

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
DEPARTAMENTO ACADÊMICO DE COMPUTAÇÃO  
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

**MAISA BARRETO**

**CRIAÇÃO DE UMA BASE DE DADOS PARA O  
ALFABETO DATILOLÓGICO UTILIZANDO  
DISPOSITIVO DE INTERAÇÃO  
NÃO-CONVENCIONAL**

MONOGRAFIA

**CAMPO MOURÃO**

**2017**

**MAISA BARRETO**

**CRIAÇÃO DE UMA BASE DE DADOS PARA O  
ALFABETO DATILOLÓGICO UTILIZANDO  
DISPOSITIVO DE INTERAÇÃO  
NÃO-CONVENCIONAL**

Trabalho de Conclusão de Curso de graduação apresentado à disciplina de Trabalho de Conclusão de Curso 2, do Curso de Bacharelado em Ciência da Computação do Departamento Acadêmico de Computação da Universidade Tecnológica Federal do Paraná, como requisito parcial para obtenção do título de Bacharel em Ciência da Computação.

Orientador: Prof. Dr. André Luiz Satoshi Kawamoto

Coorientador: Prof. Dr. Diego Bertolini Gonçalves

**CAMPO MOURÃO**

**2017**



## ATA DE DEFESA DO TRABALHO DE CONCLUSÃO DE CURSO

Às **18:30** do dia **28 de novembro de 2017** foi realizada na sala **D102** da UTFPR-CM a sessão pública da defesa do Trabalho de Conclusão do Curso de Bacharelado em Ciência da Computação do(a) acadêmico(a) **Maísa Barreto** com o título **Criação de uma Base de Dados para o Alfabeto Datilológico Utilizando Dispositivo de Interação Não-Convencional**. Estavam presentes, além do(a) acadêmico(a), os membros da banca examinadora composta por: **Prof. Dr. Andre Luiz Satoshi Kawamoto** (orientador), **Prof. Dr. Diego Bertolini Gonçalves** e **Profa. Dra. Aretha Barbosa Alencar**. Inicialmente, o(a) acadêmico(a) fez a apresentação do seu trabalho, sendo, em seguida, arguido(a) pela banca examinadora. Após as arguições, sem a presença do(a) acadêmico(a), a banca examinadora o(a) considerou \_\_\_\_\_ na disciplina de Trabalho de Conclusão de Curso **2** e atribuiu, em consenso, a nota \_\_\_\_ (\_\_\_\_\_). Este resultado foi comunicado ao(à) acadêmico(a) e aos presentes na sessão pública. A banca examinadora também comunicou ao acadêmico(a) que este resultado fica condicionado à entrega da versão final dentro dos padrões e da documentação exigida pela UTFPR ao professor Responsável do TCC no prazo de **onze dias**. Em seguida foi encerrada a sessão e, para constar, foi lavrada a presente Ata que segue assinada pelos membros da banca examinadora, após lida e considerada conforme.

Observações: \_\_\_\_\_  
\_\_\_\_\_  
\_\_\_\_\_  
\_\_\_\_\_  
\_\_\_\_\_

Campo Mourão, **28 de novembro de 2017**

\_\_\_\_\_  
**Prof. Dr. Diego Bertolini Gonçalves**

Membro 1

\_\_\_\_\_  
**Profa. Dra. Aretha Barbosa Alencar**

Membro 2

\_\_\_\_\_  
**Prof. Dr. Andre Luiz Satoshi Kawamoto**  
Orientador

**A ata de defesa assinada encontra-se na coordenação do curso.**

# Resumo

---

Barreto, Maisa. Criação de uma Base de Dados para o Alfabeto Datilológico Utilizando Dispositivo de Interação Não-Convencional. 2017. 34. f. Monografia (Curso de Bacharelado em Ciência da Computação), Universidade Tecnológica Federal do Paraná. Campo Mourão, 2017.

Gestos são uma maneira natural de comunicação, fundamental para pessoas com deficiência auditiva. Ainda assim, a utilização de língua de sinais não é trivial, tanto para surdos quanto para ouvintes, resultando em dificuldades para a adoção de linguagens de sinais. Com o intuito de facilitar a comunicação por meio de gestos, estudos e ferramentas utilizando técnicas que visam o reconhecimento de sinais vem sendo desenvolvidos. Dentre as técnicas mais utilizadas estão as que fazem o uso de (1) câmeras e sensores, de (2) luvas especiais e sensores de mão (3) e de sensores eletromiográficos.

A eletromiografia é uma técnica recente capaz de identificar sinais elétricos dos músculos, para a qual ainda não existem muitas bases de dados disponíveis específicas para línguas de sinais, diferente de outras técnicas, como para imagens digitais, que dispõem de uma grande variedade de bases representando várias línguas e alfabetos de sinais.

Dentre os objetivos deste trabalho estão provar que é interessante a utilização de dispositivos de captura não convencionais e dados eletromiográficos para a identificação de movimentos realizados e criar uma base pública de dados eletromiográficos para o alfabeto datilológico da Língua Brasileira de Sinais obtidos utilizando um dispositivo do tipo braçadeira denominado MYO.

Inicialmente ocorreu a implementação de uma aplicação capaz de capturar os dados brutos (*raw data*) do dispositivo. Após a implementação da ferramenta, foram selecionados dois grupos de voluntários, fluentes e não fluentes na língua de sinal. Uma vez selecionados, esses voluntários, participaram da etapa captura dos dados, na qual utilizando a braçadeira realizavam as configurações de mão alfabeto datilológico, de acordo com uma orientação fornecida. Os dados capturados foram submetidos a um pré-processamento e a análises estatísticas. Feito isto, estes dados pré-processados foram submetidos aos classificadores que implementavam os algoritmos *KNN* e *SVM*, gerando assim os resultados necessários para a validação da base de dados.

Os resultados obtidos dos classificadores foram satisfatórios, o melhor caso foi utilizando

o método *SVM*, o qual gerou uma taxa de acerto de 89%, classificando corretamente 578 instâncias de um conjunto com 643.

Considerando os resultados obtidos, é possível concluir que a base de dados é válida e pode ser utilizada de maneira livre. Como trabalho futuro, será investigada a possibilidade do reconhecimento expresso utilizando a braçadeira MYO.

**Palavras-chaves:** LIBRAS, Alfabeto Datilológico, Eletromiografia, Base de Dados, MYO.

# Abstract

---

Barreto, Maisa. . 2017. 34. f. Monograph (Undergraduate Program in Computer Science), Federal University of Technology – Paraná. Campo Mourão, PR, Brazil, 2017.

Gestures are one of many ways of communication, fundamental to people with hearing disabilities. Yet, using sign language is not as trivial, for both deaf and hearing people, resulting in difficulties to the adoption of sign language. With the objective of helping the communication using signs, studies and tools using the most used methods are being developed. Among the methods utilized are the ones who use (1) cameras and sensors, (2) special gloves and hand sensors and (3) electromyographic sensors. The electromyography is a recent tecnic that is capable of identifying muscle eletric signals, witch there is no much data avaliabe specifically to sign language, apart from the others methods, as digital images that offer a great variety of bases to represent many sign languages and alphabets.

Among the objectives of this work are to prove that is interesting to use unconventional capture devices and electromyographic data to the Brazilian Sign Language retrived using the armband type device named MYO.

Initially there was the implementation of an application capable of capturing the brute data(raw data) from the device. Henceforth the implementation, two groups of volunteers were selected, fluentes and not fluentes. Once selected, these volunteers got trough data capture where they used the armband while doing the hand configurations as instructed. The data were pre processed and statistically analyzed. That said, the pre processed data underwent classification by KNN and SVM algorithmis generating the necessary data to validate the data base.

The results gathered were satisfactory, in the best case were the SVM method was used, it was generated a 89% of correction, correctly classifying 578 instancies of 643 in total.

With this results, its possible to conclude that the data base is valid, therefore, can be used freely. As future work, it will be investigated the possibility of using the MYO armband as a express recognition tool.

**Keywords:** LIBRAS, Datilo Alphabet, electroyographic, data base, MYO.

# Lista de figuras

---

1.1	Tradutor visual do aplicativo <i>HandTalk</i> Fonte: HandTalk (2016). . . . .	7
1.2	Utilização do dispositivo MYO. Fonte: Nickelsburg (2016). . . . .	8
2.1	Alfabeto Manual . . . . .	10
2.2	Dispositivo do tipo <i>DataGlove</i> Fonte: QwibbleDesigns (2016) . . . . .	11
2.3	Braçadeira MYO Fonte: Adaptado de ThalmicLabs (2016b) . . . . .	13
2.4	Diagrama de desenvolvimento MYO Fonte: Adaptado de ThalmicLabs (2016a)	14
2.5	Movimentos básicos reconhecidos pelo dispositivo Fonte: Adaptado de Myers (2016). . . . .	14
3.1	Sequência de Fases Proposta para o Projeto . . . . .	17
3.2	Gráfico diferenciação classes A e B . . . . .	20
3.3	Interface da aplicação Weka . . . . .	24
4.1	Matriz de confusão KNN Weka, $k=7$ . . . . .	27
4.2	Resultados LibSVM . . . . .	27
4.3	Matriz de confusão LibSVM . . . . .	28
4.4	Letras M e N da LIBRAS . . . . .	29
4.5	Letras U e V da LIBRAS . . . . .	29

# Sumário

---

<b>1</b>	<b>Introdução</b>	<b>6</b>
1.1	Objetivos . . . . .	8
<b>2</b>	<b>Referencial Teórico</b>	<b>9</b>
2.1	LIBRAS e Alfabeto datilológico . . . . .	9
2.2	Reconhecimento de sinais . . . . .	10
2.3	EMG e Braçadeira MYO . . . . .	12
<b>3</b>	<b>Metodologia</b>	<b>16</b>
3.1	Método . . . . .	16
3.2	Consideração para avaliações . . . . .	18
3.2.1	Implementação e teste da ferramenta . . . . .	18
3.2.2	Seleção de voluntários . . . . .	20
3.2.3	Treinamento dos usuários e Captura de dados . . . . .	21
3.2.4	Análise dos dados capturados . . . . .	22
3.2.5	Classificação e Validação da base de dados . . . . .	23
<b>4</b>	<b>Resultados</b>	<b>25</b>
4.1	Descrição da base . . . . .	25
4.2	Classificação . . . . .	26
4.2.1	<i>KNN</i> . . . . .	26
4.2.2	<i>SVM</i> . . . . .	27
4.3	Considerações finais . . . . .	28
<b>5</b>	<b>Conclusão</b>	<b>30</b>
	<b>Referências</b>	<b>32</b>

---

## Introdução

---

Interação Humano-Computador (IHC) é um ramo da computação que vem ganhando muito espaço e crescendo rapidamente. Tal crescimento se deve à busca constante de tornar a experiência de utilização de sistemas computacionais o mais natural possível.

