

CENTRO UNIVERSITÁRIO FEI

GUSTAVO DICK DE CASTRO
RAFAEL AUGUSTO CORREIA DA SILVEIRA
PABLO ALVES PINHEIRO

ArmTyr: Modelo virtual para desenvolvimento de uma prótese biônica

São Bernardo do Campo

2021

GUSTAVO DICK DE CASTRO
RAFAEL AUGUSTO CORREIA DA SILVEIRA
PABLO ALVES PINHEIRO

ArmTyr: Modelo virtual para desenvolvimento de uma prótese biônica

Trabalho de Conclusão de Curso apresentado ao Centro Universitário FEI, como parte dos requisitos necessários para obtenção do título de Bacharel em Engenharia de Automação e Controle. Orientado pela Prof^a. Dra. Maria Claudia Ferrari de Castro.

São Bernardo do Campo

2021

Castro, Gustavo Dick de.

ArmTyr: Modelo virtual para desenvolvimento de uma prótese biônica
/ Gustavo Dick de Castro, Rafael Augusto Correia da Silveira, Pablo Alves
Pinheiro. São Bernardo do Campo, 2021.

73 f. : il.

Trabalho de Conclusão de Curso - Centro Universitário FEI.
Orientadora: Prof.^a Dra. Maria Claudia Ferrari de Castro.

1. prótese virtual. 2. myo armband. 3. rede neural. 4. sinal
eletromiográfico. I. Silveira, Rafael Augusto Correia da. II. Pinheiro,
Pablo Alves. III. Castro, Maria Claudia Ferrari de, orient. IV. Título.

Elaborada pelo sistema de geração automática de ficha catalográfica da FEI com
os dados fornecidos pelo(a) autor(a).

GUSTAVO DICK DE CASTRO
RAFAEL AUGUSTO CORREIA DA SILVEIRA
PABLO ALVES PINHEIRO

ArmTyr: Modelo virtual para desenvolvimento de uma prótese biônica

Trabalho de Conclusão de Curso,
apresentado ao Centro Universitário FEL,
como parte dos requisitos necessários
para obtenção do título de Bacharel em
Engenharia de Automação e Controle.

Comissão julgadora

Profa. Dra. Maria Claudia Ferrari de Castro
Orientador e presidente

Prof. Dr. Valter Fernandes Avelino
Examinador (1)

Prof. Wellington Cássio Pinheiro
Examinador (2)

São Bernardo do Campo
2021

Dedicamos este trabalho às nossas famílias, aos professores e amigos, por todo o apoio nesses anos. Também dedicamos aos novos estudantes, continuem se esforçando.

AGRADECIMENTOS

Primeiramente agradecemos as nossas famílias por toda a paciência, incentivo e apoio financeiro ao longo do curso. Agradecemos ao Centro Universitário FEI por sempre fornecer-nos o que há de melhor. Aos professores pela excelente orientação. E por último, mas não menos importante, agradecemos aos amigos, novos e antigos, por estarem ao nosso lado nos estudos e nas folgas.

“Você pode funcionar com uma prótese de braço, perna, mão, até mesmo sobreviver com um coração mecânico, só não pode usar uma prótese para o cérebro, então não deixe que ninguém pense por você.”

Cello Vieira

RESUMO

Este trabalho apresenta uma prótese mioelétrica virtual que pode ser utilizada como sistema de treinamento para futuros usuários. O sistema de controle desenvolvido também pode ser implementado em um sistema embarcado de prótese de mão desenvolvida em impressora 3D. A braçadeira Myo adquiriu os sinais eletromiográficos, caracterizados através da Raiz Quadrática Média, e uma Rede Neural Artificial indicou a intenção de movimento do usuário e o gesto de mão a ser realizado com acurácia de 97,0%. O modelo 3D foi animado com a plataforma Blender, a aplicação foi desenvolvida na plataforma Unity, utilizando a linguagem de programação C# com recepção de dados através de servidor UDP para o controle da aplicação, e o sistema de controle foi implementado em Matlab e Simulink, enviando dados através de servidor UDP.

Palavra Chave: prótese virtual, myo armband, rede neural, sinal eletromiográfico.

ABSTRACT

This work presents a myoelectric virtual prosthesis that can be used as a training system for future users. The developed control system can also be implemented in an embedded system of a 3D printed prosthetic hand. The Myo armband acquired the electromyographic, those signals characterized by the Root Mean Square (RMS), and an Artificial Neural Network indicated the user's intention to move and the hand gesture to be performed, with an accuracy of 97.0 %. The 3D model was animated with the Blender platform, the application was developed in Unity platform, using C# programming language with data reception through UDP server, and the control system was implemented in Matlab and Simulink, with data dispatch through UDP server.

