limiares estipulados, ele zerava as informações referentes àquela aquisição (*onset*, *offset*, limiar e taxa de assertividade).

Ao encontrar 14 gestos, os sinais obtidos eram avaliados de acordo com a taxa de assertividade (TA), calculada com base no tamanho identificado de cada gesto e apresentada na equação (8). Quanto maior o valor da taxa, mais semelhante era a duração dos gestos executados. A taxa de assertividade foi obtida com base no coeficiente de variação (MEYER, 1970).

$$TA = 1 - s/X \cdot 100 \quad (8)$$

Na equação (8), s é o desvio-padrão da amostra, X é a média dos dados e a divisão destes parâmetros, multiplicada por 100, é equivalente ao coeficiente de variação.

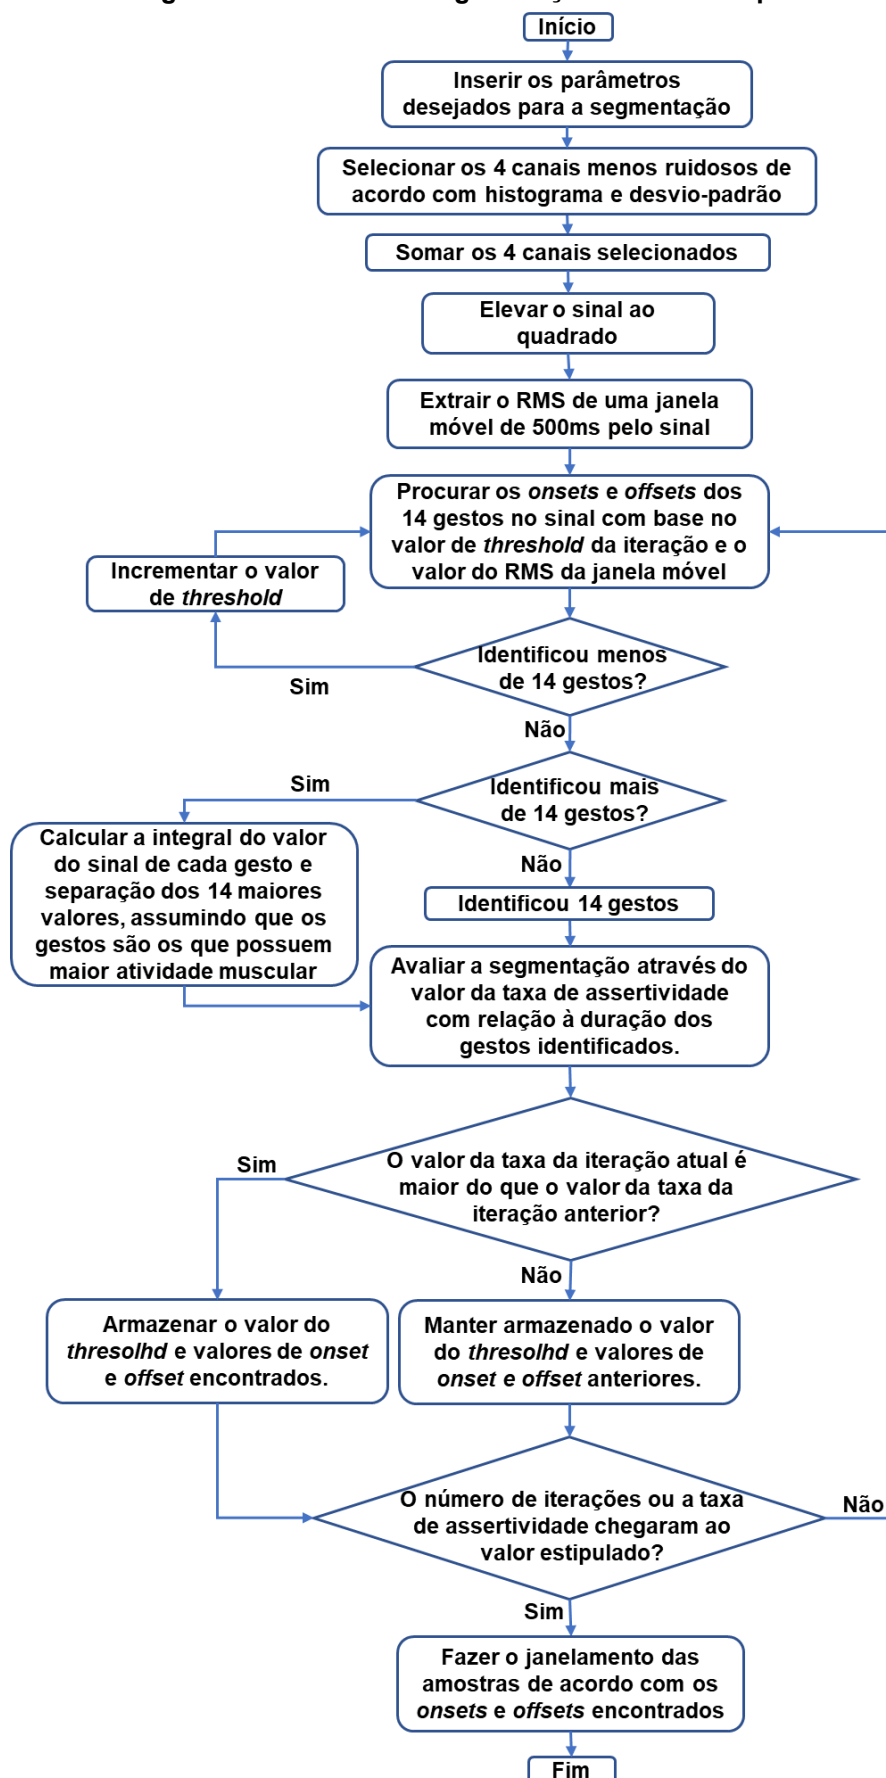
Seguindo como critérios de parada da rotina os parâmetros de taxa de assertividade e o valor limite de amplitude para o limiar (apresentados no Quadro 10), executou-se a rotina desenvolvida para cada aquisição de cada voluntário. Quando um desses parâmetros foi atingido (tendo como prioridade o valor de taxa de assertividade), salvou-se o valor de limiar obtido, assim como a posição inicial (*onset*) e final (*offset*) obtida para cada um dos 14 gestos.

Com esses valores iniciais e final dos gestos obtidos, passou-se ao janelamento das amostras. Esse processo foi executado para todas as 30 aquisições dos 10 voluntários.

O processo de segmentação proposto foi testado também com outra base de dados para validação, cujos resultados são mostrados e discutidos no estudo de Freitas *et al.* (2022) e foram apresentados no IX Congresso Latino-Americano de Engenharia Biomédica – CLAIB e XXVIII Congresso Brasileiro de Engenharia Biomédica – CBEB (no prelo).

A Figura 11 apresenta um fluxograma contendo o funcionamento da técnica de segmentação descrita em detalhes.

Figura 11 - Fluxograma da técnica de segmentação utilizada no presente trabalho



Fonte: Autoria própria (2023)

4.4.2 Normalização dos dados

Antes de realizar a extração de características do sinal, foi realizada a normalização dos dados de acordo com cada voluntário através da equação (9):

A normalização dos dados é necessária, pois cada indivíduo possui características fisiológicas, anatômicas e bioquímicas dos músculos diferentes, fazendo com que os níveis de tensão medidos sejam diferentes para cada um. Dessa forma, a normalização faz com que haja um valor de referência com o qual os sinais possam ser comparados (HALAKI; GI, 2012).

$$Norm = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (9)$$

em que Norm representa o sinal com valor normalizado, x é o valor atual do sinal de sEMG e min(x) e max(x) são os valores mínimos e máximos obtidos para o sinal de sEMG analisado, respectivamente. A normalização dos dados é necessária, pois cada indivíduo possui características fisiológicas, anatômicas e bioquímicas dos músculos diferentes, fazendo com que os níveis de tensão medidos sejam diferentes para cada um. Dessa forma, a normalização faz com que haja um valor de referência com o qual os sinais possam ser comparados (HALAKI; GI, 2012).

4.4.3 Extração de Características/Atributos do sinal

Com os dados normalizados, fez-se a extração de 19 características (descritas no Quadro 4): AR, CC, DASDV, HIST, IAV, LD, LS, MAV, MFL, MNP, MSR, RMS, SampEn, SSC, TTP, VAR, WAMP, WL e ZC. Para o cálculo das características TTP e MNP foi necessário realizar a transformação do sinal para o domínio da frequência através da transformada rápida de Fourier (FFT – *Fast Fourier Transform*), pois elas são características que avaliam o sinal dentro do domínio da frequência.

Algumas dessas características precisam ter alguns parâmetros definidos, sendo estes apresentados no Quadro 11. Para as características AR e CC variou-se a ordem dos coeficientes.

Para se avaliar a influência das características, diferentes grupos foram realizados, baseados em estudos anteriores envolvendo sEMG para reconhecimento de gestos e que apresentaram bons resultados. A divisão dos grupos de características usada é apresentada no Quadro 12.

Quadro 11 - Parâmetros usados para as características

Característica	Parâmetro
AR	Ordem de coeficientes autorregressivos: 4ª (AR4), 6ª (AR6), 9ª (AR9), 15ª (AR15)
CC	Ordem de coeficientes cepstrais: 4ª (CC4) e 9ª (CC9)
HIST	9 Bins
LS	Segundo momento
SampEn	Dimensão = 2 R = 0,2 σ
SSC	Limiar = 10^{-4}
WAMP	Limiar = 10^{-2}
ZC	Limiar = 10^{-2}

Fonte: Autoria própria (2023)

Quadro 12 - Divisão dos grupos de características escolhidos

Grupo	Características	Referência
C1	MAV, WL, ZC e SSC	Hudgins, Parker e Scott (1993)
C2	RMS, AR6	Huang <i>et al.</i> (2005)
C3	MAV, WL, ZC, SSC, RMS, AR6	Huang <i>et al.</i> (2005)
C4	AR4, HIST	Liu, Huang e Weng (2007)
C5	WL, LD, SSC, AR9	Phinyomark, Khushaba e Scheme (2018) Tkach, Huang e Kuiken (2010)
C6	WL, SSC, AR9, CC9	Phinyomark, Khushaba e Scheme (2018) Tkach, Huang e Kuiken (2010)
C7	RMS, VAR, LD, HIST	Phinyomark, Khushaba e Scheme (2018) Tkach, Huang e Kuiken (2010)
C8	WL, RMS, SampEn, CC4	Phinyomark <i>et al.</i> (2013)
C9	AR15, ZC, MAV, RMS, SSC, WL	Bhattacharya, Sarkar e Basak (2017)
C10	MAV, AR4	Mendes Junior (2020)

Grupo	Características	Referência
C11	MFL, MSR, WAMP e LS	Phinyomark, Khushaba e Scheme (2018)
C12	LS, MFL, MSR, WAMP, ZC, RMS, IAV, DASDV, VAR	Phinyomark, Khushaba e Scheme (2018)
C13	MFL, MNP, TTP e RMS	Mendes Junior (2020)

Fonte: Autoria própria (2023)

4.4.4 Classificação de padrões

Para realizar a classificação dos gestos, utilizou-se seis diferentes classificadores: LDA, QDA, KNN, RF, SVM e MLP. No caso do classificador SVM, utilizou-se a biblioteca LibSVM disponibilizada por (CHANG; LIN, 2011) e nos demais realizou-se a implementação dos classificadores no ambiente MATLAB. Para a utilização destes classificadores, são necessários alguns critérios de parametrização, sendo estes apresentados no Quadro 13. Para todos os casos, utilizou-se o método de validação cruzada *k-fold* com $k=5$. Estes parâmetros foram escolhidos por terem sido os que apresentaram os melhores resultados utilizando o método de pesquisa em grade (*grid search*).