Grande parte das interfaces computacionais atuais ainda privilegiam apenas interações intermediadas por periféricos, como mouse e teclado. Entretanto, interfaces que fazem o uso de outras formas de interação como o toque, reconhecimento de voz, reconhecimento de gestos, dentre outras, estão se tornando cada vez mais comuns.

Interfaces Naturais de Usuário, NUIs (do inglês *Natural User Interfaces*), permitem o entendimento ou sensação de que a interação ocorre de maneira natural (LIU, 2010). NUIs não exigem uma grande quantidade de conhecimento prévio acerca da tecnologia pois necessitam apenas da interação do usuário por meio de movimentos ou fala. Esse tipo de interface vem sendo utilizado amplamente no ramo de entretenimento digital (GNECCO et al., 2012), bem como para o reconhecimento de línguas de sinais como a *American Sign Language* (ASL - Língua americana de sinais)(ATHITSOS et al., 2008), a Língua Brasileira de Sinais (LIBRAS)(ABREU et al., 2016), a Língua Thaiandesa de Sinais (TSL – *Thai Sign Language* )(AMATANON et al., 2014), a Língua Árábica de Sinais (*Arabic Sign Language*) (MOHANDÉS, 2013), entre outras, com o principal objetivo de auxiliar na interação e integração de pessoas com deficiência auditiva à sociedade.

Assim como a fala e a escrita, a utilização de gestos por humanos é considerada uma forma natural de comunicação (NASCIMENTO, 2009). Para pessoas que possuem algum tipo de deficiência auditiva, a comunicação utilizando gestos é fundamental, sendo assim identificamos a necessidade de desenvolver ferramentas capazes de reconhecer esses sinais para facilitar a comunicação dessas pessoas.

Nesse sentido, existem diversas ferramentas disponíveis, por exemplo, o *Hand Talk* e o *ProDeaf* Tradutor, que têm como objetivo promover o auxílio da comunicação entre

peças que possuem deficiência auditiva e peças que não possuem. O *Hand Talk*<sup>1</sup> realiza a tradução de voz, texto e até mesmo imagens para a LIBRAS por meio de um tradutor visual (Figura 1.1). O *ProDeaf Tradutor*<sup>2</sup> por sua vez, além de realizar a tradução de texto e voz para a LIBRAS, é capaz de traduzir para a Língua Americana de Sinais com o auxílio de um tradutor visual.



**Figura 1.1.** Tradutor visual do aplicativo *HandTalk*  
Fonte: HandTalk (2016).

Línguas de sinais são compostas por gestos constituídos por meio de empréstimos linguísticos de uma determinada língua falada, ou seja, são gerados com base na forma oral e escrita de línguas oficiais para que sejam representados visualmente. Uma coleção desses gestos forma subconjuntos denominados alfabetos manuais, cuja construção e representação variam de acordo com a região ou país de origem e podem ser classificados como uni manuais, caso utilizem apenas uma das mãos para representação do gesto, ou bimanuais, se fazem o uso das duas mãos (RAMOS, 2004).

O alfabeto manual da LIBRAS, também conhecido por alfabeto datilológico, é utilizado principalmente para a representação de palavras que ainda não possuem sinais que as traduzam especificamente, como nomes próprios, objetos e palavras de línguas estrangeiras.

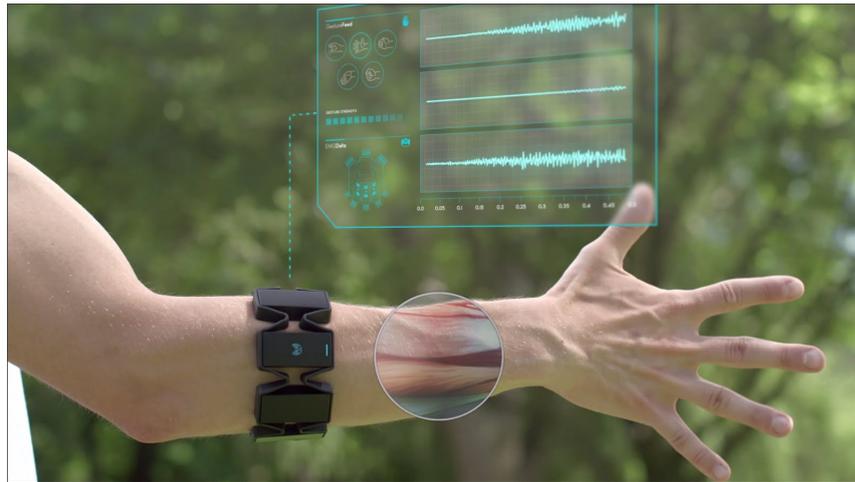
O reconhecimento de línguas de sinais tem como objetivo encontrar maneiras eficientes de tradução dos gestos para a forma escrita ou falada (CARNEIRO; CORTEZ; COSTA, 2009). Interfaces para o reconhecimento de sinais podem ser divididas em duas categorias: baseadas em visão computacional; e as que utilizam dispositivos não convencionais de interação. Interfaces baseadas em visão computacional utilizam dispositivos como câmeras e sensores de

<sup>1</sup> <<https://handtalk.me/>>

<sup>2</sup> <<http://www.prodeaf.net/>>

movimentos, dispositivos convencionais, para captura dos gestos (CHEN; GEORGANAS; PETRIU, 2007; BILAL et al., 2011), já as que utilizam dispositivos não convencionais realizam a captura com o auxílio de dispositivos utilizáveis, como luvas especiais e sensores para mãos, pulsos ou braços (PARVINI et al., 2009; SATHIYANARAYANAN; RAJAN, 2016).

Este trabalho propõe utilizar um dispositivo de interação não convencional do tipo braçadeira posicionado no antebraço, chamado MYO (Figura 1.2). Este dispositivo possui a capacidade de reconhecer movimentos por meio de eletromiografia (EMG), que por sua vez é uma técnica que identifica e registra atividades elétricas geradas por um músculo ativo<sup>3</sup>.



**Figura 1.2.** Utilização do dispositivo MYO.  
Fonte: Nickelsburg (2016).

## 1.1. Objetivos

O principal objetivo deste trabalho é criar uma base de dados para os caracteres do alfabeto datilológico de LIBRAS, com os valores capturados pelos sensores da braçadeira MYO. Essa base de dados deve ser pública, disponível para ser utilizada em estudos ou experimentos futuros. Um objetivo secundário seria avaliar os dados dessa base de dados obtida, verificando de certa forma a qualidade dos dados.

Esse trabalho está organizado da seguinte maneira: no Capítulo 2 são apresentados os conceitos de LIBRAS e alfabeto datilológico, reconhecimento de sinais, eletromiografia e a braçadeira MYO e base de dados; o método utilizado para o desenvolvimento do trabalho e suas etapas são definidos no Capítulo 3; no Capítulo 4 são apresentados os resultados obtidos; por fim no Capítulo 5 é apresentada a conclusão do trabalho.

<sup>3</sup> <<http://www.cpaqv.org/mtpmh/eletromiografia.pdf>>

---

## Referencial Teórico

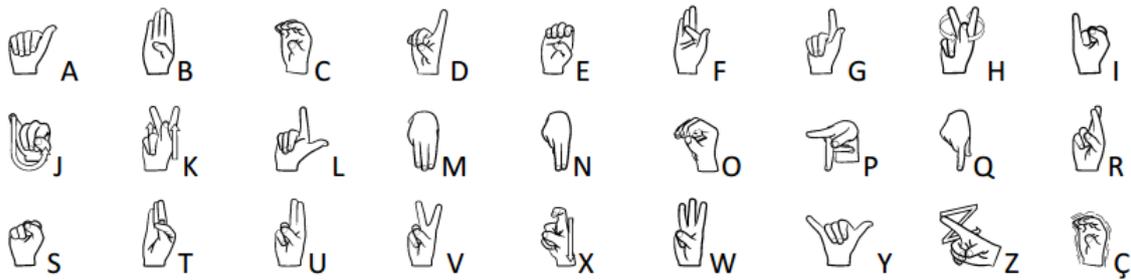
---

É apresentado nesse capítulo um referencial teórico com objetivo de embasar a construção deste trabalho. A Seção 2.1 apresenta a LIBRAS e o alfabeto datilológico. Na Seção 2.2 são descritos conceitos e características do reconhecimento de sinais. Na Seção 2.3 é apresentado o dispositivo MYO e EMG. Na Seção 2.4 será abordado o conceito de base de dados.

### **2.1. LIBRAS e Alfabeto datilológico**

Conforme o artigo 1º da Lei 10.436, LIBRAS é definida como uma forma de comunicação e expressão visual-motora que possui uma estrutura gramatical própria e constitui um sistema de divulgação de informações originado de comunidades de pessoas surdas do Brasil (BRASIL, 2002). Existem setenta e cinco configurações distintas de gestos no dicionário da LIBRAS, incluindo os símbolos que formam o alfabeto manual.

O alfabeto datilológico é um subconjunto composto por vinte e sete símbolos originados dos sinais contidos na LIBRAS, (Figura 2.1). Esse alfabeto possui gestos representados apenas por uma das mãos (uni manual) e é um recurso utilizado por surdos para expressar palavras, de maneira que cada sinal gesticulado corresponde a uma letra. Expressar-se utilizando esse alfabeto seria análogo à língua falada, correspondente a soletrar as palavras usando as mãos (ALVES et al., 2012).



