

UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS
UNIDADE ACADÊMICA DE GRADUAÇÃO
CURSO DE ENGENHARIA ELETRÔNICA

JONAS MIGUEL STANISLAU BEAL MIROVSKI

PROCESSAMENTO EMBARCADO DE SINAIS MIOELÉTRICOS
APLICADO AO CONTROLE DE PRÓTESES DE MÃO

São Leopoldo
2018

JONAS MIGUEL STANISLAU BEAL MIROVSKI

PROCESSAMENTO EMBARCADO DE SINAIS MIOELÉTRICOS
APLICADO AO CONTROLE DE PRÓTESES DE MÃO

Trabalho de Conclusão de Curso
apresentado como requisito parcial para
obtenção do título de Bacharel em
Engenharia Eletrônica, pelo Curso de
Engenharia Eletrônica da Universidade do
Vale do Rio dos Sinos - UNISINOS

Orientador: Prof. Ms. João Olegário de Oliveira de Souza

São Leopoldo

2018

RESUMO

Apesar dos constantes avanços no desenvolvimento de próteses com sistemas microprocessados, as próteses de membros superiores ainda não são capazes de suprir com satisfação as funções de um membro natural. Evoluções recentes no campo do aprendizado de máquina e inteligência artificial, além da divulgação pública de bancos de dados de sinais mioelétricos, promovem novos sistemas capazes de controlar próteses multifunção com cada vez mais confiança. Nesse trabalho são utilizadas técnicas de aprendizado de máquina em cima do banco de dados público Ninapro (Non-Invasive Adaptive Hand Prosthetics) visando a correta classificação de movimentos para controle de uma prótese mioelétrica de mão. É utilizado o algoritmo de redes neurais, sendo apresentado todo o seu desenvolvimento, ajuste de parâmetros, validação e teste. O sistema é posteriormente embarcado em uma plataforma Raspberry PI Zero, sendo realizada também a análise de desempenho do classificador de forma numérica e gráfica, visando um melhor entendimento do funcionamento prático do mesmo.

Palavras-chaves: – prótese de mão – sinal mioelétrico – redes neurais – Raspberry Pi

LISTA DE FIGURAS

Figura 1 – Prótese de mão <i>Bebionic3</i> – imagem de divulgação	13
Figura 2 – Prótese de mão <i>i-limb quantum</i> – imagem de divulgação.....	15
Figura 3 – Prótese de mão <i>TASKA</i> – imagem de divulgação	16
Figura 4 – Exemplo de segmentação de um sinal EMG utilizando janelas de tamanho T_a , deslocamento T_{inc} e tempo de processamento T_d	18
Figura 5 – Os 52 movimentos realizados no Ninapro DB1.....	22
Figura 6 – Eletrodos <i>13-E200 MyoBock</i> utilizados no Ninapro DB1.....	23
Figura 7 – Disposição dos sensores para aquisição dos dados do Ninapro DB1 com (1) oito eletrodos igualmente espaçados, (2) dois eletrodos nos músculos flexor e extensor dos dedos, (3) inclinômetro e (4) luva de aquisição de dados.....	23
Figura 8 – Disposição dos eletrodos para aquisição dos dados do Ninapro DB2	25
Figura 9 – Os 9 movimentos realizados utilizando o FFLS no Ninapro DB2.....	25
Figura 10 – Disposição dos sensores da marca <i>Cometa</i> (acima) e <i>Thalmic</i> (abaixo) para aquisição dos dados do Ninapro DB4 e DB5	28
Figura 11 – Movimentos realizados no Ninapro DB6	29
Figura 12 – Posicionamento dos eletrodos em três indivíduos para aquisição dos dados do Ninapro DB7	30
Figura 13 – Raspberry Pi Zero – Imagem de divulgação	31
Figura 14 – Dados utilizados de um dos arquivos importados (indivíduo 10, exercício 1).....	34
Figura 15 – Visualização parcial de um dos arquivos importados – Indivíduo 10, exercício 1, primeiros 300 segundos.....	35
Figura 16 – Visualização da coluna estímulo sobre os dados EMG originais – Indivíduo 10, exercício 1	36
Figura 17 – Visualização da coluna repetição sobre os dados EMG originais – Indivíduo 10, exercício 1	37
Figura 18 – Visualização do efeito de ajuste da coluna "estímulo"	38
Figura 19 – Matriz de Confusão - Todos vs Todos - Movimento inteiro	40
Figura 20 – Movimentos selecionados para classificação.....	42
Figura 21 – Matriz de Confusão – Todos vs Todos – Movimentos selecionados.....	43
Figura 22 – Análise de desempenho – Tamanho dos conjuntos de treino e validação	44

Figura 23 – Matriz de Confusão – (Todos-1) vs 1 – movimento inteiro	46
Figura 24 – Matriz de Confusão - 1 vs 1 - movimento inteiro	46
Figura 25 – Matriz de Confusão - (Todos-1) vs 1 - Janela 250/100 ms.....	47
Figura 26 – Matriz de Confusão - 1 vs 1 - Janela 250/100 ms	48
Figura 27 – Matriz de Confusão - (Todos-1) vs 1 - Janela 250/100 ms Com Repouso	49
Figura 28 – Matriz de Confusão Normalizada – (Todos-1) vs 1 – Janela 250/100 ms com Repouso	50
Figura 29 – Matriz de Confusão Normalizada – 1 vs 1 – Janela 250/100 ms com Repouso	51
Figura 30 – Análise de desempenho de acordo com o número de neurônios nas camadas escondidas.....	53
Figura 31 – Detecção das frequências de pico no gráfico da FFT de três janelas distintas.	55
Figura 32 – Gráfico da FFT de três sinais de movimentos completos.....	56
Figura 33 – Fluxograma resumido do algoritmo de simulação de análise dos dados em tempo real.	57
Figura 34 – Gráfico de análise mostrando dois erros claros de classificação	58
Figura 35 – Vetor de resultados mostrando os dois erros claros de classificação	59
Figura 36 – Gráfico de análise mostrando erros de classificação questionáveis	59
Figura 37 – Matriz de Confusão Normalizada – 1 vs 1 – Janela 250/100 – 5 Indivíduos de Teste	60
Figura 38 – Comparação do programa em execução no terminal do sistema Raspbian com a análise realizada anteriormente.....	61

LISTA DE QUADROS

Quadro 1 – <i>Bebionic3</i> - características de interesse	13
Quadro 2 – <i>i-limb Quantum</i> - características de interesse	15
Quadro 3 – <i>TASKA</i> – características de interesse	16
Quadro 4 – Ninapro DB1 – características de interesse	24
Quadro 5 – Ninapro DB2 – características de interesse	26
Quadro 6 – Ninapro DB3 – características de interesse	27
Quadro 7 – Ninapro DB4 e DB5 – características de interesse.....	28
Quadro 8 – Ninapro DB6 – características de interesse	29
Quadro 9 – Ninapro DB7 – características de interesse	31
Quadro 10 – Precisão e Revocação – Todos vs Todos – Movimentos selecionados	42
Quadro 11 – Precisão e Revocação – (Todos-1) vs 1 – Janela 250/100 ms com Repouso	50
Quadro 12 – Precisão e Revocação – (Todos-1) vs 1 – Janela 250/100 ms com Repouso	52
Quadro 13 – Precisão e Revocação – 1 vs 1 – com característica adicional SSC....	54
Quadro 14 – Precisão e Revocação – 1 vs 1 – com característica adicional FFT.....	55
Quadro 15 – Precisão e Revocação – 1 vs 1 – Janela 250/100 ms – 5 Indivíduos de Teste	60

LISTA DE SIGLAS

AR	<i>Auto Regression</i> (Auto Regressão)
CC	<i>Cepstrum Coefficients</i> (coeficientes mel-cepstrais)
DB	<i>Database</i> (Banco de Dados)
EMG	Eletromiografia / Eletromiográfico
EMGs	Eletromiografia de Superfície
FFLS	<i>Finger-Force Linear Sensor</i> (Sensor Linear de Força dos Dedos)
FFT	<i>Fast Fourier Transform</i> (Transformada Rápida de Fourier)
IEMG	<i>Integrated EMG</i> (EMG Integrado)
IP	<i>Ingress Protection</i> (Proteção de Ingresso)
MAVS	<i>Mean Absolute Value Slope</i> (Inclinação do Desvio Médio Absoluto)
MDF	<i>Median Frequency</i> (Frequência Mediana)
MLP	<i>Multi Layer Perceptron</i> (Perceptron Multicamadas)
MNF	<i>Mean Frequency</i> (Frequência Média)
NINAPRO	<i>Non-Invasive Adaptive Hand Prosthetics</i>
OTG	<i>On The Go</i> (Pronto Para Uso)
RMS	<i>Root Mean Square</i> (Raiz do Valor Médio Quadrático)
SD	<i>Standard Deviation</i> (Desvio Padrão)
SIMD	<i>Single Instruction Multiple Data</i> (Instrução Simples Dados Múltiplos)
SoC	<i>System on Chip</i> (Sistema Em Um Chip)
SSC	<i>Slope Sign Change</i> (Mudança do Sinal da Inclinação)
STFT	<i>Short Time Fourier Transform</i> (Transformada de Fourier de Tempo Curto)
USB	<i>Universal Serial Bus</i> (Barramento Serial Universal)
VAR	<i>Variance</i> (Variância)
WA	<i>Wilson Amplitude</i> (Amplitude de Wilson)
WL	<i>Wave Length</i> (Tamanho de Onda)
WPT	<i>Wavelet Packet Transform</i> (Transformada Wavelet Packet)
WT	<i>Wavelet Transform</i> (Transformada Wavelet)
ZC	<i>Zero Crossings</i> (Cruzamentos por Zero)
ATLAS	<i>Automatically Tuned Linear Algebra Software</i> (Programa de Álgebra Linear Automaticamente Ajustado)

SUMÁRIO

1 INTRODUÇÃO	9
1.1 Objetivo Geral.....	10
1.2 Objetivos Específicos	10
1.3 Delimitações do Trabalho.....	11
2 PESQUISA DE MERCADO: PRÓTESES MIOELÉTRICAS DE MÃO	12
2.1 <i>Bebionic3 Hand</i>	12
2.2 <i>i-limb Quantum</i>	14
2.3 <i>TASKA</i>	15
3 REVISÃO BIBLIOGRÁFICA	17
3.1 Classificação de Sinais EMG no Controle de Próteses de Mão	17
3.2 Janelamento do Sinal EMG	18
3.3 Características de Interesse do Sinal Mioelétrico	19
3.4 Escolha do Classificador: Rede Neural Artificial	20
3.5 O Repositório de Dados NINAPRO (<i>Non-Invasive Adaptive Hand Prosthetics</i>).....	20
3.5.1 Ninapro DB1.....	21
3.5.2 Ninapro DB2.....	24
3.5.3 Ninapro DB3.....	26
3.5.4 Ninapro DB4 e DB5	27
3.5.5 Ninapro DB6.....	29
3.5.6 Ninapro DB7.....	30
3.6 Plataforma Raspberry Pi Zero	31
4 METODOLOGIA	33
4.1 Banco de Dados Utilizado	33
4.2 Análise Exploratória dos Dados	33
4.2 Composição do Classificador	38
4.4 Análise do Classificador: Todos vs Todos - Movimento Inteiro	39
4.5 Seleção de Movimentos.....	41
4.6 Análise do Tamanho do Conjunto de Treino e Validação.....	43
4.7 Análise do Classificador: (Todos - 1) vs 1 e 1 vs 1	45
4.7 Análise do Classificador: Janelamento 250/100 ms.....	47
4.8 Análise do Classificador: Janelamento 250/100 ms Com Repouso	48

4.9 Número de Neurônios na Camada Escondida.....	52
4.10 Características Adicionais: SSC e FFT.....	53
4.11 Implementação no Raspberry Pi Zero	56
5 ANÁLISE DOS RESULTADOS	58
6 CONSIDERAÇÕES FINAIS	62
6.1 Sugestões Para Trabalhos Futuros	63
REFERÊNCIAS.....	64

1 INTRODUÇÃO

A eletromiografia de superfície (EMGs) é uma técnica indolor, não invasiva, de captação e análise dos sinais mioelétricos presentes na superfície da pele, tendo sido utilizada como meio para o controle de próteses (SHENOY, 2008), braços robóticos (ARTEMIADIS, 2010) e exoesqueletos (KIGUCHI, 2004).

Nos Estados Unidos cerca de 185.000 habitantes/ano passam por algum tipo de amputação de membros superiores ou inferiores, numa estimativa total de 3,2 milhões de amputados até 2050 (ZIEGLER-GRAHAM, 2008). No Brasil, estima-se que a incidência de amputações é de 13,9 casos/ano a cada 100.000 habitantes (MONTIEL, 2012).

As próteses de membros evoluíram de pesados dispositivos rudimentares, construídos com madeira, ferro e couro, para modernos membros artificiais, fabricados com materiais de alta tecnologia e controle microprocessado (THURSTON, 2007). Porém, ao contrário das próteses de membros inferiores que já atingem altos níveis de desempenho, as próteses de membros superiores ainda não são capazes de suprir com satisfação as funções de um membro natural (DELLON, 2007), representando ainda um desafio para diversas áreas da engenharia.

Atualmente, o número de movimentos concomitantemente disponíveis em próteses mioelétricas de mão é bastante restrito, sendo necessário ainda um longo e cansativo treinamento para sua utilização. Pesquisas passadas revelam que de 30% a 50% dos amputados não utilizam sua prótese de mão regularmente, devendo-se isso à sua baixa funcionalidade, má aparência, baixa controlabilidade e falta de sistema de *feedback* (ATKINS, 1996). Ainda hoje é muito comum o controle de um único grau de liberdade, no que são chamadas de próteses *on-off*, possibilitando uma maior simplicidade e consequente confiabilidade no uso do dispositivo, porém ao alto custo da perda de flexibilidade.

Modernas próteses multifunção exigem para seu funcionamento o correto reconhecimento de padrões do sinal mioelétrico (CUNHA, 2000), o que proporcionaria uma maior naturalidade na escolha e execução dos movimentos. O sinal eletromiográfico é a maneira mais simples de descrever o movimento de contração de um músculo (HUANG, 1999), e entender como o usuário pretende se mover (KIGUCHI, 2004).

Recentemente pesquisadores vêm aplicando diferentes algoritmos de aprendizado de máquina com diversas combinações de classificadores, características, métodos de redução e pós-processamento, aplicados ao controle de mãos protéticas (GEETHANJALI, 2014). Essa análise deve ser realizada em tempo real, de maneira rápida e precisa, sob o risco de incorrer em frustração do usuário e desistência do uso do equipamento. Outro desafio é que essa tarefa deve ser realizada por dispositivos bastante pequenos, aptos a serem embutidos em um membro artificial.

Este trabalho aborda o processo de síntese e desenvolvimento de um sistema eletrônico inteligente de classificação de padrões no sinal mioelétrico do antebraço, voltado para o uso embarcado em próteses de mão. A escolha do conjunto de técnicas utilizadas é baseada no que é proposto pela literatura atual, avaliando-se sempre o desempenho do sistema com base na precisão de classificação e velocidade de resposta.

1.1 Objetivo Geral

Este trabalho objetiva o desenvolvimento de um sistema eletrônico microprocessado capaz de classificar corretamente movimentos de mão previamente definidos, com base em sinais EMG provenientes de um banco de dados público, exibindo o resultado da classificação efetuada em terminal computacional com um tempo de resposta e taxa de precisão adequados para o uso em próteses de mão.

1.2 Objetivos Específicos

- a) Desenvolver algoritmo computacional capaz de classificar 11 movimentos de mão distintos, com taxa de precisão maior que 90%, com base nos sinais EMG provenientes do antebraço de indivíduos não amputados, catalogados no primeiro banco de dados Ninapro (DB1);
- b) Implementar o algoritmo em dispositivo embarcado capaz de realizar a classificação do sinal EMG em tempo adequado para uso em próteses, considerando ou não um pré treinamento do usuário;

- c) Analisar o desempenho do sistema de classificação de forma numérica e gráfica, de forma a visualizar os pontos de falha e suas circunstâncias.

1.3 Delimitações do Trabalho

Uma prótese elétrica pode ter seu sistema eletrônico dividido em três partes: sistema de aquisição do sinal de controle, sistema de processamento e classificação do sinal e sistema de acionamento dos motores. Este trabalho aborda o desenvolvimento do segundo bloco, o sistema intermediário, capaz de receber um sinal EMG já captado por um sistema de aquisição e processá-lo, decidindo qual movimento deve ser realizado, disponibilizando o resultado para um sistema atuador. Dessa forma, não faz parte do escopo deste trabalho a captação do sinal EMG nem o acionamento de motores em uma mão protética real, mas sim um sistema que interliga-se com estes, realizando a decisão de qual movimento realizar com base em um sinal já adquirido.

2 PESQUISA DE MERCADO: PRÓTESES MIOELÉTRICAS DE MÃO

Apesar dos recentes avanços, o mercado de próteses multifunção com disponibilidade concomitante de movimentos ainda é muito restrito. Isso se deve em grande parte à baixa robustez dos algoritmos classificadores e também ao grande número de eletrodos necessários de serem utilizados.

A seguir são descritas algumas das opções de próteses de mão atuadas por sinais EMG disponíveis hoje no mercado. Serão apresentados um breve resumo de cada produto, expondo suas principais características conforme anunciado pelos seus fabricantes, além do preço, número de sensores utilizados, variedade de movimentos detectados e método de adaptação do usuário. Somente próteses disponíveis ao usuário comum serão analisadas, desconsiderando-se protótipos ainda em desenvolvimento ou voltados para aplicações restritas.

As empresas líderes na produção de próteses mioelétricas de mão são a *Ottobock* (Alemanha), *Liberating Technologies Inc.* (USA), *Motion Control* (USA), *RSL-Stepper* (U.K.) e *Touch Bionics* (USA) (MICERA, 2010).

2.1 *Bebionic3 Hand*

A *Bebionic3* conta com 14 movimentos de mão pré-programados, movimento dos dedos individualizado, 4 opções de punho substituíveis, revestimento macio sobre os dedos e detecção de deslizamento de objetos com ajuste automático de força. O usuário deve selecionar 8 dos 14 movimentos para estarem habilitados durante o uso. Isso é feito através de um software próprio de configuração que se comunica com a prótese via um transceptor *bluetooth* USB (*Universal Serial Bus*) fornecido.