Keyword: virtual prosthesis, myo armband, neural network, electromyographic signal.

LISTA DE ILUSTRAÇÕES

Figura 1- Mão de ferro.....	17
Figura 2- Modelo I-Limb.....	18
Figura 3- Estrutura básica de uma mão.	20
Figura 4- Movimento natural dos dedos.....	21
Figura 5- Sinal EMG bruto.....	22
Figura 6- Trem de pulsos.....	23
Figura 7- Neurônio artificial.....	26
Figura 8- Rede feed-forward.	27
Figura 9- Ambiente virtual de treinamento MANUS.....	29
Figura 10- Sinal de EMG para o comando da prótese MANUS.	29
Figura 11- Diagrama Funcional do sistema.....	30
Figura 12- Arquitetura do sistema.	31
Figura 13- Ambiente em Realidade Aumentada.	32
Figura 14- Mão robótica Pisa/IIT SoftHand.....	32
Figura 15- Topologia da Rede Neural implementada através do Arduino.....	33
Figura 16- Posição dos dedos e da prótese em diferentes gestos. (a) Mão aberta, (b) pegada de precisão e (c) mão fechada.....	35
Figura 17- Fluxograma do sistema desenvolvido.....	36
Figura 18- Myo Armband.....	37
Figura 19- Posição padrão do Myo para este trabalho.	37
Figura 20- Extração de dados.	38
Figura 21- Modelo de blocos do Simulink para aquisição do EMG.	40
Figura 22- Sinal EMG Bruto com Apenas uma Repetição.	41
Figura 23- Sinal de EMG bruto com todas as repetições.	42
Figura 24- Representação visual dos movimentos programados.	43
Figura 25- Sinal de EMG tratado com RMS.	43
Figura 26- Sinal de EMG tratado, com todas as repetições.	44
Figura 27- Modelo da RNA criada.	44
Figura 28- Vetor target de treinamento.	46
Figura 29- Vetor target com todas as repetições em sequência.....	47
Figura 30- Modelo animado de uma mão.....	48
Figura 31- Modelo finalizado.	48

Figura 32- Movimentos animados (Apontar; Digitar; Jóia; Preensão lateral; Extensão Paralela; Preensão Palmar).	49
Figura 33- Fluxograma de movimentação.....	50
Figura 34- Saída Bruta média da Cross-Validation.....	51
Figura 35- Saída média da Cross-Validation tratada.....	52
Figura 36- Matriz Confusão da Rede especializada.	53
Figura 37- Histograma de Erro da rede especializada.	54
Figura 38- Saída da rede para o Indivíduo 1.	55
Figura 39- Saídas da Rede Neural para o Indivíduo I: a) Saída tratada; b) Vetor target.	56
Figura 40- Histograma de Erro para o Indivíduo 1.	57
Figura 41- Matriz de Confusão para o Indivíduo 1.	58
Figura 42- Saída bruta da rede mista.	59
Figura 43- Saída tratada da rede mista.	60
Figura 44- Matriz de Confusão da rede mista.	61
Figura 45- Histograma de Erro da rede mista.....	62
Figura 46- Esquemático das movimentações.	63
Figura 47- Diagrama de blocos para testes em tempo real.....	64

LISTA DE TABELAS

Tabela 1- Acurácia (%) obtida com cada característica utilizando classificador SVM. 30	30
Tabela 2- Comparação entre modelos gaussiano e linear SVM..... 31	31
Tabela 3- Porcentagem de acerto para cada movimento e a característica extraída (janela de 250ms). 34	34
Tabela 4 - Representação dos Displays. 65	65

