



Universidade Federal de Uberlândia - UFU  
Faculdade de Engenharia Elétrica - FEELT  
Graduação em Engenharia Biomédica

**EBER LAWRENCE SOUZA GOUVEIA**

**APLICAÇÃO DE MÁQUINAS DE VETORES DE SUPORTE PARA  
GERAÇÃO DE SINAIS DE CONTROLE ROBUSTOS PARA  
PRÓTESES MIOELÉTRICAS**

Uberlândia  
2018

**EBER LAWRENCE SOUZA GOUVEIA**

**APLICAÇÃO DE MÁQUINAS DE VETORES DE SUPORTE PARA  
GERAÇÃO DE SINAIS DE CONTROLE ROBUSTOS PARA  
PRÓTESES MIOELÉTRICAS**

Trabalho apresentado como requisito parcial de avaliação na disciplina Trabalho de Conclusão de Curso de Engenharia Biomédica da Universidade Federal de Uberlândia.

Orientador: Alcimar Barbosa Soares

---

Assinatura do Orientador

Uberlândia  
2018

## **AGRADECIMENTOS**

Aos meus pais Eber Pereira de Souza e Sandra Gouveia de Faria pelo apoio durante toda minha graduação, sempre me apoiarem e estarem ao meu lado nos momentos em que mais precisei.

Ao Professor Dr. Alcimar Barbosa Soares pelo incentivo e orientação neste trabalho.

Ao laboratório de Engenharia Biomédica (BioLab) por fornecer o laboratório para pesquisas e experimentos durante a maior parte da minha graduação, inclusive para a execução deste trabalho.

Aos professores da Faculdade de Engenharia Elétrica (FEELT) por proporcionar conhecimentos em diversas áreas da engenharia.

A Universidade Federal de Uberlândia (UFU) por me proporcionar a oportunidade de graduação no curso de Engenharia Biomédica.

## RESUMO

Os membros superiores têm grande importância para a realização de atividades cotidianas. Além disso, eles auxiliam na comunicação através de movimentos e gestos. Desta forma, a perda dos membros superiores afeta diretamente essas habilidades, podendo fazer com que o indivíduo perca sua independência, capacidade de socialização, autoestima, etc. Inúmeras pesquisas vêm sendo desenvolvidas com o intuito de resolver problemas como esses, a maioria delas voltadas para área de elaboração de próteses. Técnicas de controle de próteses que utilizam sinais EMG são as que estão em maior ascensão, principalmente a partir de reconhecimento de padrões com o uso de algoritmos de Aprendizado de Máquina, capazes de proporcionar vários graus de liberdade com alta acurácia. Porém, existem diversos problemas que ainda tornam essa forma de controle pouco utilizada em aplicações clínicas, logo, conseguir um modelo genérico se tornou algo fundamental, pois realizar o controle de próteses através de sinais EMG demanda certo esforço físico e mental por parte do usuário. Os eletrodos utilizados para captação do sinal EMG estão geralmente posicionados no socket da prótese e, com isso, podem sofrer constantes mudanças de posição, alterando os atributos extraídos do sinal EMG. Isso faz com que o desempenho do sistema se torne instável. Dessa forma, este trabalho tem como objetivo elaborar um sistema de classificação capaz de gerar um modelo mais robusto e genérico, mantendo um bom desempenho mesmo se a posição dos eletrodos for alterada. A técnica de Máquinas de Vetores de Suporte foi escolhida, uma vez que diversos trabalhos na literatura comprovaram sua eficácia em relação a outras técnicas. Além disso, a técnica de Análises de Componentes Principais foi utilizada com o intuito de reduzir de forma significativa a dimensionalidade dos dados, mantendo um bom desempenho. A validação dos resultados foi feita através da técnica de validação cruzada usando o método de k-Fold. A construção de modelos mais genéricos possibilitou um ótimo desempenho, com acurácia média dos voluntários de 91%. Além disso, o uso da técnica de Análises de Componentes Principais possibilitou a redução de dimensionalidade dos dados de 24 atributos para no máximo 8 componentes principais, mantendo 95% da variabilidade dos dados.

## **ABSTRACT**

The upper limbs have great importance while performing daily activities. In addition, they aid in communication through movements and gestures. This way loss of the upper limbs directly affects these abilities and can cause the individual to lose his independence, socialization capacity, self-esteem, etc. Numerous researches have been developed with the purpose of solving these problems, most of them focused on prosthesis design. Prosthetic control techniques that use EMG signals are on the rise, mainly from pattern recognition with the use of Machine Learning algorithms, capable of providing various degrees of freedom with high accuracy. However, there are several problems that still limits this form of control in clinical applications, so achieving a generic model has become fundamental because performing the control of prosthesis through EMG signals requires some physical and mental effort by the user. The electrodes used for EMG signal capture are usually positioned in the prosthesis socket and thereby can undergo a constant change of position by modifying the extracted features of the EMG signal. This causes an unstable system performance. Thus, this work aims to develop a classification system capable of generating a more robust and generic model, maintaining a good performance even if the position of the electrodes has been changed. The Support Vector Machines technique was chosen since several works in the literature have proved their effectiveness in relation to other techniques. Moreover, the Principal Component Analysis technique was used in order to significantly reduce the data dimensionality, maintaining a good performance. The validation of the results was done through the cross-validation technique using the k-Fold method. The construction of more generic models allowed a great performance, with the volunteers' average accuracy of 91%. In addition, the use of the Principal Component Analysis technique allowed the reduction of data dimensionality from 24 features to a maximum of 8 main components, maintaining 95% of the data variability.

## LISTA DE ILUSTRAÇÕES

|                                                                                                                                                                                                                                                                                         |    |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1: Diagrama esquemático de um sistema de controle de próteses.....                                                                                                                                                                                                               | 13 |
| Figura 2: Caminho dos potenciais de ação até a junção neuromuscular. Adaptado de (MAMBRITO e DE LUCA, 1983) .....                                                                                                                                                                       | 15 |
| Figura 3: Sinal EMG coletado para diferentes posicionamentos dos eletrodos. O esquema apresenta eletrodos posicionados a) na inervação do músculo, b) no centro do ventre muscular, c) na lateral do meio do músculo e d) na junção miotendínea. Adaptado de (TECHNOLOGIES, 2015) ..... | 17 |
| Figura 4: Matriz de dados exemplo/resposta fornecidas ao algoritmo AM para gerar a função de mapeamento. Adaptado de (LORENA e CARVALHO, 2007).....                                                                                                                                     | 18 |
| Figura 5: Modelos de classificadores para problemas binários a) ocorrência de overfitting, b) modelo ideal e c) ocorrência de underfitting. ....                                                                                                                                        | 19 |
| Figura 6: Exemplo de três hiperplanos que separam de forma correta o conjunto de treino. Porém somente o hiperplano B continua separando bem o conjunto de teste. ....                                                                                                                  | 21 |
| Figura 7: Escolha dos vetores de suporte de acordo com os dados de ambas as classes mais próximos. ....                                                                                                                                                                                 | 23 |
| Figura 8: Exemplo do uso da função de kernel para transformar problemas não linearmente separáveis para linearmente separáveis em um espaço de maior dimensão.....                                                                                                                      | 24 |
| Figura 9: Transformação de um conjunto de dados de três para duas dimensões, formado pelas duas componentes principais de maior variância. ....                                                                                                                                         | 27 |
| Figura 10: Exemplo de prótese acionada por tirantes. Adaptado de (Prosthetic & Orthotic Care).....                                                                                                                                                                                      | 29 |
| Figura 11: Reinervação muscular direcionada dos nervos periféricos ao peitoral maior para amputação na desarticulação do ombro. Adaptado de (STUBBLEFIELD, MILLER, et al., 2009) .....                                                                                                  | 31 |

|                                                                                                                                                                                                                 |    |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 12: Diagrama de blocos das principais etapas do sistema.....                                                                                                                                             | 32 |
| Figura 13: Eletromiógrafo MyosystemBr1-P84 (DataHominis Tec Ltda). .....                                                                                                                                        | 33 |
| Figura 14: Posicionamento dos eletrodos em torno do antebraço. ....                                                                                                                                             | 34 |
| Figura 15: Definição da altura das posições P1 e P2 dos eletrodos. Adaptado de (ZIPP, 1982). .....                                                                                                              | 35 |
| Figura 16: Interface para auxílio da coleta, representando o comando de repouso. .                                                                                                                              | 36 |
| Figura 17: Imagem ilustrativa para os 6 diferentes tipos de movimentos a serem executados. ....                                                                                                                 | 37 |
| Figura 18: Diagrama de blocos para o treino/teste dos conjuntos 1, 2 e 3.....                                                                                                                                   | 40 |
| Figura 19: Coleta com um voluntário. Interface de auxílio no monitor esquerdo.....                                                                                                                              | 41 |
| Figura 20: Sinal EMG coletado dos quatro eletrodos posicionados nos músculos do antebraço do voluntário para a altura P1. Os quatro sinais são apresentados de forma paralela junto com o sinal de trigger..... | 42 |
| Figura 21: Coleta com os mesmos canais de sinal EMG, porém na altura P2.....                                                                                                                                    | 43 |
| Figura 22: Gráfico de dispersão das duas primeiras CP do voluntário 5 a partir dos dados do conjunto 1 em um espaço 2D. ....                                                                                    | 47 |
| Figura 23: Gráfico de dispersão das três primeiras CP do voluntário 5 a partir dos dados do conjunto 1 em um espaço 3D. ....                                                                                    | 48 |
| Figura 24: Três modelos gerados para as duas primeiras CP do voluntário 5. a) Conjunto 1, b) Conjunto 2 e c) Todos os dados. ....                                                                               | 50 |

## LISTA DE TABELAS

|                                                                                                                                |    |
|--------------------------------------------------------------------------------------------------------------------------------|----|
| Tabela 1: Divisão dos dados para validação do método através da técnica de validação cruzada utilizando o método 10-Fold. .... | 39 |
| Tabela 2: Acurácia de cada classe e acurácia média por voluntário obtidas com os dados do conjunto 1. ....                     | 44 |
| Tabela 3: Acurácia de cada classe e acurácia média por voluntário obtidas com os dados do conjunto 2. ....                     | 45 |
| Tabela 4: Acurácia de cada classe e acurácia média por voluntário obtidas com os dados do conjunto 1 e 2. ....                 | 45 |
| Tabela 5: Novos atributos obtidos através da PCA. ....                                                                         | 46 |
| Tabela 6: Resultados para os novos atributos compostos por CP para o conjunto 1. ....                                          | 48 |
| Tabela 7: Resultados para os novos atributos compostos por CP para o conjunto 2. ....                                          | 49 |
| Tabela 8: Resultados para os novos atributos compostos por CP para todos os dados. ....                                        | 49 |