A estratégia de controle é um avançado sistema *on-off* (um único movimento possível em cada instante) com diversas configurações suplementares. Um botão pressionado no topo da mão altera entre dois grupos de movimentos ("primário" e "secundário") e duas posições de polegar compõem outro mecanismo de seleção (movimentos de polegar "oposto" e "não-oposto"). Uma terceira escolha é realizada por uma sequência de sinais acionados pelo usuário (por padrão um sinal "abrir abrir") que altera entre os modos "padrão" e "alternativo". Dessa forma, são disponibilizadas 8 opções de movimentos, através de 3 seletores binários. Outras

configurações ajustadas via software incluem a alteração da velocidade dos movimentos, o nível de força aplicada, ativação do sistema de auto preensão, tempo de reação entre comandos, nível limiar de ativação, número de eletrodos utilizados (opção entre um ou dois), tipo de *feedback* para mudança de modo (sonoro ou vibratório), entre outros.

Originalmente desenvolvida pela empresa britânica de tecnologia médica *RLS-Steeper*, a linha de produtos *Bebionic* foi adquirida em fevereiro de 2017 pela alemã *Ottobock*. A figura 1 apresenta a prótese *Bebionic3*.

Figura 1 – Prótese de mão *Bebionic3* – imagem de divulgação



Fonte: Adaptado de *Bebionic3* (2017, p.6)

O quadro 1 resume as principais características de interesse deste produto.

Quadro 1 – *Bebionic3* - características de interesse

Característica	Descrição
Preço	Entre 25.000 e 35.000 dólares.
Número de eletrodos utilizados	1 ou 2 (padrão).
Movimentos realizados	14 movimentos pré determinados: apontar para frente, apontar para baixo, coluna, adução dos dedos, aperto em gancho, aperto para mouse, palma aberta, aperto de polegar e indicador, aperto forte, aperto de precisão fechado, aperto de precisão aberto, aperto com três dedos e posição de repouso.
Método de adaptação do usuário	Treinamento individualizado baseado em 1 ou 2 estímulos configuráveis, com diversas variáveis customizáveis via software.

Fonte: Elaborado pelo autor.

2.2 *i-limb Quantum*

Desenvolvida pela norte-americana *Touch Bionics*, a *i-limb quantum* possui quatro modos de seleção de movimentos: por gestos, por aplicativo para celular, por proximidade e por atividade muscular. Seu funcionamento é dado por apenas dois estímulos, "abrir" e "fechar", geralmente retirados de sinais EMG provenientes de grupos musculares distintos.

Apesar de possuir somente dois sinais de controle, possui disponibilidade concomitante de movimentos baseado em gatilhos configuráveis como "duplo impulso" (dois estímulos de "abrir" seguidos), "triplo impulso" (três estímulos de "abrir" seguidos), "manter aberto" (usando e mantendo o estímulo "abrir"), "co-contracção" (contraíndo ambos músculos de "abrir" e "fechar" ao mesmo tempo), entre outros que podem ser adicionados, conforme o interesse e habilidade do usuário.

O sistema de controle por proximidade é baseado em tecnologia própria em que pequenos dispositivos *Bluetooth*, denominados *grip chips*, podem ser fixados em determinados locais e quando a prótese se aproxima destes, uma configuração previamente definida é imediatamente selecionada.

Possui 24 movimentos pré-configurados, com a possibilidade de se adicionar mais 12 movimentos personalizados, além de detecção de deslizamento de objetos com ajuste automático de força. Possui também compatibilidade com diversos produtos de outras empresas do ramo como o *ProWrist Electric Wrist Rotator (Motion Control)*, *Electric Wrist Rotator & MyoRotronic (Ottobock)*, *Boston Digital Arm System (Liberating Technologies Inc.)*, *Dynamic Elbow (Ottobock)*, entre outros. A figura 2 apresenta a prótese *i-limb Quantum* em diversos tamanhos.

Figura 2 – Prótese de mão *i-limb quantum* – imagem de divulgação



Fonte: Quantum (2018)

O quadro 2 resume as principais características de interesse deste produto.

Quadro 2 – *i-limb Quantum* - características de interesse

Característica	Descrição
Preço	Entre 60.000 e 120.000 dólares.
Número de eletrodos utilizados	2.
Movimentos realizados	24 movimentos pré-determinados (não divulgados) mais 12 movimentos programáveis.
Método de adaptação do usuário	Treinamento individualizado baseado em dois estímulos ("abrir" e "fechar"), com possibilidade de comandos sequenciais customizáveis.

Fonte: Elaborado pelo autor.

2.3 TASKA

Produzida pela americana *Motion Control*, empresa do grupo *Fillauer*, a *TASKA* é uma prótese elétrica com design robusto, 22 movimentos, à prova d'água e de poeira (certificação IP67 – submersível de 15cm à 1m de profundidade), e com mobilidade lateral dos dedos. Caso haja sobrecarga em algum dos dedos este se desconecta da mão, podendo ser reafixado sem maiores danos.

Os movimentos somente são disponíveis individualmente, devendo-se selecionar qual movimento se quer realizar através de botões localizados no topo da

mão. O usuário pode selecionar até três gestos de sua preferência e associá-los a um botão individual, um número que a empresa garante ser suficiente para a maioria das atividades diárias. O acionamento pode ser realizado por sinais EMG ou através de botões localizados na própria mão. Cinco dos movimentos disponíveis são customizáveis pelo usuário, através de software fornecido pela empresa. A figura 3 apresenta a prótese *TASKA* nos diversos modelos disponíveis.

Figura 3 – Prótese de mão *TASKA* – imagem de divulgação



Fonte: Taska (2018)

O quadro 3 resume as principais características de interesse deste produto.

Quadro 3 – *TASKA* – características de interesse

Característica	Descrição
Preço	35.000 dólares.
Número de eletrodos utilizados	2.
Movimentos realizados	22 movimentos: aperto comum, flexi-tool, pinça, chave, aperto de três dedos, movimento de três dedos, aperto de precisão, aperto gancho, aperto para tablet, aperto esférico, apontar, palma aberta, posição para uso de teclado, posição para vestir e desvestir, segurar, soltar, aperto para mouse, movimento de gatilho de um e dois dedos, aperto amplo e posição de repouso.
Método de adaptação do usuário	Treinamento individualizado baseado em dois estímulos ("abrir" e "fechar"), com possibilidade de comandos sequenciais customizáveis.

Fonte: Elaborado pelo autor.

3 REVISÃO BIBLIOGRÁFICA

Neste capítulo serão descritos os conhecimentos teóricos relevantes para o desenvolvimento deste trabalho. Primeiro serão abordados a viabilidade do uso da eletromiografia como sistema de controle de próteses multimovimentos. Em seguida são investigadas as principais técnicas utilizadas atualmente no processamento de sinais EMG. É também realizada uma análise do banco de dados NINAPRO, utilizado como base de dados deste trabalho, e por fim, uma análise do dispositivo utilizado para implementação do algoritmo, tornando o sistema apto para uso embarcado.

3.1 Classificação de Sinais EMG no Controle de Próteses de Mão

A rápida evolução de sensores portáteis e microcontroladores, aliados à pesquisas recentes, podem tornar possível para amputados recuperar pelo menos parte das funcionalidades de seus membros perdidos. Apesar das dificuldades no reconhecimento de movimentos complexos no membro residual de amputados, estes são capazes de reproduzir com consistência alguns padrões no sinal mioelétrico, permitindo assim o controle de próteses com maior naturalidade (BERMUDEZ, 2014).

Diversos estudos já foram realizados propondo diferentes conjuntos de técnicas para se identificar qual o movimento de mão realizado com base em sinais mioelétricos. É muito comum a realização de testes em voluntários não amputados, assumindo-se que os resultados poderiam ser generalizados para indivíduos debilitados. Isso, porém, nem sempre é possível e depende de muitos fatores como o grau e o tipo de amputação, variando muito para cada caso (NOVAK, 2014).

Os resultados apresentados pela literatura na classificação de sinais EMG são diversos, mostrando acurácia desde de 80% até mais de 95%. A comparação entre estudos, porém, deve ser realizada com cautela, pois os resultados dependem de muitos fatores como o número de classes (resultados possíveis de classificação), balanceamento entre as classes, tamanho e tipo do conjunto de dados, equipamento de aquisição entre outros.

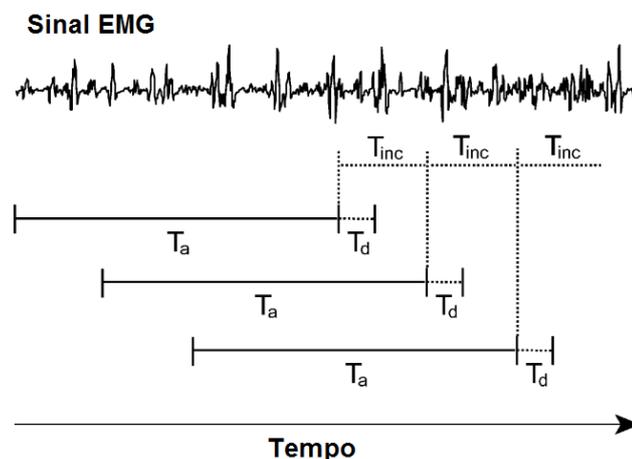
3.2 Janelamento do Sinal EMG

A estratégia de janelamento é muito utilizada em algoritmos classificadores para a análise de séries temporais não periódicas. Consiste na divisão do sinal em segmentos que são posteriormente utilizados como unidades de informação para a retirada de características, processamento e análise.

O janelamento é dado principalmente por duas variáveis: "tempo de janela" e "deslocamento". Quando o deslocamento é menor que o tempo de janela, ocorre a sobreposição dos dados, com partes do sinal original aparecendo em mais de uma janela. Com o deslocamento igual ao tempo de janela, cada segmento contém dados únicos e o conjunto de todas os segmentos reconstitui o sinal original de maneira exata. Já com deslocamento maior que o tempo de janela, uma parte original dos dados é perdida conforme a janela se desloca mais que seu tamanho de aquisição.

Dos três casos citados, o que mais ocorre na literatura de análise de sinais EMG é o primeiro, onde amplas janelas (por volta de 200 ms) realizam pequenos deslocamentos (cerca de 50 ms), efetuando a análise do sinal dentro daquele período. Isso permite uma maior velocidade na detecção de algum aspecto de interesse do sinal, a um custo computacional mais elevado. A figura 4 mostra um exemplo de sinal EMG sendo segmentado, evidenciando o tempo de janela, deslocamento e o tempo de processamento do algoritmo.

Figura 4 – Exemplo de segmentação de um sinal EMG utilizando janelas de tamanho T_a , deslocamento T_{inc} e tempo de processamento T_d



Fonte: adaptado de SMITH (2011)

Um estudo realizado em 2011 comparou o efeito de diversos tamanhos de janelas, de 50 ms até 550ms, voltado especificamente para o processamento de sinais EMG no controle de próteses. Os resultados indicam que o erro de classificação diminui conforme se aumenta o tamanho da janela, com um ponto ótimo sugerido entre 150 ms e 250 ms. Janelas maiores poderiam reduzir ainda mais o erro, porém o atraso de resposta do sistema tornaria-se inviável para o uso em próteses (SMITH, 2011).

3.3 Características de Interesse do Sinal Mioelétrico

O desempenho de um classificador de sinais EMG está fortemente ligado à escolha de características que representem esse sinal. Algoritmos classificadores exigem para o seu bom funcionamento dados de entrada adequados, geralmente parâmetros do domínio do tempo ou da frequência, que contenham informações sobre aquilo que se quer identificar.

Na classificação de movimentos são geralmente utilizados diversos parâmetros em conjunto, já que é bastante difícil encontrar uma única característica que reflita com exatidão o movimento executado (AHSAN, 2011).

Muitas características já foram extraídas do sinal EMG e utilizadas em diversas pesquisas, com diferentes graus de sucesso. São eles o valor médio absoluto (*MAV*), raiz do valor quadrático médio (*RMS*), coeficientes de auto-regressão (*AR*), variância (*VAR*), desvio padrão (*SD*), cruzamentos por zero (*ZC*), tamanho de onda (*WL*), amplitude de Willson (*WA*), inclinação do desvio médio absoluto (*MAVS*), frequência média (*MNF*), frequência mediana (*MDF*), mudança do sinal da inclinação (*SSC*), coeficientes mel-cepstrais (*CC*), coeficientes da transformada rápida de Fourier (*FFT*), coeficientes da transformada de Fourier de tempo curto (*STFT*), EMG integrado (*IEMG*), coeficientes da transformada wavelet (*WT*) e coeficientes da transformada *Wavelet Packet* (*WPT*). O conjunto ótimo de características que melhor descreve o sinal EMG ainda é tema de debate e pesquisa, não existindo um consenso sobre tal, sendo geralmente necessário a realização de testes e comparação de resultados.

3.4 Escolha do Classificador: Rede Neural Artificial

A maneira mais simples de se classificar sinais EMG é utilizando um classificador invariante com o tempo. Nesse caso, estudos mostram que a escolha de um classificador específico é menos importante que outras escolhas realizadas, especialmente quando comparado a fatores como tamanho da janela, tipos de características e posicionamento dos eletrodos. Muitos algoritmos classificadores existem e são utilizados com sucesso na literatura, porém o algoritmo de redes neurais se destaca por ser, com larga margem, o mais utilizado entre eles (NOVAK, 2014), sendo adequado para a modelagem de dados de relação linear e não linear, conseguindo reconhecer padrões sob diferentes condições. Possui ainda diversas variantes, desde a mais comum, o perceptron multicamadas (*MLP*), até redes neurais mais complexas com atraso no tempo ou do tipo neuro-fuzzy. Redes neurais ainda contam com farta literatura de apoio e disponibilidade de bibliotecas para sua implementação computacional.

Para se projetar uma rede neural para uma aplicação específica, devemos tomar as seguintes decisões: escolher o tipo de arquitetura, definir o número de camadas, definir o número de neurônios em cada camada e definir o algoritmo de aprendizado (CHOWDHURY, 2013). O tipo de arquitetura mais utilizada atualmente é a *MLP* com aprendizado utilizando o algoritmo *backpropagation*.

O número de neurônios utilizados na camada de entrada depende dos atributos de interesse utilizados, já o número de neurônios na camada de saída depende do número de classes consideradas (número de padrões classificados). O número de neurônios nas camadas escondidas é geralmente um parâmetro ajustável e regulado através de iterações conforme o desempenho apresentado da rede.

3.5 O Repositório de Dados NINAPRO (*Non-Invasive Adaptive Hand Prosthetics*)

Um conhecido obstáculo na pesquisa de classificadores mioelétricos é a dificuldade de se obter dados EMG de fontes confiáveis, que sigam protocolos de aquisição adequados e utilizem bons equipamentos. Empresas privadas possuem bancos de dados próprios, não divulgados, já estudos públicos contam geralmente

com a colaboração de voluntários, sendo comum a generalização dos resultados obtidos com não amputados para amputados (ATZORI, 2014), ou ainda um baixo número de participantes. Também existe uma alta variabilidade entre os estudos quanto ao ponto de colocação dos eletrodos, tipos de movimentos classificados, equipamentos utilizados, entre outras variáveis relevantes, o que torna difícil a comparação de resultados entre pesquisas. (ATZORI, 2015)

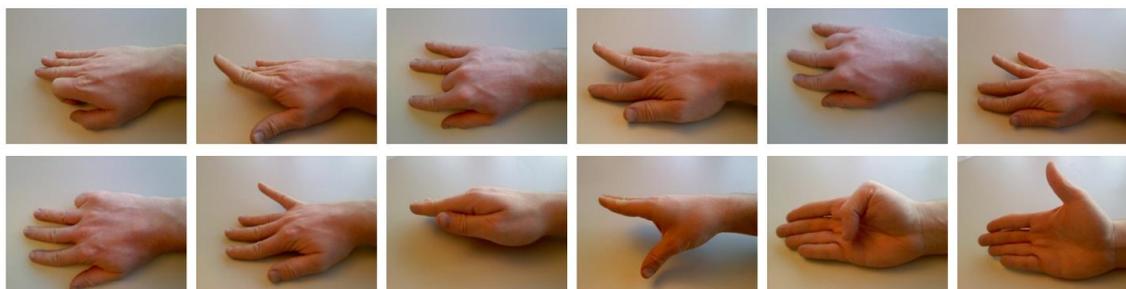
Muitos campos de estudo já se beneficiaram de bancos de dados públicos e robustos, aceitos como referência em suas áreas, facilitando a validação de novas idéias e incentivando novas pesquisas. Como exemplos podemos citar as áreas da robótica, com o repositório de dados *Radish* (HOWARD, 2003), da visão computacional, com os bancos de dados *PASCAL* (EVERINGHAM, 2010) e *CALTECH 256* (GRIFFIN, 2007) e na área médica, com o *ImageCLEF* (MULLER, 2004). A existência de uma base comparativa torna muito mais fácil a tarefa de provar a eficácia de um novo método ou técnica.

Assim, foi lançado em 2012 a primeira versão do banco de dados NINAPRO, repositório público de sinais EMG voltado para a pesquisa de métodos de controle de próteses mioelétricas de mão. Composto em seu lançamento por 27 indivíduos não amputados realizando 52 movimentos de mão distintos, hoje possui seis outros conjuntos de dados publicados, incluindo dados de amputados transradiais (com amputação entre cotovelo e punho). Abaixo são explicadas as sete base de dados disponíveis no repositório Ninapro, nomeadas de DB1 à DB7.

3.5.1 Ninapro DB1

A primeira base de dados lançada, contém dados EMG e cinemáticos de movimento da mão de 27 indivíduos não amputados, realizando 52 movimentos de mão, dedos e punho, com 10 repetições cada. Para detectar o movimento exato da mão foi utilizada a luva de aquisição de dados *Cyberglove III* da *CyberGlove Systems*, composta por 22 sensores strain gauge posicionados de modo a detectar os ângulos de interesse entre as articulações da mão e assim definir sua posição em tempo real. Um inclinômetro também foi utilizado para registrar a inclinação do braço durante a aquisição. Os 52 movimentos de mão realizados são mostrados na figura 5.