**Figura 2.1.** Alfabeto Manual

Cada letra desse alfabeto pode ter sua maneira de representação definida por um conjunto de cinco parâmetros:

- Configuração de mão;
- Movimento;
- Ponto de articulação;
- Orientação da palma;
- Expressões não-manuais.

Esses sinais são compostos por vários tipos de movimentos que, por sua vez, são desempenhados pela palma da mão e dedos em conjunto com pulso. O ponto de articulação determina onde em relação ao corpo o movimento é realizado. Quando se trata do alfabeto datilológico, o ponto de articulação geralmente é situado em frente ao corpo. A orientação da palma descreve a disposição da palma da mão, sendo as mais comuns para cima, para baixo, para dentro e para fora. Finalmente, as expressões não-manuais incluem movimentos dos olhos, sobrancelhas, cabeça, lábios, nariz, tronco e língua, empregadas com mais frequência em sinais representativos não relacionados ao alfabeto manual (NASCIMENTO, 2009).

## 2.2. Reconhecimento de sinais

Diversos estudos a respeito de reconhecimento de sinais podem ser encontrados (BILAL et al., 2011; KIM et al., 2015; XU et al., 2016; MOHANDÉS, 2013; AMATANON et al., 2014). De acordo com Khan e Ibraheem (2012), esses estudos podem ser classificados de duas maneiras: de acordo com o tipo de gesto utilizado para o reconhecimento; ou de acordo com a técnica utilizada para captura dos dados (KHAN; IBRAHEEM, 2012).

Se considerarmos o tipo de gesto reconhecido, podemos dividir os trabalhos em: (1) aqueles que optam por reconhecer sinais relacionados a alguma língua de sinais e (2) os que escolhem reconhecer sinais não associados a nenhuma língua de sinais.

Quanto à técnica empregada na captura dos dados, é possível estabelecer três principais categorias: (1) trabalhos que utilizam câmeras, sensores e técnicas computacionais para a captura e processamento de imagens dos gestos obtidos (ALVARENGA; CORREA;

OSÓRIO, 2011; OSZUST; WYSOCKI, 2013), (2) trabalhos que fazem a utilização luvas especiais com sensores capazes de detectar a posição dos dedos (KIM et al., 2015; MOHANDES, 2010; PARVINI et al., 2009) e (3) trabalhos que utilizam eletromiografia (EMG) (XU et al., 2016; BOYALI; HASHIMOTO; MATSUMOTO, 2015) capaz de obter dados com o monitoramento de atividades elétricas dos músculos.

Oszust e Wysocki (2013) apresentam em seu estudo uma proposta para o reconhecimento de gestos baseada em sequências visuais do esqueleto corporal e das posições das mãos, capturadas utilizando o sensor Kinect e classificando os dados obtidos aplicando o algoritmo KNN (do inglês *K Nearest Neighbors* - K vizinhos mais próximos) (OSZUST; WYSOCKI, 2013).

Alvarenga, Correa e Osório (2011) utilizam o sensor Kinect em seu estudo para o reconhecimento de três gestos simples e de forma livre, para o aprendizado e classificação utilizando uma Rede Neural (ALVARENGA; CORREA; OSÓRIO, 2011).

Mohandes (2013) utiliza um dispositivo do tipo *Data Glove* denominado *CyberGlove* (Figura 2.2) para a captura dos dados nos quais os gestos capturados são reproduzidos utilizando as duas mãos e compõe a Língua Unificada Árabe de Sinais. Para a classificação são utilizados vinte exemplos de cada sinal, nos quais quinze são utilizados como conjunto de treino para uma SVM (do inglês *Support Vector Machine* - Máquina de vetores de suporte) e os outros cinco sinais capturados são utilizados como conjunto de teste (MOHANDES, 2013).

Weissmann e Salomon (1999), em seu estudo, utilizam um dispositivo do tipo *Data Glove*, que possui a capacidade de medir dezoito valores de diferentes ângulos das articulações dos dedos para a captura dos dados. Além disso, foram também definidos três gestos distintos para o reconhecimento e os dados capturados são aplicados em diferentes modelos de Rede Neural para que sejam realizadas comparações dos resultados gerados por um modelo de rede neural (WEISSMANN; SALOMON, 1999).



**Figura 2.2.** Dispositivo do tipo *DataGlove*  
Fonte: QwibbleDesigns (2016)

Abordagens que utilizam sensores eletromiográficos são recentes e possuem a

vantagem de serem independentes das condições do ambiente no qual esses sensores são utilizados, diferente de câmeras e sensores de movimento que dependem de iluminação adequada. Além disso, sensores EMG não possuem custo elevado e são uma técnica tão pouco invasiva quanto o emprego de luvas especiais.

Existem trabalhos que fazem o uso específico da braçadeira MYO para obtenção dos dados. No trabalho de Abreu et al. (2016), a braçadeira MYO é utilizada para o reconhecimento de vinte gestos do alfabeto da LIBRAS, associados a uma técnica de classificação que utiliza SVM.

Outra abordagem, de autoria de Paudyal, Banerjee e Gupta (2016), utiliza duas braçadeiras MYO para o reconhecimento de vinte sinais da Língua Americana de Sinais, e combina os sensores EMG a sensores de orientação utilizando um método conhecido como *Dynamic Time Warping* (PAUDYAL; BANERJEE; GUPTA, 2016).

Por fim, utilizando EMG, porém empregando um outro arranjo de sensores similar ao MYO, Amatanon, Naiyanetr, Chanhang e Thongpang (2014) realizam a extração de características com técnicas computacionais e a classificação utilizando uma rede neural artificial com objetivo de capturar os sinais EMG de dez gestos da Língua Tailandesa de Sinais, (*Thai Sign Language*) (AMATANON et al., 2014).

## 2.3. EMG e Braçadeira MYO

Eletromiografia consiste na aquisição e tratamento de sinais elétricos produzidos pela musculatura. O registro da atividade eletromiográfica permite a investigação de quais músculos são utilizados em determinado movimento, o nível de ativação muscular durante a execução do movimento, a intensidade e duração da solicitação muscular, além de possibilitar inferências relativas à fadiga muscular (KRONBERG; NÉMETH; BROSTRÖM, 1990).

A braçadeira MYO é um dispositivo de interação capaz de reconhecer movimentos por meio da interpretação de sinais eletromiográficos<sup>1</sup>, desenvolvido com a finalidade de simplificar a maneira acesso a ambientes virtuais.

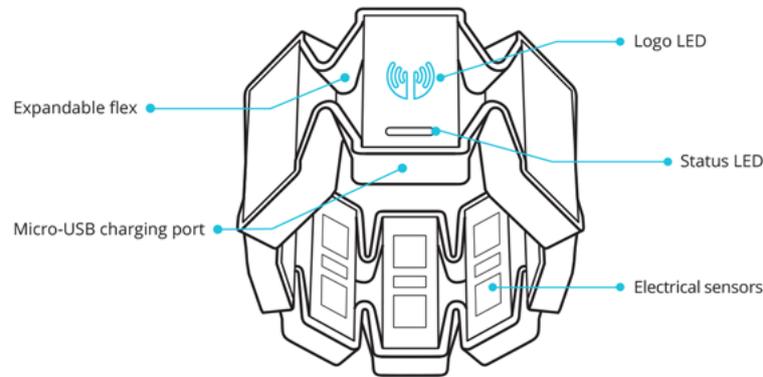
O hardware desse dispositivo é composto por (Figura 2.3):

- uma braçadeira com tiras flexíveis dividida em oito blocos, cada qual dotado de um sensor EMG;
- um giroscópio de três eixos;
- um acelerômetro de três eixos;
- um magnetômetro de três eixos;
- um processador ARM córtex M4;
- bateria de íons de lítio com duração aproximada de um dia (de acordo com o fabricante);
- um LED que indica o status do dispositivo, ligado, carregando ou desligado;

---

<sup>1</sup> <<https://www.myo.com>>

- uma porta micro-USB para recarga e conexão.

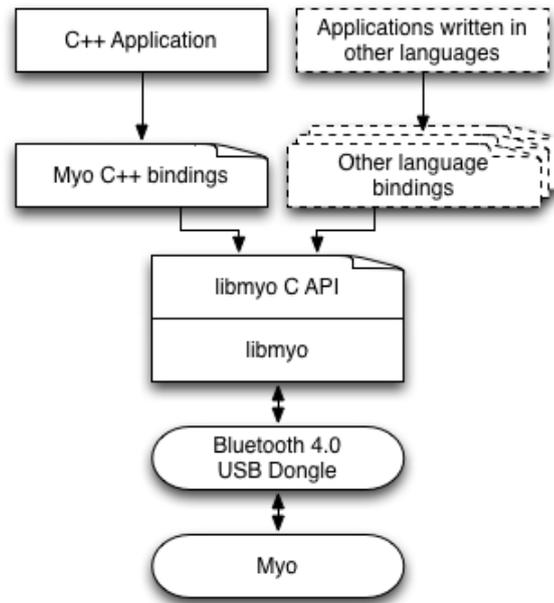


**Figura 2.3.** Braçadeira MYO  
 Fonte: Adaptado de ThalmicLabs (2016b)

Com esse conjunto de componentes é possível identificar quais grupos de músculos são acionados em um movimento (função dos sensores EMG) qual a intensidade da força empregada (função do acelerômetro) além da posição inicial, direção e posição final do gesto (funções do giroscópio e magnetrômetro). A comunicação desta braçadeira com outros dispositivos é feita por meio de *Bluetooth* ou por meio de um conector USB<sup>2</sup>.