## **LISTA DE ABREVIATURAS E SIGLAS**

AM - Aprendizado de Máquina

BioLab - Laboratório de Engenharia Biomédica

CP - Componente Principal

DT - Domínio do Tempo

EMG - Eletromiografia

FEELT - Faculdade de Engenharia Elétrica

MAV - Mean Absolute Value

OVO - One-Versus-One

P1 - Altura dos Eletrodos 1

P2 - Altura dos Eletrodos 2

PCA - Principal Component Analysis

RMS - Root Mean Square

SRM - Minimização do Risco Estrutural

SSC - Slope Sign Changes

SVM - Support Vectors Machine

UFU - Universidade Federal de Uberlândia

VAR - Variância

ZC - Zero-Crossings

## SUMÁRIO

|       |                                                                   |    |
|-------|-------------------------------------------------------------------|----|
| 1     | INTRODUÇÃO.....                                                   | 12 |
| 2     | REVISÃO BIBLIOGRÁFICA .....                                       | 15 |
| 2.1   | SINAIS MIOELÉTRICOS .....                                         | 15 |
| 2.2   | APRENDIZADO DE MÁQUINA.....                                       | 17 |
| 2.3   | MÁQUINAS DE VETORES DE SUPORTE - SVM.....                         | 20 |
| 2.3.1 | Um-Contra-Um .....                                                | 24 |
| 2.4   | EXTRAÇÃO DE ATRIBUTOS .....                                       | 25 |
| 2.4.1 | <i>Mean Absolute Value</i> (MAV) .....                            | 25 |
| 2.4.2 | <i>Waveform Length</i> (WL).....                                  | 25 |
| 2.4.3 | <i>Signal Variance</i> (VAR).....                                 | 26 |
| 2.4.4 | <i>Slope Sign Change</i> (SSC).....                               | 26 |
| 2.4.5 | <i>Zero-Crossings</i> (ZC).....                                   | 26 |
| 2.4.6 | <i>Root Mean Square</i> (RMS) .....                               | 26 |
| 2.5   | ANÁLISE DE COMPONENTES PRINCIPAIS – PCA.....                      | 27 |
| 3     | CONTROLE DE PRÓTESES - ESTADO DA ARTE .....                       | 29 |
| 3.1   | PRÓTESES ACIONADAS POR TIRANTES .....                             | 29 |
| 3.2   | PRÓTESES BASEADAS EM CONTROLE MIOELÉTRICO.....                    | 30 |
| 4     | PROPOSTA DE UM SISTEMA CLASSIFICAÇÃO DE SINAIS EMG GENÉRICO<br>32 |    |
| 5     | METODOLOGIA .....                                                 | 33 |
| 5.1   | GRUPO AMOSTRAL E AQUISIÇÃO DE DADOS .....                         | 33 |

|       |                                   |    |
|-------|-----------------------------------|----|
| 5.2   | PROCEDIMENTO EXPERIMENTAL .....   | 33 |
| 5.2.1 | DEFINIÇÃO DOS MOVIMENTOS .....    | 33 |
| 5.2.2 | POSICIONAMENTO DE ELETRODOS ..... | 34 |
| 5.2.3 | TAREFA .....                      | 35 |
| 5.3   | PROCESSAMENTO DE DADOS .....      | 37 |
| 5.4   | CLASSIFICAÇÃO .....               | 39 |
| 6     | RESULTADOS E DISCUSSÃO .....      | 41 |
| 7     | CONCLUSÃO .....                   | 51 |
| 7.1   | TRABALHOS FUTUROS .....           | 51 |
| 8     | REFERÊNCIAS BIBLIOGRÁFICAS .....  | 52 |

## 1 INTRODUÇÃO


O ser humano é capaz de realizar diversas tarefas cotidianas sem muita dificuldade. Porém, para um portador de deficiência física, a realização de determinadas tarefas do dia-a-dia pode se tornar algo extremamente difícil, ou, em alguns casos, até mesmo impossível. Essa incapacidade pode gerar problemas sérios para o indivíduo, como exemplo a dificuldade de integração social (FAVIEIRO, 2009). O avanço tecnológico nas últimas décadas possibilitou o desenvolvimento de inúmeras áreas de pesquisa relacionadas à reabilitação humana, proporcionando um aumento significativo na qualidade de vida das pessoas. Desse modo, diversas técnicas foram desenvolvidas, capazes de recuperar parcialmente ou totalmente a independência de pessoas que possuem deficiência física.

Uma das técnicas mais antigas desenvolvidas pelo ser humano é a utilização de próteses para suprir a falta do membro perdido. A utilização de próteses vem crescendo a cada dia, com mecanismos cada vez mais modernos, que são capazes reproduzir movimentos muito precisos e próximos da realidade. O controle de próteses através da utilização de sinais EMG é uma das abordagens de maior ascensão nas últimas décadas, tendo em vista que esses sinais têm sido amplamente utilizados e aplicados como um sinal de controle em inúmeras aplicações de interface homem-máquina, clínicas e industriais (PANDEY e MISHRA, 2009). Além disso, os sinais EMG contêm informações ricas, de modo que a intenção do usuário pode ser detectada na forma de uma contração muscular (OSKOEI e HU, 2007). Porém, como a geração desses sinais é eventualmente afetada por inúmeras variáveis fisiológicas e não fisiológicas (JAMAL, WARIS e NAZIR, 2011), o seu uso direto para controle de próteses não é recomendado. Portanto, torna-se importante buscar estratégias capazes de reduzir o efeito dessas variáveis antes da interpretação desses sinais (VEER e SHARMA, 2016).

As estratégias mais triviais de controle de próteses mioelétricas utilizam a variação da amplitude do sinal EMG para controlar os dispositivos protéticos. Dentre as mais conhecidas estão controle por modo liga-desliga (*on-off*) ou proporcional. Nesses casos, os sinais EMG são gravados a partir de um ou dois eletrodos e processados por filtragem passa-faixa, retificação e filtragem passa-baixa para obter a envoltória

do sinal EMG (Figura 1). Em seguida, um limiar é estipulado para determinar o nível mínimo de contração necessário para iniciar o movimento. O modo de controle *on-off* é apropriado para um máximo de dois graus de liberdade e a mão protética é operada a uma velocidade constante. Já no modo de controle mioelétrico proporcional, a potência enviada para o motor é proporcional à amplitude do sinal EMG. Seguindo esse princípio, quando o músculo está inativo, o motor não recebe energia do controlador, e quando o músculo está totalmente contraído, o motor produz torque máximo em torno da articulação que ele controla (FERRIS, CZERNIECKI e HANNAFORD, 2005). Porém, os esquemas on-off e controle proporcional possuem algumas desvantagens, tendo em vista que são métodos de controle lentos, pouco intuitivos e extremamente afetados pela co-ativação muscular. Além disso, são capazes de proporcionar poucos graus de liberdade em relação aos inúmeros movimentos realizados pelas mãos. Essas desvantagens tornam necessária a busca por novas estratégias para controle de próteses que sejam mais robustas, acuradas e que proporcionem vários graus de liberdade.

*Figura 1: Diagrama esquemático de um sistema de controle de próteses.*



A extração de atributos é uma estratégia para obter informações úteis que estão ocultas no sinal EMG e remover interferências indesejadas (BOOSTANI e MORADI, 2003). Assim, essa técnica é uma ferramenta de grande importância para alcançar um bom desempenho na classificação de sistemas de reconhecimento de padrões EMG (PHINYOMARK, LIMSAKUL e PHUKPATTARANONT, 2011). Porém, é importante a extração de atributos relevantes, os quais possuem uma alta variabilidade dos dados e são capazes discernir melhor diferentes movimentos gerados pelo usuário.

A partir da extração atributos são utilizados métodos de classificação capazes de realizar distinção entre duas ou mais classes de movimentos, como Regressão Linear, Regressão Logística, SVM, Redes Neurais, etc. Esses métodos são capazes de classificar diferentes movimentos com alta acurácia. Porém, o controle de próteses

através de sinais EMG exige que o braço fique em constante movimento, podendo gerar diversos problemas, como uma possível mudança de posicionamento dos eletrodos colocados sobre o músculo. Além disso, considerando que houveram alterações na estrutura cortical e dos músculos remanescentes do amputado (HASHIM, ROWLEY, *et al.*, 2015), a classificação pode gerar resultados não tão satisfatórios como o esperado. Assim, é necessário que o método seja mais genérico e robusto, capaz de manter uma boa classificação independentemente da posição onde o sinal EMG for coletado.

Neste trabalho foi proposto o desenvolvimento de um classificador que seja genérico e robusto, capaz de gerar uma classificação com alta acurácia independentemente da posição onde os eletrodos forem posicionados. Para isso, foram utilizadas técnicas como Maquinas de Vetores de Suporte (SVM) e Análise de Componentes Principais (PCA). Além disso, o trabalho busca encontrar os melhores atributos para serem extraídos do sinal EMG, os quais são capazes de manter uma alta variabilidade dos dados para as diferentes posições dos eletrodos testadas.

No próximo tópico será feita uma revisão bibliográfica para um maior embasamento teórico em pontos importantes, como definição e captação sinais mioelétricos, conceitos de aprendizado supervisionado em aprendizado de máquina, definição de SVM e seu uso para classificação de sinais EMG e definição de PCA e sua grande utilidade para redução de dimensionalidade de dados. Estes fundamentos foram de extrema importância para a elaboração deste trabalho.


Posteriormente, é feita uma revisão do Estado-da-Arte sobre desenvolvimento de próteses mioelétricas para a área clínica, com o objetivo de ilustrar o cenário atual do mercado e das pesquisas sobre o desenvolvimento de próteses mioelétricas para membros superiores. Na sequência, será apresentada a proposta geral, experimentos de validação, resultados obtidos, discussão e conclusão do trabalho.

## 2 REVISÃO BIBLIOGRÁFICA

### 2.1 SINAIS MIOELÉTRICOS

O sinal EMG é a manifestação elétrica da ativação neuromuscular associada a um músculo em contração. É a soma algébrica de todas as unidades motoras ativas dentro da área de captação do eletrodo (BASMAJIAN e DE LUCA, 1985). Esses sinais são gerados a partir de atividades eletroquímicas de determinados tipos de células, (células excitáveis) as quais são componentes de tecidos nervosos, musculares e glandulares (KITCHEN, 1998).

*Figura 2: Caminho dos potenciais de ação até a junção neuromuscular. Adaptado de (MAMBRITO e DE LUCA, 1983)*



Quase todas as contrações realizadas pelos músculos esqueléticos ocorrem como resultado do esforço consciente originado no cérebro (exceto para movimentos gerado por reflexos). O cérebro envia sinais eletroquímicos através do sistema nervoso para o neurônio motor que inerva várias fibras musculares (TASSINARY, CACIOPPO e VANMAN, 2000). Essa junção formada pela fibra muscular e uma terminação de um neurônio motor é chamada de junção neuromuscular (LEVITAN e KACZMAREK, 2015). É a região onde o neurônio motor transmite o potencial de ação responsável pela realização da contração muscular. Esse potencial de ação gerado


se propaga ao longo de toda a membrana muscular, gerando a contração muscular (HALL, 2011). Um neurônio muscular é capaz de inervar várias fibras musculares, fazendo com que as fibras se contraíam ao mesmo tempo (Figura 2). O conjunto de todas as junções neuromusculares formadas por todas as fibras musculares que um único neurônio motor inerva é chamado de unidade motora. O conjunto dos potenciais de ação da unidade motora compõem o sinal EMG. O sinal EMG possui uma amplitude muito baixa, na faixa de 0 a 10 mV (pico a pico). Sua frequência está entre 0 e 500 Hz, porém, a faixa de energia dominante está entre 50 a 150 Hz (DE LUCA, 2002).