SUMÁRIO

1 INTRODUÇÃO	15
1.1 OBJETIVOS	16
2. FUNDAMENTAÇÃO TEÓRICA.....	17
2.1 PRIMEIRAS PRÓTESES.....	17
2.2 PRÓTESES MIOELÉTRICAS.....	18
2.3 ARQUITETURA DAS PRÓTESES DE MÃO.....	19
2.4 ELETROMIOGRAFIA	22
2.4.1 Cuidados na aquisição do sinal EMG.....	24
2.4.2 Extração de características.....	24
2.5 REDES NEURAIS.....	25
2.5.1 Neurônio artificial.....	25
2.5.2 Redes Feed-Forward.....	26
2.6 FUNDAMENTOS DA REALIDADE VIRTUAL.....	27
2.6.1 Ambientes virtuais utilizados em reabilitação.....	28
3 REVISÃO BIBLIOGRÁFICA	28
4 METODOLOGIA.....	36
4.1 MYO ARMBAND.....	36
4.1.1 Aquisição de dados	37
4.1.2 Extração de Característica	38
4.1.3 Aquisição de dados em tempo real	39
4.2 ORGANIZAÇÃO DOS DADOS.....	40
4.3 RECONHECIMENTO E CLASSIFICAÇÃO DE PADRÕES.....	44
4.4 PROCESSO DE CRIAÇÃO E ANIMAÇÃO	47
5 RESULTADOS E DISCUSSÃO	51
5.1 REDE NEURAL.....	51
5.1.1 Rede Especializada	51
5.1.2 Rede Mista.....	58
5.2 – MODELO VIRTUAL	63
5.3 – INTEGRAÇÃO E TESTES EM TEMPO REAL	64
6 CONCLUSÃO.....	67

1 INTRODUÇÃO

O avanço da tecnologia não tem influência apenas nos aparelhos que vemos e usamos todo o tempo em nosso dia a dia, mas ela influencia e provoca avanços em diversas outras áreas, como por exemplo, na medicina.

A tecnologia trouxe esperança para pessoas que perderam ou nasceram sem um ou mais membros, possibilitando que a vida destas pessoas se torne mais similar com a de pessoas saudáveis, e o que possibilitou essa esperança foi a criação das próteses.

Atualmente, existem diversas opções de solução em próteses, desde as com membros estáticos, que proporcionam mais estética do que funcionalidade, até as ditas próteses biônicas que, através de diversos meios, simulam alguns movimentos como os de membros reais. Dentre os membros, os que apresentam maior dificuldade para a emulação de movimentos, são os braços e mais especificamente, as mãos, devido à variabilidade e complexidade (graus de liberdade), tornando assim mais funcional a seleção de alguns movimentos específicos e necessários para a realização de atividades do cotidiano, do que tentar reproduzir todos os movimentos possíveis. Estes movimentos constituem, geralmente, nos movimentos de abrir e fechar a mão, apontar e o movimento de pinça.

As próteses de mão mioelétricas, que utilizam o sinal muscular como forma de comando e de representar a intenção do usuário em realizar um movimento, geralmente, oferecem 4 movimentos programados, porque o sinal muscular é específico para cada indivíduo e, dependendo do indivíduo, tendo em vista a falta do membro, é muito limitado também. Então, as próteses comerciais se utilizam de códigos pré-programados, baseados no número e na duração de contrações de um par de músculos, de forma que o número de movimentos possíveis de se proporcionar ao usuário é restrito, além do fato do uso de códigos não ser nada intuitivo.

A adaptação dos usuários em sua maioria é lenta e desgastante; para melhorar esse processo, este trabalho propõe o uso de técnicas computacionais de treinamento, que através da interação com uma interface gráfica de Realidade Virtual (RV), estimule os usuários pelo poder da interação e imersão. A utilização de técnicas de RV no treinamento de usuários de próteses mioelétricas apresenta-se como uma ferramenta complementar que, segundo Herle et al. (2018), favorece a adaptação dos usuários aos membros artificiais, uma vez que fornece um canal de realimentação visual aos usuários, além de

possibilitar a avaliação da eficiência de diferentes estratégias de controle. Desta forma, segundo Weiss et al. (2004) e Sebelius et al. (2005), a utilização de próteses virtuais, durante a fase de treinamento, a natureza intuitiva da interação homem-máquina, proporcionada pela RV, favorece o treinamento de habilidades cognitivas e motoras dos usuários, auxiliando no processo de adaptação.

Tendo isso em vista, este trabalho apresenta um modelo virtual de uma prótese mioelétrica, dotado de uma forma mais natural e intuitiva de controle do que as soluções comerciais, além do fato de ser adaptável de indivíduo para indivíduo, utilizando-se do atual aprendizado de máquina, ou inteligência artificial que, com o passar do tempo, se apresenta cada vez mais presente e útil nas mais diversas aplicações.

1.1 OBJETIVOS

Este trabalho apresenta um modelo virtual de uma prótese mioelétrica, utilizando as plataformas *Blender* e *Unity*, visando sua utilização como plataforma de treinamento para futuros usuários de próteses biônicas.

O sistema de captura dos sinais eletromiográficos (EMG) utiliza o Myo armband, o conceito de extração de características do sinal EMG baseia-se na aplicação do método da Raiz Quadrática Média (RMS), e o processamento do sinal, visando o reconhecimento e classificação de padrões do sinal de EMG, utiliza Redes Neurais. Dessa forma, objetiva-se obter um sistema de controle mais intuitivo e adaptável às condições do usuário, expressando sua intenção de movimento no comando do modelo virtual.