O desenvolvimento de aplicações pode ser facilitado com a utilização de um SDK (do inglês Software Development Kit - Kit de desenvolvimento de software), denominado MYO SDK, que disponibiliza soluções completas para auxiliar no desenvolvimento. Seu núcleo é composto por uma biblioteca denominada *libmyo*, capaz de realizar interações com o dispositivo e que pode ser acessada utilizando uma API desenvolvida na linguagem C. Tipicamente não existe acesso direto de aplicações a esta biblioteca, antes de qualquer acesso ocorre uma etapa denominada *binding* que traduz a linguagem de desenvolvimento da aplicação para que seja interpretada pela biblioteca (Figura 2.4).

<sup>2</sup> <<https://www.myo.com/techspecs>>



**Figura 2.4.** Diagrama de desenvolvimento MYO  
 Fonte: Adaptado de ThalmicLabs (2016a)

As aplicações são geralmente desenvolvidas utilizando a linguagem C++, uma vez que os exemplos disponibilizados nos pacotes MYO SDK também utilizam esta linguagem. No entanto existem aplicações desenvolvidas utilizando outras linguagens, tais como Python e Lua, utilizada pra desenvolvimento de scripts conectores para ferramentas. O dispositivo é compatível com as plataformas Windows, MAC, IOS e Android e o download das versões dos pacotes MYO SDK estão disponíveis no site do fabricante<sup>3</sup>.

A princípio, a braçadeira é capaz de reconhecer cinco movimentos básicos: onda com a mão para a esquerda (*wave left*), onda com mão para a direita (*wave right*), punho cerrado (*fist*), mão aberta (*fingers spread*) e clique entre os dedos polegar e mínimo (*double tap*) (Figura 2.5).



**Figura 2.5.** Movimentos básicos reconhecidos pelo dispositivo  
 Fonte: Adaptado de Myers (2016).

Uma questão recorrente entre os desenvolvedores é o motivo do reconhecimento de apenas cinco movimentos básicos. Isso é justificado pela complexidade muscular e óssea única de cada indivíduo, que dificulta o reconhecimento de gestos, uma vez que o mesmo movimento

<sup>3</sup> <<https://developer.thalmic.com/downloads>>

pode ser interpretado de maneira diferente para pessoas diferentes<sup>4</sup>, o que exigiria muito treino por individuo antes da utilização. Outro motivo para essa limitação é que a braçadeira deve funcionar independentemente da posição, e o uso de sensores EMG é dificultado por ser uma técnica muito instável, uma vez que a detecção dos sinais elétricos gerados pelos músculos não é trivial. A principal limitação na quantidade de movimentos é para evitar que sejam gerados falsos positivos <sup>5</sup>.

---

<sup>4</sup> <<http://www.digitaltrends.com/pc-accessory-reviews/myo-gesture-control-armband-review/>>

<sup>5</sup> <<http://blog.thalmic.com/can-myio-armband-actually/>>

---

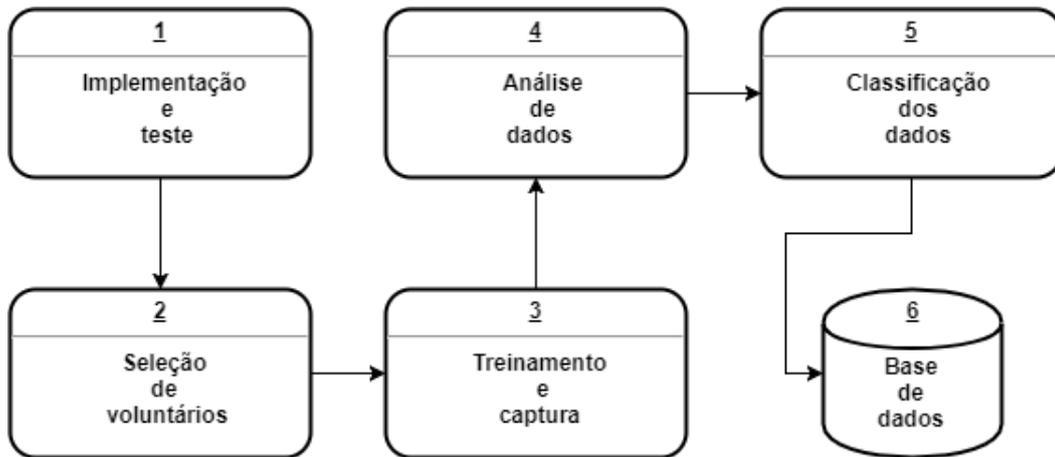
## Metodologia

---

Neste capítulo é apresentado o método e as ferramentas utilizadas para obtenção dos resultados. O método consiste nas seguintes etapas: implementação e teste; seleção de voluntários; treinamento e captura; análise de dados; classificação de dados. Em seguida, são especificadas as configurações dessas etapas para o contexto do presente trabalho. Por fim, são apresentados os métodos e ferramentas utilizadas para extrair as características e gerar os resultados, bem como as modificações necessárias para utilização de cada ferramenta.

### 3.1. Método

Conforme representado na Figura 3.1, é possível observar as etapas necessárias para o desenvolvimento deste trabalho: (1) Implementação de uma ferramenta para a captura dos dados do dispositivo e teste deste trabalho; (2) Seleção de voluntários para participação do experimento; (3) Treinamento dos voluntários e captura dos dados; (4) Análise e pré-processamento das capturas obtidas; (5) Classificação e validação dos dados preprocessados; (6) Conclusão e visualização dos resultados.



**Figura 3.1.** Sequência de Fases Proposta para o Projeto

A implementação e teste refere-se inicialmente a definição de qual linguagem será utilizada para o desenvolvimento da ferramenta, podendo estas serem C++ ou Python, uma vez que existem APIs disponibilizadas para as mesmas.

A etapa seguinte trata da seleção de voluntários para participação do experimento, verificando se é possível encontrar indivíduos com características e necessidade distintas para eventuais divisões em grupos de voluntários.

A etapa de treinamento consiste em uma breve apresentação da tecnologia aos voluntários e uma pequena demonstração de como será o processo de captura dos movimentos.

Na realização da análise das capturas verifica-se os dados obtidos a fim de remover possíveis ruídos, que consistem em dados gerados de movimentos que não compõe um gesto, e a aplicação de métodos estatísticos sobre os dados para a construção de características divididas em classes que representam as letras do alfabeto manual.

Por fim, a classificação dos dados refere-se ao emprego de algoritmos de classificação encontrados na literatura, utilizando ferramentas de classificação para obtenção dos resultados.

Nosso objetivo, por meio dessas etapas, consistiu na criação de uma base de dados utilizando dados obtidos de um dispositivo de interação não-convencional, que faz uso de sensores eletromiográficos e de posicionamento e orientação, tratando os resultados de sucessivas capturas e aplicando algoritmos de classificação para garantir que é possível realizar o reconhecimento de um gesto criando assim uma base de dados consistente. Para isso, têm-se as seguintes questões de pesquisa (QP):

- **QP1:** É possível utilizar os sensores do dispositivo MYO para o reconhecimento dos gestos do alfabeto datilológico?
- **QP2:** É possível criar uma base de dados aberta que possa ser utilizada em trabalhos futuros?

## 3.2. Consideração para avaliações

Considerando os estágios estabelecidos no método descrito na seção anterior (3.1), foram definidos os requisitos e elementos a serem empregados para a implementação, seleção, captura, análise e classificação dos dados necessários para obtenção dos resultados deste trabalho, que são apresentados nas seções seguintes.

### 3.2.1. Implementação e teste da ferramenta

Foi definida a utilização da linguagem de programação C++. A escolha se deve à quantidade de recursos disponibilizados pela API que coincidem com as necessidades deste trabalho. Dentre essas a necessidades, a principal é a captura dos dados por sensor de maneira individual, disponibilizada de forma a ser implementada de maneira mais simples utilizando a linguagem C++.

#### Ambiente de desenvolvimento

Inicialmente foi necessária a configuração do ambiente de trabalho com a instalação do pacote MYOSDK, versão 0.9.01, utilizando a plataforma Windows. Após a instalação das dependências necessárias, foram executados os exemplos disponibilizados no pacote com objetivo de observar o funcionamento deste para definição da melhor maneira de utilização.

Durante todo o processo de desenvolvimento da aplicação, foi observada a viabilidade da ferramenta em desenvolvimento e verificando o funcionamento desta, o objetivo era analisar e melhorar seu desempenho de acordo com a evolução do código, bem como aprimorar a definição do modo de captura dos dados. Essas verificações também serviram para realização de análises dos dados obtidos de capturas iniciais, nas quais foram observadas variações dos valores obtidos, e se essas variações possibilitavam distinguir os gestos do alfabeto datilológico utilizando os dados gerados pelo dispositivo.

#### Funcionamento da aplicação

A aplicação foi executada com o auxílio da *IDE do Visual Studio*<sup>1</sup>, desenvolvida pela empresa Microsoft<sup>2</sup>, sobre a versão 2015 utilizando uma licença disponibilizada para estudantes da Universidade Tecnológica Federal do Paraná.

Após a compilação da aplicação utilizando a IDE era gerado um executável para a aplicação desenvolvida. Este programa executável exibía uma tela similar a um terminal de comando onde a informação exibida era apenas sobre a conexão ou não com o dispositivo MYO.

---

<sup>1</sup> <<https://www.visualstudio.com>>

<sup>2</sup> <<https://www.microsoft.com/>>

Todo o processo de funcionamento ocorre de maneira em que os dados só podem ser visualizados após a finalização da execução da aplicação.