Quadro 13 - Critérios de parametrização para os classificadores utilizados

Classificador	Critérios de parametrização
KNN	Distância Euclidiana Número de k vizinhos próximos: 1
RF	Número de árvores: 30
SVM	Tipo RBF (<i>Radial Basis Function</i>) – biblioteca LibSVM Método <i>one-versus-one</i> para múltiplas classes Parâmetro C: 10 Tamanho da gaussiana: 0,1
MLP	Taxa de aprendizagem: $2,5 \times 10^{-3}$ Algoritmo de <i>backpropagation</i> 1 camada escondida com 30 neurônios Função tangente hiperbólica na camada escondida e função logística na saída Critérios de parada: parada antecipada, número de épocas e precisão do erro quadrático médio (10^{-7})

Fonte: Autoria própria (2023)

Além de utilizar esses seis classificadores individualmente, aplicou-se também o método de combinação de vários classificadores (*Ensemble*) para melhorar as taxas de acerto de classificação. Optou-se por utilizar três desses seis classificadores iniciais e apenas um dos treze grupos de características para simplificar o sistema de tomada de decisão do *Ensemble*. O sistema de tomada de decisão foi desenvolvido levando em conta os acertos dos classificadores na fase de validação.

A escolha dos classificadores a serem utilizados no *Ensemble* foi feita de duas formas diferentes, a fim de avaliar o custo computacional e acerto médio:

- A) na primeira foram selecionados, de forma automática, os três classificadores que apresentaram a melhor taxa de acerto em cada *fold* para a tomada de decisão;
- B) já na segunda, a seleção dos três classificadores foi feita de forma manual avaliando os três classificadores com melhor desempenho geral. Em ambos os casos, avaliou-se a classificação para o grupo de características que apresentou os melhores resultados.

A escolha do grupo de características a ser utilizado foi feita com base na taxa de acerto média obtida para os treze grupos, calculando a média do resultado dos seis classificadores para cada um desses grupos. O grupo que apresentou o melhor resultado foi escolhido para o desenvolvimento do *Ensemble*.

A decisão final de uma classificação por *Ensemble* é baseada na votação ponderada dos classificadores individuais. O sistema de votação do *Ensemble* utilizado foi desenvolvido levando em conta as seguintes condições: se dois ou três classificadores resultam no reconhecimento do mesmo gesto, este é o que é escolhido como gesto correto; se cada classificador dá como resposta um gesto diferente, escolhe-se como correto o gesto apontado pelo classificador com maior taxa de acerto geral.

Para ilustrar o sistema de tomada de decisão do *Ensemble*, a Figura 12 apresenta três exemplos. No primeiro, os três classificadores escolheram o gesto referente à compressa, logo, o resultado da classificação foi esse mesmo gesto. No segundo, dois dos classificadores escolheram o gesto da compressa e o outro escolheu o gesto do fio em carretel, como a maioria escolheu o mesmo gesto, o resultado da classificação foi o gesto da compressa. No terceiro exemplo, cada classificador escolheu um gesto diferente (classificador 1: compressa, classificador 2:

fio solto, classificador 3: fio em carretel), então levou-se em conta o classificador com a maior taxa de acerto e por isso o resultado da classificação foi o gesto da compressa.

Visando reduzir o custo computacional, o sistema do *Ensemble* só foi implementado para o grupo de características que apresentou o melhor resultado médio de classificação (cujos resultados serão apresentados no próximo capítulo).

O sistema de classificação descrito anteriormente (*Ensemble*) foi utilizado de duas formas diferentes:

- a) para analisar o resultado geral para os 10 indivíduos que compuseram a base de dados; e
- b) para analisar os resultados individualmente.

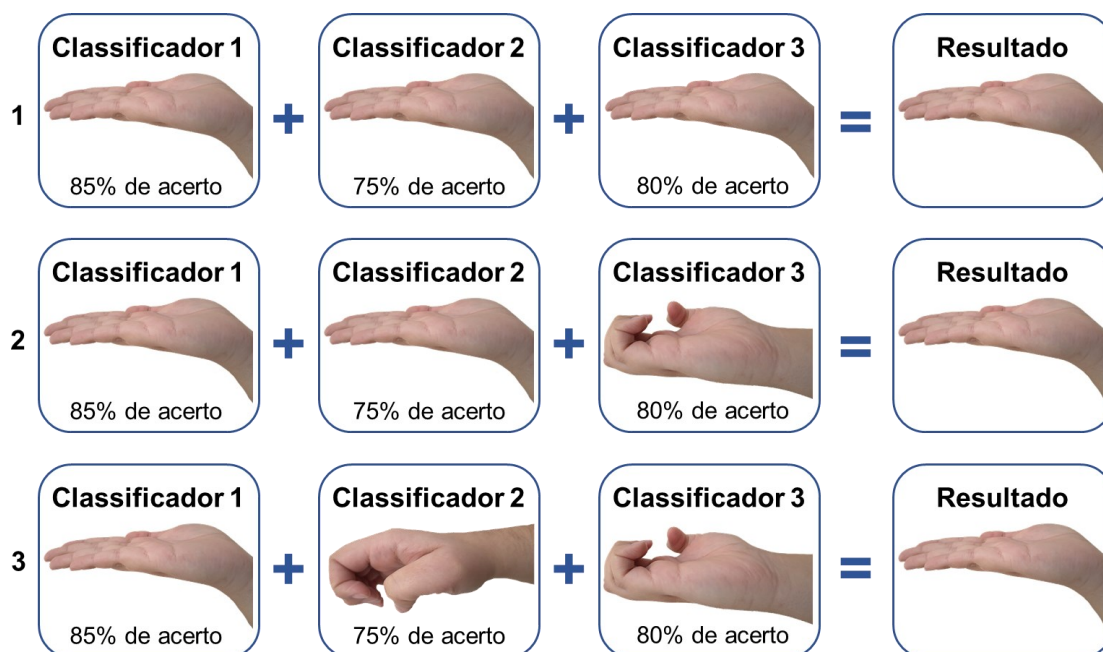
A análise individual foi feita de três maneiras diferentes, exemplificadas na Figura 13:

- b1) na primeira, a etapa de treinamento do classificador foi feita usando os dados de 1 indivíduo e a etapa de teste foi feita usando os dados dos demais 9 indivíduos (Figura 13-1);
- b2) na segunda, o treinamento do classificador foi feito com os dados de 9 indivíduos e o teste foi feito com o indivíduo restante (Figura 13-2); e
- b3) na terceira, tanto o treinamento, quanto o teste foram feitos com os dados de cada indivíduo, utilizando 90% deles para treinamento e 10% para teste (Figura 13-3).

A Figura 13 ilustra essas três maneiras de análise por indivíduos. No caso A foram separados os dados referentes ao indivíduo 1, no caso B foram separados os dados referentes indivíduo 2 e segue-se nessa lógica até o caso J, em que foram separados os dados referentes ao indivíduo 10 (lembrando que são referentes às análises individuais descritas anteriormente – b1, b2 e b3, respectivamente). Nesses casos as taxas de acerto foram sempre avaliadas com relação à etapa de teste do classificador, e não treinamento.

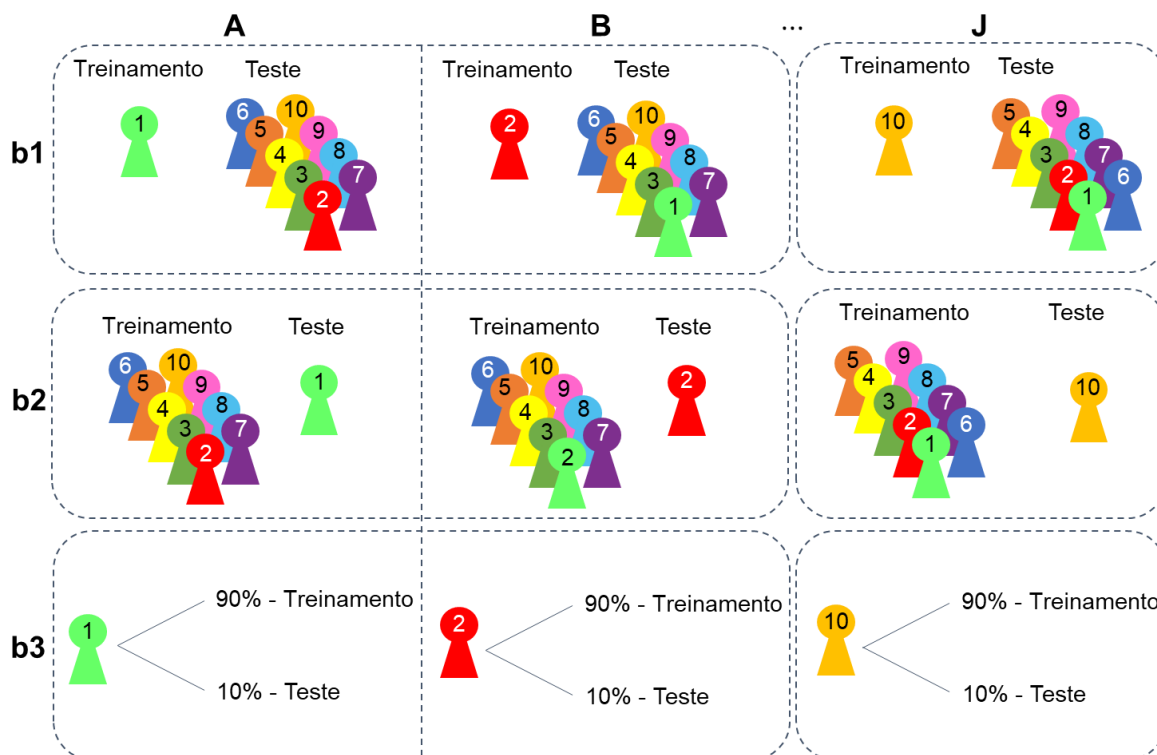
O *Ensemble* também foi utilizado para verificar quais foram os gestos que apresentaram as maiores e menores taxas de acerto na classificação. Para avaliar sua eficácia na classificação, fez-se a comparação deste método com o classificador que apresentou o melhor resultado individual de classificação no grupo de características selecionado.