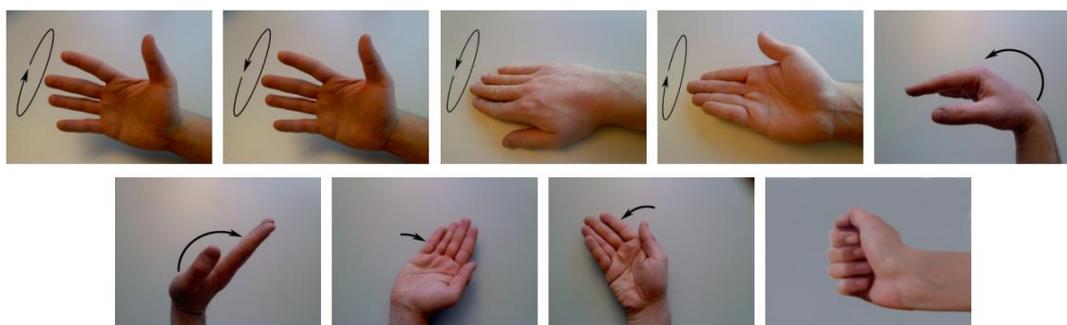
Figura 5 – Os 52 movimentos realizados no Ninapro DB1



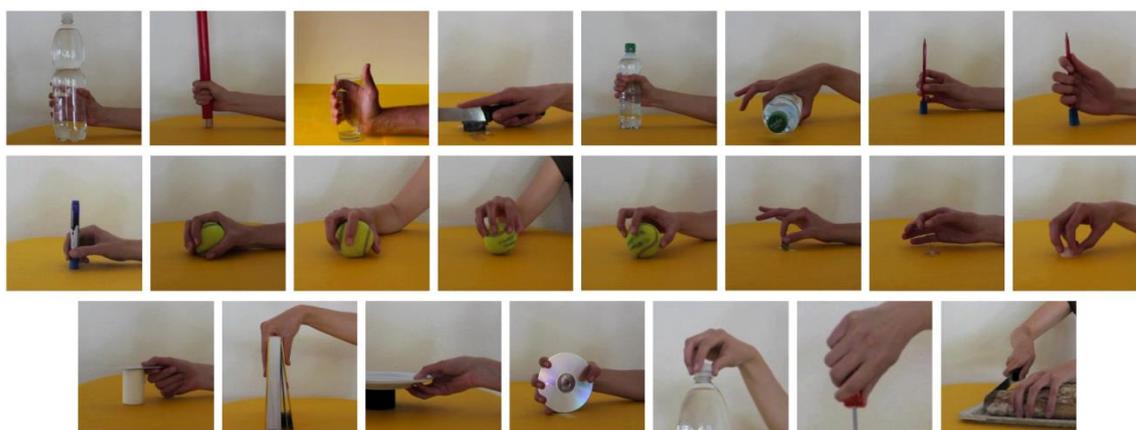
(a) 12 posturas de mão (isométrica e isotônica)



(b) 8 movimentos básicos dos dedos (flexões e extensões)



(c) 9 movimentos básicos de pulso



(d) 23 movimentos funcionais

Fonte: adaptado de ATZORI (2012).

O sinal EMG é adquirido através de 10 eletrodos ativos de par diferencial *OttoBock* modelo *MyoBock 13-E200*, mostrados na figura 6, que produzem um sinal

retificado e amplificado em cerca de 14.000 vezes, à uma taxa de aquisição de 100 Hz, além de possuírem filtro de linha de 50 ou 60 Hz (dependendo do modelo específico). Esses eletrodos são tidos na literatura como seguros e confiáveis, e seu uso não requer limpeza especial ou depilação do local (ATZORI, 2012).

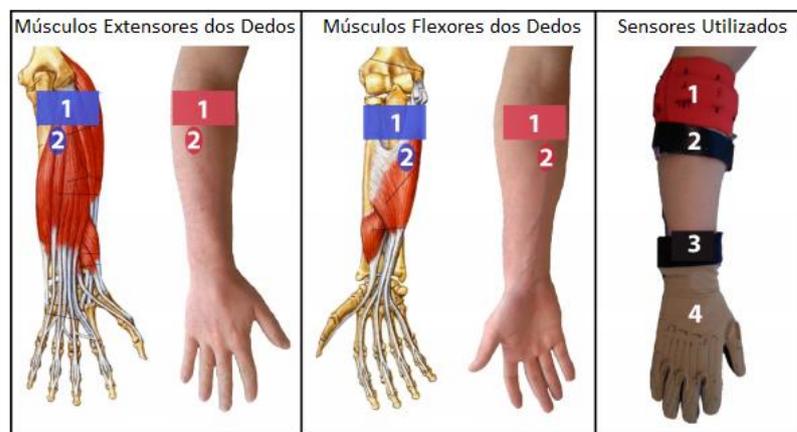
Figura 6 – Eletrodos 13-E200 MyoBock utilizados no Ninapro DB1



Fonte: Ottobock (2018).

Oito eletrodos são colocados uniformemente ao redor do antebraço, próximo ao cotovelo, outros dois eletrodos são posicionados logo abaixo, nos músculos flexor e extensor dos dedos, conforme mostrado na figura 7.

Figura 7 – Disposição dos sensores para aquisição dos dados do Ninapro DB1 com (1) oito eletrodos igualmente espaçados, (2) dois eletrodos nos músculos flexor e extensor dos dedos, (3) inclinômetro e (4) luva de aquisição de dados



Fonte: adaptado de ATZORI (2012).

Não foram selecionados pontos ótimos de colocação de cada eletrodo como sugere a literatura clássica da eletromiografia, isso é baseado no fato de que o ponto ótimo de aquisição em amputados varia muito de acordo com o tipo de amputação, além de pesquisas recentes mostrarem que a colocação de eletrodos em pontos específicos já não é um pré requisito para o reconhecimento de movimentos no sinal mioelétrico, já que as técnicas atuais conseguem compensar e até mesmo se beneficiar de sinais EMG compostos por diversos músculos (chamado de efeito *crosstalk*).

O quadro 4 resume as principais características de interesse do banco de dados Ninapro DB1.

Quadro 4 – Ninapro DB1 – características de interesse

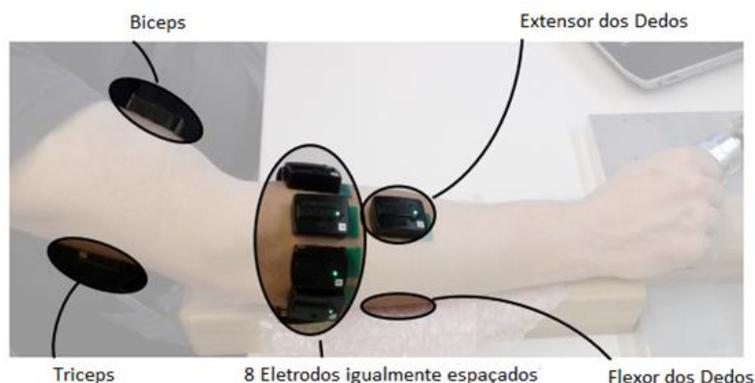
Característica	Descrição
Indivíduos não amputados	27.
Indivíduos amputados	0.
Eletrodos	10 OttoBock.
Número de movimentos	52.
Número de repetições	10.

Fonte: Elaborado pelo autor.

3.5.2 Ninapro DB2

O segundo conjunto de dados adicionado ao repositório NINAPRO é composto por 40 indivíduos não amputados. Seguindo o mesmo protocolo básico de aquisição, alguns ajustes foram realizados, como a diminuição do número de repetições de movimentos de 10 para 6, para limitar a fadiga muscular dos indivíduos em análise, e a troca dos eletrodos *MyoBock* pelo modelo *Trigno Wireless*, da empresa *De/sys*. Esses eletrodos, também ativos de par diferencial, possuem taxa de aquisição de 2 kHz, ruído de fundo menor que 750 nV RMS e acelerômetro integrado de três eixos, amostrado à 148 Hz. Ainda foram colocados dois eletrodos adicionais sob os músculos do bíceps e tríceps, que antes não eram amostrados. A figura 8 mostra o posicionamento dos eletrodos para esse procedimento.

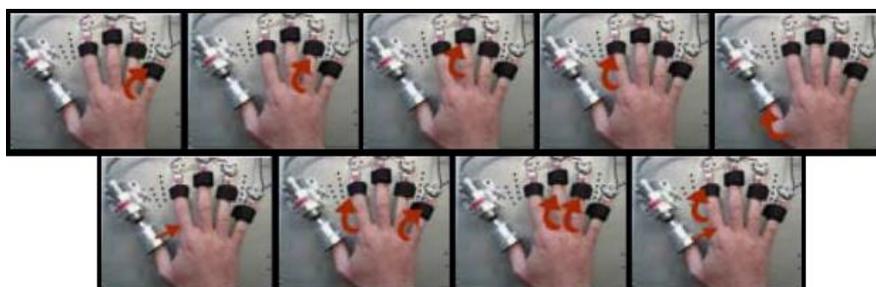
Figura 8 – Disposição dos eletrodos para aquisição dos dados do Ninapro DB2



Fonte: adaptado de GIJSBERTS (2013).

Houve também um ajuste nos movimentos realizados, onde as 12 primeiras posturas de mão (isométricas e isotônicas) foram removidas do protocolo, sendo substituídas por um exercício equivalente de dedos, composto por 9 gestos, perfazendo um total de 49 movimentos. Foi também adicionada uma informação relacionada ao padrão de força para esses 9 gestos, sendo esse dado adquirido com um equipamento chamado *Finger-Force Linear Sensor* (FFLS), que mede a força aplicada na ponta dos dedos de uma pessoa em ambas as direções (flexão e extensão), mais a rotação, adução e abdução do polegar. Nesse caso a luva de aquisição de dados cinemáticos não é utilizada. Na figura 9 vemos estes movimentos específicos sendo realizados com a utilização do FFLS.

Figura 9 – Os 9 movimentos realizados utilizando o FFLS no Ninapro DB2



Fonte: adaptado de GIJSBERTS (2012).

O quadro 5 resume as principais características de interesse do banco de dados Ninapro DB2.

Quadro 5 – Ninapro DB2 – características de interesse

Característica	Descrição
Indivíduos não amputados	40.
Indivíduos amputados	0.
Eletrodos	12 Delsys.
Número de movimentos	49.
Número de repetições	6.

Fonte: Elaborado pelo autor.

3.5.3 Ninapro DB3

Esse banco de dados é formado por 11 indivíduos com amputação trans-radial. Foi empregado o mesmo protocolo realizados no Ninapro DB2 composto por 49 movimentos, onde foi solicitado aos participantes para que pensassem em repetir o gesto mostrado em um monitor da forma mais natural possível, utilizando o membro afetado. Deve-se notar que três participantes (1, 3 e 10) não puderam concluir todo o procedimento devido à fadiga ou à dor, reproduzindo 39, 49 e 43 dos movimentos, respectivamente. Também ocorreu em dois casos (7 e 8) do número de eletrodos ser reduzido de 12 para 10, por falta de espaço no antebraço para fixação.

É importante ressaltar que amputados, em geral, não conseguem produzir nenhum tipo de referência absoluta, denominada *ground truth*, devido à impossibilidade de operar qualquer tipo de sensor com o membro inexistente (ATZORI, 2014), dessa forma o banco de dados contém como referência somente a informação de qual estímulo estava sendo exibido em vídeo no momento da aquisição. Também é importante considerar que diversos parâmetros clínicos relacionados à amputação impactam na capacidade de se classificar movimentos utilizando o sinal EMG, como nível de amputação, tempo decorrido desde a amputação e até mesmo a existência ou não da sensação de membro fantasma (ATZORI, 2016). O quadro 6 resume as principais características de interesse do Ninapro DB3.

Quadro 6 – Ninapro DB3 – características de interesse

Característica	Descrição
Indivíduos não amputados	0.
Indivíduos amputados	11.
Eletrodos	12 Delsys.
Número de movimentos	49.
Número de repetições	6.

Fonte: Elaborado pelo autor.

3.5.4 Ninapro DB4 e DB5

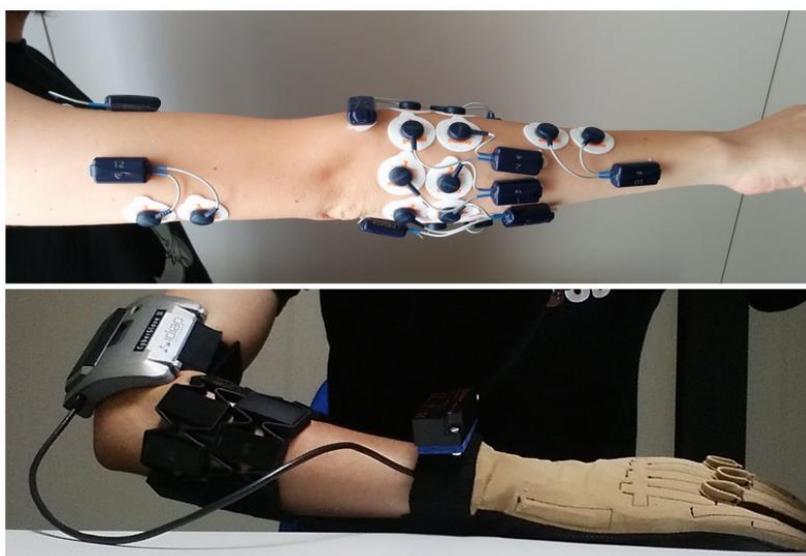
Os bancos de dados Ninapro DB4 e DB5 são descritos de maneira conjunta pois fazem parte de um mesmo estudo, que analisa o impacto dos equipamentos de aquisição na capacidade de se obter informações de dados EMG (PIZZOLATO, 2017). São utilizados sensores modelo *Cometa Wave Plus* (DB4) e dois braceletes modelo *Thalmic Myo Armband* (DB5) com 8 eletrodos cada. São analisados 10 indivíduos em cada configuração, realizando 52 movimentos, conforme o protocolo utilizado no Ninapro DB1 .

Os sensores *Cometa* possuem entrada de $\pm 2,5$ mV, ganho de 1000 vezes, filtragem passa-banda entre 10 e 1000 Hz, taxa de aquisição de 2 kHz e resolução de 16 bits. Cada sensor foi ligado à dois eletrodos descartáveis modelo *Dormo SX-30* (30 mm de diâmetro) e posicionados conforme descrito em Ninapro DB2. Todos os indivíduos foram depilados, raspados e desinfetados nos locais de colocação dos eletrodos.

Os sensores da marca *Thalmic* estão disponíveis na forma de um bracelete elástico e sua principal característica é o baixo custo, com um preço de 3 a 4 vezes menor que um único eletrodo *OttoBock 13-E200* e quase 100 vezes menor que um sistema completo de aquisição, como o *Delsys Trigno* ou o *Cometa Wave* (PIZZOLATO, 2017). Com cada bracelete contendo 8 eletrodos, possui taxa de amostragem de 200 Hz, resolução de 8 bits e transmissão de dados via Bluetooth. Dois braceletes são colocados no antebraço próximo do cotovelo, um abaixo do outro, assemelhando-se às outras configurações já utilizadas.

É importante ressaltar que ambos os modelos possuem sensores de par diferencial simples, enquanto os sensores utilizados anteriormente eram de par diferencial duplo. Isso torna os dados mais suscetíveis à influência de outros músculos não situados imediatamente abaixo dos eletrodos (efeito *crosstalk*). A figura 10 mostra o posicionamento dos eletrodos nos dois procedimentos.

Figura 10 – Disposição dos sensores da marca *Cometa* (acima) e *Thalmic* (abaixo) para aquisição dos dados do Ninapro DB4 e DB5



Fonte: adaptado de PIZZOLATO (2017).

O quadro 7 resume as principais características de interesse dos bancos de dados Ninapro DB4 e DB5.

Quadro 7 – Ninapro DB4 e DB5 – características de interesse

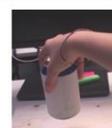
Característica	Descrição DB4	Descrição DB5
Indivíduos não amputados	10.	10.
Indivíduos amputados	0.	0.
Eletrodos	12 Cometa Systems.	16 Thalmic Labs (2x8).
Número de movimentos	52.	52.
Número de repetições	6.	6.

Fonte: Elaborado pelo autor.

3.5.5 Ninapro DB6

O sexto banco de dados adicionado ao repositório Ninapro objetiva o estudo da repetibilidade na classificação de movimentos ao longo do tempo. Composto por 10 indivíduos realizando 7 movimentos com 12 repetições cada, duas vezes ao dia, ao longo de 5 dias (totalizando 120 repetições). Os movimentos escolhidos são baseados na literatura da robótica e reabilitação, sendo realizados em 2 objetos distintos cada, conforme apresentado na figura 11.

Figura 11 – Movimentos realizados no Ninapro DB6

Descrição	Amplio Diâmetro	Polegar Aduzido	Extensão de Indicador	Envolvimento Médio	Gesto de Escrita	Força Esférica	Precisão Esférica
Movimento							
Objetos							
							

Fonte: adaptado de GIJSBERTS (2012).

Foram utilizados 14 eletrodos da marca *Delsys*, sendo 8 posicionados logo abaixo do cotovelo, conforme experimentos anteriores, e outros seis posicionados abaixo destes, também em forma de anel, correspondendo aos espaços vazios entre os eletrodos da primeira linha. É importante ressaltar que essa configuração é diferente de outras já utilizadas. O quadro 8 resume as principais características de interesse do Ninapro DB6.

Quadro 8 – Ninapro DB6 – características de interesse

Característica	Descrição
Indivíduos não amputados	10.
Indivíduos amputados	0.
Eletrodos	14 Delsys.
Número de movimentos	7.
Número de repetições	120 (ao longo de 5 dias).

Fonte: Elaborado pelo autor.

3.5.6 Ninapro DB7

O sétimo banco de dados Ninapro conta com 20 indivíduos não amputados e 2 amputados. 12 sensores *Delsys Trigno Wireless* foram posicionados conforme realizado no Ninapro DB2, sendo 8 igualmente espaçados abaixo do cotovelo, 2 sobre os músculos extensor e flexor dos dedos, e 2 posicionados sobre o bíceps e tríceps. A figura 12 mostra o posicionamento dos eletrodos neste procedimento.

Figura 12 – Posicionamento dos eletrodos em três indivíduos para aquisição dos dados do Ninapro DB7



Fonte: KRASOULIS (2017).

Os indivíduos foram orientados a reproduzir 40 gestos de mão, os mesmos utilizados no Ninapro DB2, excetuando-se os movimentos de força que utilizaram o sensor FFLS. O protocolo de aquisição segue o que foi utilizado anteriormente, com instruções exibidas em um monitor e 6 repetições para cada movimento.

Para os amputados foi solicitado que realizassem movimentos bilaterais espelhados, imaginando o movimento com o membro afetado e realizando-o de fato com o membro funcional, ao mesmo tempo. Um dos indivíduos (21) não realizou os dois últimos movimentos funcionais, sendo nesse caso o número de movimentos igual a 38. O quadro 9 resume as principais características de interesse do Ninapro DB7.

Quadro 9 – Ninapro DB7 – características de interesse

Característica	Descrição
Indivíduos não amputados	20.
Indivíduos amputados	2.
Eletrodos	12 Delsys.
Número de movimentos	40.
Número de repetições	6.

Fonte: Elaborado pelo autor.

3.6 Plataforma Raspberry Pi Zero

Um sistema de classificação de movimentos para uso embarcado em próteses deve ser pequeno, leve e capaz de realizar em tempo hábil as intensas operações matemáticas intrínsecas aos algoritmos modernos de aprendizado de máquina.