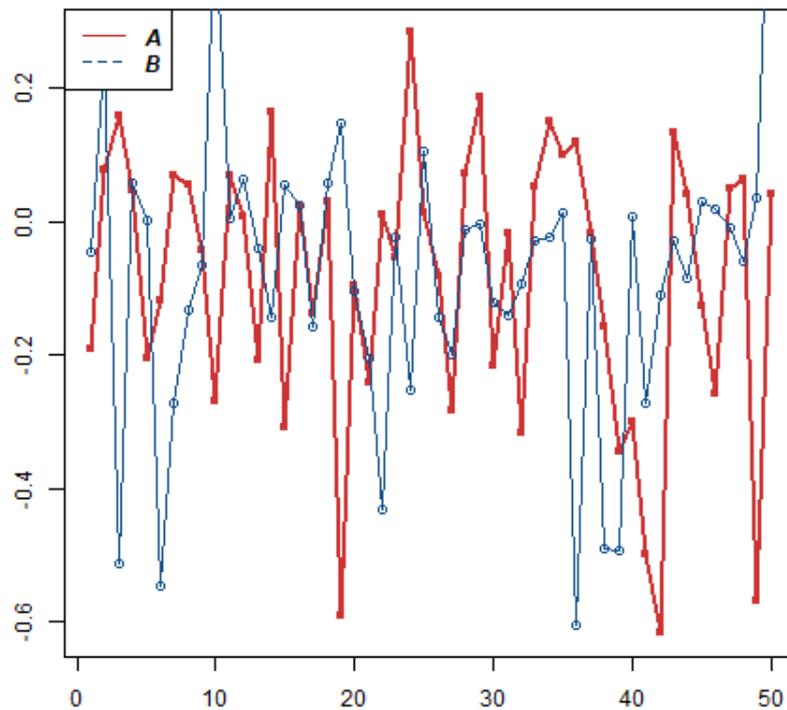
### Dados obtidos da captura

Após a execução é possível verificar os dados obtidos da captura. São gerados quatro arquivos, um para cada sensor da braçadeira. Os arquivos possuem formato CSV, onde os valores são separados por vírgula, e são organizados da seguinte forma:

- Arquivo sensor Acelerômetro: *Timestamp*, x, y, z;
- Arquivo sensor Giroscópio: *Timestamp*, x, y, z;
- Arquivo sensor Magnetômetro: *Timestamp*, x, y, z;
- Arquivo sensor Eletromiográfico (EMG): *Timestamp*, emg1, emg2, emg3, emg4, emg5, emg6, emg7, emg8;

Os nomes dos arquivos obedecem o seguinte formato: Nome do sensor hífen (-) identificador da captura ponto (.) extensão do arquivo (Exemplo : accelerometer-1494265912.csv). Os arquivos gerados de uma mesma captura possuem o mesmo número de identificação. Os sensores acelerômetro, giroscópio e magnetômetro possuem rótulos de tempo (*Timestamp*) semelhantes para uma mesma captura, já o arquivo com os dados dos sensores eletromiográficos possui rótulos de tempo duplicados, pois durante o processo estes sensores eletromiográficos realizam recalibrações para uma melhor adaptação ao braço do indivíduo.

Após a conclusão da implementação foi realizado um teste piloto para verificação do funcionamento e se os dados obtidos eram passíveis de serem utilizados. Com uma breve análise dos dados obtidos, foi possível observar que havia a possibilidade de diferenciar as classes (Figura 3.2), utilizando os dados da braçadeira.



**Figura 3.2.** Gráfico diferenciação classes A e B

### 3.2.2. Seleção de voluntários

Para esta etapa de seleção, contamos com o intermédio de um professor especialista da universidade que nos direcionou e intermediou o contato com voluntários estudantes da universidade, bem como voluntários pertencentes a Escola Municipal de Educação Especial Espaço Aberto.

Inicialmente foi apresentado o trabalho aos indivíduos, juntamente com o objetivo para a verificação do interesse na participação do estudo de maneira voluntária.

Com o aceite dos voluntários, foi possível dividir estes em dois grupos: um composto por pessoas que possuem conhecimento e são habituados à língua de sinais e outro composto por indivíduos leigos, não habituados com essa forma de comunicação. O número total de voluntários foi de vinte e cinco pessoas.

Um critério desejado para a seleção de pessoas fluentes na língua de sinais era o indivíduo possuir o certificado ProLibras (Exame Nacional para Certificação de Proficiência no uso e no ensino de Libras e para Certificação de Proficiência na tradução e interpretação de Libras/Português/Libras), que garante que pessoas surdas ou ouvintes são fluentes em

LIBRAS<sup>3</sup>.

Para a seleção do outro grupo, não fluentes na língua de sinal, estes de preferência, deveriam ter cursado ou estar cursando a disciplina de LIBRAS oferecida pela instituição ou algum tipo de curso voltado para a língua de sinais.

O principal motivo para essa divisão de usuários em grupos, foi para verificação de que usuários com mais experiência em línguas de sinais gesticulam com mais segurança, firmeza e de maneira mais precisa enquanto os menos experientes gesticulam de maneira menos segura e mais lenta. Uma vez que, o dispositivo captura sinais elétricos gerados pela musculatura, podem ocorrer variações nas intensidades desses sinais, mesmo se tratando de um único gesto. Dito isto, deseja-se comprovar se essa hipótese é verdadeira aplicando sobre os dados os seguintes métodos estatísticos: Mediana, Média, Moda, Mínimo valor e Máximo valor. Definidos os critérios os grupos foram organizados da seguinte maneira:

- **Grupo Especialista:** O grupo especialista foi formado por doze integrantes, incluindo oito alunos, três professores e um funcionário da Escola Municipal de Educação Especial Espaço Aberto. Dos alunos que se voluntariaram, um deles não conseguiu participar do experimento devido ao fato da circunferência da braçadeira ser maior que a de seu braço e outros dois devido a dificuldade na realização dos movimentos, tiveram seus dados capturados mas não utilizados, pois possuíam paralisia cerebral e deficiência intelectual. Sendo assim, dentre os participantes, três possuíam a certificação Prolibras e os outros seis eram fluentes e possuíam algum tipo de deficiência auditiva, totalizando nove voluntários válidos.
- **Grupo não especializado:** O grupo não especializado, foi formado por dezesseis pessoas incluindo estudantes e funcionários da instituição UTFPR Campus Campo Mourão. Dos voluntários, cinco não haviam participado ou cursado qualquer tipo de especialização em qualquer tipo de linguagem de sinal e conheciam apenas os gestos contidos no alfabeto datilológico.

### 3.2.3. Treinamento dos usuários e Captura de dados

Após a seleção dos voluntários, estes foram apresentados brevemente a tecnologia, indicando a maneira correta de utilização do dispositivo e sobre como seria realizada a captura de cada movimento.

Com base no teste piloto, foi possível estimar que o tempo total de captura por voluntário seria em torno de vinte minutos, quando realizadas duas repetições por movimento. Sendo assim, definimos que cada pessoa realizaria duas repetições do mesmo gesto para que o processo não se tornasse exaustivo, gerando assim cinquenta e duas amostras por pessoa, visto que o alfabeto possui vinte e seis letras.

---

<sup>3</sup> <<http://portal.inep.gov.br/prolibras1>>

A captura de dados do mesmo gesto por uma mesma pessoa foi necessária para o registro de pequenas variações que ocorrem ao gesticular repetidas vezes.

Uma vez dado início a fase captura, os voluntários vestiam a braçadeira de forma que o LED de indicação fosse posicionado para baixo, em direção a mão. O braço com o dispositivo era mantido relaxado, paralelo ao corpo, e então após um intervalo médio de três segundos o movimento era realizado de acordo com a velocidade do usuário e mantido por aproximadamente cinco segundos, excluindo casos de gestos que possuíam movimento (letras H, J, K, X, Y e Z). Cada gesto correspondente a uma letra do alfabeto foi capturado separadamente gerando quatro arquivos com os dados dos sensores por movimento.

É importante ressaltar que todo o processo de captura foi realizado sem qualquer tipo de visualização dos dados durante o processo, pois a aplicação gera arquivos com os dados dos sensores que só podem ser verificados após a finalização da captura atual.

As capturas ocorreram durante um período de aproximadamente um mês, divididas em várias sessões de acordo com a disponibilidade dos voluntários. Na Escola Municipal de Educação Especial Espaço Aberto foram realizadas três visitas agendadas que duravam cerca de duas horas por visita. Já na Universidade Tecnológica Federal do Paraná, as capturas ocorriam por voluntário, de acordo com a disponibilidade de cada indivíduo, captura esta que foi dividida durante três semanas.

### **3.2.4. Análise dos dados capturados**

A fase de análise visava submeter um conjunto de dados gerado pela fase anterior a análises estatísticas, com o propósito de avaliar as variações dos valores gerados pelos sensores para cada gesto. Essa análise tratou os dados de maneira a remover o máximo possível de ruído inserido no conjunto de dados.

Na etapa de captura, esta era iniciada com o braço em posição de relaxamento, o que não faz parte de qualquer gesto contido no alfabeto datilológico, desta forma cada conjunto possuía um certo tipo de ruído nas linhas iniciais. Estas linhas contendo dados considerados irrelevantes foram removidas, quando o braço é levantado para a realização do movimento a orientação da braçadeira é alterada de forma que conseguimos identificar o momento dessa alteração e remover os dados gerados nas primeiras linhas dos arquivos. Estes métodos estáticos foram utilizados para que os arquivos gerados fossem comprimidos na forma de características únicas por captura, segundo um professor de estatística da Universidade Tecnológica Federal do Paraná, os métodos escolhidos para formação das características são válidos.

Com as linhas irrelevantes ignoradas, os arquivos gerados por movimento foram submetidos aos cálculos de média, mediana, moda, mínimo e máximo, gerando assim um vetor de características. Cada letra foi definida como uma classe numerada de 0 a 25. O vetor de características por classe, foi constituído no total por 85 características, sendo estas

média, mediana, moda, mínimo e máximo para as colunas x, y e z dos arquivos gerados para os sensores acelerômetro, giroscópio e magnetômetro, já para o arquivo dos sensores eletromiográficos também foram aplicados os mesmo métodos estatísticos para cada um dos oito sensores contidos no arquivo.

O arquivo final gerado, é composto pela classe seguida de um vetor de características e foi totalizado com 1293 instâncias. Como o total de voluntários utilizados foi de vinte e cinco e cada indivíduo realizou duas vezes um mesmo gesto, deveriam existir 1300 amostras no arquivo final, porém durante a etapa de captura ocorreu de o dispositivo interromper sua execução, fazendo assim necessária a reconexão com o computador. Durante este processo de reconexão, foram geradas 7 amostras vazias, o que só foi observado após a captura dos dados devido ao fato de não existir visualização durante o processo.