2. FUNDAMENTAÇÃO TEÓRICA


2.1 PRIMEIRAS PRÓTESES

O desenvolvimento de próteses não é uma necessidade recente, o avanço da tecnologia e a busca pelo bem estar da sociedade, fez com que este tema se tornasse importante não só para quem tem a necessidade do uso de prótese, mas também para a sociedade que, como um todo, valoriza a igualdade e busca possibilitar uma melhora na qualidade de vida de todos.

A prótese mais antiga que se tem registro é de 600 a.c. Trata-se de uma prótese para simular o dedão do pé, feita de madeira no antigo Egito, que está em exposição no museu de Cairo.

Avançando um pouco no tempo, por volta de 1500 foi desenvolvida uma prótese de ferro para substituir o braço de um militar alemão chamado Götz von Berlichque que perdeu seu braço na guerra. Esse modelo tinha como composição quatro dedos emparelhados fixos e o polegar móvel por mecanismo de catraca visto na figura 1 (ZUO e OLSON, 2014).

Figura 1- Mão de ferro.



Fonte: Zuo e Olson, 2014.

Este modelo é muito semelhante ao primeiro já documentado como mão protética que foi usado pelo general romano Marcus Sergius, que usava a prótese para segurar seu escudo durante a guerra Púnica (218-201 a.c). Sua mão de ferro o ajudou não só na batalha como a ganhar fama na carreira militar (ZUO e OLSON, 2014).

2.2 PRÓTESES MIOELÉTRICAS

A partir dos anos 2000 a internet estava começando a ficar acessível em todo o mundo e a troca de informações via rede facilitou o desenvolvimento de novas tecnologias, assim como o avanço no desenvolvimento de próteses biônicas. De acordo com a literatura, o método mais utilizado no comando de próteses biônicas é o uso de sinais musculares como forma de representação da intenção do usuário na realização de movimentos. Este método, responsável por captar os sinais elétricos transmitidos do músculo, é chamado de eletromiografia (EMG).

As próteses biônicas, desenvolvidas através da captação de sinal por EMG, são chamadas de próteses mioelétricas. No mercado, atualmente, duas próteses se destacam, sendo elas a *BeBionic*, criada pela empresa britânica *Steeper Group* e a prótese *I-Limb*, fabricada pela *Touch Bionics*. O diferencial da *I-Limb*, apresentada pela figura 2, é o fato dela poder fazer alguns movimentos pré-programados comandados pelo smartphone via *bluetooth*, aumentando a quantidade de movimentos possíveis de serem realizados.

Figura 2- Modelo I-Limb



Fonte: Camargo e Stoppa, 2016.

Uma das abordagens mais populares para controle de próteses baseia-se na utilização de sinais EMG como sinais de controle de membros artificiais (LAMOUNIER, et al., 2010). Estes sinais consistem em manifestar eletricamente a atividade neuromuscular associada à contração muscular. Atualmente, a maioria das próteses

transradiais funcionais, utilizam estes sinais para controlar o abrir e fechar das mãos artificiais (LI, SCHULTZ e KUIKEN, 2010).

Em comparação com as próteses "gancho" que podem ser usadas como pinças controladas pelo usuário por um cabo no corpo, colocado no tronco, e fechados automaticamente com elementos de mola ou borracha, as próteses mioelétricas proporcionam ao usuário mais graus de liberdade de movimento. No entanto, o número de graus de liberdade limita-se pela capacidade do sistema em decodificar os sinais gerados pelo usuário afetando o desempenho para gerar os sinais de comando (CRAELIUS, ABBOUDI e NEWBY, 1999). Em alguns dispositivos, por exemplo, os usuários devem ativar o modo de rotação do punho, executando a contração simultânea de um par de músculos do antebraço. Deve-se ressaltar, contudo, que a adaptação dos usuários aos comandos requer um processo de treinamento, uma vez que o controle de diferentes funções utilizando as contrações musculares codificadas não se dá de forma natural (LI, SCHULTZ e KUIKEN, 2010).

Em um modelo de prótese mioelétrica de controle autônomo, a movimentação de qualquer parte da prótese ocorre automaticamente, a partir de uma instrução simples dada pelo usuário. Ou seja, a partir da contração de certo músculo, uma prótese de mão com controle autônomo fechará os dedos da mão com velocidade constante. Detectando-se a contração de outro músculo, os dedos da mão mecânica se abrirão. Geralmente utiliza-se uma linguagem codificada, ou seja, sucessivas contrações em número e largura diferentes formam códigos binários, utilizados para comandar diferentes movimentos (OKUNO, YOSHIDA e AKAZAWA, 2005).