Figura 12 - Exemplos de funcionamento do *Ensemble*: 1) três classificadores apontaram o mesmo gesto, 2) dois classificadores apontaram o mesmo gesto e 3) cada classificador apontou um gesto diferente



Fonte: Autoria própria (2023)

Figura 13 – Funcionamento da análise por indivíduos, usando: 1) 1 para treinamento, 9 para teste, 2) 9 para treinamento, 1 para teste e 3) 1 – 90% para treinamento e 10% para teste, A) separando os dados do indivíduo 1, B) separando os dados do indivíduo 2, J) separando os dados do indivíduo 10



Fonte: Autoria própria (2023)

5 RESULTADOS E DISCUSSÃO

Nesta seção serão apresentados os resultados obtidos e a discussão acerca desses resultados. A análise dos resultados pode ser dividida de acordo com as seguintes categorias: análise geral dos classificadores, de acordo com o *Ensemble*, de acordo com os gestos e de acordo com os indivíduos.

5.1 Análise Geral dos Classificadores

De maneira geral, a taxa de acerto para os seis classificadores é apresentada na Tabela 1. Essa taxa foi obtida através da média da taxa de acerto para os treze grupos de características escolhidos.

Tabela 1 - Taxa de acerto média dos classificadores

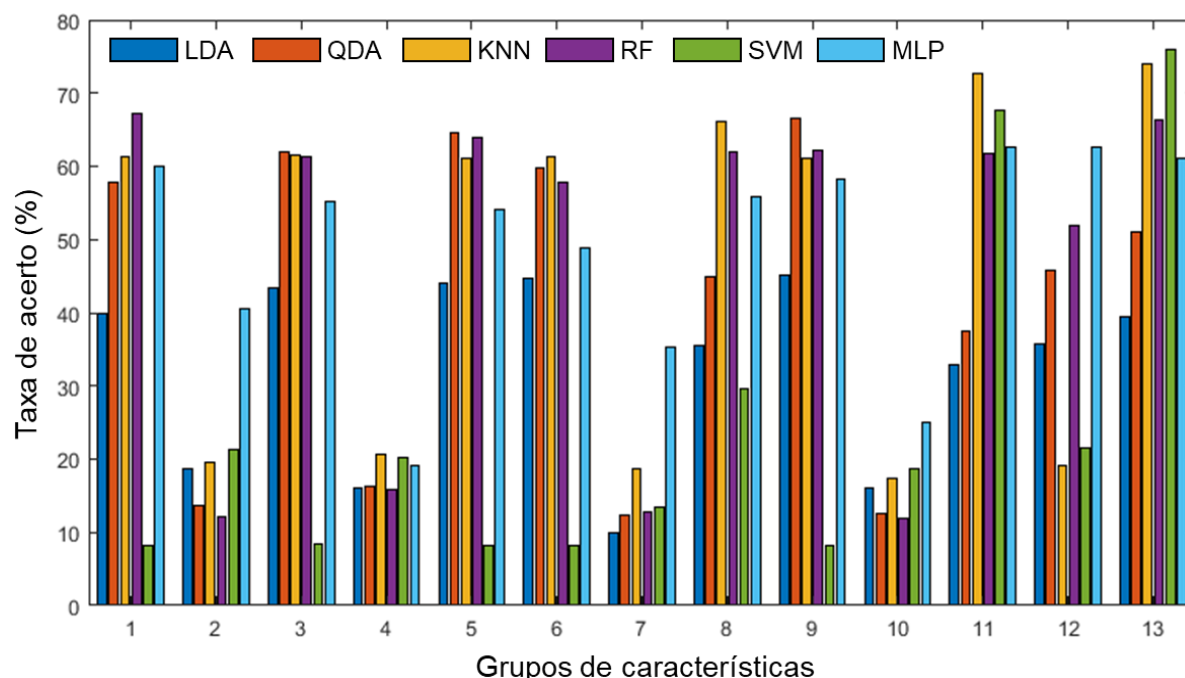
Classificador	Taxa de acerto média
LDA	32,42%
QDA	41,92%
KNN	47,28%
RF	46,72%
SVM	23,81%
MLP	49,14%

Fonte: Autoria própria (2023)

Analisando a Tabela 1, constata-se que o classificador que apresentou os melhores resultados foi a MLP, seguido do KNN e RF. Porém, é importante não apenas analisar essa taxa média, mas também qual foi o desempenho dos classificadores com relação a cada grupo de características escolhido. Por essa razão, a Figura 14 apresenta a taxa de acerto dos seis classificadores para cada um dos grupos de características.

Avaliando a figura, pode-se observar que alguns grupos apresentaram um desempenho mais alto (como os grupos 11 e 13), enquanto outros grupos apresentaram um desempenho mais baixo (como os grupos 2, 4, 7 e 10). Também se percebe que dependendo do tipo de classificador e do grupo de características, os comportamentos são diferentes. Por exemplo, para os grupos 11 e 13 os classificadores SVM e KNN apresentaram valores mais altos, enquanto para os grupos 3, 5, 6 e 9 os classificadores que mais se destacaram foram os classificadores QDA, KNN e RF.

Figura 14 – Taxas de acerto para os seis classificadores e treze grupos de características




Fonte: Autoria própria (2023)

5.2 Análise de Acordo com o *Ensemble*

Por causa dessa grande variabilidade de resultados presente para os treze grupos de características, calculou-se a média de taxa de acerto obtida entre os seis classificadores para cada grupo, cujos resultados são apresentados na Figura 15. Com base nos resultados, o grupo de características a ser usado como base no *Ensemble*, foi o grupo 13, pois foi ele quem apresentou o maior valor médio.


Como mencionado anteriormente, foram utilizados dois métodos diferentes para o desenvolvimento do *Ensemble*: em um deles seleciona-se os três melhores classificadores para cada *fold* na etapa de teste de forma automática, e no outro método escolheu-se de forma manual quais seriam os três classificadores a serem usados. Essa escolha manual foi feita com base no acerto médio dos classificadores para o grupo 13, conforme apresentado na Figura 16. Assim, para o método manual, escolheu-se os classificadores RF, KNN e SVM para a tomada de decisão do *Ensemble*.

Figura 15 - Acerto médio por grupo de característica



Fonte: Autoria própria (2023)

Figura 16 - Acerto médio dos classificadores para o grupo 13



Fonte: Autoria própria (2023)

Para selecionar qual dos métodos do *Ensemble* (manual ou automático) seria utilizado para a análise com relação aos gestos e indivíduos, executou-se cada um deles dez vezes. Após as execuções, avaliou-se a taxa de acerto média e o tempo médio de execução obtidos, apresentados na Tabela 2. Essas dez execuções para

cada método não foram feitas em paralelo, devido às limitações do computador utilizado, elas foram executadas separadamente, porém seguindo as mesmas condições de funcionamento.

Tabela 2 - Taxa de acerto e tempo de execução para os métodos de *Ensemble* manual e automático

Parâmetros	<i>Ensemble</i>	
	Manual	Automático
Taxa de acerto média	76,32%	76,23%
Variância do acerto	1,26%	2,02%
Tempo médio de execução	72,27 s	275,62 s
Variância do tempo	1,24 s	8,31 s

Fonte: Autoria própria (2023)


Analisando os dados da Tabela 2, pode-se observar que as taxas de acerto foram muito próximas, sendo a vantagem para o método manual. Como a variância para os dois casos também foi baixa, os dados são confiáveis e mostram repetibilidade. Com relação ao tempo médio de execução, o método manual apresentou o valor mais baixo, dando uma diferença de mais de 200 s, além da variância para o método automático ter sido consideravelmente maior, mostrando mais uma vantagem para o método manual. Por essa razão, constata-se que o método manual deve ser utilizado, pois este reduz o custo computacional, possui menor dispersão de dados e boa taxa de acerto na classificação.

5.3 Análise de Acordo com os Gestos


Depois de obtido o método do *Ensemble* que apresentou os melhores resultados, passou-se para a avaliação da classificação com relação aos gestos. Essa análise foi feita tanto para o *Ensemble* manual, quanto para o classificador SVM (pois foi o classificador que apresentou os melhores resultados de classificação para o grupo 13). Dessa forma, a Figura 17 apresenta a matriz de confusão obtida para o método de *Ensemble* manual e a Figura 18 apresenta a matriz de confusão obtida para o classificador SVM.

Analisando as Figuras 15 e 16, pode-se perceber que o comportamento para os dois casos foi muito semelhante. Em ambos os casos pode-se observar que os gestos 11 (pinça Allis), 12 (pinça anatômica) e 13 (pinça dente de rato) foram confundidos entre si. Isso se deve ao fato de que eles realmente possuem

configuração de mão bem semelhante, mudando basicamente o tipo de movimento executado com o indicador e o dedo polegar. Por sua vez, o gesto 9 (porta agulha) apresentou dificuldades de diferenciação com relação aos gestos 2 (fio em carretel), 3 (fio solto) e 8 (bisturi), principalmente. No caso dos gestos 2 e 3, a configuração de mão é semelhante à do gesto 9, mudando apenas a direção em que a mão aponta e o tipo de movimento. Já no caso do gesto 8, a configuração de mão é diferente, porém o movimento é semelhante.



Fonte: Autoria própria (2023)








Fonte: Autoria própria (2023)

Para uma análise mais completa dos gestos que apresentaram os resultados de classificação mais altos e baixos, o Quadro 14 apresenta os cinco gestos com os melhores resultados para o *Ensemble* e SVM, seguidos dos cinco gestos com os piores resultados apresentados no Quadro 15. Em ambos os casos (melhores e piores resultados), os gestos avaliados acabaram sendo os mesmos, conforme comportamento observado nas matrizes de confusão da Figura 17 e Figura 18.




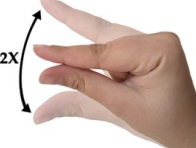

Avaliando o Quadro 14, pode-se perceber que o método do *Ensemble* apresentou resultados mais altos para os cinco gestos com maior taxa de acerto, alcançando valores superiores a 80% (o menor valor foi de 84,33 para o gesto do fio solto). Isso mostra que, embora sejam valores bem próximos, o sistema de tomada de decisão do *Ensemble* trouxe melhorias para a classificação dos melhores gestos.

Quadro 14 - Gestos que apresentaram os melhores resultados de classificação para o *Ensemble* e o SVM

Gesto	Imagem	Taxa de acerto	
		<i>Ensemble</i>	SVM
1 – Compressa		91,67%	87,33%
3 – Fio solto		84,33%	84,33%
5 – Pinça hemostática		87,00%	83,33%
6 – Pinça hemostática Kelly		86,00%	83,00%
10 – Válvula Doyen		86,33%	85,67%

Fonte: Autoria própria (2023)

Quadro 15 - Gestos que apresentaram os piores resultados de classificação para o *Ensemble* e o SVM

Gesto	Imagem	Taxa de Acerto	
		<i>Ensemble</i>	SVM
8 – Bisturi		72,67%	73,00%
9 – Porta agulha		64,00%	63,67%
11 – Pinça Allis		66,00%	69,00%
12 – Pinça anatômica		54,33%	58,00%
13 – Pinça dente de rato		61,33%	62,33%

Fonte: Autoria própria (2023)

Já no caso do Quadro 15, o SVM apresentou de forma geral resultados melhores para a classificação (com exceção apenas do gesto relacionado ao instrumento porta agulha) em comparação ao método *Ensemble*. Isso pode ser justificado pelo fato de que, como são mais confundidos com outros, os demais classificadores do *Ensemble* (RF e KNN) exerceram uma influência negativa no processo de tomada de decisão (por exemplo, para determinado gesto o SVM indicava o correto, porém o RF e KNN indicavam o mesmo errado, resultando numa decisão equivocada). Assim, a exclusão de gestos que possui configuração de mão

ou movimentos semelhantes pode aumentar o acerto do classificador utilizando o *Ensemble*.