### 3.2.5. Classificação e Validação da base de dados

Nessa fase, foram selecionados classificadores utilizados em estudos similares a este, bem como outros, incluídos no decorrer do desenvolvimento deste trabalho.

Existem diversos algoritmos de classificação, sendo assim o objetivo desta etapa é aplicar os algoritmos mais utilizados em estudos semelhantes com a finalidade de observar a variação quantos as taxas de acerto.

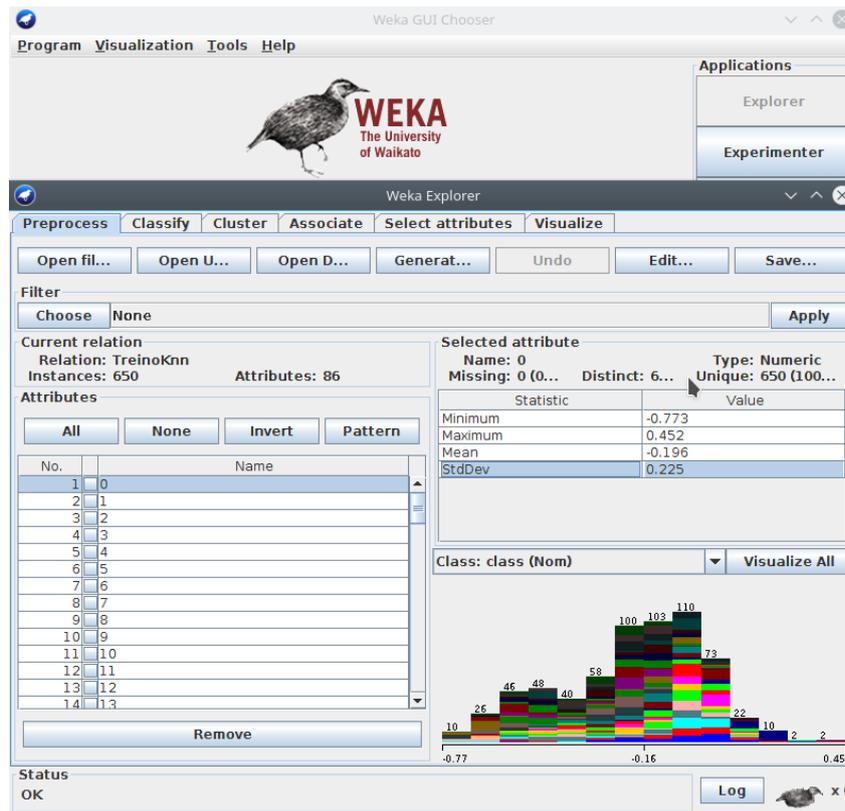
Tradicionalmente, os classificadores mais utilizados e escolhidos para utilização neste trabalho foram:

- ***KNN*** (do inglês *K Nearest Neighbors* - K vizinhos mais próximos): Associa um objeto a uma classe baseando-se na quantidade de vizinhos mais próximos no espaço de características. Para utilização do KNN é necessária a definição de um conjunto de exemplos de treinamento e teste; Definição de uma métrica para o cálculo da distância entre as amostras do conjunto de treinamento; Definição do parâmetro de K, que consiste no número de vizinhos mais próximos que serão considerados pelo algoritmo (XIONG; CHITTI; LIU, 2007);
- ***SVM*** (do inglês *Support Vector Machine* - Máquina de vetores de suporte): É um método popular de aprendizagem supervisionada utilizado para classificação, regressão, reconhecimento de padrões e outras tarefas que envolvem aprendizagem (CHANG; LIN, 2011).

O classificador *KNN* foi utilizado a partir da ferramenta para mineração de dados Weka<sup>4</sup> (Figura 3.3) que consiste em um software livre desenvolvido em Java. Já a implementação escolhida para o classificador *SVM* foi a disponibilizada pela LIBSVM<sup>5</sup>.

<sup>4</sup> <<https://www.cs.waikato.ac.nz/ml/weka/>>

<sup>5</sup> <<https://www.csie.ntu.edu.tw/~cjlin/libsvm/>>



**Figura 3.3.** Interface da aplicação Weka

As duas ferramentas de classificação exigem formatos de entrada distintos, portanto foi necessária a adaptação dos dados gerados para realização das classificações. O arquivo gerado para o programa Weka está representado de forma que são dispostas primeiramente as características e o último dado representa a classe correspondente, todos os parâmetros são separados por vírgula. Já o arquivo gerado para o LIBSVM possui no início a classe correspondente seguindo do número da característica dois pontos e o valor desta (número:valor), a separação é feita utilizando espaços em branco.

A classificação foi realizada utilizando amostras de treino e teste. Uma das amostras de uma mesma pessoa contida no treino, também está contida no teste. O arquivo total foi submetido a uma divisão onde, 650 amostras foram destinadas a um arquivo de treino e as 643 restantes a um arquivo de teste.

---

## Resultados

---

Neste capítulo, são apresentadas as avaliações de resultados gerados com o auxílio de classificadores previamente selecionados, considerando um conjunto de dados obtidos de sensores eletromiográficos e de orientação, com o objetivo de criar uma base de dados que possa ser livremente disponibilizada.

### 4.1. Descrição da base

A base utilizada para realização dos testes, criada durante o desenvolvimento do trabalho, constitui-se de 1293 amostras. O total de amostras foi dividido em dois grupos, sendo um utilizado como treino, constituído 650 amostras, e outro como teste, constituído por 643 amostras.

Cada amostra é representada por um vetor de 86 características, divididas em 26 classes numeradas (0 a 25) representando de forma ordenada as letras do alfabeto datilológico. Cada classe do conjunto de treino possui 25 amostras, bem como as do conjunto de teste, com exceção das classes que representam as letras J, O, P, T, V as quais possuem 24 amostras e a classe representante da letra Y que possui 23 amostras.

Os parâmetros estão organizados conforme descrito na Tabela 4.1. As respectivas colunas de 02 á 16 correspondem as representações das métricas estatísticas dos eixos x, y e z do arquivo gerado para o sensor acelerômetro, bem como as colunas 17 á 31 correspondem as representações das métricas estatísticas dos eixos x, y e z do arquivo gerado para o sensor giroscópio e assim por diante.

	Acelerômetro <i>x, y, z</i>	Giroscópio <i>x, y, z</i>	Magnetômetro <i>x, y, z</i>	Eletromiográfico <i>e1, e2, e3, e4, e5, e6, e7, e8</i>
<i>Colunas correspondentes</i>				
<b>Classe</b>	01			
<b>Média</b>	02, 03, 04	17, 18, 19	32, 33, 34	47, 48, 49, 50, 51, 52, 53, 54
<b>Mediana</b>	05, 06, 07	20, 21, 22	35, 36, 37	55, 56, 57, 58, 59, 60, 61, 62
<b>Moda</b>	08, 09, 10	23, 24, 25	38, 39, 40	63, 64, 65, 66, 67, 68, 69, 70
<b>Mínimo</b>	11, 12, 13	26, 27, 28	41, 42, 43	71, 72, 73, 74, 75, 76, 77, 78
<b>Máximo</b>	14, 15, 16	29, 30, 31	44, 45, 46	79, 80, 81, 82, 83, 84, 85, 86

Tabela 4.1. Descrição do arquivo

## 4.2. Classificação

Todos os classificadores utilizaram os conjuntos de treinamento e teste para obtenção dos resultados descritos. Na Subseção 4.2.1 serão apresentados os resultados obtidos utilizando o algoritmo de classificação *KNN*. Já na Subseção 4.2.2 serão apresentados os resultados obtidos utilizando o classificador *SVM*.

### 4.2.1. *KNN*

Este classificador foi parametrizado utilizando a função de distância euclidiana, padrão da ferramenta Weka, com valores para *k* variando da mesma maneira que ocorre na literatura. Foram definidos os valores 1, 3, 5, e 7 para a quantidade de vizinhos, de acordo com as taxas de acerto do algoritmo de classificação.

Quanto aos resultados obtidos, a pior taxa de acerto foi quando *k* valia 1 e o melhor resultado foi obtido quando *K* valia 7. Definimos o limite de sete para número de vizinhos, devido ao fato das taxas de acerto começarem a cair quando ultrapassado esse valor. A Tabela 4.2 descreve os resultados obtidos para cada valor de *K*.

Valor de <i>k</i>	Classificadas corretamente	Classificadas incorretamente	% de acerto
<b>01</b>	509	134	79.1602 %
<b>03</b>	519	124	80.7154 %
<b>05</b>	521	122	81.0264 %
<b>07</b>	524	119	<b>81.493 %</b>