Figura 13 – Raspberry Pi Zero – Imagem de divulgação



Fonte: RASPBERRY (2018)

O Raspberry Pi Zero (figura 13) é um computador de placa única, sendo o menor e mais acessível modelo de Raspberry Pi disponível no mercado. Foi desenvolvido pela Fundação Raspberry Pi no Reino Unido, possui arquitetura ARM baseada no SoC (*System On Chip*) BCM2835 da Broadcom, processador de 1 GHz, 512 MB de memória RAM, 1 porta mini HDMI, 1 USB Power, 1 USB OTG (*On The Go*) para periféricos e entrada para cartão de memória microSD.

Esse sistema roda um sistema operacional próprio baseado em Linux denominado Raspbian que é gravado em um cartão de memória e inserido no

dispositivo. Uma das vantagens de se trabalhar com um sistema baseado em Linux é a disponibilidade nativa da linguagem de programação Python, o que facilita muito a implementação e possível alteração posterior de funcionalidades do sistema. O custo atual do Raspberry Pi Zero é de cerca de U\$5.

Essas características tornam esse dispositivo uma boa opção para a implementação de algoritmos de aprendizado de máquina que exigem médio desempenho de processamento, pequeno tamanho e baixo custo.

4 METODOLOGIA

Nesta etapa são detalhados os procedimentos para construção do sistema classificador de movimentos para uso embarcado em próteses de mão. São abordados os procedimentos tomados para compor o modelo classificador, bem como sua implementação e posterior validação.

4.1 Banco de Dados Utilizado

Os dados utilizados são o cerne de qualquer algoritmo de aprendizado de máquina, representando a matéria prima com que os resultados são produzidos. Foram escolhidos dados do repositório Ninapro devido à alta qualidade de equipamentos utilizados, protocolos de aquisição bem definidos e boa documentação sobre a construção desses bancos de dados, na forma de artigos.

Após extensa análise de todo o repositório Ninapro, além de análise dos tamanhos de arquivos, equipamentos de aquisição e do dispositivo utilizado para embarcar o sistema, optou-se pela utilização somente do banco de dados DB1. Excluiu-se a utilização dos demais bancos de dados devido à existência de condições discrepantes com relação à este, como utilização de eletrodos de baixo custo (DB5), a aquisição dos dados realizada ao longo dos vários dias (DB6), e o espaço de memória utilizado pelos arquivos (cerca de 500 MB por indivíduo no caso do DB2 por exemplo, quando comparado à uma média de apenas 20 MB no DB1). Dessa forma, buscando em um primeiro momento a maior homogeneidade possível nos dados trabalhados, optou-se pela restrição de utilizar somente o Ninapro DB1.

4.2 Análise Exploratória dos Dados

Após escolha do banco de dados a ser trabalhado se faz necessário uma compreensão completa daquilo que o compõe, numa etapa de análise prévia dos dados para que se possa trabalhar de maneira lógica e correta com os mesmos.

O Ninapro DB1 é composto por 81 arquivos, sendo 3 arquivos para cada indivíduo, totalizando 27 indivíduos distintos. Cada arquivo contém um grupo de movimentos padronizado denominado exercício, e cada movimento individual foi chamado de estímulo. Cada exercício leva entre 1000 e 2500 segundos para ser

realizado, dependendo da quantidade de movimentos contidos em cada exercício, sendo o primeiro exercício o mais curto (12 movimentos de dedos) e o terceiro o mais longo (23 movimentos funcionais).

A figura 14 mostra as colunas utilizadas após importação de um dos arquivos em ambiente Python. Foram utilizadas para manipulação dos dados as bibliotecas Pandas, Numpy e Matplotlib, já bastante conhecidas e utilizadas na exploração de dados em Python. As colunas "CH1" à "CH10" contém as amostras dos dez eletrodos de par diferencial e são a principal fonte de informação para o modelo. A taxa de aquisição utilizada nesse banco de dados foi de 100 Hz.

Figura 14 – Dados utilizados de um dos arquivos importados

Indivíduo 10 - Exercício 1														
	CH1	CH2	CH3	CH4	CH5	CH6	CH7	CH8	CH9	CH10	estímulo	repetição	reestímulo	rerepetição
0	0.0024	0.0024	0.0024	0.0024	0.0024	0.0098	0.0146	0.0488	0.0024	0.0317	0	0	0	0
1	0.0024	0.0024	0.0024	0.0024	0.0024	0.0098	0.0122	0.0439	0.0024	0.0317	0	0	0	0
2	0.0024	0.0024	0.0024	0.0024	0.0024	0.0073	0.0073	0.0366	0.0024	0.0293	0	0	0	0
3	0.0049	0.0024	0.0024	0.0024	0.0024	0.0073	0.0049	0.0317	0.0024	0.0269	0	0	0	0
4	0.0049	0.0024	0.0024	0.0024	0.0024	0.0024	0.0024	0.0293	0.0024	0.0220	0	0	0	0

Dimensões: 100778 linhas x 14 colunas

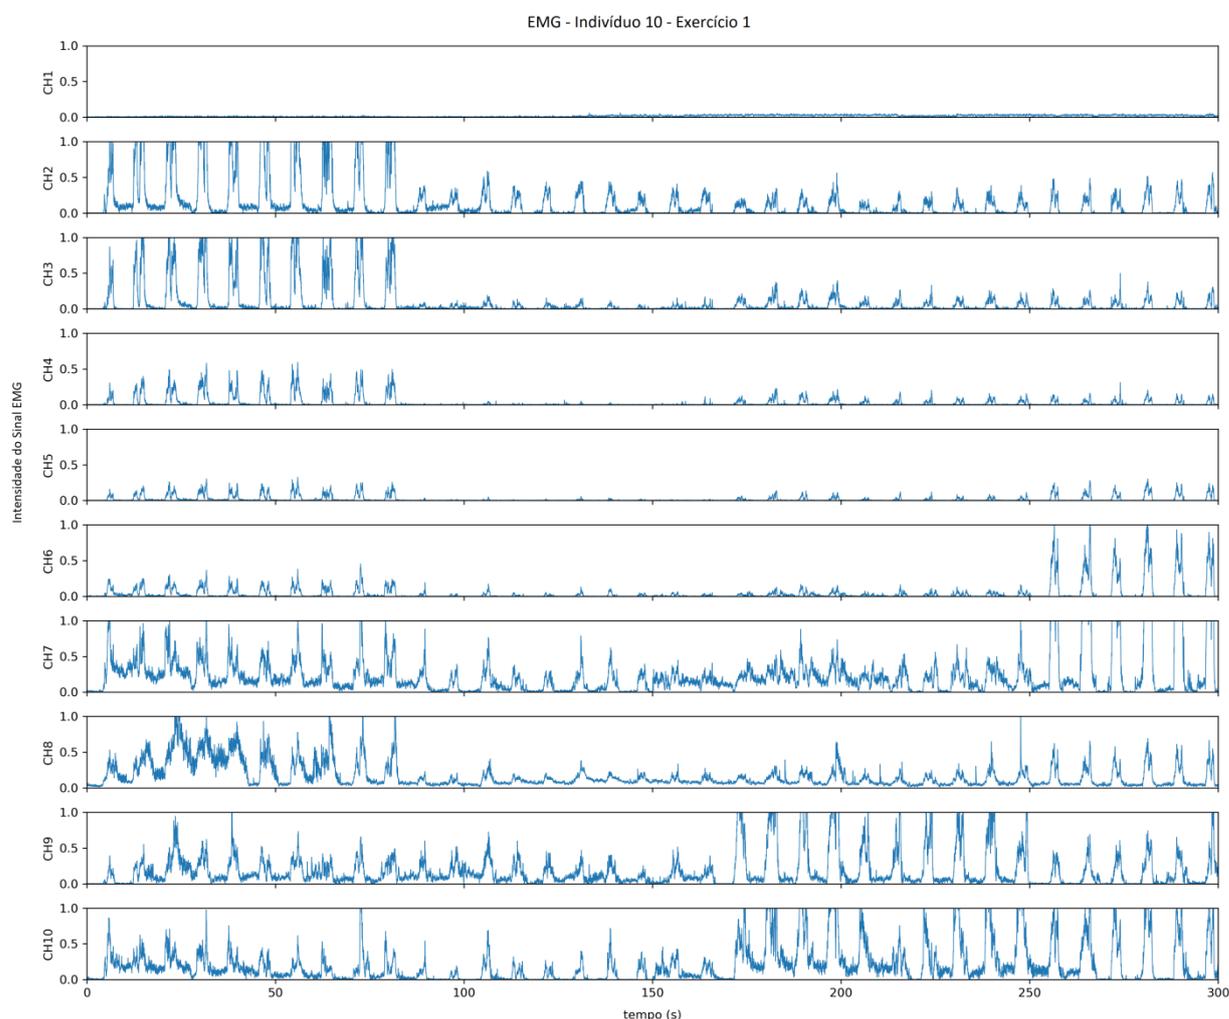
Taxa de aquisição: 100Hz

Fonte: Elaborado pelo autor.

Começou-se pela visualização desses dados de forma gráfica, com o objetivo de identificar possíveis falhas no equipamento, artefatos ou outras anomalias. Foi elaborada uma rotina que exporta em arquivo de imagem o sinal EMG de todos os 81 arquivos, além de uma função que permite a visualização em tela de um trecho específico, conforme mostrado na figura 15.

Nessa etapa foram encontradas certas inconsistências na colocação dos eletrodos, o que não era inesperado pois não é dito no artigo referente à este banco de dados que o posicionamento exato dos eletrodos fazia parte do protocolo. Outro ponto de alerta encontrado foi um pequeno nível DC oscilante em alguns indivíduos e alguns canais. Como esse comportamento era bastante infrequente e atingindo somente um ou outro canal específico, não foi realizada nenhum tipo de tentativa de correção, sob pena de ter que realizá-la também em produção, o que tornaria o sistema computacionalmente mais lento.

Figura 15 – Visualização parcial de um dos arquivos importados – Indivíduo 10, exercício 1, primeiros 300 segundos



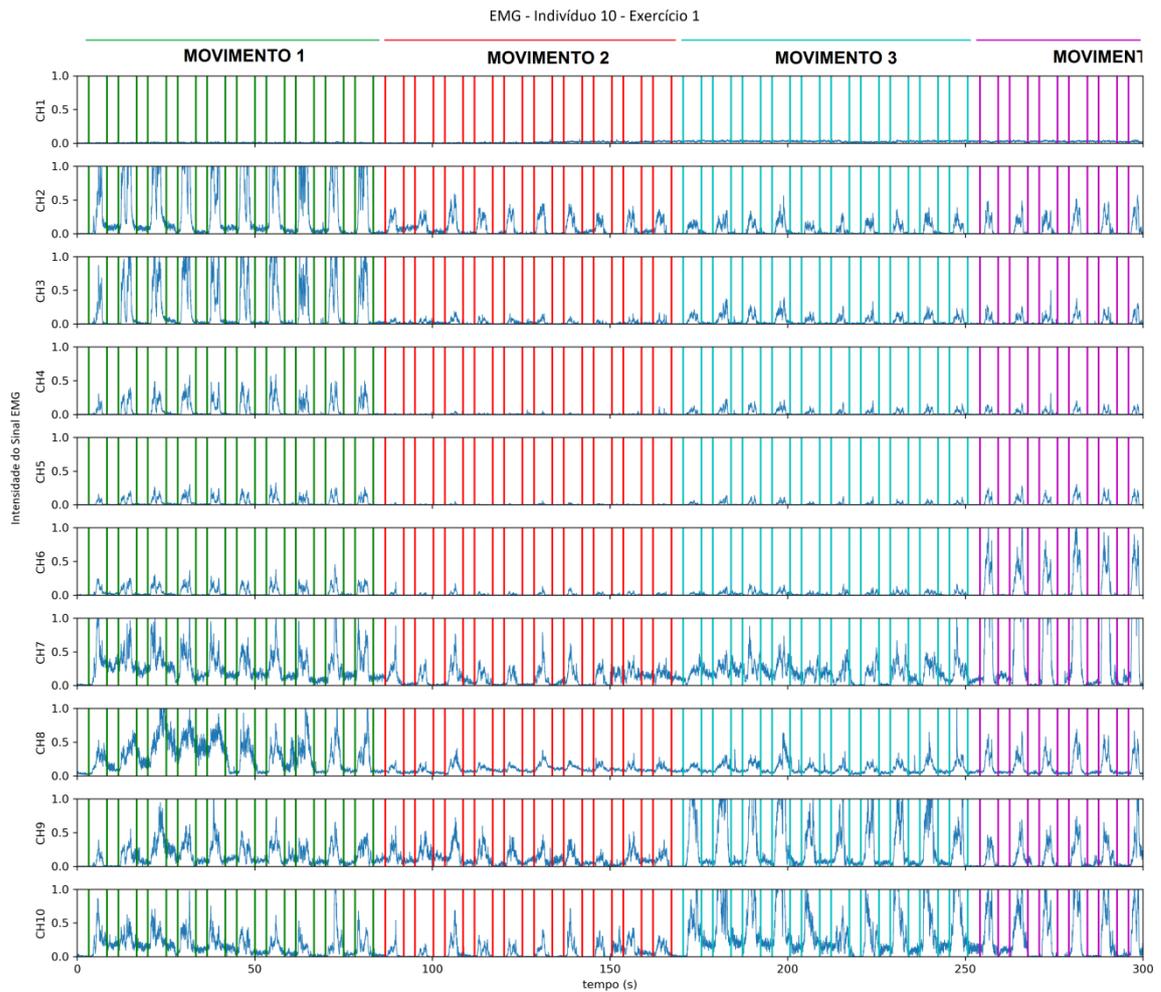
Fonte: Elaborado pelo autor.

As colunas "estímulo" e "repetição" contém informações de qual movimento estaria sendo solicitado que indivíduo realizasse e qual repetição daquele movimento, respectivamente. O protocolo de aquisição estabelece que um vídeo seria transmitido em um monitor, mostrando os movimentos de mão que o participante deveria replicar. No instante em que o vídeo de um movimento começa a ser exibido, os dados adicionados à essas colunas mudam seus valores de zero para o número respectivo daquele movimento e daquela repetição.

Para um melhor entendimento e confirmação visual do que estas colunas representam, foi elaborada uma função que gera a imagem com a transição desses valores na forma de barras, mostradas em cima do gráfico original EMG. Nesse

gráfico cada cor corresponde a um movimento distinto. Na figura 16 vemos o significado da coluna "estímulo" sobre o gráfico EMG original.

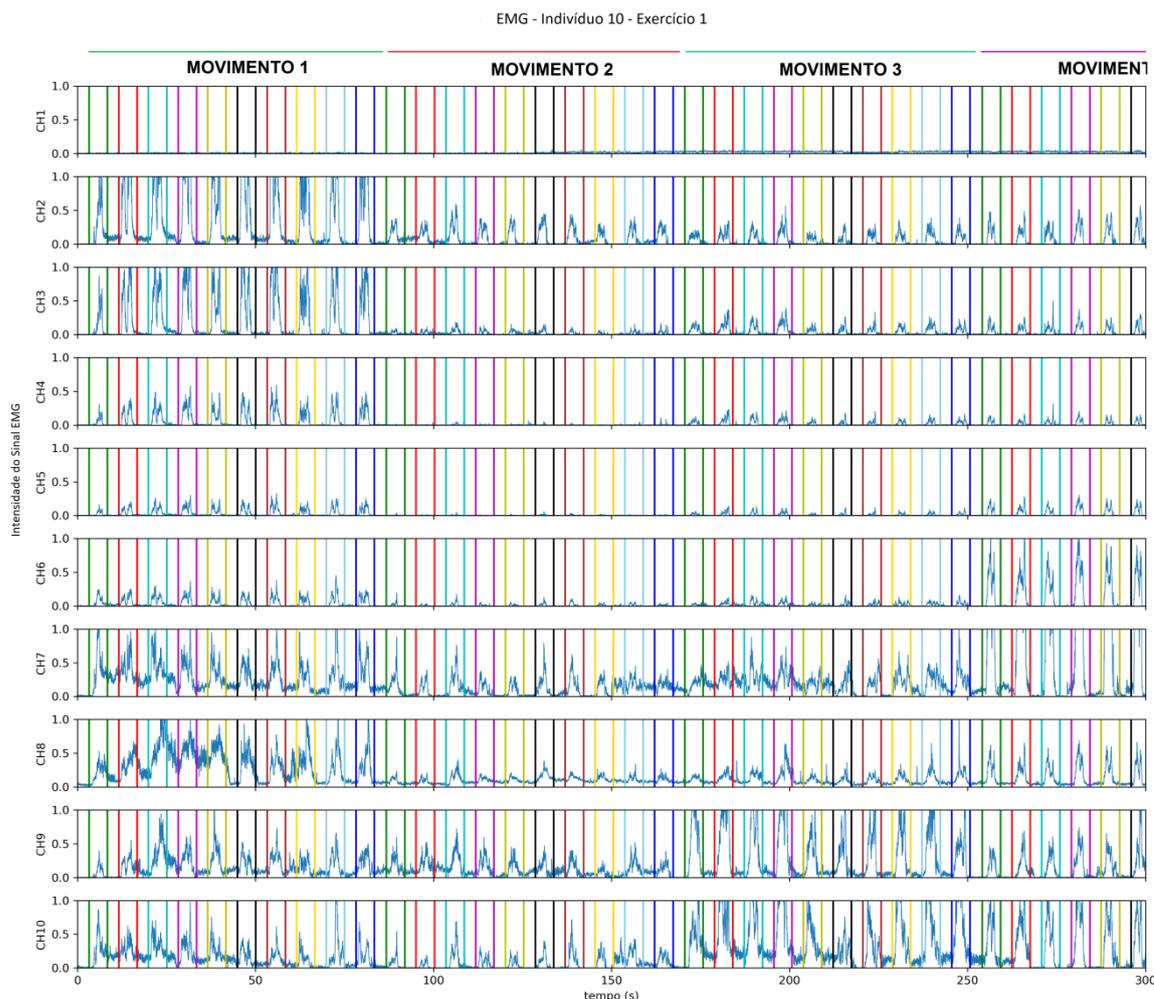
Figura 16 – Visualização da coluna estímulo sobre os dados EMG originais –
Indivíduo 10, exercício 1



Fonte: Elaborado pelo autor.

Da mesma forma podemos gerar o gráfico para a coluna "repetição", e encontramos que cada repetição de um mesmo movimento possui um número diferente nessa coluna.