A aquisição de sinais EMG é feita através de transdutores que tem como finalidade converter uma forma de energia em outra. No caso de sinais EMG o transdutor é responsável por transformar a corrente iônica em corrente elétrica. O transdutor mais utilizado é o eletrodo não polarizado de cloreto de prata (Ag/AgCl), pois possui um potencial de eletrodo baixo e é de fácil manutenção (MOURA e VIRATO, 2008). As duas formas mais utilizadas para registrar os sinais EMG são configuração monopolar e bipolar. Na configuração monopolar um eletrodo é colocado sobre o ventre do músculo e outro eletrodo em uma posição de referência. O sinal entre os dois eletrodos é amplificado e registrado. Na configuração bipolar dois eletrodos são colocados sobre o ventre do músculo (normalmente com uma distância entre 1 a 2 cm um do outro) e outro eletrodo em uma posição um pouco mais afastada para ser a referência. O sinal entre os dois eletrodos sobre o ventre do músculo é amplificado diferencialmente em relação à referência eletrodo. A vantagem nesta configuração é que o ruído comum entre os dois eletrodos é eliminado e, portanto, o sinal EMG captado estará sujeito a uma menor quantidade de interferências.

Outro ponto importante a ser destacado é quanto ao posicionamento dos eletrodos, que podem alterar drasticamente a forma do sinal. A Figura 3 mostra a captação de sinais EMG em quatro diferentes posições sobre o músculo. O sinal de maior amplitude e normalmente escolhido para posicionamento de eletrodos é no centro do ventre do músculo, pois é a posição de que capta a maior quantidade de potenciais de ação de todas as unidades motoras presentes no músculo. O desempenho de algoritmos de Aprendizado de Máquina usados para classificação de

sinais EMG é extremamente afetado pelo posicionamento dos eletrodos. Uma pequena variação na posição pode gerar resultados bem abaixo do esperado.

*Figura 3: Sinal EMG coletado para diferentes posicionamentos dos eletrodos. O esquema apresenta eletrodos posicionados a) na inervação do músculo, b) no centro do ventre muscular, c) na lateral do meio do músculo e d) na junção miotendínea. Adaptado de (TECHNOLOGIES, 2015)*




## 2.2 APRENDIZADO DE MÁQUINA

O Aprendizado de Máquina (AM), ou do inglês *Machine Learning* é uma aplicação de inteligência artificial no campo da ciência da computação que utiliza de técnicas estatísticas para dar aos computadores a capacidade de aprender, ou seja, melhorar progressivamente o desempenho de uma tarefa específica, sem serem explicitamente programados. Pode-se dizer que AM é uma ciência que busca fazer com que um computador aprenda como os humanos, melhorando seu aprendizado ao longo do tempo de maneira autônoma, a partir de conhecimentos obtidos de observações e iterações com o mundo real. O objetivo fundamental dos algoritmos de AM é fazer com que o computador seja capaz de generalizar a partir das amostras de treinamento, ou seja, interpretar de forma correta dados os quais nunca haviam sido mostrados antes. O aprendizado de máquina é usado em pesquisas na Web, filtros de spam, sistemas de recomendação, anúncios, pontuação de crédito, detecção de fraudes, negociação de ações, design de medicamentos, e muitas outras aplicações

(DOMINGOS, 2012). O AM pode ser dividido em dois tipos principais: supervisionado e não-supervisionado.

No aprendizado supervisionado, há um ensinamento prévio, indicando para o algoritmo de AM qual é a saída desejada de acordo com a entrada fornecida. Ou seja, a partir de variáveis de entrada  $x$  e saída  $y$ , o algoritmo é usado para aprender a função de mapeamento da entrada para saída:  $y = f(x)$ . O objetivo é utilizar um conjunto de exemplos (dados de treino) para treinar o algoritmo de forma com que ele seja capaz de gerar uma função de mapeamento genérica para novas variáveis de entrada (dados de teste), mantendo um bom índice de acerto na classificação. A entrada  $x$  indica um exemplo e a saída  $y$  indica sua resposta, assim, deve-se produzir um classificador, também denominado modelo, preditor ou hipótese, capaz de prever precisamente a resposta para novos dados. Esse processo que gera uma função de mapeamento a partir de um conjunto de dados exemplo/resposta é denominado treinamento (LORENA e CARVALHO, 2007). As respostas também podem ser denominadas de classes, as quais representam o fenômeno sobre o qual deseja-se fazer previsões. A Figura 4 exemplifica um conjunto com  $n$  dados, onde para cada um dos dados existem  $m$  atributos. Pode-se definir atributos como diferentes tipos de características que são extraídas dos dados. Já as variáveis  $y$  indicam as classes, ou seja, as respostas para cada um dos exemplos.

Figura 4: Matriz de dados exemplo/resposta fornecidas ao algoritmo AM para gerar a função de mapeamento. Adaptado de (LORENA e CARVALHO, 2007).




No aprendizado não-supervisionado não é fornecida a saída desejada para o algoritmo AM, o qual aprende a representar as variáveis de entrada segundo uma

medida de qualidade. O objetivo central dessa técnica é encontrar padrões ou tendências que auxiliem no entendimento dos dados (SOUTO, LORENA, *et al.*, 2003).

A habilidade de generalização de um classificador é um conceito de grande importância em AM, pois demonstra a sua capacidade de conseguir boas previsões na análise de novos dados não vistos enquanto ele estava aprendendo. Existem dois conceitos que estão atrelados a quão genérico um classificador pode ser: sobreajustamento (*overfitting*) e sub-ajustamento (*underfitting*). O *overfitting* ocorre quando um modelo aprende os detalhes e o ruído nos dados de treinamento (*outliers*), isso afeta negativamente o desempenho do modelo em novos dados, pois estes *outliers* dos dados de treinamento são captados e aprendidos como conceitos pelo modelo. O problema é que esses conceitos não se aplicam a novos dados e afetam negativamente a capacidade de generalização dos modelos. Já o caso de *underfitting* ocorre quando o modelo se mostra pouco representativo, fazendo com que ele apresente baixas taxas de acerto. Isso significa que o modelo não se ajustou bem aos dados. Para gerar um modelo ideal é necessário encontrar um equilíbrio entre ambos os casos, de forma que o modelo seja capaz de descartar *outliers* mantendo um bom ajustamento aos dados (Figura 5).

Figura 5: Modelos de classificadores para problemas binários a) ocorrência de *overfitting*, b) modelo ideal e c) ocorrência de *underfitting*.



Existem diversas técnicas de AM que utilizam da estratégia de aprendizado supervisionado e são capazes de gerar um ótimo desempenho. Dentre essas técnicas é possível encontrar aplicações utilizando inteligência artificial, como redes neurais artificiais, algoritmos genéticos e lógica difusa. Existem também técnicas de classificadores estatísticos e recentemente, SVM mostrou melhorar o desempenho em diversas tarefas de classificação. A principal vantagem do SVM está relacionada


à sua solução global e única que permite com que ele não sofra com o problema de múltiplos mínimos locais, como redes neurais artificiais (LEÓN, GUTIÉRREZ, *et al.*, 2011). Além disso, a complexidade final desse modelo não depende da dimensionalidade do espaço de entrada, pois ele opera no princípio de indução de Minimização do Risco Estrutural (SRM), o que torna o modelo de SVM menos suscetível ao problema de overfitting. Este trabalho utiliza SVM como técnica de classificação, pois os fatores relatados acima o tornam uma ferramenta excelente para a classificação de sinais EMG.

### 2.3 MÁQUINAS DE VETORES DE SUPORTE - SVM

O conceito de Máquina de Vetores de Suporte, do inglês *Support Vector Machine* (SVM) foi introduzido inicialmente por Vapnik e Chervonenkis em 1965. Consiste em uma técnica de aprendizado supervisionado do campo de aprendizado de máquina aplicável tanto à classificação quanto à regressão. É baseado no princípio da minimização do risco estrutural, do inglês *Structural Risk Minimization* (SRM) e tem como objetivo encontrar o melhor hiperplano, capaz de maximizar a margem de separação entre as classes.

Existem infinitos hiperplanos que são capazes de realizar a separação entre duas classes. Na Figura 6 são ilustrados três exemplos que separam as duas classes de acordo com os dados de treinamento. Porém, se o modelo gerar um hiperplano mais próximo a uma das classes (hiperplanos A e C) pode passar a classificar incorretamente quando confrontado com novos dados de teste. Isso faz com que seja crucial obter o hiperplano que consiga a máxima margem entre as duas classes (hiperplano B) para aumentar o desempenho do classificador. Para encontrar o hiperplano ideal, o qual maximiza a margem entre as classes são utilizados vetores de suporte, que são as amostras do conjunto de treinamento de ambas as classes que estão mais próximas.

Figura 6: Exemplo de três hiperplanos que separam de forma correta o conjunto de treino. Porém somente o hiperplano B continua separando bem o conjunto de teste.



Pode-se definir o conjunto  $P$  que treina o classificador de SVM como:

$$P = \{(x_i, y_i) | x_i \in \mathbb{R}^k, y_i \in \{-1, 1\}\}_{i=1}^n$$

Onde  $x_i$  representa um vetor com os exemplos de entrada contendo  $k$  atributos, enquanto  $y_i$  representa um vetor com a resposta ou classe de cada exemplo. O objetivo é encontrar o hiperplano que tenha a máxima distância do conjunto de dados  $x_i$  de acordo com sua classe, sendo ela  $y_i = +1$  ou  $y_i = -1$ .

Um hiperplano pode ser escrito como o conjunto de pontos  $\vec{x}$  satisfazendo:

$$\vec{w} \cdot \vec{x} - b = 0,$$

Onde  $\vec{w}$  é o vetor normal para o hiperplano ou vetor de peso e o  $b$  é o viés. Assim, se os dados forem linearmente separáveis é possível selecionar dois hiperplanos paralelos, fazendo com que a distância entre as duas classes seja máxima (BURBIDGE, TROTTER, *et al.*, 2001). A região entre os dois hiperplanos que separam as duas classes é chamada de margem. A equação desses hiperplanos pode ser definida como:

$$\vec{w} \cdot \vec{x} + b = +1 \quad \text{e} \quad \vec{w} \cdot \vec{x} + b = -1$$

A distância entre os dois hiperplanos é igual a  $\frac{2}{\|\vec{w}\|}$ . Dessa forma, para maximizar a distância entre os hiperplanos é necessário minimizar o valor de  $\|\vec{w}\|$ . O hiperplano ideal o qual maximiza a margem entre as duas classes está exatamente entre os dois hiperplanos base, consequentemente, a distância entre ele e cada classe é igual a  $\frac{1}{\|\vec{w}\|}$ . Além disso, para impedir que os pontos estejam dentro da margem e minimizar o valor de  $\|\vec{w}\|$ , torna-se necessária a seguinte restrição para cada  $i$ :

$$\vec{w} \cdot \vec{x} + b \geq +1, \text{ se } y_i = +1$$

$$\vec{w} \cdot \vec{x} + b \leq -1, \text{ se } y_i = -1$$

Essas inequações podem ser combinadas para fornecer (BURGES, 1998):


$$y_i(\vec{w} \cdot \vec{x}_i + b) \geq 1, \text{ para todo } 1 \leq i \leq n$$

Esse tipo de problema é chamado de problema de otimização quadrática. A solução para esse problema matemático nos leva à conclusão de que o resultado da etapa de aprendizado é obtido de forma que o hiperplano ideal é calculado pela combinação linear dos elementos do conjunto de treino, e a predição de  $f(x)$  para um novo exemplo  $x$  é da seguinte forma (PARRELLA, 2007):

$$f(x) = \text{sign}\left(\sum_{i=1}^n y_i \alpha_i (\vec{x} \cdot \vec{x}_i) + b\right)$$

Onde  $n$  é o número de elementos no conjunto de treino,  $\alpha$  e  $b$  compõem os parâmetros que o SVM usa para construir um modelo capaz de obter uma solução ideal. A consequência mais importante desta descrição geométrica é que o hiperplano de margem máxima é completamente determinado por aqueles  $\vec{x}_i$  os quais mais aproximam as classes  $y_i = +1$  e  $y_i = -1$ . Estes  $\vec{x}_i$  são chamados vetores de suporte (Figura 7).