Tabela 4.2. Resultados *KNN*

Observando a matriz de confusão gerada do melhor resultado obtido para o algoritmo *KNN*, podemos observar a quantidade de acertos por classe, descrita na diagonal principal da matriz (Figura 4.1), bem como com qual classe cada característica foi confundida.

```

=== Confusion Matrix ===
      a  b  c  d  e  f  g  h  i  j  k  l  m  n  o  p  q  r  s  t  u  v  w  x  y  z  <-- classified as
23  0  0  1  0  0  0  0  0  0  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  | a = 1
0 21  0  1  1  2  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  | b = 2
1  3 18  1  1  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  | c = 3
0  3  3 15  0  2  2  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  | d = 4
0  0  0  0 23  1  0  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  | e = 5
0  0  0  2  0 23  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  | f = 6
0  0  0  1  6  1 16  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  | g = 7
0  0  0  0  0  0  1 21  1  2  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  | h = 8
0  0  0  2  0  0  1  0 22  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  | i = 9
0  0  0  0  0  0  0  4  1 19  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  | j = 10
1  0  1  1  0  0  0  3  2  0 17  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  | k = 11
1  0  0  0  0  0  1  1  0  0  0 22  0  0  0  0  0  0  0  0  0  0  0  0  0  0  | l = 12
0  1  0  0  0  0  0  0  0  0  0  0 24  0  0  0  0  0  0  0  0  0  0  0  0  0  | m = 13
0  0  0  0  0  0  0  0  0  0  0  0 12 11  1  0  0  0  1  0  0  0  0  0  0  0  | n = 14
0  0  0  0  0  1  0  0  0  0  0  0  1  0 19  3  0  0  0  0  0  0  0  0  0  0  | o = 15
0  0  0  0  0  0  0  0  0  0  0  0  0  0  6 16  0  0  2  0  0  0  0  0  0  0  | p = 16
0  0  0  0  0  0  0  0  0  0  0  0  0  0  1  2 18  1  3  0  0  0  0  0  0  0  | q = 17
0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 24  1  0  0  0  0  0  0  0  0  | r = 18
0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  2 22  1  0  0  0  0  0  0  | s = 19
0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 24  0  0  0  0  0  0  0  | t = 20
0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 23  2  0  0  0  0  0  | u = 21
0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  9 12  3  0  0  0  0  | v = 22
0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  2 23  0  0  0  0  | w = 23
0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 24  0  1  0  0  | x = 24
0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 23  0  | y = 25
0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  1  3  0 21  | z = 26

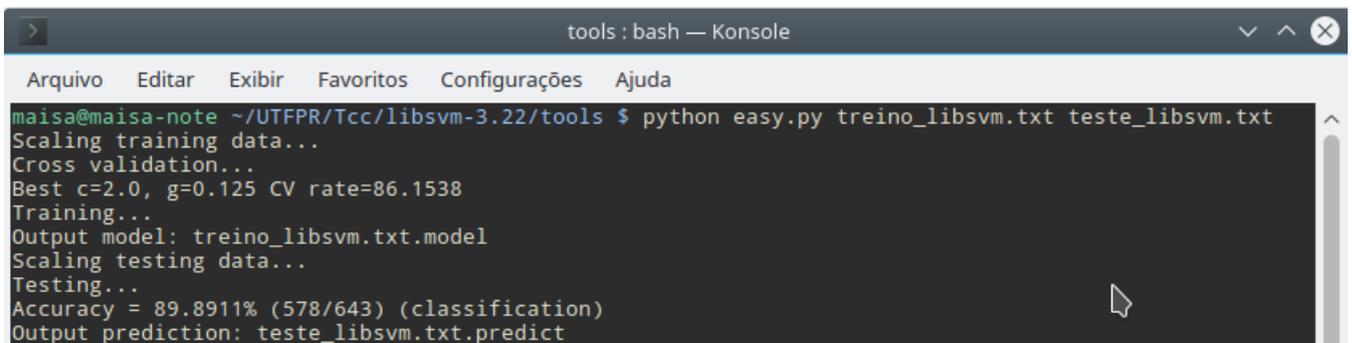
```

**Figura 4.1.** Matriz de confusão KNN Weka, k=7

Com base na matriz de confusão descrita na imagem acima, podemos afirmar que para o algoritmo de classificação *KNN* as classes com os maiores índices de erro foram as de número 14 e 22, sendo a classe 14 representante da letra N confundida doze vezes com a classe 13 representante da letra M e a classe 22 representante da letra V confundida nove vezes com a classe 21 representante da letra U.

#### 4.2.2. SVM

O classificador *SVM* contou com as configurações pré-definidas pela aplicação LIBSVM, a qual utiliza um *kernel RGB (Gaussian Radial Basis)* e define os dois parâmetros, C e Gamma, de acordo com o conjunto de treino. Foi utilizada apenas um tipo de configuração para os parâmetros deste classificador.



```

tools : bash — Konsole
Arquivo  Editar  Exibir  Favoritos  Configurações  Ajuda
maisa@maisa-note ~/UTFPR/Tcc/libsvm-3.22/tools $ python easy.py treino_libsvm.txt teste_libsvm.txt
Scaling training data...
Cross validation...
Best c=2.0, g=0.125 CV rate=86.1538
Training...
Output model: treino_libsvm.txt.model
Scaling testing data...
Testing...
Accuracy = 89.8911% (578/643) (classification)
Output prediction: teste_libsvm.txt.predict

```

**Figura 4.2.** Resultados LibSVM

Como descrito na Figura 4.2 podemos observar melhores valores definidos para os parâmetros C e Gamma, bem como a taxa de acerto utilizando *SVM* que foi de 89,8911%, visto que 578 amostras foram classificadas corretamente e 65 foram classificadas incorretamente. A matriz de confusão gerada para este classificador segue representada abaixo.

```

=== Confusion Matrix ===
  a  b  c  d  e  f  g  h  i  j  k  l  m  n  o  p  q  r  s  t  u  v  w  x  y  z  <-- classified as
23  0  0  1  0  0  0  0  0  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 | a = 1
 0 23  0  1  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 | b = 2
 1  1 22  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 | c = 3
 0  1  1 21  0  0  2  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 | d = 4
 0  0  0  0 23  0  1  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 | e = 5
 0  1  0  0  0 24  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 | f = 6
 0  0  0  2  2  0 20  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 | g = 7
 0  0  0  0  0  0  1 20  1  3  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 | h = 8
 0  0  0  0  0  0  0  0 24  0  0  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0 | i = 9
 0  0  0  0  0  0  0  0  0 24  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 | j = 10
 0  1  0  0  0  0  0  0  1  0 23  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 | k = 11
 0  0  0  0  0  0  3  0  1  0  0 21  0  0  0  0  0  0  0  0  0  0  0  0  0  0 | l = 12
 0  0  0  0  0  0  0  0  0  0  0  0 24  1  0  0  0  0  0  0  0  0  0  0  0  0 | m = 13
 0  0  0  0  0  0  0  0  0  0  0  0  5 20  0  0  0  0  0  0  0  0  0  0  0  0 | n = 14
 0  0  0  0  0  0  0  0  0  0  0  0  0  0 21  3  0  0  0  0  0  0  0  0  0  0 | o = 15
 0  0  0  0  0  0  0  0  0  0  0  0  0  0  1 21  1  1  0  0  0  0  0  0  0  0 | p = 16
 0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  1 1 23  0  1  0  0  0  0  0  0 | q = 17
 0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 25  0  0  0  0  0  0  0  0 | r = 18
 0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  1  4 20  0  0  0  0  0  0  0 | s = 19
 0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 24  0  0  0  0  0  0 | t = 20
 0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 21  4  0  0  0  0 | u = 21
 0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  7 16  1  0  0  0 | v = 22
 0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 25  0  0  0 | w = 23
 0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 25  0  0 | x = 24
 0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 23  0 | y = 25
 0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 25 | z = 26

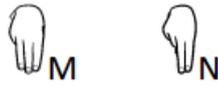
```

**Figura 4.3.** Matriz de confusão LibSVM

Observando matriz de confusão representada pela Figura 4.3, podemos afirmar que para o método *SVM*, as classes 14 e 22 foram as que apresentaram as maiores quantidades de erro, sendo a classe 14 representante da letra N confundida cinco vezes com a classe 13 representante da letra M e a classe 22 representante da letra V confundida sete vezes com a classe 21 representante da letra U.

### 4.3. Considerações finais

Por meio dos resultados obtidos das classificações, demonstradas na Seção 4.2, podemos ressaltar alguns aspectos considerados interessantes para a pesquisa. Inicialmente não era possível afirmar que um gesto era similar a outro baseando-se apenas na configuração de mão definida para estes, pois tratando-se de sensores eletromiográficos, não se tem garantia de que configurações de mão similares, geravam movimentações do mesmo conjunto de músculos do braço. Porém com base nos resultados obtidos, podemos afirmar que configurações de mão semelhantes, geram movimentações similares dos músculos, como são os casos das letras, M e N e das letras V e U e W.



**Figura 4.4.** Letras M e N da LIBRAS



**Figura 4.5.** Letras U e V da LIBRAS

Com os resultados obtidos, visivelmente a letra N foi confundida diversas vezes com a letra M, visto que as duas possuem configuração de mão similares, bem como as letra U, V e W, as quais também possuem gestos similares, com sutis variações, e também foram confundidas entre si, pelos classificadores.

O capítulo seguinte apresenta as conclusões deste trabalho, considerando todos os resultados obtidos.

---

## Conclusão

---

Este capítulo apresenta nossa conclusão com base nos resultados obtidos a fim de responder nossas questões de pesquisa e apresentar os trabalhos futuros para uma possível continuidade do projeto. Por meio dos resultados obtidos, podemos responder nossas questões de pesquisa firmadas na Seção 3.1:

- **QP1:** É possível utilizar os sensores do dispositivo MYO para o reconhecimento dos gestos do alfabeto datilológico?
- **QP2:** É possível criar uma base de dados aberta que possa ser utilizada em trabalhos futuros?

A fim de responder a **QP1**, foram realizadas capturas sucessivas de dados, transformações e análises destes, descritas nos capítulos anteriores. Levando em consideração os resultados obtidos, podemos afirmar que a declaração é verdadeira, pois cada gesto capturado utilizando o dispositivo MYO, gera características capazes de serem consideradas únicas.

Para responder a questão **QP2** foi necessária a classificação dos dados obtidos para que fosse verificado se o método proposto era válido. Com base nos resultados, pelos classificadores, descritos na Seção 4.2, podemos observar que os resultados de classificação da base de dados gerada deste estudo satisfatórios, e esta pode ser utilizada em trabalhos futuros.

Existem diversos trabalhos que podem ser desenvolvidos utilizando a base de dados gerada. Um deles seria a investigação da possibilidade da base gerada ser suficientemente adequada para permitir o reconhecimento de letras expressas, em tempo de conversação, ou seja, identificar se é possível realizar o reconhecimento dinâmico dos gestos enquanto os movimentos estão sendo realizados, de maneira contínua.

Caso seja possível realizar esse reconhecimento dinâmico, outro trabalho interessante seria a realização da transcrição automática de palavras expressas, usando o alfabeto

datilológico para texto, ou mesmo geração de voz sintetizada, a fim de facilitar a comunicação entre ouvintes e não-ouvintes, inclusive com predição de palavras a fim de evitar erros.