5.4 Análise de Acordo com os Indivíduos

Utilizando o método do *Ensemble* manual, fez-se a análise do classificador de acordo com os indivíduos. Para avaliar as possíveis aplicações do sistema proposto, a análise foi feita de três maneiras diferentes, conforme detalhado no capítulo referente aos materiais e métodos adotados no presente trabalho.

5.4.1 Treinamento com dados de um indivíduo e teste com dados dos demais nove

A Figura 19 apresenta os resultados da etapa de teste do classificador *Ensemble*, cujo treinamento foi realizado utilizando os dados de um indivíduo e teste realizado utilizando os dados dos demais nove indivíduos. Cada barra do gráfico representa os resultados quando utilizados os dados de cada indivíduo para treinamento do classificador. Por exemplo, a primeira barra representa que foram utilizados os dados do indivíduo 1 para o treinamento, a segunda barra representa que foram utilizados os dados do indivíduo 2 para o treinamento e assim por diante.

Figura 19 - Resultados da etapa de teste do classificador *Ensemble* treinado com os dados de um indivíduo e testado com os demais nove




Fonte: Autoria própria (2023)

Através dos resultados observados pode-se destacar que as taxas de acerto foram baixas (inferiores a 20%), o que implica que essa forma de classificação não seria viável levando em conta um sistema comercial projetado para um determinado indivíduo e utilizado por outros. Os melhores resultados obtidos foram para os casos 1, 4, 5 e 10.

5.4.2 Treinamento com dados de nove indivíduos e teste com dados do indivíduo restante

Os resultados para a etapa de teste no caso em que o treinamento do classificador foi realizado utilizando os dados nove indivíduos e a etapa de teste utilizando os dados do indivíduo restante são apresentados na Figura 20. Cada barra do gráfico representa os resultados quando utilizados os dados de cada indivíduo para teste do classificador. Por exemplo, a primeira barra representa que foram utilizados os dados do indivíduo 1 para o teste, a segunda barra representa que foram utilizados os dados do indivíduo 2 para o teste e assim por diante.

Figura 20 - Resultados da etapa de teste do classificador *Ensemble* treinado com os dados de nove indivíduos e testado com os dados do indivíduo restante



Fonte: Autoria própria (2023)


Novamente, as taxas de acerto foram baixas (inferiores a 35%), porém foi observado um pequeno aumento em comparação à análise anterior. Isso implica que

um sistema comercial projetado para utilizar os dados de diversos indivíduos como base, porém aplicado a outro indivíduo também não seria viável. Mesmo assim, foi observado o mesmo comportamento com relação aos melhores resultados obtidos, os casos que se destacaram ainda foram os casos 1, 4, 5 e 10.

5.4.3 Treinamento e teste com cada indivíduo separadamente

Como uma última análise, avaliou-se o sistema de classificação utilizando os dados de um mesmo indivíduo para treinamento e teste, sendo 90% para treinamento e 10% para teste. Desta forma, a Figura 21 os resultados obtidos para cada um dos dez indivíduos.

Figura 21 - Resultados da etapa de teste do classificador Ensemble treinado 90% dos dados de um indivíduo e testado com 10% dos dados deste mesmo indivíduo




Fonte: Autoria própria (2023)

Com base nos resultados obtidos, pode-se observar que a análise dessa forma apresentou resultados significativamente maiores (sendo os melhores resultados com taxas superiores a 90% de acerto). Foi observado quase o mesmo comportamento com relação aos destaques positivos, sendo acrescido também o caso 8, junto com os demais (1, 4, 5 e 10). Pensando na viabilidade de um sistema comercial operante, a maneira ideal de utilizá-lo seria fazendo previamente uma calibração para cada indivíduo antes do uso, de fato, em ambiente cirúrgico. Isso se deve ao fato de que,

mesmo com as mesmas instruções para a execução dos gestos, cada indivíduo apresenta uma resposta diferente, seja na forma de execução do gesto, como também na forma de ativação muscular, o sinal de sEMG é bem característico para cada indivíduo.

Para ilustrar um pouco mais sobre essa diferença de sinais entre os indivíduos, a Figura 22 apresenta as matrizes de confusão para os dois indivíduos que apresentaram os melhores resultados (5 e 8, respectivamente). Analisando as figuras, pode-se verificar que o único gesto em comum entre esses dois indivíduos que se confundiu foi o gesto 11 (Pinça Allis).

Figura 22 - Matrizes de confusão para os indivíduos que apresentaram os melhores resultados: 1) indivíduo 5 e 2) indivíduo 8



Fonte: Autoria própria (2023)

Outra análise que foi feita é com relação aos gestos que apresentaram as melhores taxas de acerto levando em conta essa avaliação de acordo com os indivíduos. O Quadro 16 mostra quais foram os gestos com o maior número de indivíduos que obteve 100% de acerto para esses determinados gestos.

Avaliando o quadro apresentado, pode-se observar que os gestos com melhores resultados são bem distintos entre si, o que justifica esse resultado positivo de classificação. Esses mesmos gestos também se mostraram presentes na análise realizada para os resultados de acordo com os gestos, presentes no Quadro 14, o que corrobora os resultados apresentados anteriormente.

Quadro 16 - Gestos que apresentaram os melhores resultados de classificação para a análise de acordo com os indivíduos

Gesto	Imagem	Número de indivíduos que acertaram 100% do gesto apresentado
1 – Compressa		10 de 10
5 – Pinça hemostática		9 de 10
10 – Válvula Doyen		9 de 10

Fonte: Autoria própria (2023)

Cabe também comparar os resultados obtidos no presente trabalho com os resultados apresentados nos dois trabalhos que envolveram instrumentação cirúrgica e sEMG vistos no estado da arte.

Avaliando o trabalho apresentado por Bieck, Fuchs e Neumuth (2019), percebe-se que chegou-se a taxas de acerto semelhantes, avaliando os resultados individualmente (cerca de 95% para ambos os casos). Porém, avaliando os resultados com mais indivíduos, utilizando o *Ensemble* manual, chegou-se a resultados mais altos (76,32% para o presente trabalho e 71,2% no melhor caso do trabalho usado na comparação), utilizando dados de mais indivíduos (10 no presente trabalho e 5 no outro) e com mais gestos sendo analisados (14 no presente trabalho e 5 no outro).

Em comparação ao trabalho apresentado por Qi *et al.* (2021), os resultados obtidos no presente trabalho foram inferiores (76,32% para o presente trabalho, 88,47% para o melhor caso no estudo usado como comparação). Nos dois casos, usou-se os dados de 10 voluntários para fazer a aquisição. Porém, no estudo usado para comparação, utilizou-se apenas 10 gestos e estes são mais distintos entre si, pois representam os números de 1 a 10. Outro fator que pode ter interferido é que no presente trabalho utilizou-se apenas dados de sEMG, enquanto no outro estudo

utilizou-se fusão de sensores. Logo, uma possibilidade para melhorar os resultados da proposta aqui desenvolvida é realizar a fusão de sensores e escolher menos gestos, que sejam mais distintos entre si.

Após analisados todos os resultados, verifica-se que com base na taxa de acerto dos classificadores de forma geral para todos os grupos de características, o sistema proposto não seria viável, pois os valores foram muito baixos (inferiores a 50%, sendo o valor mais alto para a MLP com 49,14%). Porém, com base em outras análises os resultados foram melhorando. Por exemplo, avaliando os resultados para cada grupo de características, chegou-se a valores superiores a 70% para o grupo 13, com os classificadores KNN e SVM.

Avaliando os resultados dos dois tipos de *Ensemble* propostos, percebe-se que o método manual se mostrou mais eficaz, pois as taxas de acerto médias foram bem próximas (76,32% para o método manual e 76,23% para o automático), porém o tempo de execução foi muito inferior em comparação ao método automático (1,24 s para o método manual e 8,31 s para o método automático).

Com relação aos gestos escolhidos, os que apresentaram maior taxa de acerto foram os gestos referentes à solicitação da compressa, fio solto, pinça hemostática, pinça hemostática Kelly e válvula Doyen (taxas superiores a 84%, chegando até 91,67%). Já os gestos com piores taxas de acerto foram os do bisturi, porta agulha, pinça Allis, pinça anatômica e pinça dente de rato (variando de 54,33% a 75,67%). Isso se deve ao fato de que os gestos com melhores resultados são mais distintos entre si com relação à configuração de mão e os gestos com piores resultados são semelhantes na configuração de mão e movimento (os gestos de bisturi e porta agulha se confundiram bastante entre si, assim como os gestos da pinça Allis, anatômica e dente de rato).

Visando a construção de um sistema comercial, outro fator que se deve levar em conta é como evitar falsos positivos durante a movimentação do cirurgião, pois alguns gestos de sinalização cirúrgica são semelhantes aos gestos realizados durante o manuseio dos instrumentos. Por isso, sugere-se que seja escolhido um gesto diferente para servir como ponto de disparo do sistema de classificação (um sinal de ativação), para que então o sistema entenda que deve classificar o próximo gesto como sendo um gesto de sinalização cirúrgica.

6 CONCLUSÃO

Esta dissertação apresentou uma avaliação dos sinais de sEMG adquiridos durante a realização de gestos de sinalização cirúrgica, visando a criação de um sistema que auxilie em processos de telecirurgia e cirurgia robótica. Para tal, foi montada uma base de dados formada pela aquisição do sinal sEMG de 10 voluntários contendo a execução de 14 gestos de sinalização cirúrgica (30 aquisições por voluntário), realizada a segmentação destes dados, extração de características, separação destas em grupos e, por fim, a classificação dos gestos através de seis diferentes classificadores e diferentes combinações destes através do *Ensemble*.

O conjunto dos gestos foi escolhido por ser composto pelos gestos mais presentes na literatura e por serem executados com apenas um dos braços (devido à limitação de se ter apenas uma *armband* disponível para a aquisição), independentemente de serem gestos estáticos ou dinâmicos.

A definição do protocolo experimental para coleta dos sinais de sEMG levou em conta a execução dos gestos selecionados tendo a cadência dos movimentos guiada por um metrônomo, para auxiliar no processo de segmentação. Mesmo com algumas limitações, como o tempo de execução do gesto diferente para cada voluntário, foi possível realizar a aquisição e montagem da base de dados com sinais de 10 voluntários. Um fator que interferiu diretamente na aquisição dos dados foi a forma de instruir os voluntários na execução dos gestos, uma vez que não eram voluntários especializados na área da saúde.