Figura 7: Escolha dos vetores de suporte de acordo com os dados de ambas as classes mais próximos.



Em alguns casos, quando existem algumas amostras das classes que estão muito próximas, pode não ser possível uma separação sem nenhum erro. Assim, torna-se necessário acrescentar parâmetros que permitam com que o modelo se adeque aos dados, tornando alguns erros toleráveis ao modelo de SVM. A função que exemplifica o problema pode ser adaptada para a seguinte forma:

$$\min_w \rightarrow \frac{1}{2} \|\vec{w}\|^2 + C \sum_{i=1}^n \xi_i$$


$$y_i(\vec{w} \cdot \vec{x}_i + b) \geq 1 - \xi_i, \text{ para todo } \xi_i \geq 0 \text{ e } 1 \leq i \leq n$$

Onde  $\xi_i$  e  $C$  são parâmetros que definem a máxima tolerância para o erro. Quanto maior o valor do parâmetro  $C$  maior será a tolerância. Encontrar o valor certo é muito complicado e há uma vasta literatura sobre como escolher os melhores valores. Geralmente, a técnica mais usada é encontrá-las por tentativa e erro.

O que foi mostrado até aqui é a ideia básica por trás da técnica de SVM, onde o problema possui uma solução que pode ser representada por uma linha que divide as classes de forma linear. Porém existem problemas um pouco mais complexos, como conseguir separar classes que estão dispostas de forma que é impossível realizar uma separação linear (Figura 8). Nos exemplos apresentados, cada amostra é multiplicada pelo valor dos exemplos treinados. Porém, é possível utilizar operações mais complexas capazes de alterar o resultado final, em vez de uma simples multiplicação.

Por exemplo, a expressão  $(\vec{x} \cdot \vec{x}_i)$  apresentada pode ser substituída por outra função, chamada de função Kernel, a qual permite aumentar a dimensionalidade da solução. Essa elevação na dimensão dos dados tem a intensão de tornar os problemas que antes eram impossíveis de serem separados linearmente, em problemas com uma possível solução linear a partir de hiperplanos gerados nessa nova dimensão. Isso nos permite classificar melhor os exemplos, gerando modelos que se adequam melhor ao conjunto de dados. Essa característica da técnica de SVM aumenta sua usabilidade e, conseqüentemente, aumenta sua complexidade, já que agora novos parâmetros como o  $C$  e o tipo de função Kernel a ser utilizada foram adicionados.

*Figura 8: Exemplo do uso da função de kernel para transformar problemas não linearmente separáveis para linearmente separáveis em um espaço de maior dimensão.*



Outro fator que torna o problema ainda mais complexo é a quantidade de classes. Geralmente, não enfrentamos problemas binários, mas sim problemas multiclases. Para isso, existem métodos como Um-Contra-Um, Um-Contra-Todos, etc. O método utilizado neste trabalho foi o Um-Contra-Um.

### 2.3.1 Um-Contra-Um

Um-Contra-Um, do inglês *One-Versus-One* (OVO), também conhecido como classificação de pares é um método de classificação de multiclases que emparelha um conjunto de dados de uma classe com outro conjunto de dados de outra classe para aprendizagem. Esse emparelhamento acontece para todas as classes existentes, de forma a combinar cada uma das classes umas com as outras formando pares. Assim, o número de modelos gerados depende do número de classes, seguindo a seguinte equação:

$$M = n \frac{(n-1)}{2}$$

Onde  $M$  é o número de modelos gerados e  $n$  é igual ao número de classes. Ou seja, se existem 5 classes de dados, o número de modelos gerados é igual a 10. Nesse método, cada classe é emparelhada com outra classe, um por um, formando um problema binário. No final da classificação (na fase de testes), cada classificação recebe um voto para a classe vencedora. Os votos mais altos determinarão a qual classe cada amostra do conjunto de teste pertence.

## 2.4 EXTRAÇÃO DE ATRIBUTOS

A escolha de um conjunto de atributos desempenha papel significativo no desempenho de um sistema de reconhecimento de padrões. Estudos passados (OSKOEI e HU, 2007) mostraram a grande eficiência da extração e uso de atributos do domínio do tempo (DT), pois possuem alta taxa de precisão, estabilidade contra a variação do comprimento do segmento, baixa alteração em sessões repetidas e simplicidade computacional. *Mean Absolute Value* (MAV), *Waveform Length* (WL), *Signal Variance* (VAR), *Slope Sign Change* (SSC), *Zero-Crossings* (ZC) e *Root Mean Square* (RMS) são alguns dos principais atributos do DT que podem ser extraídos de um sinal EMG. Desta forma, esses atributos foram escolhidos para este trabalho.

### 2.4.1 Mean Absolute Value (MAV)

MAV é o valor absoluto médio do sinal EMG em uma janela de tempo. MAV pode ser calculada como:

$$MAV = \frac{1}{N} \sum_{k=1}^N |x_k|$$

Onde  $x_k$  é a  $k$ -ésima amostra de uma janela de dados de tamanho  $N$ .

### 2.4.2 Waveform Length (WL)

WL é a variação acumulativa do sinal EMG. Ela pode indicar o grau de variação sobre o sinal EMG. WL pode ser calculado como:

$$WL = \sum_{k=1}^{N-1} (|x_{k+1} - x_k|)$$

### 2.4.3 Signal Variance (VAR)

VAR é a medida da potência do sinal EMG em uma janela de tempo. VAR pode ser calculado como:

$$VAR = \frac{1}{N-1} \sum_{k=1}^N x_k^2$$

### 2.4.4 Slope Sign Change (SSC)

SSC é a somatória de todas as vezes em que há uma mudança na inclinação da forma de onda do sinal em uma janela de tempo. SSC pode ser calculado como:

$$SSC = \sum f(x) \text{ onde, } f(x) = \begin{cases} 1, \text{ se } (x_k < x_{k+1}) \text{ e } (x_k < x_{k-1}) \\ 1, \text{ se } (x_k > x_{k+1}) \text{ e } (x_k > x_{k-1}) \\ 0, \text{ para outras condições} \end{cases}$$

### 2.4.5 Zero-Crossings (ZC)

ZC é a somatória de todas as vezes em que o sinal EMG cruzou o eixo zero em uma janela de tempo no DT. ZC pode ser calculado como:

$$ZC = \sum f(x) \text{ onde, } f(x) = \begin{cases} 1, \text{ se } (x_k > 0) \text{ e } (x_{k+1} < 0) \\ 1, \text{ se } (x_k < 0) \text{ e } (x_{k+1} > 0) \\ 0, \text{ para outras condições} \end{cases}$$

### 2.4.6 Root Mean Square (RMS)

RMS é a raiz do valor quadrático médio do sinal EMG em uma janela de tempo. Também conhecido como valor eficaz e é utilizado como uma medida estatística da magnitude. RMS pode ser calculada como:


$$RMS = \sqrt{\frac{1}{N} \sum_{k=1}^N x_k^2}$$

## 2.5 ANÁLISE DE COMPONENTES PRINCIPAIS – PCA

A Análise de Componentes Principais, do inglês *Principal Component Analysis* (PCA) é um método que tem por finalidade básica, a análise dos dados usados visando sua redução, eliminação de sobreposições e a escolha de formas mais representativas de dados a partir de combinações lineares das variáveis originais (VASCONCELOS, 2013). Os principais objetivos da PCA são extrair as informações mais importantes da tabela de dados, compactar o tamanho do conjunto de dados mantendo apenas essas informações importantes, simplificar a descrição do conjunto de dados e analisar a estrutura das observações e as variáveis (ABDI e WILLIAMS, 2010).

O PCA analisa uma tabela de dados representando observações descritas por várias variáveis dependentes, que são, em geral, inter-correlacionadas. Esse conjunto de novas variáveis ortogonais são chamadas de componentes principais. O número de componentes principais é menor ou igual ao número de variáveis originais, de forma que a primeira componente principal é responsável pela máxima variabilidade nos dados e cada componente seguinte, por sua vez, tem a máxima variância sob a restrição de ser ortogonal aos componentes precedentes. A somatória de todas as componentes principais indica toda a variabilidade dos dados originais. Dessa forma, podem ser usadas a quantidade de componentes principais que juntas representam suficientemente bem os dados originais sem perdas significativas na variabilidade do conjunto de dados. A Figura 9 ilustra um exemplo de transformação de um conjunto de dados com três dimensões para um novo conjunto de dados com duas dimensões formados pelas duas primeiras componentes principais dos dados originais.

Figura 9: Transformação de um conjunto de dados de três para duas dimensões, formado pelas duas componentes principais de maior variância.




A PCA se tornou uma excelente ferramenta em AM, principalmente em aplicações de compactação de dados. Pois em muitos casos existe uma ampla quantidade de atributos, tornando o algoritmo pouco otimizado e de difícil análise.

### 3 CONTROLE DE PRÓTESES - ESTADO DA ARTE

#### 3.1 PRÓTESES ACIONADAS POR TIRANTES

A maioria das próteses de membros superiores disponíveis comercialmente são acionadas por tirantes ou por sinais mioelétricos. As próteses acionadas por tirantes são operadas por certos movimentos dos amputados através de um sistema de cabos, tirantes e, às vezes, controle manual. A utilização dessa abordagem depende do nível de amputação do usuário, pois para operar esse tipo de prótese, os amputados devem possuir força e controle significativos sobre algumas partes do corpo, como ombros e tórax, os quais precisam ter musculatura e amplitude de movimento suficientes. Os movimentos são capturados por sistemas de tirantes e são transferidos através de cabos para operar os movimentos da mão, punho ou cotovelo de uma prótese (Figura 10). Esse sistema possui algumas vantagens, como exemplo, baixo custo, alta confiabilidade e modo de uso intuitivo, o que faz com que essa abordagem atualmente seja amplamente aceita por amputados de membros superiores. Porém em alguns casos, esse tipo de abordagem pode se tornar inadequado, pois estas próteses são limitadas em utilidade, lentas para operar, difíceis de manter e podem operar apenas uma articulação de cada vez (LI, 2011). Aproximadamente metade do mercado atual de próteses de membros superiores é de fato baseado em sistemas acionados por tirantes (VUJAKLIJA, FARINA e ASZMANN, 2016).

Figura 10: Exemplo de prótese acionada por tirantes. Adaptado de (Prosthetic & Orthotic Care).




### 3.2 PRÓTESES BASEADAS EM CONTROLE MIOELÉTRICO

Uma outra abordagem um pouco mais sofisticada baseia-se no controle de próteses através de sinais EMG. Essas próteses surgiram por volta de 1940, porém, devido às limitações da tecnologia da época, as próteses mioelétricas não eram viáveis em aplicações clínicas. Assim, um progresso relevante da área ocorreu somente no final da década de 1960, em consequência do avanço tecnológico, principalmente em tecnologias eletrônicas. Desde então, uma ampla variedade de esquemas de controle foram desenvolvidos para traduzir as informações contidas no sinal EMG, como controle *on-off*, controle proporcional, controle baseado em reconhecimento de padrões, etc. (GEETHANJALI, 2016). O conceito de controle proporcional ainda está presente nos atuais sistemas comercialmente disponíveis, devido à sua simplicidade e robustez (VUJAKLIJA, FARINA e ASZMANN, 2016).