# Referências

---

- ABREU, J. G. et al. Evaluating sign language recognition using the myo armband. In: *2016 XVIII Symposium on Virtual and Augmented Reality (SVR)*. IEEE, 2016. p. 64–70. Disponível em: <<http://ieeexplore.ieee.org/document/7517255/>>.
- ALVARENGA, Matheus Lin Truglio; CORREA, Diogo S. Ortiz; OSÓRIO, Fernando Santos. Redes Neurais Artificiais aplicadas no Reconhecimento de Gestos usando o Kinect. p. 347–356, 2011. Disponível em: <<http://osorio.wait4.org/publications/2012/COTB-MatheusLin-2012.pdf>>.
- ALVES, Aline da Silva et al. Comunicabilidade em sistemas de informação web corporativos: Analisando a interação de surdos bilíngues. In: *Proceedings of the 11th Brazilian Symposium on Human Factors in Computing Systems*. Porto Alegre, Brazil, Brazil: Brazilian Computer Society, 2012. (IHC '12), p. 13–22. ISBN 978-85-7669-262-1. Disponível em: <<http://dl.acm.org/citation.cfm?id=2393536.2393539>>.
- AMATANON, V. et al. Sign language-thai alphabet conversion based on electromyogram (emg). In: *Biomedical Engineering International Conference (BMEiCON), 2014 7th*. IEEE, 2014. p. 1–4. Disponível em: <<http://ieeexplore.ieee.org/document/7017398/>>.
- ATHITSOS, V. et al. The american sign language lexicon video dataset. In: *Computer Vision and Pattern Recognition Workshops, 2008. CVPRW '08. IEEE Computer Society Conference on*. IEEE, 2008. p. 1–8. ISSN 2160-7508. Disponível em: <<http://ieeexplore.ieee.org/document/4563181/>>.
- BILAL, Sara et al. Vision-based hand posture detection and recognition for Sign Language — A study. *2011 4th International Conference on Mechatronics (ICOM)*, n. May, p. 1–6, 2011. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5937178>>.
- BOYALI, A.; HASHIMOTO, N.; MATSUMOTO, O. Hand posture and gesture recognition using myo armband and spectral collaborative representation based classification. In: *2015 IEEE 4th Global Conference on Consumer Electronics (GCCE)*. IEEE, 2015. p. 200–201. Disponível em: <<http://ieeexplore.ieee.org/document/7398619/>>.
- BRASIL. *Lei Nº 10.436, 24 de abril de 2002, Dispõe sobre a Língua Brasileira de Sinais - Libras e dá outras providências*. 2002. <[http://www.planalto.gov.br/ccivil\\_03/leis/2002/L10436.htm](http://www.planalto.gov.br/ccivil_03/leis/2002/L10436.htm)>. Acessado em 16-11-2016.
- CARNEIRO, Alex T S; CORTEZ, Paulo C; COSTA, Rodrigo C S. Reconhecimento de Gestos da LIBRAS com Classificadores Neurais a partir dos Momentos Invariantes de Hu. *Interaction 09 - South America, 2009, São Paulo*, p. 190–195, 2009.

CHANG, Chih-Chung; LIN, Chih-Jen. Libsvm: A library for support vector machines. *ACM Trans. Intell. Syst. Technol.*, ACM, New York, NY, USA, v. 2, n. 3, p. 27:1–27:27, maio 2011. ISSN 2157-6904. Disponível em: <<http://doi.acm.org/10.1145/1961189.1961199>>.

CHEN, Q.; GEORGANAS, N. D.; PETRIU, E. M. Real-time vision-based hand gesture recognition using haar-like features. In: *2007 IEEE Instrumentation Measurement Technology Conference IMTC 2007*. IEEE, 2007. p. 1–6. ISSN 1091-5281. Disponível em: <<http://ieeexplore.ieee.org/document/4258134/>>.

GNECCO, Bruno Barberi et al. Desenvolvimento de interfaces naturais de interação usando o hardware kinect. *Tendências e Técnicas em Realidade Virtual e Aumentada*, v. 2, p. 37–62, 2012.

HANDTALK. *Tradutor Visual da Ferramenta HandTalk*. 2016. <[https://play.google.com/store/apps/details?id=br.com.handtalk&hl=pt\\_BR](https://play.google.com/store/apps/details?id=br.com.handtalk&hl=pt_BR)>. Acessado em 16-11-2016.

KHAN, Rafiqul Zaman; IBRAHEEM, Noor Adnan. Survey on Gesture Recognition for Hand Image Postures. *Computer and Information Science*, v. 5, n. 3, p. 110, 2012. ISSN 1913-8997.

KIM, Kyung-Won et al. Recognition of sign language with an inertial sensor-based data glove. In: . IOS Press, 2015. v. 24, n. s1, p. S223–S230. Disponível em: <<https://www.ncbi.nlm.nih.gov/pubmed/26444804>>.

KRONBERG, Margareta; NÉMETH, GUNNAR; BROSTRÖM, LARS-AKE. Muscle activity and coordination in the normal shoulder: An electromyographic study. *Clinical orthopaedics and related research*, LWW, v. 257, p. 76–85, 1990.

LIU, Weiyuan. Natural user interface- next mainstream product user interface. In: *Computer-Aided Industrial Design Conceptual Design (CAIDCD), 2010 IEEE 11th International Conference on*. IEEE, 2010. v. 1, p. 203–205. Disponível em: <<http://ieeexplore.ieee.org/document/5681374/>>.

MOHANDES, Mohamed A. Recognition of two-handed arabic signs using the cyberglove. In: CITESEER. *The 4th International Conference on Advanced Engineering Computing and Applications in Sciences, ADVCOMP, Florence, Italy*. 2010. p. 25–30. Disponível em: <<http://link.springer.com/article/10.1007/s13369-012-0378-z>>.

MOHANDES, Mohamed A. Recognition of Two-Handed Arabic Signs Using the CyberGlove. *Arabian Journal for Science and Engineering*, v. 38, n. 3, p. 669–677, 2013. ISSN 13198025.

MYERS, Chelsea. *Gestos reconhecidos pelo dispositivo MYO*. 2016. <<http://chelmyers.com/research/2015/06/20/myo-gesture-test-pt-01.html>>. Acessado em 05-11-2016.

NASCIMENTO, Sandra Patrícia de Faria do. Representações Lexicais Da Língua De Sinais Brasileira. Uma Proposta Lexicográfica. p. 290, 2009.

NICKELSBURG, Monica. *Diagrama de desenvolvimento para uma aplicação utilizando MYO*. 2016. <<http://www.geekwire.com/2016/thalmic-labs-maker-high-tech-armband-controls-muscles-raises-120m-amazon-high-profile-investors/>>. Acessado em 05-11-2016.

OSZUST, M.; WYSOCKI, M. Recognition of signed expressions observed by kinect sensor. In: *Advanced Video and Signal Based Surveillance (AVSS), 2013 10th IEEE International Conference on*. IEEE, 2013. p. 220–225. Disponível em: <<http://ieeexplore.ieee.org/document/6636643/>>.

PARVINI, Farid et al. An approach to glove-based gesture recognition. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, v. 5611 LNCS, n. PART 2, p. 236–245, 2009. ISSN 03029743.

PAUDYAL, Prajwal; BANERJEE, Ayan; GUPTA, Sandeep K S. SCEPTRE: A Pervasive, Non-Invasive, and Programmable Gesture Recognition Technology. *Proceedings of the 21st International Conference on Intelligent User Interfaces*, p. 282–293, 2016. Disponível em: <<http://doi.acm.org/10.1145/2856767.2856794>>.

QWIBBLEDESIGNS. *Dispositivo CyberGlove*. 2016. <[http://www.cs.ru.ac.za/research/g0712273/project\\_background\\_gloves.html](http://www.cs.ru.ac.za/research/g0712273/project_background_gloves.html)>. Acessado em 16-11-2016.

RAMOS, Clélia Regina. Libras: a língua de sinais dos surdos brasileiros. *Revista virtual de cultura surda*, Editora Arara, 2004.

SATHIYANARAYANAN, M.; RAJAN, S. Myo armband for physiotherapy healthcare: A case study using gesture recognition application. In: *2016 8th International Conference on Communication Systems and Networks (COMSNETS)*. IEEE, 2016. p. 1–6. Disponível em: <<http://ieeexplore.ieee.org/document/7439933/>>.

THALMICLABS. *Diagrama de desenvolvimento para uma aplicação utilizando MYO*. 2016. <[https://developer.thalmic.com/docs/api\\_reference/platform/the-sdk.html](https://developer.thalmic.com/docs/api_reference/platform/the-sdk.html)>. Acessado em 18-11-2016.

THALMICLABS. *Dispositivo MYO*. 2016. <[https://developer.thalmic.com/docs/api\\_reference/platform/getting-started.html](https://developer.thalmic.com/docs/api_reference/platform/getting-started.html)>. Acessado em 02-11-2016.

WEISSMANN, J.; SALOMON, R. Gesture recognition for virtual reality applications using data gloves and neural networks. In: *Neural Networks, 1999. IJCNN '99. International Joint Conference on*. IEEE, 1999. v. 3, p. 2043–2046 vol.3. ISSN 1098-7576. Disponível em: <<http://ieeexplore.ieee.org/document/832699/>>.

XIONG, Li; CHITTI, Subramanyam; LIU, Ling. Mining multiple private databases using a knn classifier. In: *Proceedings of the 2007 ACM Symposium on Applied Computing*. New York, NY, USA: ACM, 2007. (SAC '07), p. 435–440. ISBN 1-59593-480-4. Disponível em: <<http://doi.acm.org/10.1145/1244002.1244102>>.

XU, Y. et al. Development of a hybrid motion capture method using myo armband with application to teleoperation. In: *2016 IEEE International Conference on Mechatronics and Automation*. IEEE, 2016. p. 1179–1184. Disponível em: <<http://ieeexplore.ieee.org/document/7558729/>>.