Próteses de mão com controle proporcional indicam velocidade e força de preensão equivalentes à intensidade dos sinais de ativação coletados nos músculos (HESSE e HERRMANN 2010). Alguns autores, tais como Nielsen et. al. (2011) e Jiang, Englehart e Parker (2009) pesquisaram o processamento de sinais EMG buscando o controle proporcional de próteses de mão.

2.3 ARQUITETURA DAS PRÓTESES DE MÃO

A mão humana possui diversas funções como movimentação, segurar objetos, sensibilidade à textura e temperatura. Para se desenvolver um modelo 3D da mão é necessário entender as características anatômicas e as principais estruturas de uma mão

humana para que o modelo criado possua a mesma capacidade de efetuar tarefas e realizar movimentos com o mesmo grau de complexidade.

A mão humana possui 27 ossos principais, como mostrado pela figura 3 (oito carpos, cinco metacarpos e as falanges) e 18 articulações conjuntas com aproximadamente 26 graus de liberdade, ainda tendo estudos em desenvolvimento para determinar o valor exato, coordenados por aproximadamente quarenta músculos que abrangem todos os dedos da mão. Os movimentos executados pelas mãos são operados por dois tipos de músculos, os que estão dentro da mão (intrínsecos) e os que se estão no antebraço (extrínsecos). Os músculos extrínsecos se ligam às falanges, que são os ossos dos dedos, por meio de tendões. As falanges podem ser divididas em:

Proximais - que se encontram mais próximas à palma da mão.

Médias - que se encontram no meio dos dedos.

Distais - que se encontram nas extremidades dos dedos.

Figura 3- Estrutura básica de uma mão.



Fonte: Johnson et al., 2015.

Cada uma das articulações dos dedos pode ser flexionada e estendida. Além disso, as falanges proximais exibem abdução (afastamento) e adução (aproximação). O polegar detém a estrutura mais complexa, seus possíveis movimentos são flexão/extensão,


abdução/adução e rotação em torno do eixo do metacarpo (BIAGIOTTI et al., 2003).

Muitas próteses hoje em dia ainda possuem sua função muito limitada apresentando grau de liberdade único. As próteses mioelétricas comerciais possuem elevada força de aderência na tarefa de segurar objetos através do movimento de pinça para assegurar uma preensão estável. Sendo necessário um esforço consciente realizado pelo utilizador para efetuar o movimento.

As próteses do mercado possuem poucas funções e com isso tem gerado insatisfação dos usuários. Sendo assim, as características mais citadas pelos clientes são: que não parece muito humano (ambos na aparência estática e dinâmica); peso; consumo de energia e o tamanho adequado para cada um e a fluidez e velocidade do movimento. O elemento mais importante em uma prótese é a presença do polegar nas mãos, pois aumenta significativamente a gama de movimentos (LIGHT e CHAPPELL, 2001).

Analisando o movimento feito naturalmente por nós ao segurar um objeto, o objeto deve tocar primeiro a falange mais próxima a mão (proximal) (B), em seguida, a média (C), e pôr fim a mais longe da mão (distal) (D), conforme mostra a figura 4 (MASSA et al., 2002).

Figura 4- Movimento natural dos dedos



Fonte: Massa et al., 2002.

Após o estudo das características da mão humana pensando no desenvolvimento de um sistema que representa com fidelidade e com ótima experiência visual ao usuário, foi escolhido um modelo que graficamente se assemelha muito a realidade e desenvolvidas as estruturas ósseas nesse modelo por meio das articulações presentes no Blender para que o número de graus de liberdade do modelo se aproxime o máximo possível aos que a mão humana possui para realização de uma gama de movimentos.


Com essas informações foram criados movimentos no Blender, de maneira que a realização da animação fique com a fluidez do movimento natural.

2.4 ELETROMIOGRAFIA

A eletromiografia (EMG) é um método utilizado para avaliar a atividade elétrica produzida por fibras musculares e membranas. Para coleta de dados é necessário a utilização de eletrodos que são aplicados na superfície da pele (eletromiografia de superfície - sEMG) ou no músculo que se deseja registrar a atividade elétrica, sendo possível assim a aquisição do sinal eletromiográfico. A estimulação da unidade motora (conjunto formado pelo neurônio motor e pelas fibras musculares por ele inervadas) é derivada do córtex motor localizado no cérebro. Com os dados colhidos, pode-se determinar quais músculos foram recrutados durante a realização de um movimento, assim como sua condição, determinando se está saudável ou se sofre de alguma doença neuromuscular, lesão, entre outras possibilidades (KONRAD, 2005).