Os primeiros esquemas de controle baseados em reconhecimento de padrões foram desenvolvidos no início da década de 1970. Desde então, melhorias no processamento de sinal, instrumentação de múltiplos canais e tecnologia de microprocessadores facilitaram a implementação em sistemas de controle embarcados. As últimas décadas testemunharam uma melhoria notável na eficiência de classificação desses algoritmos baseados em reconhecimento de padrões, utilizando diferentes tipos de recursos e classificadores para reconhecimento de padrões de sinais EMG. Assim, essa forma de controle emergiu como o método mais promissor para operar as próteses de membros superiores de maneira intuitiva e fácil. Além disso, procedimentos cirúrgicos inovadores, como a reinervação muscular direcionada (TMR) (Figura 11), tornaram possível a captação e utilização de sinais EMG associados ao membro perdido. Isso ajudou a usar controles baseados em reconhecimento de padrões mesmo nos casos de amputação a acima do cotovelo (KUIKEN, LI, *et al.*, 2009). Através dos esforços de muitas iniciativas acadêmicas e comerciais, o controle baseado em reconhecimento de padrões se aproxima cada vez mais da viabilidade clínica (SCHEME e ENGLEHART, 2011). Porém, não existem muitas próteses baseadas em reconhecimento de padrões lançadas no mercado atualmente. Apenas um sistema foi lançado em 2014 pela empresa COAPT, porém ainda não se sabe até que ponto esse sistema será aceito no mercado. Isso reafirmou

a descoberta de que somente a precisão da classificação não levava automaticamente à boa usabilidade de um controlador.

*Figura 11: Reinervação muscular direcionada dos nervos periféricos ao peitoral maior para amputação na desarticulação do ombro. Adaptado de (STUBBLEFIELD, MILLER, et al., 2009)*




Numerosos estudos foram conduzidos nas últimas duas décadas, ainda indicando altas taxas de rejeição de todos os tipos de dispositivos protéticos de membros superiores em grande parte dos usuários. Dependendo da população em estudo, as taxas de rejeição variam de 25% a mais de 50% para próteses mioelétricas e até 35% para próteses acionadas por tirantes (VUJAKLIJA, FARINA e ASZMANN, 2016). No entanto, esses números se estabilizaram em relação a períodos anteriores, principalmente devido à tecnologia moderna.

## 4 PROPOSTA DE UM SISTEMA CLASSIFICAÇÃO DE SINAIS EMG GENÉRICO

O trabalho em questão propõe o desenvolvimento de um sistema de classificação de sinais EMG baseado na técnica de SVM capaz de gerar um modelo mais genérico, mantendo um bom desempenho independentemente se a posição dos eletrodos for alterada. Para isso foram realizadas coletas de sinais EMG através de um conjunto de quatro eletrodos posicionados em duas diferentes alturas do antebraço.

Figura 12: Diagrama de blocos das principais etapas do sistema.



O diagrama de blocos ilustrado na Figura 12 representa as principais etapas do sistema, sendo elas, aquisição, processamento e janelamento dos dados, extração de atributos, classificação das amostras da posição 1, 2 e para todas as amostras. Por fim, foi feita uma comparação do desempenho para cada um dos conjuntos de dados. Essas etapas foram descritas de forma detalhada no próximo tópico.

## 5 METODOLOGIA

### 5.1 GRUPO AMOSTRAL E AQUISIÇÃO DE DADOS

Para a realização das coletas de sinais EMG, foram selecionados 6 voluntários saudáveis com idades entre 20 e 23 anos, os quais não possuíam nenhuma disfunção motora. Entre eles, 5 do sexo masculino e 1 do sexo feminino.

Foi utilizado o Eletromiógrafo MyosystemBr1-P84 (DataHominis Tec Ltda) para aquisição dos sinais EMG (Figura 13). Foram utilizados 4 canais, os quais possuíam dois eletrodos diferenciais ativos. A taxa de amostragem foi definida em 2kHz e os sinais de cada canal foram filtrados por um filtro passa-faixa Butterworth de 20 a 500Hz.

*Figura 13: Eletromiógrafo MyosystemBr1-P84 (DataHominis Tec Ltda).*



### 5.2 PROCEDIMENTO EXPERIMENTAL


#### 5.2.1 DEFINIÇÃO DOS MOVIMENTOS

Foram definidos 6 diferentes tipos de movimentos além da posição de repouso. Os movimentos foram flexão de punho, extensão de punho, supinação de mão, pronação de mão, fechamento de mão e movimento de pinça. Estes movimentos foram escolhidos pois tendem a ser os de maior relevância para controle de próteses mioelétricas.

### 5.2.2 POSICIONAMENTO DE ELETRODOS

Antes da definição do posicionamento dos eletrodos, foi feita a escolha dos músculos de acordo com a importância do mesmo na execução de cada movimento escolhido. Foram escolhidos quatro músculos, sendo eles, flexor radial do carpo, flexor ulnar do carpo, extensor ulnar do carpo e extensor dos dedos. Os eletrodos foram posicionados cada um em um dos músculos selecionados (Figura 14).

*Figura 14: Posicionamento dos eletrodos em torno do antebraço.*




Foram predefinidas duas posições em alturas diferentes para realizar os testes, sendo, a primeira como a altura mais adequada para aquisição de sinais EMG (P1) e a segunda como uma altura menos adequada para coleta de sinais EMG (P2).

Foi buscado na literatura a altura ideal para o posicionamento P1 dos eletrodos ao longo do antebraço. Para a marcação das alturas P1 e P2, foi realizada a medida total interna do antebraço do voluntário, medindo do Epicôndilo medial do úmero (Epitróclea) até o sulco distal do punho. Em seguida foi realizada a medida total externa do antebraço do voluntário, medindo do Epicôndilo lateral do úmero até o ponto médio entre o processo estilóide da ulna e o processo estilóide do rádio (ZIPP, 1982). Foram feitas marcações em 25% do comprimento total da parte interna e externa e em seguida, as duas marcações foram ligadas formando uma circunferência em torno do braço do voluntário, determinando a altura P1. A partir da altura P1 foi

definida a altura P2 repetindo o mesmo procedimento, porém com marcações em 40% do comprimento total (Figura 15).

Figura 15: Definição da altura das posições P1 e P2 dos eletrodos. Adaptado de (ZIPP, 1982).




### 5.2.3 TAREFA

A coleta consistiu na realização de 8 baterias, sendo as 4 primeiras para a altura P1 e as quatro últimas para a altura P2. Cada bateria foi composta por 60 movimentos, totalizando 480 movimentos. De modo que foram realizados 80 movimentos para cada uma das seis classes predefinidas. Entre a realização de cada bateria, foi dado um período de descanso de um minuto ou mais, de maneira a evitar a fadiga do voluntário.


Com o intuito de deixar o experimento mais didático para o voluntário, foi elaborada uma interface para auxiliar o voluntário durante todo o procedimento. A interface foi desenvolvida na linguagem de programação C# na plataforma do Visual Studio 2017. Na Figura 16 é apresentada a tela inicial da interface com a ilustração do estado de repouso.

Figura 16: Interface para auxílio da coleta, representando o comando de repouso.



Ao dar início a bateria, o voluntário foi instruído a realizar os movimentos conforme solicitado pela apresentação de uma imagem ilustrativa do movimento na interface desenvolvida juntamente com um comando verbal de acordo com o movimento pedido (“FLEXIONE”, “ESTENDA”, “SUPINE”, “PRONE”, “PINCE” ou “FECHE”). Após manter a posição durante um período de 3 segundos, o voluntário foi instruído (por uma imagem ilustrativa do movimento na interface desenvolvida juntamente com um comando verbal de “RELAXE”) a relaxar durante um período de 3 segundos. Para realizar os 60 movimentos de cada bateria, o conjunto com as 6 classes foi repetido 10 vezes, de modo que a ordem dos movimentos dentro de cada conjunto foi gerada de forma aleatória. A Figura 17 mostra a imagem ilustrativa dos 6 movimentos que foram apresentados na interface durante a realização da coleta.

Figura 17: Imagem ilustrativa para os 6 diferentes tipos de movimentos a serem executados.



Com o intuito de saber o exato momento em que o voluntário foi solicitado a executar o movimento, o processo contou com a utilização de um canal auxiliar com um sinal de sincronização (trigger). O mecanismo para obtenção do pulso de trigger foi dado por meio de um fotodiodo, o qual alterava de nível baixo para nível alto (ou vice-versa) através da variação de tensão de acordo com a luminosidade recebida. A cada comando para a execução de um movimento, a interface mudava a cor da região inferior esquerda da tela para preto, onde o trigger foi posicionado, fazendo assim com que o trigger gerasse nível alto durante a execução do movimento. Ao fim dos três segundos de contração, junto com o comando de repouso, a cor da região inferior esquerda da tela volta a ser branca, gerando nível baixo novamente. Além disso, O programa em C# foi responsável por gerar e salvar a ordem dos movimentos, tornando possível saber qual movimento foi realizado em cada tempo.

### 5.3 PROCESSAMENTO DE DADOS

Após todas as coletas realizadas, foi necessária uma etapa de pré-processamento dos dados para filtragem do nível DC e da interferência da rede de 60 Hz e suas harmônicas sobre o sinal. Para a remoção do nível DC foi utilizado um filtro digital passa-alta de 20 Hz. Para a atenuação da frequência de 60 Hz foi utilizado um

filtro digital notch de 60 Hz. Além disso, foram utilizados mais dois filtros notch de 120 e 180 Hz para atenuar as interferências da rede causadas pelas suas duas primeiras harmônicas. Todo o processamento de dados foi feito na linguagem de programação Python (versão 3.6) dentro da plataforma Visual Studio 2017.

Para realizar a separação entre contração e repouso, o sinal EMG foi quebrado a cada mudança de estado do sinal de trigger. Cada nível alto do sinal de trigger marcava um período de contração e cada nível baixo marcava um período de repouso. Foram obtidas 240 amostras de contração e 240 amostras de repouso para cada altura dos eletrodos, totalizando 480 amostras de contração e 480 amostras de repouso por voluntário. As 480 amostras de contração foram separadas de acordo com a sua classe de movimento, obtendo 80 amostras para cada uma das 6 classes.

Além de conseguir diferenciar as 6 classes, o sistema deve ser robusto o suficiente para diferenciar a posição de repouso dos demais movimentos. Então torna-se necessário considerar a posição de repouso como uma sétima classe. Para isso, foram selecionadas 80 das 480 amostras de repouso de forma aleatória com o intuito de igualar a quantidade de amostras de repouso com a quantidade de amostras das outras 6 classes. Ao final da separação foram obtidas 560 amostras, sendo as 280 primeiras relacionadas à altura P1 e as 280 últimas relacionadas à altura P2. Essa separação das classes é essencial para a extração de atributos, pois determina a janela de tempo em análise.

Foram extraídos 6 diferentes atributos para cada um dos 4 canais de sinal EMG, gerando um total de 24 atributos. Os atributos escolhidos foram *Mean Absolute Value* (MAV), *Waveform Length* (WL), *Signal Variance* (VAR), *Slope Sign Change* (SSC), *Zero-Crossings* (ZC) e *Root Mean Square* (RMS), de acordo com o tópico 2.4. Esses atributos foram organizados na forma de um tabela de dados seguindo o modelo exemplificado na Figura 4, contendo as 560 amostras, suas respectivas respostas e os 24 atributos.