Figura 17 – Visualização da coluna repetição sobre os dados EMG originais



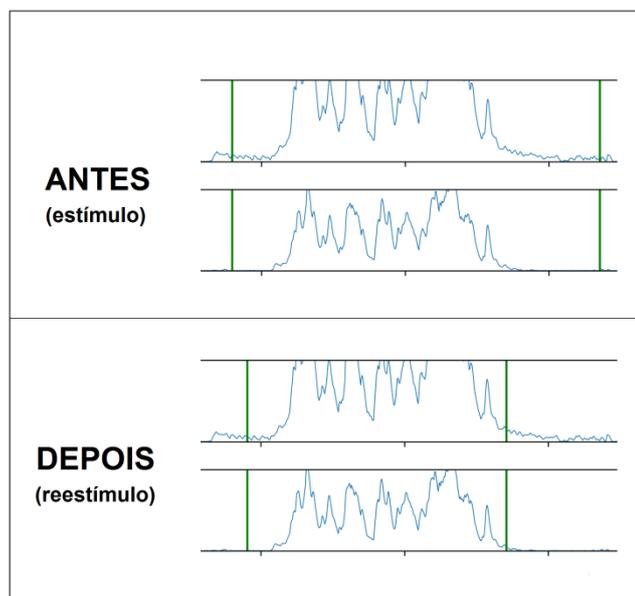
Fonte: Elaborado pelo autor.

Essas informações são muito úteis para facilitar o processo de treinamento, validação e teste do modelo desenvolvido. Através de mecanismos de seleção disponíveis nas bibliotecas utilizadas pode-se facilmente cruzar esses números para buscar qual movimento e repetição se quer utilizar, sem necessidade de trabalhar com índices específicos de início e fim de movimento. Outra informação importante é que os pontos de início e fim das marcações são exatamente os mesmos para ambas colunas (as duas colunas mudam seus valores de zero para um número e deste número para zero ao mesmo tempo).

Restam então as colunas "reestímulo" e "rerepetição" que nada mais são que um ajuste realizado nessas marcações já vistas. O objetivo é que representem o intervalo de realização do movimento de maneira mais correta. Enquanto as colunas "estímulo" e "repetição" foram preenchidas automaticamente no ato da aquisição dos

dados, as colunas de "reestímulo" e "rerepetição" foram calculadas *a posteriori*, utilizando um algoritmo de máxima verossimilhança para detecção do movimento e ajuste das marcas. O resultado é um melhor enquadramento dos movimentos nas marcações, conforme mostra de maneira ampliada a figura 18.

Figura 18 – Visualização do efeito de ajuste da coluna "estímulo"



Fonte: Elaborado pelo autor.

O mesmo acontece com a coluna "repetição" que passa a se chamar "rerepetição", mantendo os pontos de início e fim do movimento consistentes entre as colunas originais e ajustadas. É importante notar também que as marcações originais possuíam tamanho fixo de 5 segundos, enquanto as marcações ajustadas possuem tamanho variável. A partir desse momento são utilizadas somente as colunas "reestímulo" e "rerepetição" para as análises seguintes.

4.2 Composição do Classificador

É utilizada a topologia de rede neural MLP com algoritmo de treino *backpropagation*, a mais empregada na literatura atual e de funcionamento relativamente simples quando comparada à outras topologias existentes.

Com relação às características a serem extraídas do sinal EMG, o foco é nas 5 características do domínio do tempo mais comumente utilizadas, conforme descrito em (NOVAK, 2014), também chamado de conjunto de características de Hudgins. Estas são o MAV (valor absoluto médio), WL (comprimento da forma de onda), ZC

(cruzamentos por zero), SSC (mudanças no sinal da reta de inclinação) e valor RMS (média quadrática). Em especial são utilizadas as duas primeiras, MAV e WL, que a literatura indica serem as mais relevantes deste conjunto. Posteriormente outras configurações de características serão testadas com base nos resultados obtidos.

O número de neurônios na camada de entrada é igual ao número de características utilizadas vezes dez, pois são dez canais EMG distintos. Como foram utilizadas 2 características, temos 20 neurônios na camada de entrada. A camada de saída possuirá número de neurônios igual ao número de movimentos considerados. O número de neurônios nas camadas escondidas é obtido de maneira iterativa, sendo um parâmetro ajustado conforme o desempenho de classificação obtido.

As principais métricas de desempenho utilizadas são a acurácia (número de classificações corretas pelo número total de classificações) a precisão (número de classificações corretas de uma classe pelo número total de classificações daquela classe) e revocação (número de classificações corretas de uma classe pelo número total existente daquela classe). Nota-se que a acurácia se refere à todas as classes, enquanto a precisão e a revocação são referentes à cada classe individualmente.

São considerados em primeira instância todos os 52 movimentos de mão disponíveis com o objetivo de se obter um resultado base com que se possa comparar resultados futuros, refinando o sistema até que se chegue ao modelo final, capaz de classificar 11 movimentos distintos.

Uma parte dos dados é utilizada para treino e outra para validação, separando-se ainda alguns indivíduos completamente dos demais, para o teste final. Na fase de treinamento e validação são definidos o melhor conjunto de parâmetros livres, como características utilizadas e o número de neurônios na camada escondida, além de outros parâmetros de configuração da MLP.

Na fase de testes, os dados dos indivíduos mantidos em separado são analisados, validando-se o desempenho do classificador para aqueles indivíduos específicos.

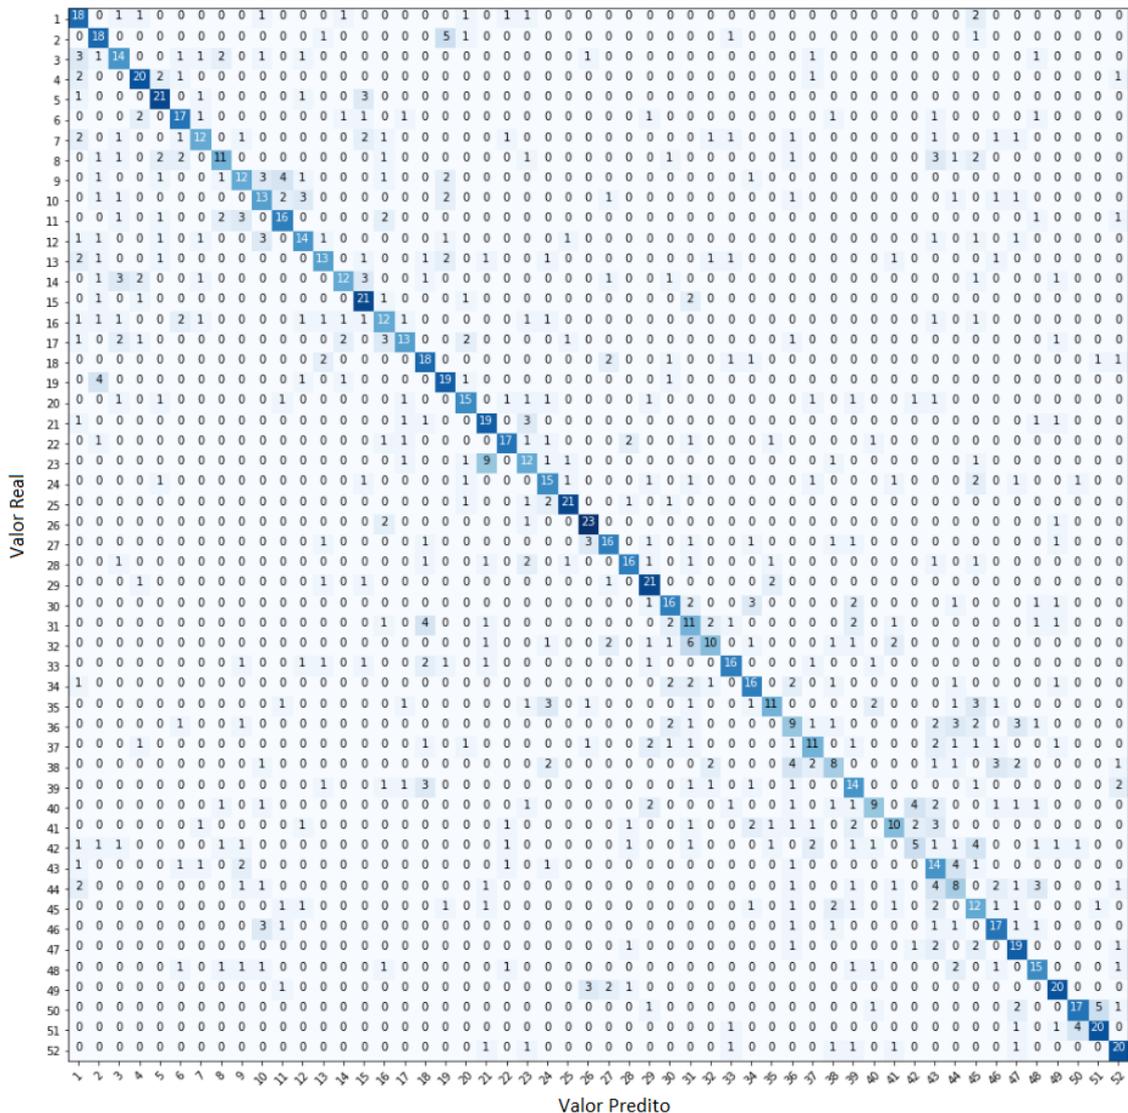
4.4 Análise do Classificador: Todos vs Todos - Movimento Inteiro

Nessa etapa inicial é considerado um único treinamento em todo o banco de dados (chamado aqui de todos vs todos), onde 9 repetições, de cada movimento, de

cada indivíduo, são utilizados para treino e 1 repetição para validação. São ainda considerados movimentos inteiros, ou seja, cada movimento é transformado em uma única amostra para a rede neural. É ainda utilizado uma única camada escondida com 100 neurônios, o padrão da biblioteca utilizada, visando a realização de ajuste posterior.

O objetivo nessa etapa é conseguir algum resultado relevante utilizando o método mais simples possível, para que se possa comparar com modelos futuros de maior complexidade. O fato de se realizar um único treinamento em todo o banco de dados faz com que todas as informações estejam disponíveis para o classificador, tanto informações características de cada indivíduo quanto informações comuns à todos.

Figura 19 – Matriz de Confusão - Todos vs Todos - Movimento inteiro



Acurácia: 55%

Fonte: Elaborado pelo autor.

Na figura 19 podemos ver o resultado alcançado na forma de uma tabela de confusão, que mostra em um eixo as classes preditas e no outro as classes reais. O objetivo desse gráfico é analisar de que forma o modelo errou e entre quais classes.

Vemos através da diagonal principal da matriz uma boa tendência do modelo predizer corretamente o movimento realizado. Dessa forma, foi alcançado uma acurácia de 55% no conjunto de validação, ou seja, para as amostras que o modelo nunca viu, existe, em média, 55 % de chance de o modelo estimar corretamente o movimento realizado.

A acurácia alcançada é bastante relevante considerando-se o número de classes envolvidas, porém ainda abaixo do necessário para o uso no controle de próteses.

4.5 Seleção de Movimentos

Nesse etapa são selecionados 11 movimentos de interesse de todos os 52 possíveis, restringindo bastante o número de classes disponíveis para classificação. Os movimentos foram selecionados com base em sua aparente funcionalidade no dia a dia. Os movimentos selecionados são apresentados na figura 20.

Realizando novamente a análise anterior (Todos vs Todos) temos um aumento significativo na acurácia, para 91,36 %. A nova matriz de confusão é apresentada na figura 21 e mostra uma forte tendência na diagonal principal, com algumas classes sendo perfeitamente classificadas, como a 19 e a 26. Vemos também outras classes com um engano mais significativo, como entre as classes 51 e 50 e 18 e 13.

Foi gerado o Quadro 10 de precisão e revocação para cada classe, exibindo também o suporte que atualmente é de 27 amostras por classe, ou 1 repetição por indivíduo.

Figura 20 – Movimentos selecionados para classificação



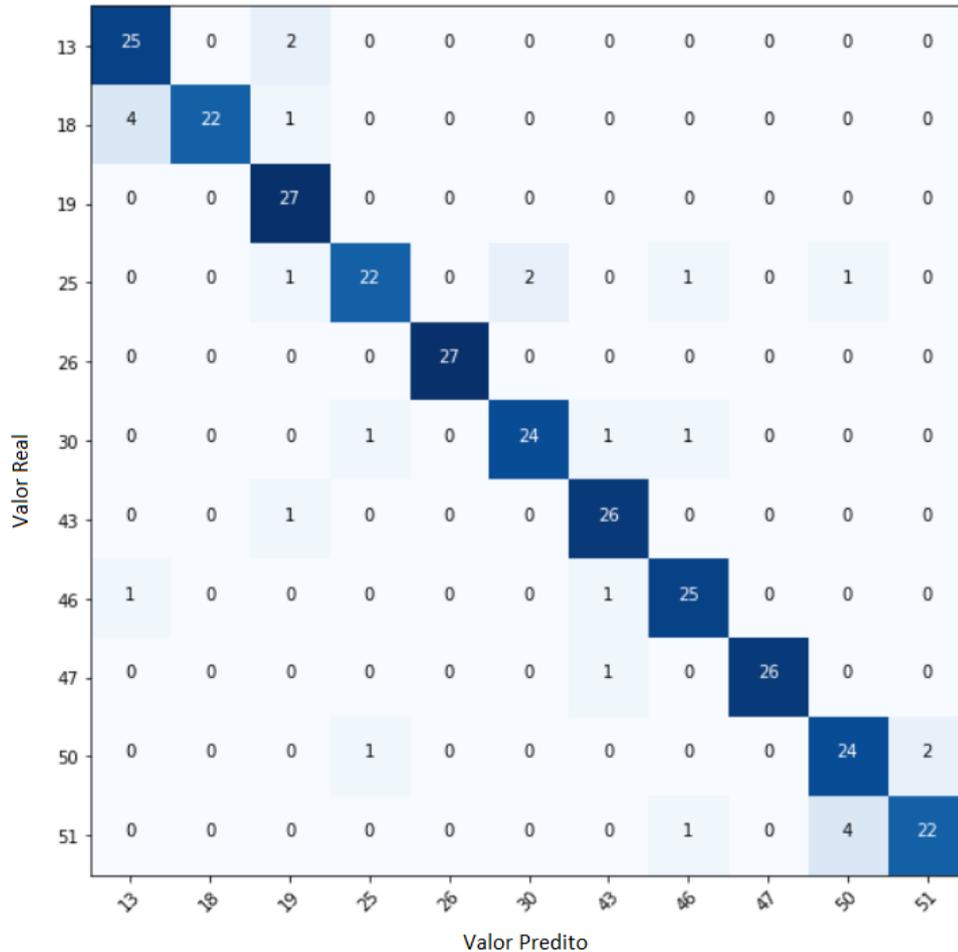
Fonte: Adaptado de ATZORI (2012).

Quadro 10 – Precisão e Revocação – Todos vs Todos – Movimentos selecionados

Classes	Precisão	Revocação	Suporte
13	0,83	0,93	27
18	1,00	0,81	27
19	0,84	1,00	27
25	0,92	0,81	27
26	1,00	1,00	27
30	0,92	0,89	27
43	0,90	0,96	27
46	0,89	0,93	27
47	1,00	0,96	27
50	0,83	0,89	27
51	0,92	0,81	27
Média / Total	0,91	0,91	297

Fonte: Elaborado pelo autor.

Figura 21 – Matriz de Confusão – Todos vs Todos – Movimentos selecionados



Acurácia: 91,36 %

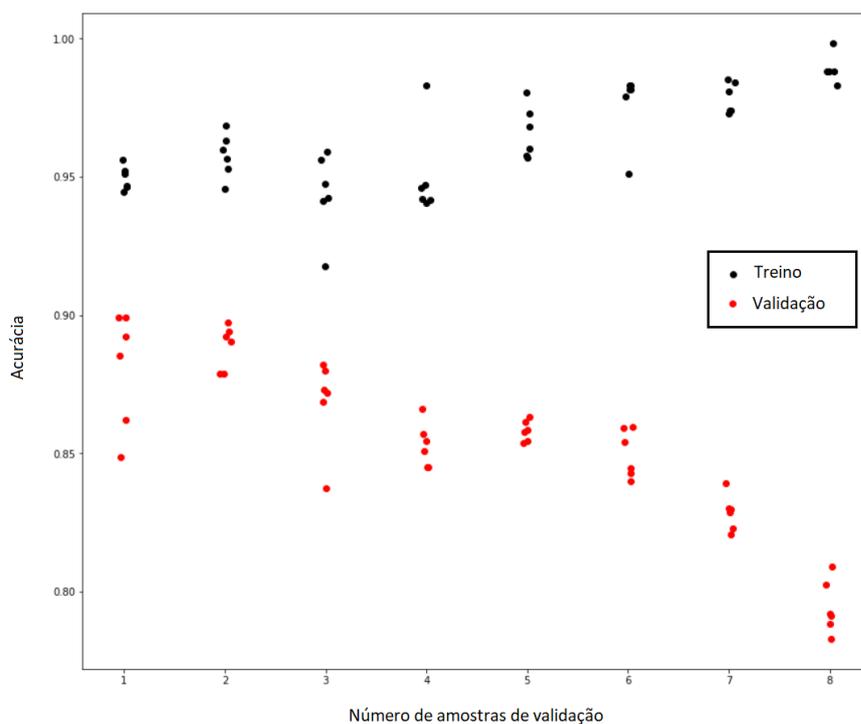
Fonte: Elaborado pelo autor.

4.6 Análise do Tamanho do Conjunto de Treino e Validação

Conjuntos de validação pequenos diminuem a confiança nos resultados obtidos devido à sua suscetibilidade às variações probabilísticas, já conjuntos de treino pequenos afetam diretamente o desempenho do classificador. Nessa etapa foi realizado um estudo sobre o impacto do tamanho dos conjuntos de treino e validação, para que se possa dar prosseguimento às análises com o maior conjunto de validação possível mas que não impacte significativamente nos resultados gerados. Foi realizado o mesmo treinamento e validação realizado no último passo porém variando-se o número de amostras utilizadas na validação, e

consequentemente, no treino. Nessa análise o número de amostras de validação é variado de 1 até 8 para que se veja como isso afeta o desempenho do modelo. Isso é repetido seis vezes para que variações estatísticas também sejam aparentes. O resultado é mostrado na figura 22.

Figura 22 – Análise de desempenho – Tamanho dos conjuntos de treino e validação



Fonte: Elaborado pelo autor.

Vemos que conforme se aumenta o número de amostras de validação o desempenho do classificador no conjunto de validação cai pois há menos amostras de treino disponíveis. Já o desempenho no conjunto de treinamento aumenta, pois o baixo número de amostras para treino faz a RNA tender a uma superespecialização, também chamado de *overfitting*, que é quando o modelo torna-se incapaz de generalizar os resultados obtidos no conjunto de treino para novos dados.