O sinal de EMG, apresentado pela figura 5, é obtido devido ao fluxo de íons de sódio e potássio entre as células musculares. O equilíbrio entre estes íons causa um potencial de repouso que pode variar entre -80 e -90mV quando relaxado. Com a chegada de um estímulo supraliminar, pode chegar até +30mV, gerando um potencial de ação. Este modelo recebe o nome de membrana semi-permeável, de forma que quando o músculo é excitado através do sistema nervoso, as células musculares liberam íons de potássio para membrana externa, ao mesmo tempo que absorvem os íons de sódio, causando assim a flutuação do potencial na superfície das fibras musculares (KONRAD, 2005; GODOI, 2013).

Figura 5- Sinal EMG bruto.




Fonte: Konrad, 2005.

Outra aplicação para o sEMG é no controle de próteses biônicas, indicando a intenção do usuário. Quando há excitação do músculo, é gerado uma variação de tensão

que se propaga nas fibras musculares, fenômeno conhecido como Potencial de Ação da Unidade Motora (*Motor Unit Action Potential*, MUAP). No entanto, tendo em vista que um músculo é formado por milhares de fibras, normalmente é ativado por mais de um MUAP, além do fato de precisarem ser ativados repetidamente, já que a duração de um MUAP é relativamente pequena (2 a 10 ms), sendo gerado um trem de pulsos produzido pelos MUAP's , como é mostrado pela figura 6. Como resultado, o sEMG, dos sinais registrados pelos eletrodos na superfície muscular, é uma sobreposição de MUAP de diferentes frequências. Na eletromiografia de superfície o EMG medido apresenta amplitudes típicas entre 50 e 300 μ V e faixa de frequência ampla, principalmente entre de 20 e 250 Hz (ECARD, 2017).

Figura 6- Trem de pulsos.



Fonte: Adaptada de Félix e Vasconcellos, 2008.

O sinal transmitido pelo corpo humano é um sinal analógico (sinal contínuo no tempo), de baixa amplitude e frequência e para efetuar a análise e aplicação desse sinal é necessário transformá-lo em um sinal digital (sinal quantizado e discreto no tempo, aplicado em determinados instantes); para tanto, dependendo do objetivo proposto, é feito o ajuste de alguns parâmetros, sendo os principais: eletrodos, amplificadores, filtros, frequência de amostragem e componentes físicos como o equipamento para armazenamento de dados.

2.4.1 Cuidados na aquisição do sinal EMG

Alguns fatores podem interferir no sinal de EMG bruto adquirido como a condutividade e outras características do tecido muscular que variam dependendo do indivíduo observado, tornando extremamente difícil a comparação direta entre indivíduos. Outro fator que adiciona ruído ao sinal é a variação de polarização de músculos vizinhos, que podem causar interferência uns nos outros, a geometria do espaço entre as fibras musculares e o eletrodo, interferências do ambiente e interferências devido aos amplificadores de sinal utilizados na medição que podem ser diversos, dependendo da aplicação (KONRAD, 2005).

Uma preparação da pele sobre o músculo que se deseja realizar a medição é necessária, tornando a posição e leitura do eletrodo estável, além de diminuir a impedância da pele do indivíduo testado. O grau destas preparações depende da aplicação onde o sinal será utilizado, podendo ser apenas a limpeza da pele com a utilização de álcool, e a remoção de pelos ou qualquer outro fator de variação da superfície da pele através de materiais abrasivos como gel esfoliante e/ou lixa, evitando a danificação da pele. Também é necessário a instalação de pelo menos um eletrodo de referência, para que a aquisição do sinal seja consistente, impondo todos os valores obtidos a mesma referência (KONRAD, 2005).

2.4.2 Extração de características

O sinal de EMG obtido através de eletrodos superficiais apresenta amplitude e formatos aleatórios (vide item 2.4); mas é possível, após o tratamento do sinal, extrair algumas características de recrutamento muscular associados a cada movimento executado, tornando possível relacionar diferentes padrões a comandos para a execução de movimentos de uma prótese.

O valor *Root Mean Square* (RMS) ou Raiz Quadrática Média é um valor médio de um sinal alternado que gera a mesma potência de um sinal contínuo e é um método bastante utilizado na caracterização de sinais de EMG que pode ser obtido pela Equação 1.