A segmentação foi realizada com a detecção do *onset* e *offset* do sinal sEMG para identificação dos 14 gestos através de um determinado limiar (*threshold*). Visando maior robustez, desenvolveu-se um método que realiza a busca do limiar de forma automática, tendo como parâmetros a taxa de assertividade desejada, número de gestos executados na aquisição, número de aquisições por voluntário e duração esperada de cada gesto.

As características que foram extraídas para serem usadas nos classificadores foram divididas em 13 grupos. A escolha dos grupos foi realizada com base em estudos encontrados na literatura envolvendo a classificação de gestos provenientes de sinais de sEMG.

Para a classificação dos gestos, foram utilizados os classificadores LDA, QDA, KNN, RF, MLP e SVM. Esses seis classificadores foram escolhidos por serem

de tipos diferentes e demandarem de custos computacionais diferentes, justamente para avaliar se há uma grande diferença nos resultados apresentados para estes. Visando melhorar a taxa de acerto na classificação, utilizou-se também o método de combinação de classificadores (*Ensemble*) composto por três deles. A seleção dos três classificadores a serem utilizados foi feita de duas maneiras: selecionando os três classificadores com maior taxa de acerto geral de forma manual, e selecionando os três classificadores com maior taxa de acerto para cada *fold* de forma automática.

Analisando os resultados obtidos para cada voluntário, verificou-se que a criação de um sistema comercial projetado com um indivíduo para ser usado por outros não seria viável (as taxas de acerto foram inferiores a 18%), assim como um sistema projetado com vários indivíduos para ser usado por outro indivíduo (as taxas de acerto foram inferiores a 35%). Porém, pensando em um sistema em que é feita uma calibração individual de acordo com o usuário que vai usar antes do momento da cirurgia, ele se torna mais viável (os indivíduos com melhores resultados apresentaram taxas superiores a 90%). Os melhores gestos avaliados de acordo com os indivíduos foram o da compressa (100% de acerto para os 10 indivíduos), pinça hemostática (100% de acerto para 9 dos 10 indivíduos) e válvula Doyen (100% de acerto para 9 dos 10 indivíduos).

Por fim, baseando-se nos resultados obtidos, tem-se como proposta para trabalhos futuros:

- Trabalhar em uma nova base de dados composta pelos gestos que apresentaram os melhores resultados, adicionando outros gestos que sejam mais distintos entre si e aumentando o número de aquisições por voluntário;
- Avaliar a influência do posicionamento da *armband* durante a aquisição para os resultados de classificação;
- Alterar o protocolo de aquisição dos dados, em que ao invés de executar todos os gestos em sequência numa aquisição, executar o mesmo gesto diversas vezes por aquisição e, em cada aquisição, um gesto diferente;
- Utilizar fusão de sensores na aquisição da nova base de dados, utilizando por exemplo um sensor inercial, para auxiliar no processo de segmentação e classificação;

- Testar outros tipos de classificadores e grupos de características, para se encontrar um sistema mais robusto e com maior taxa de acerto na classificação dos gestos;
- Preparar um sistema para classificação *online* e testar a viabilidade deste sistema para operação em tempo real e em sala de cirurgia, acrescentando neste sistema a identificação de um gesto inicial como um comando de disparo para o sistema de classificação dos gestos de instrumentação cirúrgica ser ativado.

REFERÊNCIAS

- 4MD MEDICAL. **AngioTech Surgical LOOK Silk Spools Sutures**. Disponível em: <<https://www.4mdmedical.com/look-silk-spools-sutures.html>>. Acesso em: 3 set. 2022.
- ALENCAR, J. **Instrumentação cirúrgica**. Disponível em: <<https://prezi.com/wvicdas0ozns/httpqueroinstrumentarfmrpuspbrimagensmesa-cirurgica/>>. Acesso em: 20 jun. 2022.
- AL-QURAIISHI, M. S. *et al.* **Multichannel EMG data acquisition system: Design and temporal analysis during human ankle joint movements**. IEEE, dez. 2014. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7047516>>. Acesso em: 17 ago. 2020
- ANGELINI, L.; PAPASPYROPOULOS, V. Telesurgery. **Ultrasound in Medicine & Biology**, v. 26, p. S45–S47, maio 2000.
- ARJUNAN, S. *et al.* Effect of age and gender on the surface electromyogram during various levels of isometric contraction. *In*: 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. **Anais** [...]. Boston, MA: IEEE, ago. 2011. Disponível em: <<http://ieeexplore.ieee.org/document/6090957/>>. Acesso em: 18 ago. 2020
- BALAKRISHNAMA, S.; GANAPATHIRAJU, A. **Linear discriminant analysis** —a brief tutorial. Mississippi State University, 1998.
- BHATTACHARYA, A.; SARKAR, A.; BASAK, P. **Time domain multi-feature extraction and classification of human hand movements using surface EMG**. IEEE, jan. 2017. Disponível em: <<http://ieeexplore.ieee.org/document/8014594/>>. Acesso em: 8 jul. 2022
- BIECK, R.; FUCHS, R.; NEUMUTH, T. Surface EMG-based surgical instrument classification for dynamic activity recognition in surgical workflows. **Current Directions in Biomedical Engineering**, v. 5, n. 1, p. 37–40, 1 set. 2019.
- BIOPAC SYSTEMS. **EMG frequency signal analysis**. Disponível em: <<https://www.biopac.com/wp-content/uploads/app118.pdf>>. Acesso em: 25 out. 2018.
- BOOSTANI, R.; MORADI, M. H. Evaluation of the forearm EMG signal features for the control of a prosthetic hand. **Physiological Measurement**, v. 24, n. 2, p. 309–319, 1 maio 2003.
- BOTROS, F. S.; PHINYOMARK, A.; SCHEME, E. J. Electromyography-based gesture recognition: is it time to change focus from the forearm to the wrist? **IEEE Transactions on Industrial Informatics**, v. 18, n. 1, p. 174–184, jan. 2022.

BRADLEY, S. **Human computer interfaces for telesurgery**. IEE, 1995. Disponível em: <https://digital-library.theiet.org/content/conferences/10.1049/ic_19950856>. Acesso em: 8 fev. 2022

BRAMER, M. **Principles of data mining**. 2nd ed ed. New York: Springer, 2013.

BRUCE, P. C.; BRUCE, A.; GEDECK, P. **Practical statistics for data scientists: 50+ essential concepts using R and Python**. Second edition ed. Sebastopol, CA: O'Reilly Media, Inc, 2020.

CARVALHO, A. H. *et al.* **Instrumentação Cirúrgica**. Belém, Pará: Universidade Estadual do Pará, 2019. Acesso em: 30 jul. 2021.

CENTERMEDICAL. **Pinça Backhaus 15cm**. Disponível em: <<https://www.centermedical.com.br/pinca-backhaus-stark-16cm/p>>. Acesso em: 3 set. 2022a.

CENTERMEDICAL. **Pinça mixer baby (hemostática) 16cm**. Disponível em: <<https://www.centermedical.com.br/pinca-mixer-baby-hemostatica-stark-16cm/p>>. Acesso em: 3 set. 2022b.

CENTERMEDICAL. **Pinça Kelly curva 18cm**. Disponível em: <<https://www.centermedical.com.br/pinca-kelly-curva-stark-18cm/p>>. Acesso em: 3 set. 2022c.

CENTERMEDICAL. **Afastador Farabeuf 15x150mm extra**. Disponível em: <<https://www.centermedical.com.br/afastador-farabeuf-extra-stark-15-150mm/p>>. Acesso em: 3 set. 2022d.

CENTERMEDICAL. **Porta agulha Mayo Hegar 30cm**. Disponível em: <<https://www.centermedical.com.br/porta-agulha-mayo-hegar-stark-30cm/p>>. Acesso em: 3 set. 2022e.

CENTERMEDICAL. **Pinça Allis 5x6 dentes 25cm**. Disponível em: <<https://www.centermedical.com.br/pinca-allis-5-6-dentes-stark-25cm/p>>. Acesso em: 3 set. 2022f.

CENTERMEDICAL. **Pinça anatômica dissecação 25cm**. Disponível em: <<https://www.centermedical.com.br/pinca-anatomica-disseccao-stark-25cm/p>>. Acesso em: 3 set. 2022g.

CENTERMEDICAL. **Pinça anatômica 1x2 dentes (dente de rato) 12cm**. Disponível em: <<https://www.centermedical.com.br/pinca-anatomica-1-2-dentes-dente-de-rato-stark-12cm/p>>. Acesso em: 3 set. 2022h.

CENTERMEDICAL. **Tesoura cirúrgica F/F reta 20cm**. Disponível em: <<https://www.centermedical.com.br/tesoura-cirurgica-ff-reta-stark-20cm/p>>. Acesso em: 3 set. 2022i.

CHAN, A. D. C.; ENGLEHART, K. B. **Continuous classification of myoelectric signals for powered prostheses using gaussian mixture models**. IEEE, 2003.

Disponível em: <<http://ieeexplore.ieee.org/document/1280510/>>. Acesso em: 21 fev. 2022

CHANG, C.-C.; LIN, C.-J. LIBSVM: a library for support vector machines. 2011.

CHANG, F.; CHEN, H.-C.; LIU, H.-C. **Double k-folds in SVM**. IEEE, jul. 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7284980/>>. Acesso em: 7 mar. 2022

CHAPMAN, S. J. **Programação em MATLAB para engenheiros**. [s.l: s.n.].

CHOI, P. J.; OSKOUIAN, R. J.; TUBBS, R. S. Telesurgery: past, present, and future. **Cureus**, 31 maio 2018.

CLANCY, E. .; MORIN, E. .; MERLETTI, R. Sampling, noise-reduction and amplitude estimation issues in surface electromyography. **Journal of Electromyography and Kinesiology**, v. 12, n. 1, p. 1–16, fev. 2002.

CORTI, N. **Myo EMG Visualizer**. Disponível em: <<https://myo-emg-visualizer-nicola-corti.br.aptoide.com/app>>. Acesso em: 8 out. 2022.

COSTA NETO, J. M. *et al.* **Instrumental e instrumentação cirúrgica**. Salvador, Bahia: Universidade Federal da Bahia, 2011. Disponível em: <<http://www.cirurgia.vet.ufba.br/arquivos/docs/aulas/instrumental24082011.pdf>>. Acesso em: 29 jul. 2021.

CRISWELL, E.; CRAM, J. R. (EDS.). **Cram's introduction to surface electromyography**. 2nd ed ed. Sudbury, MA: Jones and Bartlett, 2011.

DALLEY, S. A.; VAROL, H. A.; GOLDFARB, M. A Method for the Control of Multigrasp Myoelectric Prosthetic Hands. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 20, n. 1, p. 58–67, jan. 2012.

DE LUCA, C. Electromyography. In: WEBSTER, J. G. (Ed.). **Encyclopedia of Medical Devices and Instrumentation**. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2006.

DE LUCA, C. J. **Surface Electromyography: Detection and Recording**. Disponível em: <<https://www.delsys.com/downloads/TUTORIAL/semg-detection-and-recording.pdf>>.