A variação da escala dos atributos pode ser um fator negativo para o desempenho do classificador. Alguns atributos podem ter escalas muito maiores que outros, fazendo com que o classificador crie um modelo tendencioso, com os cálculos das distâncias baseadas na escala desses atributos. Para minimizar os efeitos

causados por essas diferentes escalas, cada um dos 24 atributos foi normalizado para uma nova escala com valores de 0 a 100, essa técnica é conhecida como redimensionamento Min-Max.

## 5.4 CLASSIFICAÇÃO

Após a etapa de extração de atributos, os dados foram organizados na forma de uma matriz, sendo que as amostras representavam as linhas e os atributos as colunas. As amostras foram agrupadas em dois conjuntos:

- Conjunto 1: as 280 amostras coletadas para a altura P1, obtendo uma matriz 280x24;
- Conjunto 2: as 280 amostras coletadas para a altura P2, obtendo uma matriz 280x24.

Os dois conjuntos foram treinados e testados separadamente. Para realizar o treino/teste do classificador, foi utilizada a técnica de validação cruzada com o método de 10-Fold. Esse método é exemplificado na Tabela 1, na qual cada conjunto foi dividindo em 10 subconjuntos mutuamente exclusivos do mesmo tamanho e com as 7 classes uniformemente distribuídas. Assim 1 subconjunto foi usado para teste e os outros 9 para treino. Isso se repetiu 10 vezes, de forma que cada subconjunto foi usado para teste uma vez.


Tabela 1: Divisão dos dados para validação do método através da técnica de validação cruzada utilizando o método 10-Fold.

|               | Divisões |        |        |        |        |        |        |        |        |        |
|---------------|----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
|               | 1        | 2      | 3      | 4      | 5      | 6      | 7      | 8      | 9      | 10     |
| Iteração 1 →  | Treino   | Teste  | Treino | Treino | Treino | Treino | Treino | Treino | Treino | Treino |
| Iteração 2 →  | Teste    | Treino | Treino | Treino | Treino | Treino | Treino | Treino | Treino | Treino |
| Iteração 3 →  | Treino   | Treino | Teste  | Treino | Treino | Treino | Treino | Treino | Treino | Treino |
| Iteração 4 →  | Treino   | Treino | Treino | Teste  | Treino | Treino | Treino | Treino | Treino | Treino |
| Iteração 5 →  | Treino   | Treino | Treino | Treino | Teste  | Treino | Treino | Treino | Treino | Treino |
| Iteração 6 →  | Treino   | Treino | Treino | Treino | Treino | Teste  | Treino | Treino | Treino | Treino |
| Iteração 7 →  | Treino   | Treino | Treino | Treino | Treino | Treino | Teste  | Treino | Treino | Treino |
| Iteração 8 →  | Treino   | Treino | Treino | Treino | Treino | Treino | Treino | Teste  | Treino | Treino |
| Iteração 9 →  | Treino   | Treino | Treino | Treino | Treino | Treino | Treino | Treino | Teste  | Treino |
| Iteração 10 → | Treino   | Treino | Treino | Treino | Treino | Treino | Treino | Treino | Treino | Teste  |

Treino  
Teste

Além dos conjuntos 1 e 2, foi realizada a classificação para os dados das alturas 1 e 2 juntos, os quais formavam uma matriz  $560 \times 24$  (amostras x atributos). Para realizar a classificação foi necessário separar os dados de forma que cada um dos seus 10 subconjuntos tivessem a mesma quantidade de amostras de cada altura dos eletrodos. Assim, cada subconjunto teve 56 amostras, sendo 28 relacionadas à altura P1 e 28 relacionadas à altura P2. O diagrama da Figura 18 exemplifica a classificação dos dados juntos e de suas subdivisões, formando os conjuntos 1 e 2.

Figura 18: Diagrama de blocos para o treino/teste dos conjuntos 1, 2 e 3.



## 6 RESULTADOS E DISCUSSÃO

As coletas foram realizadas no Laboratório de Engenharia Biomédica (BioLab) na Universidade Federal de Uberlândia. A Figura 19 mostra um dos voluntários realizando a coleta. Na imagem, é possível ver a interface com os comandos a serem executados no monitor a esquerda. Já no monitor do lado direito está a interface do MyosystemBr1-P84 que apresenta a aquisição dos 4 canais de sinais EMG e do canal de trigger em tempo real. Além disso, na parte esquerda está posicionado o trigger responsável pela sincronização do sinal. Como as coletas duravam cerca de uma hora, o voluntário foi instruído a ficar em uma posição de conforto, porém com a condição de manter a articulação do cotovelo em 90 graus.


*Figura 19: Coleta com um voluntário. Interface de auxílio no monitor esquerdo.*



Na Figura 20 é mostrado os sinais EMG coletados dos 60 movimentos de uma das baterias realizada por um dos voluntários na altura P1 do antebraço. Os sinais apresentados foram pré-processados, atenuando a interferência de 60Hz e o nível DC. No eixo vertical está a amplitude do sinal apresentada em microvolts ( $\mu V$ ) e no eixo horizontal o tempo de coleta em segundos (s). Os sinais EMG coletados de cada canal são apresentados de forma paralela e cada bateria durou cerca de 380 segundos. O sinal de trigger é apresentado junto com cada um dos quatro canais para tornar mais fácil a visualização da marcação de cada período de contração e repouso.

É interessante notar que em cada canal houve a prevalência de determinadas contrações, principalmente nos canais 2 e 3. Isso se dá pela região onde esses sinais foram captados. O sinal do canal 2 foi coletado a partir de eletrodos posicionados no músculo flexor radial do carpo. Esse músculo é responsável principalmente pela flexão da mão, por isso o sinal EMG teve maior amplitude quando esse movimento foi realizado. Já para o canal 3, o músculo em questão foi o extensor dos dedos, grande responsável pela extensão da mão. Desta forma, o sinal EMG teve maior amplitude quando esse movimento foi realizado. Como os músculos do canal 2 e 3 são antagonistas, eles nunca têm um pico de amplitude para o mesmo movimento, assim, é possível ver que enquanto há um pico de amplitude para o principal movimento do canal 2, o canal 3 possui amplitude mínima, e vice-versa.


*Figura 20: Sinal EMG coletado dos quatro eletrodos posicionados nos músculos do antebraço do voluntário para a altura P1. Os quatro sinais são apresentados de forma paralela junto com o sinal de trigger.*



Na Figura 21 é mostrado a coleta de outra bateria do mesmo voluntário para a altura P2. Levando em consideração que a altura P2 é uma posição menos propícia para coleta de sinais EMG, pode-se considerar que era esperado uma redução da sua amplitude. Isso ocorreu para quase todos os canais, exceto para o canal 3. Isso mostra que mesmo alterando a posição do eletrodo 3 em 15% do comprimento total externo do antebraço, esse músculo ainda é responsável por fornecer uma boa amplitude do sinal EMG, o que não acontece com os demais eletrodos. Porém, pode ter ocorrido

outras mudanças no sinal, por exemplo, no seu espectro de frequência. De todo modo, foi possível ver que existe uma grande diferença no sinal EMG de acordo com a altura que os eletrodos são posicionados. Ou seja, essa alteração da posição dos eletrodos certamente influenciará negativamente o desempenho de um algoritmo de AM.

*Figura 21: Coleta com os mesmos canais de sinal EMG, porém na altura P2.*



As primeiras amostras que foram testadas pelo sistema foram as do conjunto 1, pertencentes ao sinal EMG coletado na altura P1. Como essa posição foi considerada como a ideal para aquisição de sinais EMG e a técnica de SVM é excelente para classificação desse tipo de sinais, era esperado um bom desempenho do classificador para o esse conjunto de dados. Isso foi afirmado de acordo com os resultados apresentados na Tabela 2. A acurácia média de todos os 6 voluntários foi de aproximadamente 97%, chegando em 99% para os voluntários 1 e 5. Porém, o fato de alcançar bons resultados a partir dos dados do conjunto 1 não torna o classificador suficientemente genérico para manter o bom desempenho quando testado em uma nova posição de eletrodos. Por isso, torna-se necessário realizar o mesmo teste para os dados do conjunto 2.

Tabela 2: Acurácia de cada classe e acurácia média por voluntário obtidas com os dados do conjunto 1.

| Conjunto 1 |          |        |           |        |        |          |         |       |
|------------|----------|--------|-----------|--------|--------|----------|---------|-------|
| Voluntário | Estender | Fechar | Flexionar | Pinçar | Pronar | Repousar | Supinar | Média |
| 1          | 1,00     | 0,95   | 1,00      | 0,95   | 1,00   | 1,00     | 1,00    | 0,99  |
| 2          | 0,95     | 0,94   | 0,84      | 0,93   | 1,00   | 1,00     | 1,00    | 0,95  |
| 3          | 1,00     | 0,97   | 0,93      | 0,93   | 1,00   | 1,00     | 1,00    | 0,98  |
| 4          | 1,00     | 0,85   | 0,89      | 0,85   | 1,00   | 1,00     | 1,00    | 0,94  |
| 5          | 1,00     | 0,98   | 0,93      | 1,00   | 1,00   | 1,00     | 1,00    | 0,99  |
| 6          | 0,98     | 0,86   | 0,95      | 0,90   | 1,00   | 0,95     | 1,00    | 0,95  |
| Média      | 0,99     | 0,93   | 0,92      | 0,93   | 1,00   | 0,99     | 1,00    | 0,97  |

A Tabela 3 mostra os resultados obtidos para os dados do conjunto 2, que foram coletados em uma posição menos propícia para a aquisição de sinais EMG. Na tabela nota-se que, como o esperado, a acurácia do modelo caiu, já que os eletrodos estão posicionados mais próximos do final do músculo, de forma que a amplitude do sinal não é suficientemente grande comparado com a amplitude coletada no ventre muscular. Dessa forma, os atributos extraídos do conjunto 2 não fornecem a mesma variabilidade dos atributos extraídos do conjunto 1. Em alguns casos, é possível ver que a acurácia média caiu drasticamente, como os resultados obtidos do voluntário 6, que caiu de 95% para 72% somente com a alteração da posição dos eletrodos. Porém, como a coleta é relativamente longa e demanda certo esforço físico, outros fatores podem ter sido cruciais para seu baixo desempenho, como a fadiga muscular. Em outros casos, os resultados foram extremamente satisfatórios, como para o voluntário 5, que caiu apenas 2% no valor de sua acurácia média. Essa divergência de desempenho em alguns casos e em outros não, mostra que os resultados variam de acordo com o voluntário, seja por condição física, mental ou até mesmo sua anatomia. Outra coisa a ser observada nos resultados do conjunto 2 foi a baixa acurácia para a classe repousar, que saiu de 99% no conjunto 1 para 77% no conjunto 2. Um dos fatores que explica isso é a queda da amplitude do sinal EMG captado na altura P2 em comparação com a amplitude do sinal EMG captado na altura P1. Isso faz com que a amplitude dos sinais do período de contração esteja muito próxima da amplitude do período de repouso. Como foram extraídos atributos do DT, sendo a maioria relacionados a amplitude do sinal, certamente os valores das classes ficaram muito próximos um do outro, gerando uma dificuldade para gerar um modelo que separe bem essas classes.