Através do gráfico vemos que utilizando até duas amostras de validação podemos manter os resultados obtidos aproximadamente na mesma faixa de acerto, logo, escolheu-se esse número para utilizar como número de amostras de validação daqui em diante; oito para treino e duas para validação, o que trará mais confiança nos resultados obtidos.

Nesse ponto também foram separados os dados de 5 indivíduos para teste final, pois nesse momento ajustes de parâmetros são realizados no modelo e é

importante que tais ajustes não levem em consideração o conjunto de teste final. A partir de então o número total de indivíduos para treinamento e validação é de 22 e não mais 27.

4.7 Análise do Classificador: (Todos - 1) vs 1 e 1 vs 1

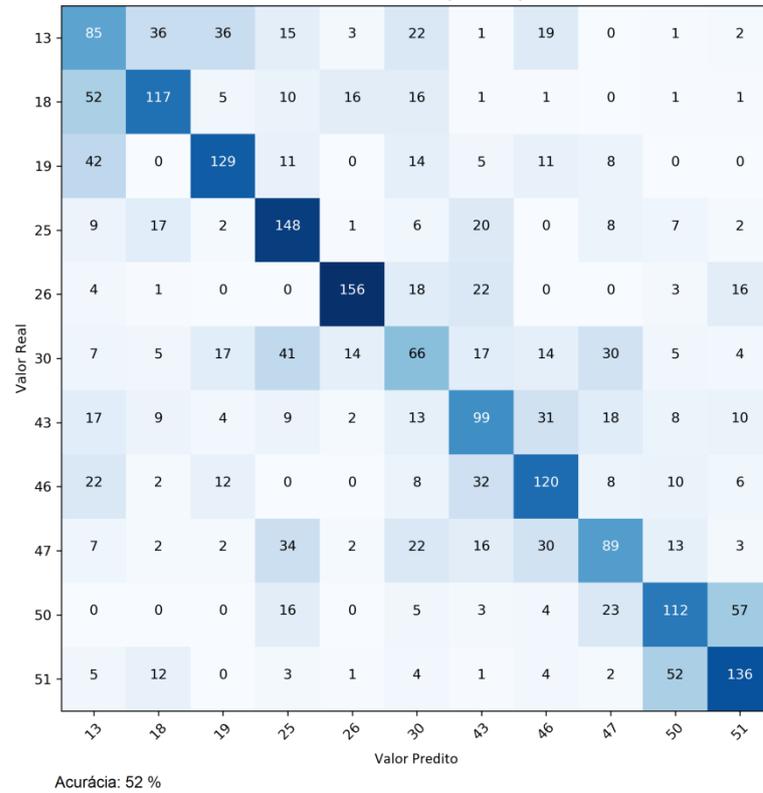
Nessa etapa a análise divide-se em dois casos, um onde o modelo é treinado com todos os indivíduos exceto um e em seguida validado neste (caso todos-1 vs 1), e outro onde o modelo é treinado em um único indivíduo e validado neste (caso 1 vs 1). A idéia é comparar os resultados para duas situações práticas distintas, uma onde o usuário adquire a prótese já treinada e a utiliza diretamente, e outra onde o usuário passa por um período de treinamento para que a prótese se adeque a ele, situação mais parecida com o que é feito atualmente nas próteses comerciais.

Começando pelo caso todos-1 vs 1, foi alcançado uma acurácia relativamente baixa de 52 %, o menor nível até então, mas ainda assim significativa. Podemos ver na matriz de confusão (figura 23) a tendência de resultados na diagonal principal, porém com muitos casos de engano entre classes também, especialmente naquelas já apontadas anteriormente, classes 51 e 50 e 18 e 13, mas também entre outras.

No caso 1 vs 1 o resultado foi o melhor alcançado até então, conforme mostra a matriz da figura 24, a acurácia obtida foi de 95,4 %.

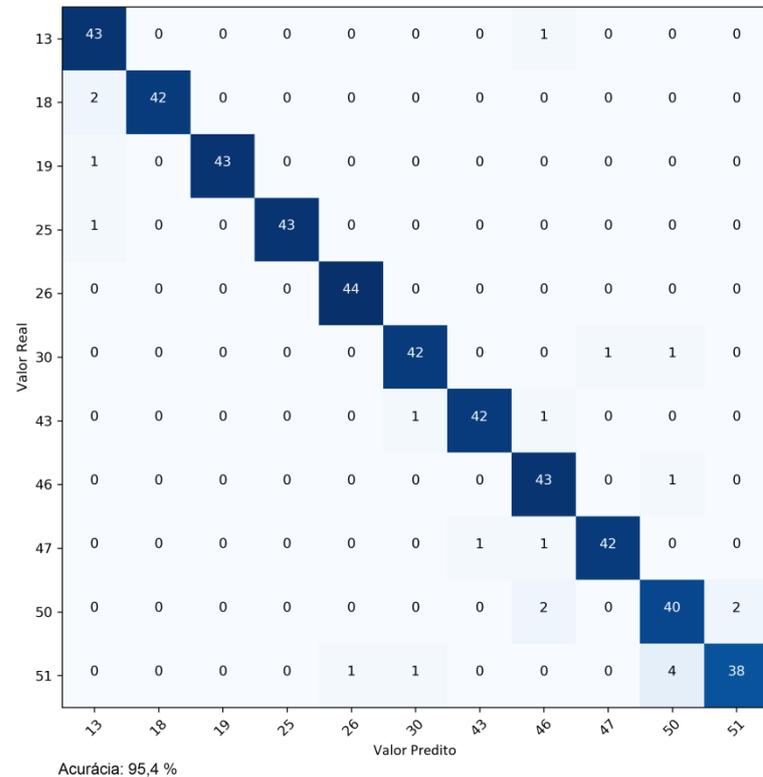
Isso mostra que existe relação entre um mesmo movimento realizado por duas pessoas distintas, porém a relação é muito mais forte e facilmente diferenciável se considerarmos o movimento da própria pessoa, conforme já havia sido sugerido na literatura.

Figura 23 – Matriz de Confusão – (Todos-1) vs 1 – movimento inteiro



Fonte: Elaborado pelo autor.

Figura 24 – Matriz de Confusão - 1 vs 1 - movimento inteiro



Fonte: Elaborado pelo autor.

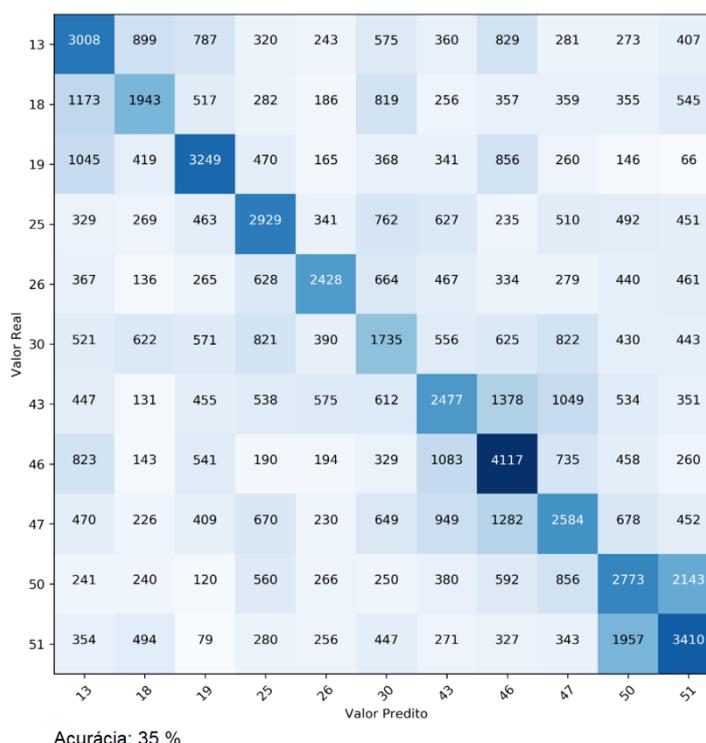
4.7 Análise do Classificador: Janelamento 250/100 ms

Análises realizadas levando-se em conta movimentos inteiros possuem boa acurácia porém na prática não são o método mais adequado para o controle moderno de próteses. Isso deve-se à baixa velocidade de resposta que tal sistema possui, visto que é necessário que um movimento inteiro seja realizado pelo usuário para que somente depois o processo de classificação se inicie e o sistema possa responder.

Estudos recentes sugerem o controle de próteses de maneira muito mais natural utilizando a técnica de janelamento, onde pequenas fatias do sinal são classificadas e não o sinal inteiro. Seguindo as recomendações apontadas na revisão bibliográfica, foi utilizado uma janela de 250 ms com deslocamentos de 100 ms, o que traria resultados próximos do ideal em termos de acurácia e velocidade de resposta (SMITH, 2011). A técnica de janelamento foi utilizada para comparação com os dois casos anteriores já vistos.

No caso todos-1 vs 1 temos como resultado a matriz de confusão da figura 25, com acurácia de 35 %. Nota-se a quantidade muito maior de amostras classificadas devido ao fato de termos fatiado cada movimento em diversas janelas.

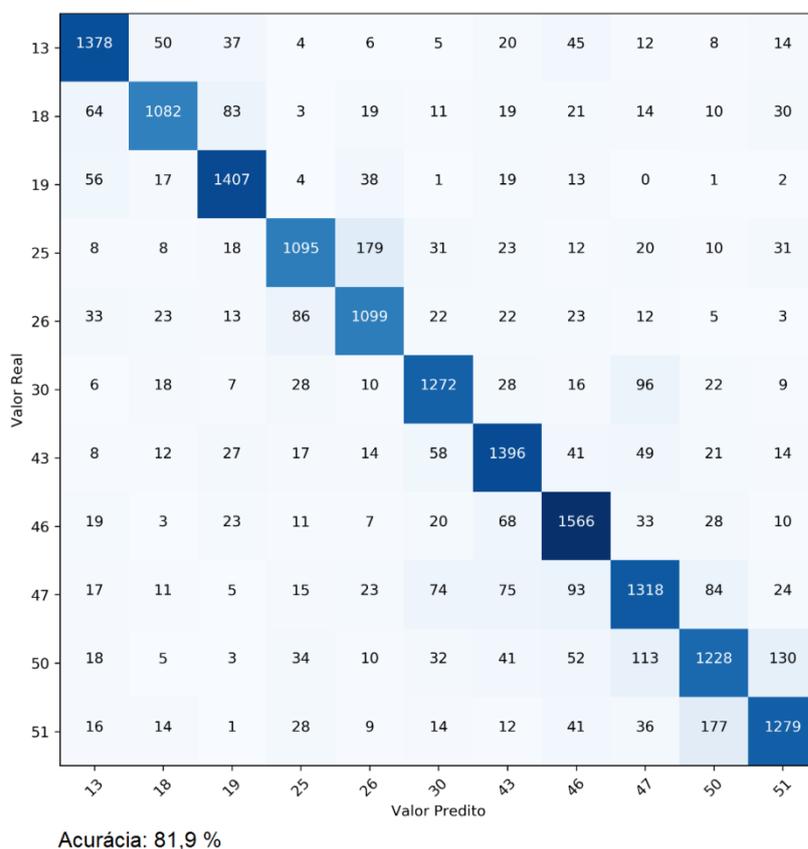
Figura 25 – Matriz de Confusão - (Todos-1) vs 1 - Janela 250/100 ms



Fonte: Elaborado pelo autor.

No caso 1 vs 1 temos também uma redução já esperada na acurácia, porém esta manteve-se relativamente elevada, em 81,9 %. Isso significa que 81,9 % das vezes o modelo identifica corretamente à qual movimento um segmento de sinal de 250 ms pertence.

Figura 26 – Matriz de Confusão - 1 vs 1 - Janela 250/100 ms



Fonte: Elaborado pelo autor.

4.8 Análise do Classificador: Janelamento 250/100 ms Com Repouso

Para o uso efetivo do sistema classificador em próteses este deve ser capaz de detectar não somente qual movimento o indivíduo está realizando, mas também quando não se quer realizar nenhum movimento. Uma solução para este problema é a adição de uma nova classe ao modelo, denominada "repouso", identificada pelo número zero. Dessa forma o modelo é agora composto por 12 classes distintas.

Uma característica da classe de repouso é que esta possui muito mais amostras que as outras, o que gera um grande desbalanceamento entre as classes. Para o caso todos-1 vs 1 por exemplo, utilizando a matriz de confusão como estava sendo feito, temos algo como mostrado na figura 27.

Figura 27 – Matriz de Confusão - (Todos-1) vs 1 - Janela 250/100 ms
Com Repouso

0	554278	1340	454	2440	1438	575	1290	1325	2396	1255	1224	809	
13	3244	1668	799	361	169	275	362	87	130	189	288	410	
18	1772	813	1573	236	299	185	712	148	89	135	265	565	
19	4472	573	299	1090	170	76	311	29	168	83	56	58	
25	2069	146	336	148	2324	242	699	304	43	290	444	363	
26	2125	215	128	108	401	2046	423	205	104	45	327	342	
30	2528	162	584	320	535	366	1607	230	228	327	364	285	
43	5736	108	77	80	306	338	421	350	180	280	574	97	
46	6680	162	62	79	21	89	148	169	772	373	214	104	
47	4541	81	165	117	355	44	576	157	478	1417	414	254	
50	2542	236	265	53	352	209	234	205	190	360	2355	1420	
51	1753	339	506	92	294	233	333	138	126	190	1620	2594	
		0	13	18	19	25	26	30	43	46	47	50	51

Valor Real

Valor Predito

Acurácia: 87,3 %

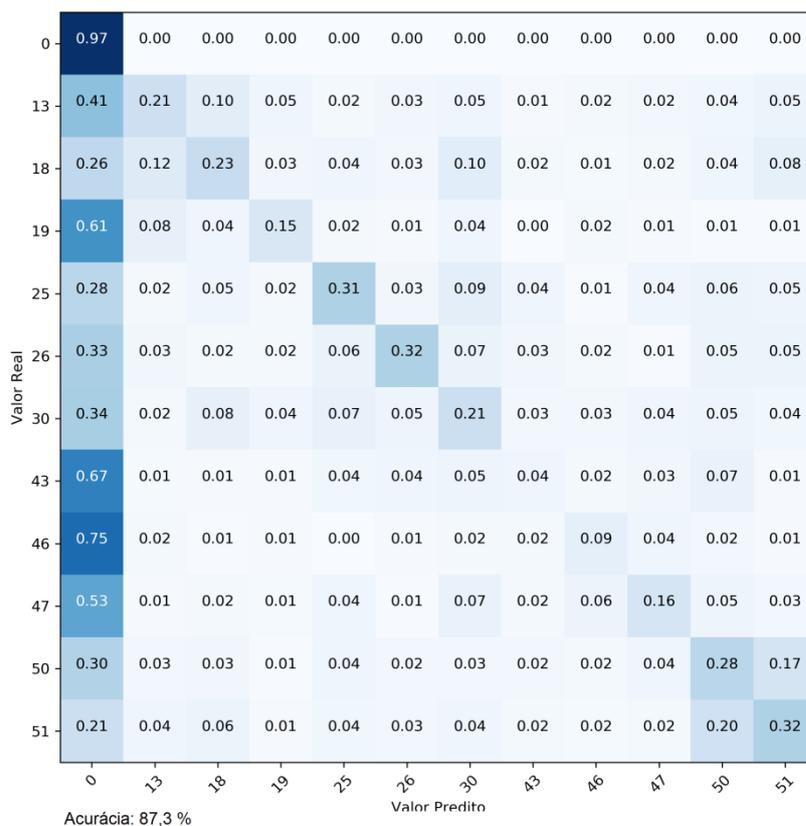
Fonte: Elaborado pelo autor.

A interpretação da acurácia também nesse caso torna-se inadequada pois não leva em conta o desbalanceamento entre as classes. Dessa forma optou-se pelo uso da matriz de confusão normalizada, apresentada na figura 28, onde cada linha possui soma igual a um. Na matriz normalizada vemos que existe ainda uma tendência na diagonal principal, porém com todas as classes fortemente influenciadas pelo repouso.

Também foi utilizado o quadro de precisão e revocação para melhor analisar o comportamento individual das classes. Para o caso todos-1 vs 1 com repouso foi gerado o quadro 11, evidenciando os altos níveis de precisão e revocação na classe de repouso, porém bastante baixos nas outras classes.

Devido ao baixo desempenho desse modelo, essa é a última análise do caso Todos-1 vs 1 realizada, sendo as próximas análises focadas no caso mais promissor 1 vs 1.

Figura 28 – Matriz de Confusão Normalizada – (Todos-1) vs 1 – Janela 250/100 ms com Repouso



Fonte: Elaborado pelo autor.

Quadro 11 – Precisão e Revocação – (Todos-1) vs 1 – Janela 250/100 ms com Repouso

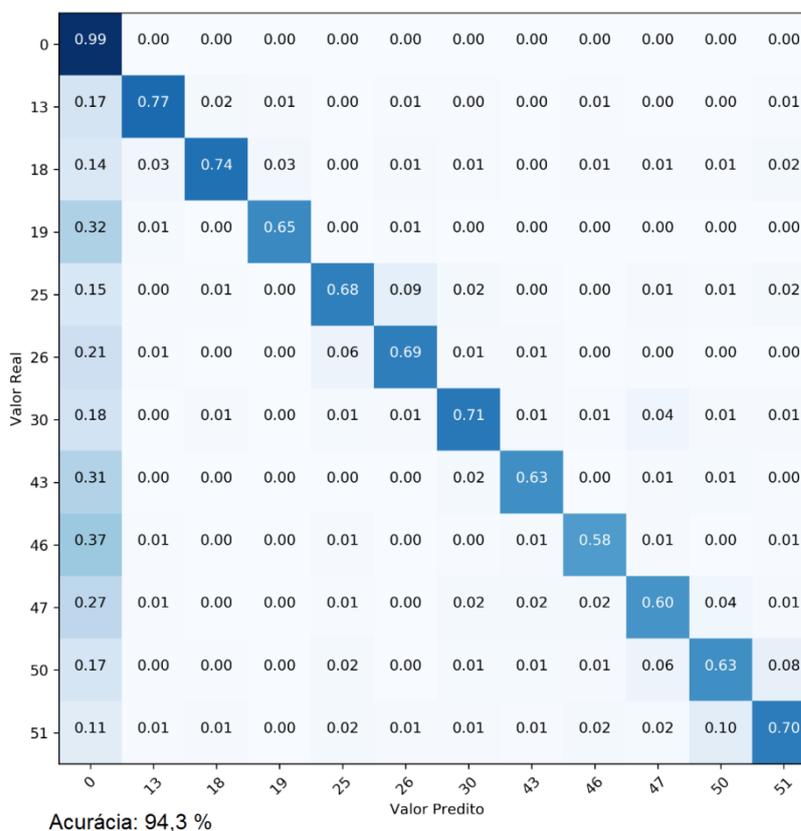
Classes	Precisão	Revocação	Suporte
0	0,94	0,97	568824
13	0,29	0,21	7982
18	0,30	0,23	6792
19	0,21	0,15	7385
25	0,35	0,31	7408
26	0,44	0,32	6469
30	0,23	0,21	7536
43	0,10	0,04	8547
46	0,16	0,09	8873
47	0,29	0,16	8599
50	0,29	0,28	8421
51	0,36	0,32	8218
Média / Total	0,85	0,87	655054

Fonte: Elaborado pelo autor.