DONG, W. *et al.* Soft wrist-worn multi-functional sensor array for real-time hand gesture recognition. **IEEE Sensors Journal**, p. 1–1, 2021.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. 2nd ed ed. New York: Wiley, 2001.

ESFAHANI, E. N. *et al.* Hand gesture recognition for contactless device control in operating rooms. **International Journal of Computer Assisted Radiology and Surgery**, v. 12, n. S1, p. 1–286, jun. 2017.

FARFÁN, F. D.; POLITTI, J. C.; FELICE, C. J. Evaluation of EMG processing techniques using Information Theory. **BioMedical Engineering OnLine**, v. 9, n. 1, p. 72, 2010.

FREITAS, M. L. B. *et al.* Algoritmo de Segmentação com Base em análise automática de Limiar para Sinais de Eletromiografia de Superfície. *In: IX Congresso Latino-Americano de Engenharia Biomédica e XXVIII Congresso Brasileiro de Engenharia de Engenharia Biomédica. Anais [...].* Florianópolis, Santa Catarina: no prelo.

FREITAS, M. L. B. **Análise de características do sinal EMG para auxílio em processos de classificação de padrões.** Trabalho de Conclusão de Curso—Ponta Grossa, Paraná: Universidade Tecnológica Federal do Paraná, 2018.

FRIDLUND, A. J.; CACIOPPO, J. T. Guidelines for human electromyographic research. **Psychophysiology**, v. 23, n. 5, p. 567–589, set. 1986.

FUKUNAGA, K. **Introduction to statistical pattern recognition.** Boston: Academic Press, 1990.

GÓES JR., A. *et al.* **Instrumentação cirúrgica.** Belém, Pará, [s.d.]. . Acesso em: 29 jul. 2021

GUPTA, R.; KUMAR, A. Indian sign language recognition using wearable sensors and multi-label classification. **Computers & Electrical Engineering**, v. 90, p. 106898, mar. 2021.

HAKONEN, M.; PIITULAINEN, H.; VISALA, A. Current state of digital signal processing in myoelectric interfaces and related applications. **Biomedical Signal Processing and Control**, v. 18, p. 334–359, abr. 2015.

HALAKI, M.; GI, K. Normalization of EMG signals: to normalize or not to normalize and what to normalize to? *In: NAIK, G. R. (Ed.). Computational Intelligence in Electromyography Analysis - A Perspective on Current Applications and Future Challenges.* [s.l.] InTech, 2012.

HAN, J.; KAMBER, M. **Data mining: concepts and techniques.** 3rd ed ed. Burlington, MA: Elsevier, 2012.

HAND, D. J.; MANNILA, H.; SMYTH, P. **Principles of data mining.** Cambridge, Mass: MIT Press, 2001.

HAYKIN, S. S. **Neural networks: a comprehensive foundation.** 2nd ed ed. Upper Saddle River, N.J: Prentice Hall, 1999.

HUANG, Y. *et al.* A gaussian mixture model based classification scheme for myoelectric control of powered upper limb prostheses. **IEEE Transactions on Biomedical Engineering**, v. 52, n. 11, p. 1801–1811, nov. 2005.

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

JACOB, M. *et al.* Gestonurse: a robotic surgical nurse for handling surgical instruments in the operating room. **Journal of Robotic Surgery**, v. 6, n. 1, p. 53–63, mar. 2012.

JACOB, M. G.; LI, Y.-T.; WACHS, J. P. **A gesture driven robotic scrub nurse**. IEEE, out. 2011. Disponível em: <<http://ieeexplore.ieee.org/document/6083972/>>. Acesso em: 8 fev. 2022

JACOB, M. G.; LI, Y.-T.; WACHS, J. P. **Gestonurse: a multimodal robotic scrub nurse**. ACM Press, 2012. Disponível em: <<http://dl.acm.org/citation.cfm?doid=2157689.2157731>>. Acesso em: 8 fev. 2022

JACOB, M. G.; LI, Y.-T.; WACHS, J. P. **Surgical instrument handling and retrieval in the operating room with a multimodal robotic assistant**. IEEE, maio 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6630864/>>. Acesso em: 8 fev. 2022

JAMAL, M. Z. Signal acquisition using surface EMG and circuit design considerations for robotic prosthesis. In: NAIK, G. R. (Ed.). **Computational Intelligence in Electromyography Analysis - A Perspective on Current Applications and Future Challenges**. [s.l.] InTech, 2012.

JAMES, G. *et al.* (EDS.). **An introduction to statistical learning: with applications in R**. New York: Springer, 2013.

JUBANY, J.; ANGULO-BARROSO, R. An algorithm for detecting EMG onset/offset in trunk muscles during a reaction- stabilization test. **Journal of Back and Musculoskeletal Rehabilitation**, v. 29, n. 2, p. 219–230, 27 abr. 2016.

KAMEN, G.; GABRIEL, D. A. **Essentials of electromyography**. Champaign, IL: Human Kinetics, 2010.

KHOMAMI, S. A.; SHAMEKHI, S. Persian sign language recognition using IMU and surface EMG sensors. **Measurement**, v. 168, p. 108471, jan. 2021.

KIM, K. S. *et al.* Comparison of k-nearest neighbor, quadratic discriminant and linear discriminant analysis in classification of electromyogram signals based on the wrist-motion directions. **Current Applied Physics**, v. 11, n. 3, p. 740–745, maio 2011.

KOCAK, A. T.; YILMAZ, A. **Segmentation and classification of contractions in uterine 16 channels EMG signals for preterm birth prediction**. IEEE, maio 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8404821/>>. Acesso em: 15 fev. 2022

KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: Proceedings of the 14th International Joint Conference on Artificial Intelligence. **Anais [...]**. Canada: 1995.

LA BANCA, M. M. R. *et al.* Captura e Processamento de Sinais Biomédicos Utilizando o LabVIEW. **Brazilian Journal of Instrumentation and Control**, v. 4, n. 2, p. 1, 19 dez. 2016.

LE, H. T.; PHAM, H. T. T. Hand signal recognition for handling surgical instruments. In: VO VAN, T.; NGUYEN LE, T. A.; NGUYEN DUC, T. (Eds.). **6th International Conference on the Development of Biomedical Engineering in Vietnam (BME6)**. Singapore: Springer Singapore, 2018. v. 63p. 587–592.

LI, Z. *et al.* **Intelligent classification of multi-gesture EMG signals based on LSTM**. IEEE, jun. 2020. Disponível em:
<<https://ieeexplore.ieee.org/document/9221418/>>. Acesso em: 11 mar. 2022

LIN, P.-J.; CHEN, H. Y. Design and implement of a rehabilitation system with surface electromyography technology. In: 2018 IEEE International Conference on Applied System Invention (ICASI). **Anais [...]** Chiba: IEEE, abr. 2018. Disponível em:
<<https://ieeexplore.ieee.org/document/8394300/>>. Acesso em: 19 ago. 2020

LIU, B.-S. *et al.* **Ergonomic evaluation of new wrist rest on using computer mouse**. IEEE, nov. 2016. Disponível em:
<<http://ieeexplore.ieee.org/document/7840230/>>. Acesso em: 11 fev. 2022

LIU, J. Feature dimensionality reduction for myoelectric pattern recognition: A comparison study of feature selection and feature projection methods. **Medical Engineering & Physics**, v. 36, n. 12, p. 1716–1720, dez. 2014.

LIU, Y.-H.; HUANG, H.-P.; WENG, C.-H. Recognition of electromyographic signals using cascaded kernel learning machine. **IEEE/ASME Transactions on Mechatronics**, v. 12, n. 3, p. 253–264, jun. 2007.

LUONGO, F. *et al.* Deep learning-based computer vision to recognize and classify suturing gestures in robot-assisted surgery. **Surgery**, v. 169, n. 5, p. 1240–1244, maio 2021.

MARIN, G.; DOMINIO, F.; ZANUTTIGH, P. **Hand gesture recognition with leap motion and kinect devices**. IEEE, out. 2014. Disponível em:
<<http://ieeexplore.ieee.org/document/7025313/>>. Acesso em: 24 fev. 2022

MENDES, J. J. A. *et al.* Circuit Design for Surface Electromyography Data Acquisition. **IEEE Latin America Transactions**, v. 13, n. 10, p. 3193–3200, out. 2015.

MENDES JUNIOR, J. J. A. *et al.* Desenvolvimento de armband com fusão de sEMG e giroscópio para identificação de grupos musculares do braço. In: XXV Congresso Brasileiro de Engenharia Biomédica. **Anais [...]** In: XXV CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA. Foz do Iguaçu, Paraná, Brasil: 2016.

MENDES JUNIOR, J. J. A. **Estudo da influência das etapas de segmentação, extração de características e classificação do alfabeto em Linguagem Brasileira de Sinais a partir de sinais eletromiográficos de superfície**. Doutorado em Engenharia Elétrica—Curitiba, Paraná: Universidade Tecnológica Federal do Paraná, 2020.

MENDES JUNIOR, J. J. A. *et al.* Feature selection and dimensionality reduction: an extensive comparison in hand gesture classification by sEMG in eight channels

armband approach. **Biomedical Signal Processing and Control**, v. 59, p. 101920, maio 2020a.

MENDES JUNIOR, J. J. A. *et al.* Analysis of influence of segmentation, features, and classification in sEMG processing: a case study of recognition of brazilian sign language alphabet. **Sensors**, v. 20, n. 16, p. 4359, 5 ago. 2020b.

MERCADO LIVRE. **Kit bisturi profissional artesanato calos 10 peças**. Disponível em: <https://produto.mercadolivre.com.br/MLB-1108083036-kit-bisturi-profissional-artesanato-calos-10-pecas-_JM>. Acesso em: 3 set. 2022.

MERLETTI, R.; PARKER, P. (EDS.). **Electromyography: physiology, engineering, and noninvasive applications**. Hoboken, NJ: IEEE/John Wiley & Sons, 2004.

MEYER, P. L. **Introductory probability and statistical applications**. 2. ed ed. Reading, Mass.: Addison-Wesley, 1970.

MOHAMAD, A. S.; NOOR, H. M. **Development of smart ECG machine using LabVIEW for biomedical engineering students**. IEEE, ago. 2014. Disponível em: <<http://ieeexplore.ieee.org/document/7006270/>>. Acesso em: 17 ago. 2020

MORETTIN, P. A.; BUSSAB, W. O. **Estatística básica**. 9ª edição ed. [s.l.] Saraiva Uni, 2017.

MORIYA, T.; VICENTE, Y. A. M. V. DE A.; TAZIMA, M. DE F. G. S. Instrumental cirúrgico. **Medicina (Ribeirão Preto)**, v. 44, n. 1, p. 18–32, 30 mar. 2011.

MURILLO, P. C. U.; ARENAS, J. O. P.; MORENO, R. J. Tree-structured CNN for the classification of surgical instruments. In: BRITO-LOEZA, C.; ESPINOSA-ROMERO, A. (Eds.). **Intelligent Computing Systems**. Cham: Springer International Publishing, 2018. v. 820p. 15–30.