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

A equação apresentada é utilizada para a aplicação em um sinal discreto. Para uma menor taxa de processamento computacional, a RMS é utilizada em uma janela do sinal que se move sobre o vetor de dados, recebendo assim o nome de RMS móvel, onde n é a quantidade de amostras da janela observada e x é o valor da amostra de índice i (ALMEIDA, 2010).

Este método, aplicado ao sinal de EMG, fornece um valor médio da atividade fisiológica de contração de cada músculo analisado, assim sendo frequentemente utilizado para o processamento do sinal de EMG para próteses, pelo seu baixo custo de processamento (ALMEIDA, 2010).

Outras características que podem ser extraídas do sinal de EMG para a caracterização de padrões são número de cruzamentos por zeros, média do valor absoluto, análise da frequência, ângulo de inclinação da média com valor absoluto e o comprimento do traço do sinal. Também existem métodos utilizando mais de um canal de aquisição de dados e a comparação entre os padrões destes canais, significando a aquisição e comparação dos padrões paralelamente em mais de um músculo. Este trabalho, no entanto, utilizará apenas o método de RMS.

2.5 REDES NEURAIS

Uma Rede Neural Artificial (RNA) é uma máquina feita com o propósito de simular a rede de neurônios presente no cérebro humano, portanto, a RNA tem como funcionalidade operar por meio de processo de aprendizado extraído a partir do ambiente, e ela pode ser projetada por meio de componentes físicos ou *softwares*.


A RNA é composta por neurônios artificiais (células computacionais) e para obter um bom desempenho de aprendizagem e armazenar o conhecimento aprendido são executadas conexões entre os neurônios existentes; essas conexões são denominadas pesos sinápticos (HAYKIN, 2001).

2.5.1 Neurônio artificial

O neurônio é a unidade básica de processamento onde ocorre a leitura e processamento dos dados de entrada, os pesos sinápticos são capazes de generalizar o conhecimento a partir de exemplos anteriores, assim sendo capaz de lidar com ruídos e distorções que atrapalham o reconhecimento do padrão desejado. A figura 7 representa o

modelo de um neurônio artificial.

Figura 7- Neurônio artificial.



Fonte: Carnap, 1938.


Para cada conexão existe um peso sináptico que determina o efeito de processamento. A equação 2, a seguir, representa o modelo matemático do neurônio, onde x_n representa cada uma das n entradas e w_{jn} representa o peso da entrada n , e T consiste na função de ativação do neurônio, podendo ser uma função rampa, sigmoide, tangente, ou alguma outra função.

$$saída = T\left(\sum_{i=1}^n x_i w_{ji}\right) \quad (2)$$

2.5.2 Redes Feed-Forward

As Redes *Feed-Forward* são redes de uma ou mais camadas de neurônios, sendo o tipo de rede mais comum já que ela pode ser aplicada em diversos tipos de problemas. O fluxo de dados ocorre em apenas uma direção e não existe realimentação do sinal. Uma rede *feed-forward* é composta por camadas, uma de entrada, uma de saída, sendo que a quantidade de neurônios na entrada e saída é variável dependendo da quantidade de entradas e saídas da rede, e por último é possível que haja camadas ocultas que fazem a combinação das entradas e saídas (figura 8).

Figura 8- Rede feed-forward.



Fonte: Miloca et al., 2007.

2.6 FUNDAMENTOS DA REALIDADE VIRTUAL

A realidade virtual (VR) pode ser definida como uma "interface de usuário avançada" para aplicações executadas virtualmente, com as características de visualização e movimentação em ambientes tridimensionais, em tempo real, possuindo interação com elementos desse ambiente (TORI e KIRNER 2006). Ou seja, realidade virtual é uma tecnologia que convence o utilizador de estar imerso em outra realidade, substituindo os estímulos sensoriais primários do participante por dados recebidos de um computador (YOH, 2001).

Os sistemas de realidade virtual têm sido utilizados nas mais diversas áreas do conhecimento. Alguns domínios de aplicação incluem as indústrias petrolíferas e de gás, fabricação de automóveis e aviões, aplicações militares, educação, publicidade e propaganda (CARDOSO e LAMOUNIER, 2006; SORDI e VALDAMBRINI, 2006; QIU e CHEN, 2009; LIMA, CUNHA e LANDAU, 2010).

Além das aplicações acima mencionadas, a realidade virtual tem sido também utilizada há alguns anos nas ciências médicas, abrindo várias possibilidades no tratamento de várias doenças e patologias humanas (BURDEA, 2003; COSTA e RIBEIRO, 2009). Entre as aplicações da realidade virtual podem ser mencionadas o tratamento de fobias e

ambientes virtuais destinados à reabilitação humana (BATTEAU, et al. 2004; NUNES, et al. 2007, BRINKMAN, SANDINO e MAST, 2009; BRUCE e REGENBRECHT, 2009).