Para o caso 1 vs 1 com repouso temos como resultado a matriz de confusão da figura 29. Vemos nesse caso ainda uma forte tendência na diagonal principal, com erros ocorrendo principalmente entre as classes de movimento com a classe de repouso. Isso se deve em grande parte ao desbalanceamento entre as classes, o que faz com que o modelo tenha uma tendência maior para detectar a classe de repouso, que possui muito mais amostras.

Isso pode ser contornado de algumas formas (como simplesmente limitando o número de exemplos da classe desbalanceada) porém entendeu-se que esse poderia não ser um comportamento indesejado já que do ponto de vista prático é interessante que a classe de repouso seja sempre corretamente detectada, visto que seria bastante inconveniente a realização de movimentos aleatórios pela prótese em períodos de repouso.

Figura 29 – Matriz de Confusão Normalizada – 1 vs 1 – Janela 250/100 ms com Repouso



Fonte: Elaborado pelo autor.

O quadro 12 apresenta os resultados de precisão e revocação de cada classe individualmente. Vemos uma revocação de 99% para a classe de repouso, que como comentado é algo bastante desejável.

Quadro 12 – Precisão e Revocação – (Todos-1) vs 1 – Janela 250/100 ms com Repouso

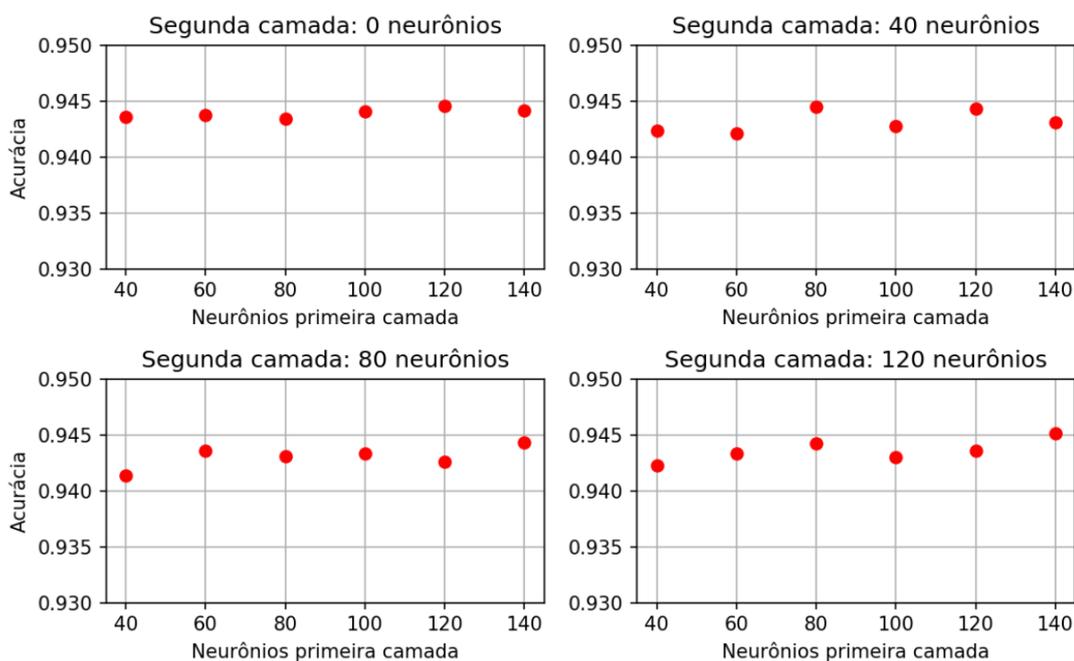
Classes	Precisão	Revocação	Suporte
0	0,96	0,99	102254
13	0,84	0,77	1579
18	0,88	0,74	1356
19	0,82	0,65	1558
25	0,78	0,68	1435
26	0,79	0,69	1341
30	0,84	0,71	1512
43	0,78	0,63	1657
46	0,79	0,58	1788
47	0,72	0,60	1739
50	0,75	0,63	1666
51	0,79	0,70	1627
Média / Total	0,94	0,94	119512

Fonte: Elaborado pelo autor.

4.9 Número de Neurônios na Camada Escondida

Foram elaborados modelos com diversas configurações de número de neurônios em uma e duas camadas, porém não foi encontrada nenhuma relação de desempenho com o aumento no número de neurônios ou com a utilização de duas camadas escondidas. A figura 30 mostra os resultados encontrados para as diversas configurações de neurônios. Todos os resultados ficaram entre 0.94 e 0.945 aproximadamente.

Figura 30 – Análise de desempenho de acordo com o número de neurônios nas camadas escondidas



Fonte: Elaborado pelo autor.

4.10 Características Adicionais: SSC e FFT

Foram realizadas ainda duas tentativas de características adicionais, SSC (Slope Sign Change) e FFT (Fast Fourier Transform).

A SSC é uma característica bastante simples que representa a quantidade de inversões do sinal de inclinação de cada ponto da série temporal, ou seja, quantas vezes a derivada da série muda de sentido (é positiva e passa a ser negativa, ou vice-versa). O resultado é um único número para uma série de tamanho arbitrário e que está relacionado às frequências presentes naquela série. Após implementação da função que calcula esse valor e aplicação nos dez canais EMG, o modelo de rede neural passou de 20 entradas para 30.

O quadro 13 mostra os resultados de precisão e revocação de cada classe. Os resultados ficaram próximos dos alcançados anteriormente, porém um pouco piores em todas os casos, não sendo mais utilizada essa característica em análises futuras.

Quadro 13 – Precisão e Revocação – 1 vs 1 – com característica adicional SSC

Classes	Precisão	Revocação	Suporte
0	0,96	0,99	102254
13	0,79	0,73	1579
18	0,84	0,73	1356
19	0,79	0,63	1558
25	0,78	0,65	1435
26	0,74	0,69	1341
30	0,80	0,70	1512
43	0,73	0,59	1657
46	0,75	0,54	1788
47	0,70	0,58	1739
50	0,74	0,60	1666
51	0,77	0,69	1627
Média / Total	0,93	0,94	119512

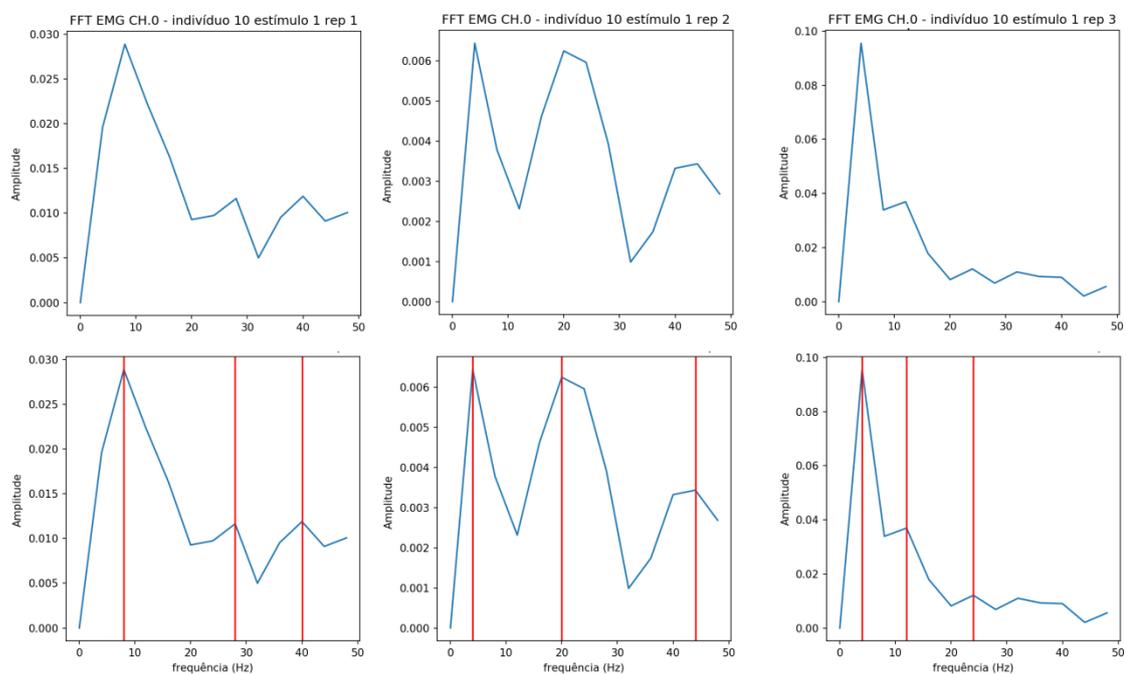
Fonte: Elaborado pelo autor.

A FFT é um algoritmo computacionalmente otimizado para cálculo da Transformada Discreta de Fourier e utilizado em diversas aplicações de processamento digital de sinais. Por si só não é uma característica que possa ser utilizada, devendo ser interpretada para poder ser aplicada como entrada do modelo.

A forma escolhida para o uso da FFT foi selecionar as frequências dos três maiores picos de intensidade encontrados em cada janela de dados. Para o cálculo da FFT foi utilizado o algoritmo já conhecido da biblioteca numpy, juntamente com uma rotina própria que identifica os picos do gráfico em questão. O resultado dessa análise pode ser visto na figura 31, onde três segmentos de sinal distintos são exibidos. Nota-se que o eixo das frequências vai de 0 a 50, metade da frequência de aquisição do banco de dados, que é de 100 Hz.

Após implementação dessa característica no modelo o número de entradas da rede neural passou de 20 para 50 (são obtidos 3 valores de frequência por canal). O resultado obtido pode ser visto no quadro 14, sendo pior que o resultado obtido anteriormente, não sendo essa característica utilizada em análises futuras.

Figura 31 – Detecção das frequências de pico no gráfico da FFT de três janelas distintas.



Fonte: Elaborado pelo autor.

Quadro 14 – Precisão e Revocação – 1 vs 1 – com característica adicional FFT

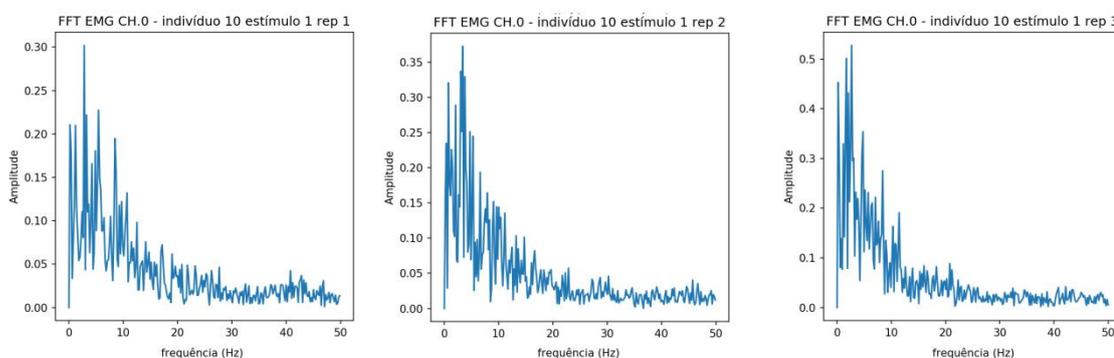
Classes	Precisão	Revocação	Suporte
0	0,96	0,98	102254
13	0,75	0,69	1579
18	0,78	0,68	1356
19	0,73	0,61	1558
25	0,71	0,63	1435
26	0,71	0,64	1341
30	0,72	0,65	1512
43	0,65	0,58	1657
46	0,65	0,52	1788
47	0,61	0,51	1739
50	0,69	0,56	1666
51	0,76	0,68	1627
Média / Total	0,92	0,93	119512

Fonte: Elaborado pelo autor.

Nenhuma das duas características melhorou o modelo implementado. No caso da FFT chama a atenção dois pontos, o primeiro é o grande número de

entradas criadas devido à se estar trabalhando com 10 canais EMG, o que pode atrapalhar o modelo classificador caso este não possua dados suficientes (que poderia ser o caso para o treinamento 1 vs 1 pois temos somente 8 repetições de cada movimento para treino). Outro ponto é a baixa resolução do gráfico da transformada de uma janela de 250 ms. Isso se deve à baixa taxa de aquisição utilizada no banco de dados (100 Hz), que faz com que cada janela de 250 ms tenha somente 25 amostras. Se compararmos com a FFT de um movimento inteiro como os da figura 32 (de aproximadamente 3 segundos, ou 300 amostras cada) vemos a diferença na resolução alcançada.

Figura 32 – Gráfico da FFT de três sinais de movimentos completos



Fonte: Elaborado pelo autor.

4.11 Implementação no Raspberry Pi Zero

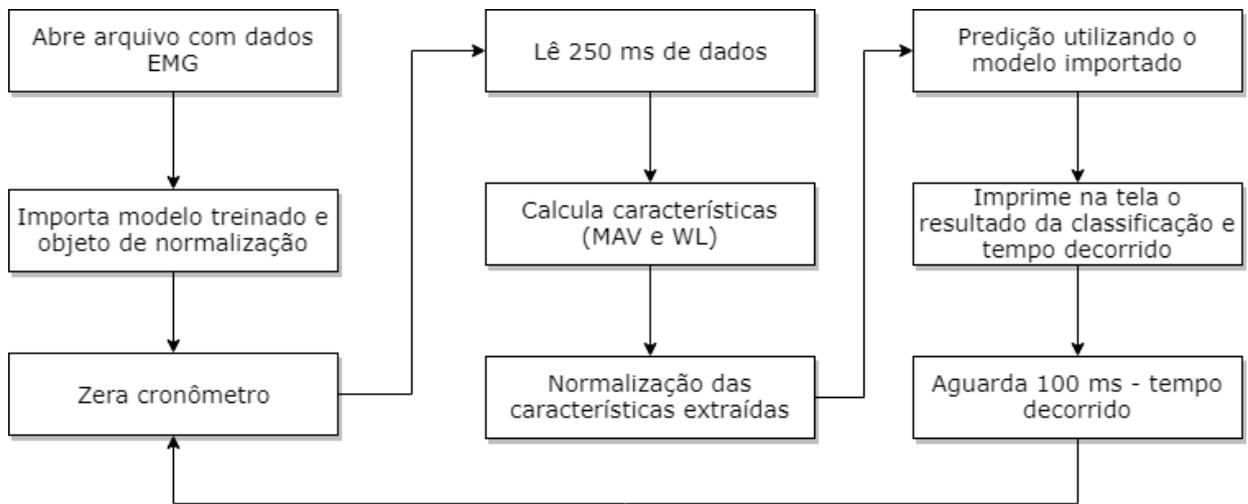
Para utilização do Raspberry Pi Zero foi instalado o sistema operacional próprio indicado (Raspbian) que já possui as linguagens de programação Python 2 e 3 disponíveis. Foram instaladas todas as bibliotecas utilizadas para o desenvolvimento desse trabalho até então, sendo os scripts adaptados na forma de funções que podem ser chamadas diretamente no terminal de comando do Raspbian. Foi também necessário a instalação do programa ATLAS (*Automatically Tuned Linear Algebra Software*) utilizado por algumas bibliotecas Python no Linux.

O modelo já treinado é exportado utilizando a biblioteca *pickle*, capaz de implementar protocolos para a serialização de objetos Python. É também exportado o objeto responsável pela normalização estatística dos dados que foi ajustado juntamente com o modelo, com base nos dados de treino. Cada indivíduo possui sua

própria rede neural artificial treinada e exportada. O modelo final serializado é um arquivo de aproximadamente 90 KB.

Para a simulação de leitura e análise dos dados em tempo real é utilizada uma função que lê 250 ms de dados de um arquivo e depois a cada 100 ms outra janela de 250 ms (deslocada 100 ms adiante). O algoritmo executado pode ser resumido através do fluxograma apresentado na figura 33.

Figura 33 – Fluxograma resumido do algoritmo de simulação de análise dos dados em tempo real.



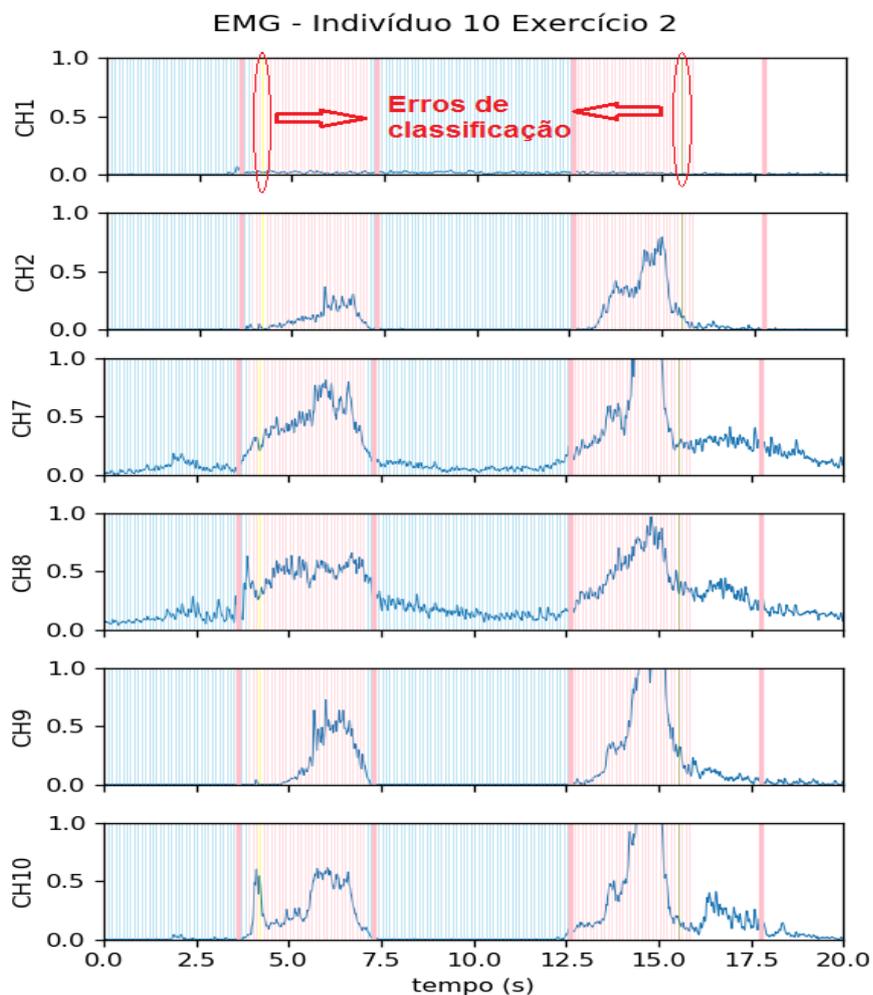
Fonte: Elaborado pelo autor.