NAJARIAN, K.; SPLINTER, R. **Biomedical signal and image processing**. [s.l.: s.n.].

NAZMI, N. *et al.* A Review of Classification Techniques of EMG Signals during Isotonic and Isometric Contractions. **Sensors**, v. 16, n. 8, p. 1304, 17 ago. 2016.

NEMITZ, R. **Surgical instrumentation: an interactive approach**. Third edition ed. St. Louis, Missouri: Elsevier, 2019.

NIU, S. *et al.* **Ergonomic evaluation between laparoscopic and robotic surgery based on EMG**. IEEE, 13 out. 2020. Disponível em: <<https://ieeexplore.ieee.org/document/9233756/>>. Acesso em: 11 fev. 2022

NOBLE, W. S. What is a support vector machine? **Nature Biotechnology**, v. 24, n. 12, p. 1565–1567, dez. 2006.

OLIVEIRA, K. A. **Impacto do trabalho na força e fadiga muscoesquelética de pedreiros: uma análise eletromiográfica**. Mestrado em Engenharia de Produção—Ponta Grossa, Paraná: Universidade Tecnológica Federal do Paraná, 2019.

OSKOEI, M. A.; HU, H. Myoelectric control systems—A survey. **Biomedical Signal Processing and Control**, v. 2, n. 4, p. 275–294, out. 2007.

OSKOEI, M. A.; HU, H. Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb. **IEEE Transactions on Biomedical Engineering**, v. 55, n. 8, p. 1956–1965, ago. 2008.

OYMOTION. **gForcePro + EMG Armband**. Fabricante. Disponível em: <<http://www.oymotion.com/en/product32/149>>. Acesso em: 1 out. 2022.

PEREIRA-MONTIEL, E. *et al.* Automatic sign language recognition based on accelerometry and surface electromyography signals: A study for Colombian sign language. **Biomedical Signal Processing and Control**, v. 71, p. 103201, jan. 2022.

PEREZ-VIDAL, C. *et al.* Steps in the development of a robotic scrub nurse. **Robotics and Autonomous Systems**, v. 60, n. 6, p. 901–911, jun. 2012.

PEZZELLA, A. T. Hand signals in surgery. **AORN Journal**, v. 63, n. 4, p. 769–771, abr. 1996.

PHILLIPS, N. F. **Surgical instrumentation**. 2nd ed ed. Clifton Park, N.Y.: Andover: Delmar; Cengage Learning [distribuidor], 2019.

PHINYOMARK, A. *et al.* EMG feature evaluation for improving myoelectric pattern recognition robustness. **Expert Systems with Applications**, v. 40, n. 12, p. 4832–4840, set. 2013.

PHINYOMARK, A.; N. KHUSHABA, R.; SCHEME, E. Feature Extraction and Selection for Myoelectric Control Based on Wearable EMG Sensors. **Sensors**, v. 18, n. 5, p. 1615, 18 maio 2018.

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

PINHEIRO, M. T. R. **Enfermagem em bloco cirúrgico**. Ceará: Escola Técnica de Maracanaú, 2018. Acesso em: 30 jul. 2021.

POLARFIX. **Compressa cirúrgica non Woven estéril Polar Fix**. Disponível em: <<https://polarfix.com.br/produto/compressa-cirurgica-non-woven-esteril-com-raio-x/>>. Acesso em: 3 set. 2022.

PRONTO VETERINÁRIO. **Fio nylon 3-0 com agulha cortante 3/8 2,0cm Fio 45cm**. Disponível em: <<https://www.prontoveterinario.com.br/fio-nylon-4-0-com-agulha-12.html>>. Acesso em: 20 jun. 2022.

QI, W. *et al.* Adaptive sensor fusion labeling framework for hand pose recognition in robot teleoperation. **Assembly Automation**, v. 41, n. 3, p. 393–400, 22 jul. 2021.

RAURALE, S. A.; MCALLISTER, J.; RINCON, J. M. D. EMG biometric systems based on different wrist-hand movements. **IEEE Access**, v. 9, p. 12256–12266, 2021.

- RHOSS. **Válvula Doyen**. Disponível em: <<https://www.produtosmedicos.com.br/valvula-doyen>>. Acesso em: 3 set. 2022.
- RICHMAN, J. S.; MOORMAN, J. R. Physiological time-series analysis using approximate entropy and sample entropy. **American Journal of Physiology-Heart and Circulatory Physiology**, v. 278, n. 6, p. H2039–H2049, 1 jun. 2000.
- ROKACH, L.; MAIMON, O. **Data mining with decision trees: theory and applications**. Second edition ed. Hackensack, New Jersey: World Scientific, 2015.
- SANEI, S.; HOSSEINI-YAZDI, A. **Extraction of ECG from single channel EMG signal using constrained singular spectrum analysis**. IEEE, jul. 2011. Disponível em: <<http://ieeexplore.ieee.org/document/6004876/>>. Acesso em: 15 fev. 2022
- SCHORSCH, J. F. *et al.* Multifunction Prosthesis Control Using Implanted Myoelectric Sensors (IMES). In: 2008 MyoElectric Controls/Powered Prosthetics Symposium. **Anais [...]**. Fredericton, New Brunswick, Canada: 2008. Disponível em: <<https://dukespace.lib.duke.edu/dspace/bitstream/handle/10161/2811/Schorsch%202008.pdf?sequence=3>>. Acesso em: 30 set. 2016
- SERNANI, P. *et al.* **Italian sign language alphabet recognition from surface EMG and IMU sensors with a deep neural network**. In: RECENT TRENDS AND APPLICATIONS IN COMPUTER SCIENCE AND INFORMATION TECHNOLOGY. jul. 2021. Disponível em: <<http://ceur-ws.org/Vol-2872/paper11.pdf>>. Acesso em: 3 out. 2022
- SHARMA, S.; DUBEY, A. K. **Movement control of robot in real time using EMG signal**. IEEE, dez. 2012. Disponível em: <<http://ieeexplore.ieee.org/document/6508060/>>. Acesso em: 17 ago. 2020
- SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**. Curso prático. São Paulo: Artliber, 2010.
- SINGH, Y. **Analysis and classification of EMG signal using LabVIEW with different weights**. Master of Engineering—Thapar, Punjab, India: Thapar University, 2013.
- SOUZA, E. B.; HOFFMAN, I.; COUTINHO, L. S. **Manual básico de metodização cirúrgica**. Palmas, Tocantins: Universidade Federal do Tocantins, 2014.
- TAMURA, H. *et al.* EOG-sEMG Human Interface for Communication. **Computational Intelligence and Neuroscience**, v. 2016, p. 1–10, 2016.
- TAN, P.-N.; STEINBACH, M.; KUMAR, V. **Introdução ao datamining: mineração de dados**. Rio de Janeiro (RJ): Ciencia Moderna, 2009.
- THALMIC LABS. **Myo: Technical specifications**. Disponível em: <<https://www.myo.com/techspecs>>. Acesso em: 8 out. 2018.
- THEODORIDIS, S. *et al.* (EDS.). **Introduction to pattern recognition: a MATLAB approach**. Burlington, MA: Academic Press, 2010.

TKACH, D.; HUANG, H.; KUIKEN, T. A. Study of stability of time-domain features for electromyographic pattern recognition. **Journal of NeuroEngineering and Rehabilitation**, v. 7, n. 1, p. 21, 2010.

TURCHIELLO, G. M.; MARINO-NETO, J.; MARQUES, J. L. B. Plataforma computacional para processamento de sinais biomédicos. *In*: XXIV Congresso Brasileiro de Engenharia Biomédica. **Anais [...]**. Uberlândia, Minas Gerais: 2014. Disponível em: <https://www.canal6.com.br/cbeb/2014/artigos/cbeb2014_submission_316.pdf>. Acesso em: 18 jul. 2016

UFRGS, C. V. **Tempos cirúrgicos**. Disponível em: <https://sites.google.com/site/cirurgiavetufrgs/_/rsrc/1373315320384/material-para-estudo/tempos-cirurgicos/>. Acesso em: 15 jun. 2022.

VISCONTI, P. *et al.* Technical features and functionalities of Myo armband: an overview on related literature and advanced applications of myoelectric armbands mainly focused on arm prostheses. **International Journal on Smart Sensing and Intelligent Systems**, v. 11, n. 1, p. 1–25, 2018.

WEN-JUH KANG *et al.* The application of cepstral coefficients and maximum likelihood method in EMG pattern recognition [movements classification]. **IEEE Transactions on Biomedical Engineering**, v. 42, n. 8, p. 777–785, ago. 1995.

WIJANARKO, E. D.; SETIJADI, A.; MENGKO, T. L. R. **Application of surface EMG signal on forearms for finger classification**. IEEE, nov. 2014. Disponível em: <<http://ieeexplore.ieee.org/document/7111775/>>. Acesso em: 8 jul. 2022

WILLISON, R. G. A method of measuring motor unit activity in human muscle. p. 35–36, 1963.

WU, C.-H. *et al.* **An ECG extraction and reconstruction system with dynamic EMG filtering implemented on an ARM chip**. IEEE, abr. 2019. Disponível em: <<https://ieeexplore.ieee.org/document/9074076/>>. Acesso em: 8 jul. 2022

ZARDOSHTI-KERMANI, M. *et al.* EMG feature evaluation for movement control of upper extremity prostheses. **IEEE Transactions on Rehabilitation Engineering**, v. 3, n. 4, p. 324–333, dez. 1995.

ZECCA, M. *et al.* Control of multifunctional prosthetic hands by processing the electromyographic signal. **Critical Reviews in Biomedical Engineering**, v. 30, n. 4–6, p. 459–485, 2002.

ZHOU, T.; WACHS, J. P. Needle in a haystack: Interactive surgical instrument recognition through perception and manipulation. **Robotics and Autonomous Systems**, v. 97, p. 182–192, nov. 2017.

APÊNDICE A - Termo de Consentimento Livre e Esclarecido

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO (TCLE)

Título da pesquisa: Aquisição e análise de dados de sinais bioelétricos e de sinais de movimento através de sensores não invasivos, para aplicações de reconhecimento de padrões.

Pesquisador: Prof. Dr. Sergio Luiz Stevan Jr., UTFPR – Campus Ponta Grossa – Centro de Instrumentação nas Engenharias Biomédica e Esportiva (CIEBE). Telefones: (42) 998040168

Pesquisador Responsável: Prof. Dr. Sergio Luiz Stevan Jr.

Local de realização da pesquisa: Centro de Instrumentação nas Engenharias Biomédica e Esportiva (CIEBE), UTFPR – Ponta Grossa – PR

A) INFORMAÇÕES AO PARTICIPANTE

1. Apresentação da pesquisa.

Você está sendo convidado a participar de uma pesquisa que avaliará padrões envolvendo reconhecimento de movimentos dos membros superiores e inferiores, ou de expressões faciais (movimento ocular) utilizando aparelhos de eletromiografia e sensores dinâmicos (inerciais). Estes equipamentos, que não são invasivos nem causam dor, fazem o registro de sinais de movimentação dos membros por meio de sensores alocados na superfície da pele. Os eletrodos de eletromiografia e os sensores dinâmicos são posicionados nas regiões de interesse da leitura do movimento para coletar dados da resposta muscular durante a realização dos mesmos. A partir destes dados, serão investigados padrões de movimentação (gestos, passos, entre outros). Esse estudo deve contribuir para a investigação de detecção de gestos para tecnologias assistivas, análise de fadiga muscular, de análise postural e de marcha.