Tabela 3: Acurácia de cada classe e acurácia média por voluntário obtidas com os dados do conjunto 2.

| Conjunto 2 |          |        |           |        |        |          |         |       |
|------------|----------|--------|-----------|--------|--------|----------|---------|-------|
| Voluntário | Estender | Fechar | Flexionar | Pinçar | Pronar | Repousar | Supinar | Média |
| 1          | 1,00     | 0,81   | 0,82      | 0,74   | 0,95   | 0,81     | 0,90    | 0,86  |
| 2          | 0,75     | 0,87   | 0,74      | 0,89   | 0,89   | 0,98     | 0,84    | 0,85  |
| 3          | 1,00     | 1,00   | 0,83      | 0,68   | 0,82   | 0,70     | 0,84    | 0,84  |
| 4          | 1,00     | 0,81   | 0,95      | 0,82   | 0,88   | 0,67     | 0,85    | 0,85  |
| 5          | 1,00     | 1,00   | 0,91      | 0,98   | 1,00   | 0,95     | 0,98    | 0,97  |
| 6          | 0,79     | 0,74   | 0,66      | 0,74   | 0,78   | 0,51     | 0,78    | 0,72  |
| Média      | 0,92     | 0,87   | 0,82      | 0,81   | 0,89   | 0,77     | 0,87    | 0,85  |

Tanto os resultados obtidos pelos dados do conjunto 1 quanto pelos do conjunto 2 representam o desempenho para posições específicas e não informam qual a capacidade de adaptação do modelo quando confrontado com novos dados em outras posições. Dessa forma, uma nova abordagem contendo dados de ambos os posicionamentos dos eletrodos tornou-se fundamental. A Tabela 4 mostra os resultados obtidos para o conjunto de dados mais amplo, contendo todos os dados dos conjuntos 1 e 2. Na tabela é possível ver que desempenho geral comparado com o do conjunto 2 aumentou, com acurácia média de aproximadamente 91% para todos os 6 voluntários. Esses resultados mostram o quanto um sistema genérico pode impactar no desempenho de um classificador, pois consegue se ajustar melhor aos dados. Isso se dá pelo fato do classificador ter usado amostras de ambas as alturas para efetuar o treinamento, gerando um modelo que se adequou melhor para os dois conjuntos de dados.

Tabela 4: Acurácia de cada classe e acurácia média por voluntário obtidas com os dados do conjunto 1 e 2.

| Todos os dados |          |        |           |        |        |          |         |       |
|----------------|----------|--------|-----------|--------|--------|----------|---------|-------|
| Voluntário     | Estender | Fechar | Flexionar | Pinçar | Pronar | Repousar | Supinar | Média |
| 1              | 1,00     | 0,87   | 0,93      | 0,85   | 0,96   | 0,91     | 0,95    | 0,92  |
| 2              | 0,82     | 0,86   | 0,85      | 0,88   | 1,00   | 0,98     | 0,99    | 0,91  |
| 3              | 1,00     | 0,96   | 0,89      | 0,84   | 0,89   | 0,85     | 0,96    | 0,91  |
| 4              | 1,00     | 0,82   | 0,91      | 0,76   | 0,99   | 0,85     | 0,94    | 0,90  |
| 5              | 1,00     | 0,99   | 0,90      | 0,99   | 1,00   | 0,99     | 0,99    | 0,98  |
| 6              | 0,89     | 0,86   | 0,83      | 0,83   | 0,92   | 0,66     | 0,94    | 0,85  |
| Média          | 0,95     | 0,89   | 0,89      | 0,86   | 0,96   | 0,87     | 0,96    | 0,91  |

Os resultados obtidos com o treinamento a partir de todos os dados foram satisfatórios, mostrando que o sistema se adequou bem ao conjunto de dados de ambas as alturas testadas. Porém, um conjunto de dados com 24 atributos pode ter

um baixo desempenho computacional, gastando muito tempo para executar o algoritmo de classificação. Isso mostra que o sistema não está otimizado. Assim, o uso da técnica de PCA para redução de dimensionalidade de dados foi outra importante abordagem deste trabalho.

Foi escolhido o número de CP que representavam pelo menos 95% da variabilidade dos dados originais. A Tabela 5 mostra a quantidade de CP que foram usadas de cada voluntário e a variabilidade dos dados que elas representam. Em alguns casos, foi possível reduzir significativamente a quantidade de atributos, passando de 24 para apenas 5. Com os novos atributos obtidos através da técnica de PCA, os dados foram organizados novamente com as mesmas 560 amostras, porém, no lugar dos 24 atributos, passou-se a utilizar as CP obtidas de cada voluntário.


*Tabela 5: Novos atributos obtidos através da PCA.*

| Voluntário | Conjunto 1   |                             | Conjunto 2   |                             | Todos os dados |                             |
|------------|--------------|-----------------------------|--------------|-----------------------------|----------------|-----------------------------|
|            | Número de CP | Variabilidade dos dados (%) | Número de CP | Variabilidade dos dados (%) | Número de CP   | Variabilidade dos dados (%) |
| 1          | 6            | 95,52                       | 7            | 96,74                       | 7              | 95,85                       |
| 2          | 6            | 95,03                       | 6            | 95,46                       | 7              | 95,56                       |
| 3          | 5            | 95,53                       | 6            | 95,17                       | 7              | 96,43                       |
| 4          | 6            | 96,51                       | 6            | 95,25                       | 7              | 96,79                       |
| 5          | 5            | 95,34                       | 6            | 95,99                       | 6              | 95,09                       |
| 6          | 7            | 96,81                       | 7            | 95,01                       | 8              | 96,57                       |

Esses novos atributos formados pelas CP não são necessariamente os atributos originais de maior variância e sim transformações ortogonais de possíveis variáveis correlacionadas. A Figura 22 mostra o gráfico de dispersão das duas primeiras CP do voluntário 5 a partir dos dados do conjunto 1 em um espaço 2D. Apenas essas duas CP são responsáveis por 70,18% da variabilidade dos dados originais. O que é um valor bastante elevado, levando em consideração que originalmente existem 24 atributos. Nota-se que algumas classes são facilmente separadas, como é o caso de Repousar, Estender e Flexionar. Como mostrado na Figura 20, as classes Flexionar e Estender possuem amplitudes altas para os canais 2 e 3, respectivamente. Dessa forma, os atributos extraídos dessas duas classes terão valores altos. Já para a classe Repouso, ocorre exatamente o contrário, de modo que essa classe sempre tem uma baixa amplitude, o que faz com que os atributos extraídos dela tenham valores mais baixos. Já as demais classes não se destacam bem, principalmente em atributos de amplitude, o que faz com que elas estejam próximas umas das outras. Porém, isso


pode ser resolvido adicionando mais CP, de forma a se aproximar ao máximo da variabilidade total dos dados originais.

Figura 22: Gráfico de dispersão das duas primeiras CP do voluntário 5 a partir dos dados do conjunto 1 em um espaço 2D.



A Figura 23 mostra as três primeiras CP do voluntário 5 a partir dos dados do conjunto 1 em um espaço 3D. As três CP juntas são responsáveis por 85% da variabilidade dos dados. Logo, o conjunto de dados de 3 CP perde apenas 15% da variabilidade dos 24 atributos originais. Nota-se que todas as classes estão bem separadas, o que vai de acordo com o desempenho médio de 99% desse voluntário. Nota-se que a proximidade dos valores das classes Fechar, Pinçar, Supinar e Pronar foi praticamente resolvida adicionando a terceira CP de maior variância. A variabilidade dos dados ainda não está de acordo com os 95% da variabilidade dos dados originais como foi proposto, mas ainda assim, nota-se que é possível gerar um modelo capaz de separar de forma satisfatória as 7 classes.

Figura 23: Gráfico de dispersão das três primeiras CP do voluntário 5 a partir dos dados do conjunto 1 em um espaço 3D.



As Tabela 6 mostra os novos resultados obtidos para o conjunto 1 com o uso apenas das primeiras CP responsáveis por pelo menos 95% da variabilidade dos dados originais para cada voluntário (Tabela 5). A média geral caiu apenas 0,01% e para alguns voluntários de forma individual a média se manteve a mesma. Isso mostra a força que a técnica de PCA possui e o quanto ela pode ser útil para a redução de dimensionalidade dos dados. Neste trabalho, foram usados apenas 24 atributos, mas existem aplicações de AM que necessitam da extração de muito mais atributos. Isso reforça ainda mais a utilidade dessa técnica, sendo que nesses casos em que a quantidade de atributos é extremamente elevada, a complexidade computacional aumenta, tornando a utilização de PCA (ou outra técnica de redução de dimensionalidade) de certo modo obrigatória.

Tabela 6: Resultados para os novos atributos compostos por CP para o conjunto 1.

| Conjunto 1 - PCA |          |        |           |        |        |          |         |       |
|------------------|----------|--------|-----------|--------|--------|----------|---------|-------|
| Voluntário       | Estender | Fechar | Flexionar | Pinçar | Pronar | Repousar | Supinar | Média |
| 1                | 1,00     | 0,85   | 1,00      | 0,97   | 1,00   | 1,00     | 1,00    | 0,97  |
| 2                | 0,95     | 0,83   | 0,95      | 0,90   | 1,00   | 1,00     | 1,00    | 0,95  |
| 3                | 1,00     | 0,90   | 0,98      | 0,88   | 1,00   | 1,00     | 1,00    | 0,97  |
| 4                | 1,00     | 0,76   | 0,98      | 0,81   | 0,97   | 1,00     | 0,98    | 0,93  |
| 5                | 1,00     | 0,98   | 0,95      | 1,00   | 1,00   | 1,00     | 1,00    | 0,99  |
| 6                | 1,00     | 0,82   | 0,97      | 0,85   | 1,00   | 0,95     | 0,97    | 0,94  |
| Média            | 0,99     | 0,86   | 0,97      | 0,90   | 1,00   | 0,99     | 0,99    | 0,96  |

Na Tabela 7 são mostrados os resultados obtidos a partir dos novos atributos do conjunto 2. É interessante notar que para esse conjunto, a média do voluntário 1 foi maior com as 7 CP do que com os 24 atributos originais. Como inicialmente temos um conjunto de dados com um grande número de variáveis, algumas podem estar correlacionadas, de forma que essa correlação entre variáveis traz uma redundância na informação. Em alguns casos isso pode ser prejudicial para o classificador, podendo gerar um modelo que não se encaixa bem ao conjunto de dados.

*Tabela 7: Resultados para os novos atributos compostos por CP para o conjunto 2.*

| <b>Conjunto 2 - PCA</b> |                 |               |                  |               |               |                 |                |              |
|-------------------------|-----------------|---------------|------------------|---------------|---------------|-----------------|----------------|--------------|
| <b>Voluntário</b>       | <b>Estender</b> | <b>Fechar</b> | <b>Flexionar</b> | <b>Pinçar</b> | <b>Pronar</b> | <b>Repousar</b> | <b>Supinar</b> | <b>Média</b> |
| 1                       | 1,00            | 0,86          | 0,80             | 0,80          | 0,95          | 0,84            | 0,88           | 0,88         |
| 2                       | 0,69            | 0,80          | 0,86             | 0,96          | 0,94          | 0,93            | 0,67           | 0,84         |
| 3                       | 1,00            | 0,95          | 0,93             | 0,66          | 0,78          | 0,71            | 0,82           | 0,84         |
| 4                       | 1,00            | 0,72          | 0,95             | 0,59          | 0,88          | 0,65            | 0,91           | 0,81         |
| 5                       | 1,00            | 0,95          | 0,86             | 0,97          | 0,93          | 0,87            | 0,95           | 0,93         |
| 6                       | 0,74            | 0,88          | 0,70             | 0,69          | 0,77          | 0,53            | 0,72           | 0,72         |
| <b>Média</b>            | <b>0,91</b>     | <b>0,86</b>   | <b>0,85</b>      | <b>0,78</b>   | <b>0,88</b>   | <b>0,76</b>     | <b>0,83</b>    | <b>0,84</b>  |

A Tabela 8 mostra os resultados do conjunto com todos os dados, e não foi diferente dos resultados anteriores, onde o classificador teve um ótimo desempenho para uma quantidade de dados reduzida.