5 ANÁLISE DOS RESULTADOS

Para análise dos resultados foi implementada uma função que gera um gráfico EMG com barras verticais representando a classificação realizada pelo modelo. Cada barra vertical representa o resultado do modelo para uma janela de 250 ms e cada cor representa um movimento distinto, sendo escolhido para o repouso a cor azul claro.

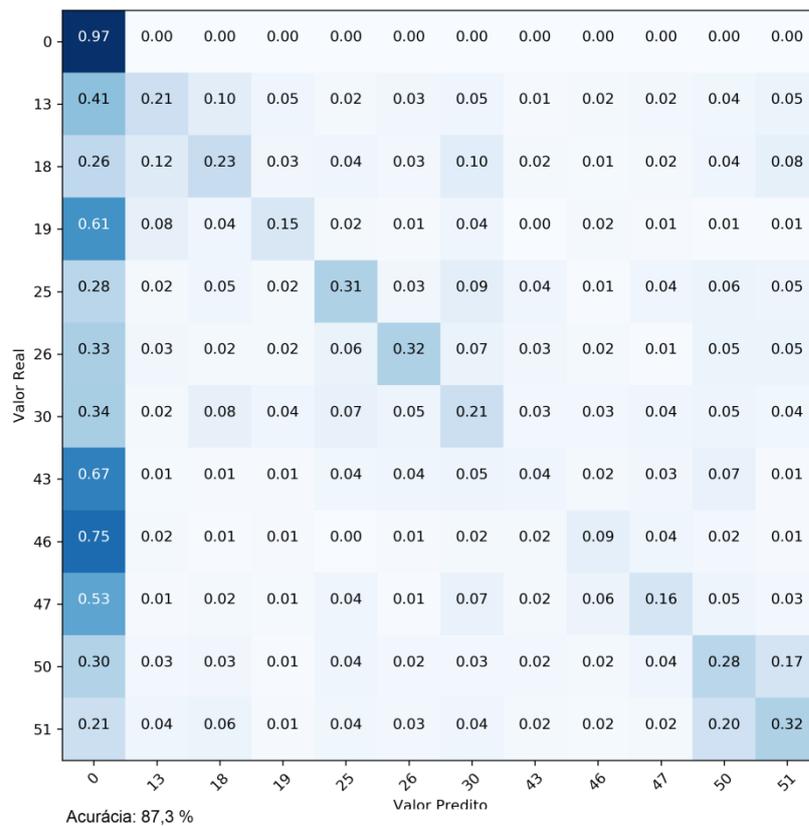
Essa função recebe um modelo treinado e serializado, além do arquivo original com os dados, onde cada fatia de 250 ms é analisada e adicionada ao gráfico de análise de resultados. Podemos ainda especificar o período de análise, bem como os pontos de início e fim do gráfico EMG. Na figura 34 temos a análise sendo realizada com o gráfico mostrando de 0 a 20 segundos e com classificação entre 0 e 16 segundos. Alguns canais foram omitidos da imagem para simplificação.

Figura 34 – Gráfico de análise mostrando dois erros claros de classificação



Fonte: Elaborado pelo autor.

Figura 37 – Matriz de Confusão Normalizada – 1 vs 1 – Janela 250/100 –
5 Indivíduos de Teste



Fonte: Elaborado pelo autor.

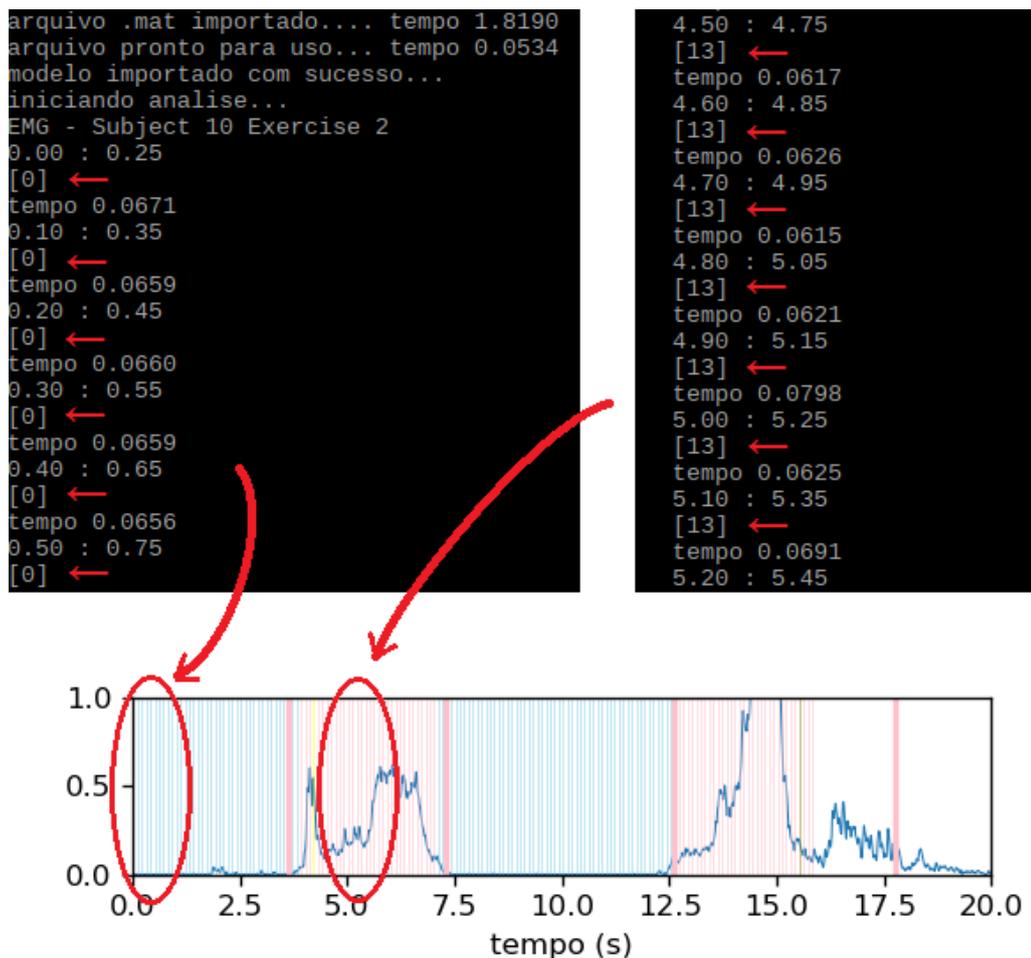
Quadro 15 – Precisão e Revocação – 1 vs 1 – Janela 250/100 ms –
5 Indivíduos de Teste

Classes	Precisão	Revocação	Suporte
0	0,96	0,99	22821
13	0,90	0,61	415
18	0,89	0,95	241
19	0,86	0,80	375
25	0,83	0,67	367
26	0,69	0,65	314
30	0,87	0,82	271
43	0,79	0,52	350
46	0,71	0,59	464
47	0,86	0,62	339
50	0,72	0,63	392
51	0,85	0,75	371
Média / Total	0,85	0,87	26720

Fonte: Elaborado pelo autor.

Após iniciar a rotina de simulação de análise no Raspberry Pi, podemos ver, conforme figura 38, que os resultados correspondem com o que havia sido alcançado anteriormente, conforme esperado, visto que estão sendo utilizadas as mesmas bibliotecas e linguagem de programação que haviam sido utilizadas anteriormente, somente alterando-se a plataforma de execução.

Figura 38 – Comparação do programa em execução no terminal do sistema Raspbian com a análise realizada anteriormente



Fonte: Elaborado pelo autor.

Vemos também que cada amostra leva entre 60 ms e 70 ms para ser avaliada, de acordo com o processo descrito na figura 32. Isso está dentro da faixa desejável que é de menos de 100 ms, tempo necessário para que uma nova janela se torne disponível ao modelo.

6 CONSIDERAÇÕES FINAIS

A partir dos resultados observados é possível afirmar que os objetivos propostos foram alcançados parcialmente. O sistema não está apto para ser utilizado em uma situação real de controle de uma prótese, sendo os resultados alcançados baseados em sinais de indivíduos saudáveis. Isso facilita muito a análise se comparado à indivíduos amputados, que segundo a bibliografia possuem o sinal mais sutil e outras características dificultantes de acordo com o tipo e o grau de amputação.

Outro ponto desfavorável quanto ao uso prático do sistema foi a utilização de dados adquiridos em laboratório, de acordo com um protocolo muito bem definido, em um único momento do dia, com os indivíduos sentados e com o braço em uma mesma posição de repouso. Essa é uma situação muito diferente da que se espera em um cenário de uso real.

A taxa de acerto ficou abaixo, porém próxima, do que se achou necessário para o uso final do sistema, com muitos momentos onde o modelo identifica de maneira errada os segmentos de início e fim do movimento, o que pode não ser considerado um erro claro de classificação, porém impacta negativamente nas métricas de desempenho utilizadas.

Como ponto positivo destaca-se a alta revocação do sinal de repouso o que significa que o sistema desenvolvido dificilmente confunde um sinal de repouso com movimento, o que se considera ser bastante desejável na aplicação para o controle de próteses. Destaca-se também a velocidade de resposta do sistema que ficou dentro do esperado, o que possibilita inclusive a adoção de novas camadas de processamento e/ou expansões em trabalhos futuros.

Em resumo, foi possível desenvolver e embarcar um sistema de classificação de sinais mioelétricos baseado em algoritmo de janelamento de sinal, tido como o estado da arte, e com 11 movimentos distintos, porém sendo necessário ainda um maior refinamento do algoritmo de seleção de movimentos e também posteriores estudos quanto ao comportamento do sistema com amputados.

6.1 Sugestões Para Trabalhos Futuros

- Teste e adaptação do sistema para uso com equipamentos com alta taxa de aquisição. Sugere-se a utilização do Ninapro DB2.
- Teste e adaptação do sistema para uso com amputados. Sugere-se a utilização do Ninapro DB3.
- Teste e adaptação do sistema para dados adquiridos com equipamentos de baixo custo. Sugere-se a utilização do Ninapro DB5.
- Teste e adaptação do sistema para dados adquiridos em dias e horários diferentes. Sugere-se a utilização do Ninapro DB6.
- Utilização de outros modelos de aprendizado de máquina ou de outros tipos de redes neurais.
- Utilização de um modelo variante com o tempo, capaz de levar em conta predições passadas realizadas.
- Utilização de outros tamanhos de janela e deslizamento.
- Utilização de outros conjuntos de características.
- Redução do número de entradas do modelo, identificando para quais canais determinadas características são mais relevantes.
- Implementação embarcada em outros sistemas como microcontroladores e FPGAs.

REFERÊNCIAS

- AHSAN, Md R.; IBRAHIMY, M. I.; KHALIFA, O. O. **Neural network classifier for hand motion detection from EMG signal**. In: 5th Kuala Lumpur International Conference on Biomedical Engineering 2011. Springer, Berlin, Heidelberg, 2011. p. 536-541.
- ARTEMIADIS, Panagiotis K.; KYRIAKOPOULOS, Kostas J. **EMG-based control of a robot arm using low-dimensional embeddings**. IEEE Transactions on Robotics, v. 26, n. 2, p. 393-398, 2010.
- ATKINS, Diane J.; HEARD, Denise CY; DONOVAN, William H. **Epidemiologic overview of individuals with upper-limb loss and their reported research priorities**. JPO: Journal of Prosthetics and Orthotics, v. 8, n. 1, p. 2-11, 1996.
- ATZORI, Manfredo et al. **Classification of hand movements in amputated subjects by sEMG and accelerometers**. In: Engineering in Medicine and Biology Society (EMBC), 2014 36th Annual International Conference of the IEEE. IEEE, 2014. p. 3545-3549.
- ATZORI, Manfredo et al. **Characterization of a benchmark database for myoelectric movement classification**. IEEE Transactions on Neural Systems and Rehabilitation Engineering, v. 23, n. 1, p. 73-83, 2015.
- ATZORI, Manfredo et al. **Electromyography data for non-invasive naturally-controlled robotic hand prostheses**. Scientific data, v. 1, p. 140053, 2014.
- ATZORI, Manfredo et al. **Building the Ninapro database: A resource for the biorobotics community**. In: Biomedical Robotics and Biomechatronics (BioRob), 2012 4th IEEE RAS & EMBS International Conference on. IEEE, 2012. p. 1258-1265.
- Bebionic3. **Bebionic3: Technical information**. Reino Unido, p. 1-68, 2017. Disponível em: <bebionic.com/distributor/documents/bebionic3_technical_information_-_Lo_Res.pdf>. Acesso em: 01/06/2018.
- BERMUDEZ, R.; SHUCK, A.; BALBINOT, A. **Caracterização de movimentos do segmento mão-braço através de wavelets e redes neurais artificiais**. In: Uberlândia. 25th. Congresso Brasileiro de Engenharia Biomédica. 2014. p. 169-172.
- CHOWDHURY, Rubana H. et al. **Surface electromyography signal processing and classification techniques**. Sensors, v. 13, n. 9, p. 12431-12466, 2013.
- CUNHA, Fransérgio L. et al. **O uso de redes neurais artificiais para o reconhecimento de padrões em uma prótese mioelétrica de mão**. In: VIII Congresso Brasileiro de Redes Neurais. 2007.

DELLON, Brian; MATSUOKA, Yoky. **Prosthetics, exoskeletons, and rehabilitation** [grand challenges of robotics]. IEEE robotics & automation magazine, v. 14, n. 1, p. 30-34, 2007.

ELSIG, Simone; GIATSIDIS, Giorgio; BASSETTO, Franco. **Effect of clinical parameters on the control of myoelectric robotic prosthetic hands**. Journal of rehabilitation research and development, v. 53, n. 3, p. 345, 2016.

EVERINGHAM, Mark et al. **The pascal visual object classes (voc) challenge**. International journal of computer vision, v. 88, n. 2, p. 303-338, 2010.

GEETHANJALI, P.; RAY, K. K. **A low-cost real-time research platform for EMG pattern recognition-based prosthetic hand**. IEEE/ASME Transactions on mechatronics, v. 20, n. 4, p. 1948-1955, 2015.

GIJSBERTS, Arjan et al. **Movement error rate for evaluation of machine learning methods for sEMG-based hand movement classification**. IEEE transactions on neural systems and rehabilitation engineering, v. 22, n. 4, p. 735-744, 2014.

GRIFFIN, Gregory; HOLUB, Alex; PERONA, Pietro. **Caltech-256 object category dataset**. 2007.

HOWARD, Andrew; ROY, Nick. **Radish: The robotics data set repository**. URL <http://radish.sourceforge.net>, 2003.

HUANG, Han-Pang; CHEN, Chun-Yen. **Development of a myoelectric discrimination system for a multi-degree prosthetic hand**. In: Robotics and Automation, 1999. Proceedings. 1999 IEEE International Conference on. IEEE, 1999. p. 2392-2397.

KRASOULIS, Agamemnon et al. **Improved prosthetic hand control with concurrent use of myoelectric and inertial measurements**. Journal of neuroengineering and rehabilitation, v. 14, n. 1, p. 71, 2017.

KIGUCHI, Kazuo; TANAKA, Takakazu; FUKUDA, Toshio. **Neuro-fuzzy control of a robotic exoskeleton with EMG signals**. IEEE Transactions on fuzzy systems, v. 12, n. 4, p. 481-490, 2004.

MICERA, Silvestro; CARPANETO, Jacopo; RASPOPOVIC, Stanisa. **Control of hand prostheses using peripheral information**. IEEE Reviews in Biomedical Engineering, v. 3, p. 48-68, 2010.

MONTIEL, Alexandra; DE OLIVEIRA VARGAS, Mara Ambrosina; LEAL, Sandra Maria Cezar. **Caracterização de pessoas submetidas à amputação**. Enfermagem em Foco, v. 3, n. 4, p. 169-173, 2012.

MÜLLER, Henning et al. **A reference data set for the evaluation of medical image retrieval systems**. Computerized Medical Imaging and Graphics, v. 28, n. 6, p. 295-305, 2004.

NOVAK, Domen; RIENER, Robert. **A survey of sensor fusion methods in wearable robotics**. Robotics and Autonomous Systems, v. 73, p. 155-170, 2015.

Ottobock. **Imagem**. Disponível em: <http://professionals.ottobock.com.au/Products/Prosthetics/Prosthetics-Upper-Limb/Adult-Terminal-Devices/13E200-MyoBock-electrode/p/13E200> Acessado em 15/06/2018

PIZZOLATO, Stefano et al. **Comparison of six electromyography acquisition setups on hand movement classification tasks**. PloS one, v. 12, n. 10, p. e0186132, 2017.

PRABHU, K. M. M. **Window functions and their applications in signal processing**. CRC press, 2013.

Quantum. **Imagem**. Disponível em: <http://touchbionics.com/products/active-prostheses/i-limb-quantumch> Acessado em 15/06/2018

Raspberry. **Imagem**. Disponível em: <http://raspberrypi.org/products> Acessado em 01/11/2018

SHENOY, Pradeep et al. **Online electromyographic control of a robotic prosthesis**. IEEE transactions on biomedical engineering, v. 55, n. 3, p. 1128-1135, 2008.

SMITH, Lauren H. et al. **Determining the optimal window length for pattern recognition-based myoelectric control: balancing the competing effects of classification error and controller delay**. IEEE Transactions on Neural Systems and Rehabilitation Engineering, v. 19, n. 2, p. 186-192, 2011.

Taska. **Imagem**. Disponível em: <http://taskaprosthetics.com/> Acessado em 15/06/2018

THURSTON, Alan J. **Paré and prosthetics: the early history of artificial limbs**. ANZ journal of surgery, v. 77, n. 12, p. 1114-1119, 2007.

ZIEGLER-GRAHAM, Kathryn et al. **Estimating the prevalence of limb loss in the United States: 2005 to 2050**. Archives of physical medicine and rehabilitation, v. 89, n. 3, p. 422-429, 2008.