2. Objetivos da pesquisa.

Desenvolver dispositivos de aquisição de sinais bioelétricos (como EMG e EOG), de sinais movimentos provindos de sensores inerciais (IMU) e de pressão para a formação de bases de dados que sustentem o estudo das técnicas de reconhecimento de padrões em movimentos e/ou gestos.

3. Participação na pesquisa.

Sua participação na pesquisa será uma única vez e durará em torno de 30 minutos. Caso o convidado seja do sexo masculino, pode ser necessário solicitar que neste dia retire os pelos das regiões em que serão alocados os eletrodos. Você ficará em uma sala em temperatura ambiente enquanto serão realizadas as aquisições. Serão posicionados os sensores e será pedido para que se realize uma série de movimentos, como por exemplo gestos com as

mãos, movimentar os olhos e andar uma quantidade de passos. Após a coleta, o equipamento será retirado.

4. Confidencialidade.

A sua privacidade será respeitada, ou seja, o seu nome ou qualquer outro dado, informação ou elemento que possa de qualquer forma lhe identificar, será mantido em sigilo. Os pesquisadores se responsabilizam pela guarda e confidencialidade das informações.

5. Riscos e Benefícios.

5a) Riscos: Os dispositivos desenvolvidos, por si só, não apresentam riscos para os indivíduos em que serão usados. Isso porque serão observadas as normas de segurança e operação de equipamentos biomédicos (como a norma ANSI/AAMI ES1-1993, que trata sobre os limites de segurança da corrente elétrica em equipamentos eletro-médicos), além de que os sistemas de aquisição são não-invasivos. Ressalta-se que os circuitos a serem implementados possuem isolação da rede elétrica de alimentação, serão alimentados por baterias e os circuitos integrados para a aquisição drenarão uma corrente na ordem dos nA dos eletrodos, inferior aos limiares de percepção. Os valores discriminados para a corrente de risco do circuito com conexões por baterias, tanto para circuitos isolados quando não isolados, foram 100 μ A para condições normais e 300 μ A para situações de falta; além de 300 μ A para o mesmo caso quando há corrente de falta. Por outro lado, para falhas com correntes de descarga para o terra, os limites são de 500 μ A a 2500 μ A, podendo chegar a 5000 μ A se o contato for permanente. Segundo a norma, não há impedimento quanto ao uso do circuito de captação de sinais eletroencefalográficos, desde que esses esteja montado e operando perfeitamente (AAMI, 1993; WEBSTER, 2010).

Em relação à fixação dos eletrodos, não configura risco à pele, ou por serem comerciais e possuírem adesivo hipoalergênico, ou secos sem cola. A limpeza do local de fixação dos eletrodos com álcool 70%, amplamente utilizado na pele durante a pandemia, também não configura risco.

Outros riscos que podem acontecer são de origem cotidiana, exemplo, o indivíduo tropeçar, colidir com objetos no laboratório. Entretanto, o ambiente será preparado para o experimento, onde todos os cuidados serão tomados, em especial os cuidados relacionados à pandemia de Sars-Cov-2, conforme mencionado anteriormente, atendendo a todos os pontos referentes à Instrução Normativa 17/2020 da UTFPR. Todos os experimentadores serão orientados para evitar qualquer tipo de risco. Em caso de acidente, o Serviço de Atendimento Móvel de Urgência (Samu) será solicitado.

No momento da montagem dos sensores e do levantamento de informações do participante pode existir risco por constrangimento. Para evitar esse tipo de risco, o participante não precisará responder alguma pergunta caso não ache conveniente. Além disso, poderá optar ser auxiliado por um experimentador do sexo masculino ou feminino. Se o participante não se sentir à vontade poderá suspender o teste em qualquer momento.

No decorrer do experimento será observado continuamente a sua ergonomia e o seu conforto. Entretanto, os testes ocorrerão em áreas controladas (no caso, laboratório), os quais tenderão a diminuição destes problemas.

5b) Benefícios: Dentre os benefícios para os participantes desta pesquisa, o primeiro de destaque é a possibilidade dos voluntários do teste terem acesso aos seus dados individuais dos parâmetros coletados. O voluntário terá benefícios culturais ao conhecer um laboratório de pesquisa e ao conhecer ferramentas tecnológicas. Além disso, obterá uma explicação sobre alguns conceitos da pesquisa e poderá fazer perguntas relacionadas à engenharia biomédica, esportiva, eletrônica, elétrica e da computação. Como um benefício social, o voluntário será convidado para um feedback ao final da pesquisa sobre quais foram os resultados e desenvolvimentos que foram alcançados com a sua ajuda.

Os benefícios da pesquisa para a comunidade estão relacionados a fatores ligados à acessibilidade. Na seguinte pesquisa, deseja-se obter um sistema de boa confiabilidade, para posteriormente, o desenvolvimento de equipamentos mais sofisticados. Além desses fatores, fortalecer a pesquisa nacional e local em relação a engenharia biomédica no campo da eletromiografia e eletro-oculografia para que futuros pesquisadores possuam maior acesso de dados. Como consequência dos resultados obtidos da compreensão dos sinais dos sensores não invasivos, espera-se primeiramente, a criação de bases de dados, para que os pesquisadores do grupo possam investigar técnicas de processamento de sinais. O segundo resultado é o aprimoramento das técnicas de desenvolvimento de hardware, ou seja, de circuitos, sistemas e equipamentos, os quais irão captar os sinais para as bases de dados. Além disso, serão investigados aspectos metodológicos para aplicação dos eletrodos, como posicionamento, fixação, orientação, materiais, conforto e ergonomia do sistema.

6. Critérios de inclusão e exclusão.

6a) Inclusão: Indivíduos de sexo masculino e feminino, com idade maior que 18 anos.

6b) Exclusão: Participantes que não atenderam às solicitações que possibilitam a execução do experimento, como a correta alocação dos eletrodos na região estudada e uso de roupas adequadas para as atividades. Participantes que tenham algum tipo de dermatite no local de posicionamento dos eletrodos. Participantes que não possam participar do experimento em sua íntegra ou que por algum motivo decidam fazer uso do direito de abandonar o experimento durante a coleta de dados. Participantes que apresentaram problemas com relação à montagem dos eletrodos como: aqueles que se sentirem desconfortáveis com os eletrodos ou, que por motivo pessoal ou técnico, possam alterar os resultados. Participantes que apresentarem execução inadequada ou equivocada, ou que não compreendam/assimilem os movimentos solicitados. Participantes que no dia do teste apresentarem indisposição física, psicológica ou fisiológica que impeça a execução do roteiro experimental proposto.

7. Direito de sair da pesquisa e a esclarecimentos durante o processo.

É assegurada a você assistência durante toda a pesquisa, bem como é garantido o seu livre acesso a todas as informações e esclarecimentos adicionais sobre o estudo e suas consequências, enfim, tudo o que você queira saber antes, durante e depois da sua participação. Pode também se recusar a participar do estudo, ou se retirar a qualquer momento sem qualquer constrangimento ou penalização.

Você pode assinalar o campo a seguir, para receber o resultado desta pesquisa, caso seja de seu interesse:

() quero receber os resultados da pesquisa (e-mail para envio: _____)

() não quero receber os resultados da pesquisa.

.8. Ressarcimento e indenização.

Os participantes serão convidados a se deslocarem até o local de testes (laboratório CIEBE, bloco V1, UTFPR-PG), e caso haja necessidade, serão ressarcidos por este deslocamento de uma forma previamente negociada.

Os participantes são/serão orientados a se deslocarem até a UTFPR-PG utilizando máscara para a realização das coletas, as quais caso os participantes não portem, serão fornecidas pelos pesquisadores. Os pesquisadores fornecerão álcool em gel, 70% para uso nas mãos. Não haverá nenhum ressarcimento em função dos gastos do uso destes equipamentos de proteção.

Os participantes não terão nenhum outro gasto para participar desta pesquisa, assim não haverá nenhum outro tipo de ressarcimento, ou outra forma de pagamento ou compensação financeira relacionada à sua participação nesta pesquisa.

Em caso de eventuais danos decorrentes da participação na pesquisa, você será devidamente indenizado, de acordo com o que prevê a Resolução 466/12.

ESCLARECIMENTOS SOBRE O COMITÊ DE ÉTICA EM PESQUISA:

O Comitê de Ética em Pesquisa envolvendo Seres Humanos (CEP) é constituído por uma equipe de profissionais com formação multidisciplinar que está trabalhando para assegurar o respeito aos seus direitos como participante de pesquisa. Ele tem por objetivo avaliar se a pesquisa foi planejada e se será executada de forma ética. Se você considerar que a pesquisa não está sendo realizada da forma como você foi informado ou que você está sendo prejudicado de alguma forma, entre em contato com o Comitê de Ética em Pesquisa envolvendo Seres Humanos da Universidade Tecnológica Federal do Paraná (CEP/UTFPR). Av. Sete de Setembro, 3165, Bloco N, Térreo, Bairro Rebouças, CEP 80230-901, Curitiba-PR, telefone: (41) 3310-4494, e-mail: coep@utfpr.edu.br.

B) CONSENTIMENTO

Declaro que li e entendi todas as informações presentes neste Termo de Consentimento Livre e Esclarecido e tive a oportunidade de discutir as informações deste termo. Todas as minhas perguntas foram respondidas e eu estou satisfeito com as respostas. Entendo que receberei uma via assinada e datada deste documento e que outra via assinada e datada será arquivada pela pesquisadora responsável pelo estudo.

Enfim, tendo sido orientado quanto a todo o teor aqui mencionado e compreendido a natureza e o objetivo do já referido estudo, manifesto meu livre consentimento em participar, estando totalmente ciente de que não há nenhum valor econômico a receber ou a pagar, por minha participação.

Após reflexão e um tempo razoável, eu decidi, livre e voluntariamente, participar deste estudo.

Concordo que o material e as informações obtidas relacionadas a minha pessoa possam ser publicados em aulas, congressos, eventos científicos, palestras ou periódicos científicos. Porém, não devo ser identificado por nome ou qualquer outra forma.

Nome completo: _____

RG: _____ Data de Nascimento: ___/___/___ Telefone: _____

Endereço: _____

CEP: _____ Cidade: _____ Estado: _____

Assinatura: _____ Data: ___/___/___

Eu declaro ter apresentado o estudo, explicado seus objetivos, natureza, riscos e benefícios e ter respondido da melhor forma possível às questões formuladas.

Assinatura pesquisador: _____ Data: ___/___/___

(ou seu representante)

Nome completo: _____

Para todas as questões relativas ao estudo ou para se retirar do mesmo, poderão se comunicar com _____, via e-mail:

_____ ou telefone:

_____.