*Tabela 8: Resultados para os novos atributos compostos por CP para todos os dados.*

| <b>Todos os dados - PCA</b> |                 |               |                  |               |               |                 |                |              |
|-----------------------------|-----------------|---------------|------------------|---------------|---------------|-----------------|----------------|--------------|
| <b>Voluntário</b>           | <b>Estender</b> | <b>Fechar</b> | <b>Flexionar</b> | <b>Pinçar</b> | <b>Pronar</b> | <b>Repousar</b> | <b>Supinar</b> | <b>Média</b> |
| 1                           | 0,99            | 0,85          | 0,95             | 0,88          | 0,95          | 0,92            | 0,94           | 0,93         |
| 2                           | 0,88            | 0,84          | 0,85             | 0,88          | 0,99          | 0,96            | 0,92           | 0,90         |
| 3                           | 1,00            | 0,90          | 0,95             | 0,79          | 0,97          | 0,82            | 0,96           | 0,91         |
| 4                           | 1,00            | 0,74          | 0,95             | 0,69          | 0,96          | 0,78            | 0,89           | 0,86         |
| 5                           | 1,00            | 0,96          | 0,93             | 0,97          | 0,96          | 0,93            | 1,00           | 0,96         |
| 6                           | 0,91            | 0,86          | 0,85             | 0,78          | 0,93          | 0,65            | 0,92           | 0,84         |
| <b>Média</b>                | <b>0,96</b>     | <b>0,86</b>   | <b>0,91</b>      | <b>0,83</b>   | <b>0,96</b>   | <b>0,84</b>     | <b>0,94</b>    | <b>0,90</b>  |

Outro aspecto importante a ser comentado foi uma menor acurácia das classes fechar e pinçar para alguns voluntários. Isso pode ter sido causado pelo fato de serem movimentos muito parecidos, e muitas vezes o classificador não consegue separar de forma eficiente os dados das duas classes. Porém, o voluntário 1 foi uma exceção e obteve ótimos resultados para essas duas classes, como mostra a Figura 23.

A Figura 24 mostra um exemplo de modelo criado para apenas as duas primeiras CP dos dados do voluntário 5. A primeira mostra um modelo gerado para o conjunto 1, a segunda para o conjunto 2 e a terceira para todos os dados, que obteve um modelo genérico que se adequasse aos dois conjuntos de dados. O dado deve estar na área de mesma cor para ser classificado corretamente. Nos casos em que a cor do dado se encontra em uma área de outra cor significa que o modelo não se adequou bem para aquele dado, seja por estar muito mais próximo do valor de outra classe ou simplesmente por ser um outliers.

Figura 24: Três modelos gerados para as duas primeiras CP do voluntário 5. a) Conjunto 1, b) Conjunto 2 e c) Todos os dados.



## 7 CONCLUSÃO

O trabalho em questão obteve bons resultados de forma geral, mostrando que a posição dos eletrodos influencia diretamente no desempenho do classificador. Dessa forma, o trabalho mostrou a vantagem de construir um modelo genérico, que se adeque a todos os conjuntos de dados obtidos através de mais de um posicionamento de eletrodos. Os modelos criados obtiveram resultados acima 84%, o que é adequado, considerando que existiam 7 classes. Isso é um ponto importante pois a quantidade de classes impacta diretamente no desempenho de um algoritmo de AM, de forma que, quanto maior o número de classes, maior é a complexidade para discernir todas as classes. Além disso, a técnica de PCA foi de extrema importância, pois possibilitou uma redução de dimensionalidade dos dados muito significativa, variando de 5 a 8 CP dos 24 atributos originais. Além disso, a classificação a partir das CP obteve um melhor desempenho em alguns casos, mostrando que algumas redundâncias nos dados poderiam estar afetando de forma negativa o classificador.

### 7.1 TRABALHOS FUTUROS

O desenvolvimento deste trabalho possibilitou oportunidades de trabalhos futuros, como a avaliação do uso de atributos no domínio da frequência. Esses atributos são computacionalmente mais exigentes, pois requerem a transformação do domínio do tempo para domínio da frequência. Por outro lado, podem fornecer novas perspectivas valiosas sobre o sinal EMG. A rotação dos eletrodos é outra abordagem a ser avaliada, já que este trabalho avaliou apenas diferentes alturas de cada eletrodo sobre um músculo específico. Além disso, o classificador foi treinado e testado para uma única posição do braço, dessa forma, pode-se avaliar o efeito da alteração da posição do braço sobre os sinais EMG. Para isso, são necessárias novas coletas com um maior número de voluntários.

Após a avaliação dessas novas abordagens, o sistema pode ser adaptado para uso, sendo necessário colocá-lo em tempo real. Assim, é possível ver na prática o desempenho que o sistema irá alcançar. Com o sistema em tempo real, será possível imergi-lo em um controle de próteses. Primeiramente em um ambiente virtual, para a realização de testes e posteriormente em próteses reais.

## 8 REFERÊNCIAS BIBLIOGRÁFICAS

ABDI, H.; WILLIAMS, L. J. **Principal component analysis**. [S.l.]: [s.n.], 2010.

BASMAJIAN, J. V.; DE LUCA, J. C. **Muscles alive**: their functions revealed by electromyography. [S.l.]: [s.n.], 1985.

BOOSTANI, R.; MORADI, M. **Evaluation of the forearm EMG signal features for the control of a prosthetic hand**. Tehran: [s.n.], 2003.

BURBIDGE, R. et al. **Drug design by machine learning**: support vector machines for pharmaceutical data analysis. London: Elsevier, 2001.

BURGES, C. **A Tutorial on Support Vector Machines for Pattern Recognition**. Boston: Kluwer Academic Publishers, 1998.

DE LUCA, C. J. **The Use of Surface Electromyography in Biomechanics**. New York: JOURNAL OF APPLIED BIOMECHANICS, 1997.

DE LUCA, J. C. **Surface electromyography**: detection and recording. [S.l.]: [s.n.], 2002.

DOMINGOS, P. **A Few Useful Things to Know about Machine Learning**. Washington: [s.n.], 2012.

FAVIEIRO, W. **Controle de uma prótese experimental do segmento mão-braço por sinais mioelétricos e redes neurais artificiais**. Universidade Federal do Rio Grande do Sul, Porto Alegre: [s.n.], 2009.

FERRIS, D. P.; CZERNIECKI, J. M.; HANNAFORD, B. **An ankle-foot orthosis powered by artificial pneumatic muscles**. [S.l.]: Journal of Applied Biomechanics, 2005.

GEETHANJALI, P. **Myoelectric control of prosthetic hands**: state-of-the-art review. Vellore, India: Medical Devices, 2016.

HALL, J. E. **Tratado de fisiologia médica**. São Paulo: Elsevier, 2011.

HASHIM, E. et al. **Patterns of myeloarchitecture in lower limb amputees: an MRI study**. Hamilton: Frontiers in Neuroscience, 2015.

JAMAL, Z.; WARIS, A.; NAZIR, S. **Motor drive using surface electromyography for flexion and extension of finger and hand muscles**. Shanghai: 4th International Conference on Biomedical Engineering and Informatics, 2011.

KITCHEN, S. **Eletroterapia de Clayton**. São Paulo: Manole, 1998.

KUIKEN, T. A. et al. **Targeted muscle reinnervation for real-time myoelectric control of multifunction artificial arms**. [S.l.]: Jama, 2009.

LEÓN, M. et al. **Multiclass Motion Identification using Myoelectric Signals and Support Vector Machines**. Madrid: [s.n.], 2011.

LEVITAN, I.; KACZMAREK, L. **Intercellular communication**. New York: [s.n.], 2015.

LI, G. **Electromyography Pattern-Recognition-Based Control of Powered Multifunctional Upper-Limb Prostheses**. China: Shenzhen Institutes of Advanced Technology, 2011.

LORENA, A. C.; CARVALHO, A. C. **Uma Introdução às Support Vector Machines**. São Carlos: [s.n.], 2007.

MAMBRITO, B.; DE LUCA, J. C. **Acquisition and decomposition of the EMG signal**. Switzerland: [s.n.], 1983.

MERRILL, D. R. et al. **Development of an implantable myoelectric sensor for advanced prosthesis control**. Vienna: Artif Organs, 2011.

MOURA, A.; VIRATO, A. **Gestão Hospitalar: da organização ao Serviço de Apoio Diagnóstico e Terapêutico**. 1ª. ed. Barueri: Manole Ltda, 2008.

OSKOEI, M.; HU, H. **Myoelectric control systems - A survey**. Colchester: ELSEVIER, 2007.

PANDEY, B.; MISHRA, R. **An integrated intelligent computing model for the interpretation of EMG based neuromuscular diseases**. Varanasi, India.: ELSEVIER, 2009.

- PARRELLA, F. **Online Support Vector Regression**. Genoa: [s.n.], 2007.
- PHINYOMARK, A.; LIMSAKUL, C.; PHUKPATTARANONT, P. **Application of Wavelet Analysis in EMG Feature Extraction for Pattern Classification**. Songkhla, Thailand: MEASUREMENT SCIENCE REVIEW, 2011.
- PROSTHETIC & Orthotic Care. [S.I.]: [s.n.].
- SCHEME, E.; ENGLEHART, K. **Electromyogram pattern recognition for control of powered upper-limb prostheses: State of the art and challenges for clinical use**. Fredericton: Journal of Rehabilitation Research & Development, 2011.
- SOUTO, M. C. et al. **Técnicas de Aprendizado de Máquina para problemas de Biologia Molecular**. São Carlos: XXIII Congresso da Sociedade Brasileira de Computação, 2003.
- STUBBLEFIELD, A. K. et al. **Occupational therapy protocol for amputees with targeted muscle reinnervation**. Chicago: Journal of Rehabilitation Research & Development, 2009.
- TASSINARY, L. G.; CACIOPPO, J. T.; VANMAN, E. J. **The Skeletomotor system: surface electromyography**. [S.I.]: [s.n.], 2000.
- TECHNOLOGIES, A. **Myoware datasheet**. [S.I.]: [s.n.], 2015.
- VASCONCELOS, S. **Análise de Componentes Principais (PCA)**. [S.I.]: [s.n.], 2013.
- VEER, K.; SHARMA, T. **A novel feature extraction for robust EMG pattern recognition**. Khanpur Kui, India: JOURNAL OF MEDICAL ENGINEERING & TECHNOLOGY, 2016.
- VUJAKLIJA, I.; FARINA, D.; ASZMANN, O. C. **New developments in prosthetic arm systems**. Vienna, Austria: Orthopedic Research and Reviews, 2016.
- ZIPP, P. **Recommendations for the Standardization of Lead Positions in Surface Electromyography**. Darmstadt, Federal Republic of Germany: European Journal of Applied Physiology, 1982.