2.6.1 Ambientes virtuais utilizados em reabilitação

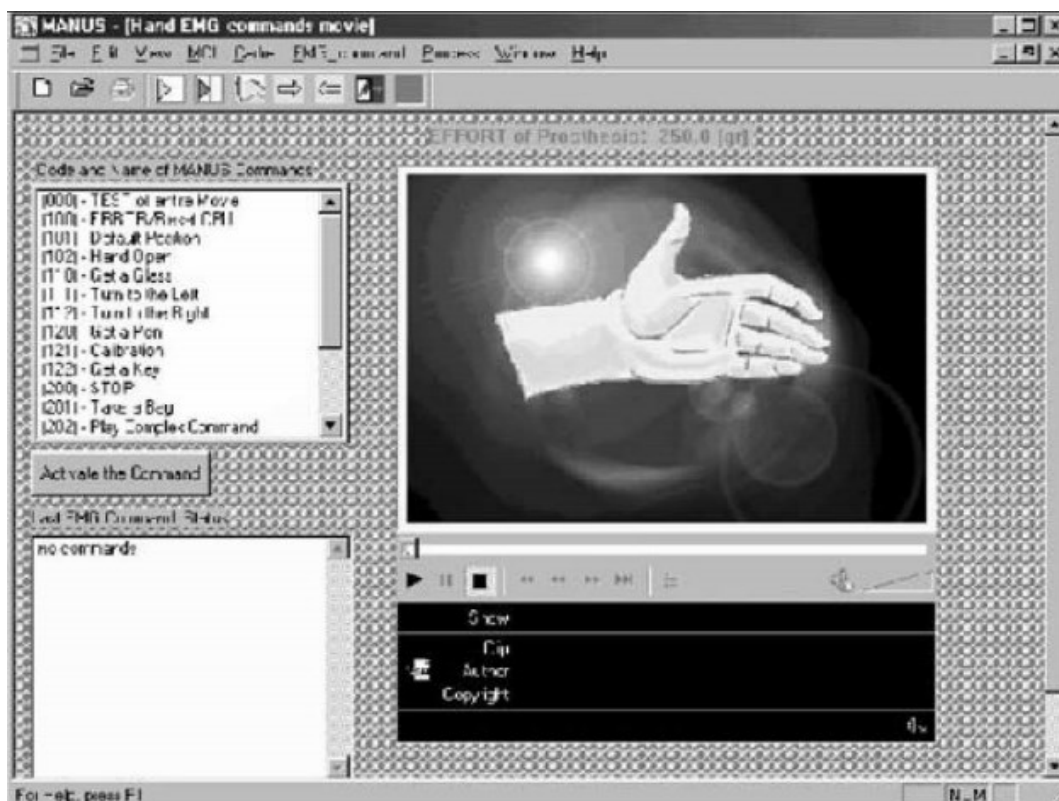
A realidade virtual, quando aplicada à reabilitação humana, permite a criação de ambientes em que a intensidade da capacitação pode ser sistematicamente manipulada, a fim de adaptar o ambiente de reabilitação virtual às necessidades de cada paciente (JACK, et al. 2001). Para tal, os pacientes são convidados a realizar, num ambiente virtual, uma série de exercícios determinados pelo profissional de saúde responsável (médico, psicólogo ou terapeuta). A comunicação entre o paciente e o ambiente virtual é feita através de dispositivos específicos de entrada/saída, tais como dispositivos tácteis, óculos de realidade virtual, entre outros. Finalmente, a reabilitação assistida por computador pode ser integrada em sistemas de bancos de dados, gerando relatórios de treinamento e avaliações estatísticas das sessões, além de proporcionar ao médico ou terapeuta a possibilidade de monitorar, em tempo real ou posteriormente, a performance do paciente na execução dos exercícios (MATTIOLI, et al. 2011).

3 REVISÃO BIBLIOGRÁFICA

Existem diversos trabalhos e pesquisas que estão sendo feitas na área de desenvolvimento do presente projeto.


No trabalho desenvolvido por Pons et al. (2005), uma nova linguagem de comando para as próteses mioelétricas MANUS foi proposta, sendo testada em um ambiente de realidade virtual (figura 9). O usuário da prótese realiza sucessivas contrações de um determinado músculo. De acordo com os limiares pré-estabelecidos, cada contração pode ser classificada em três níveis diferentes: "0", "1" ou "2". Uma vez que a palavra de comando é reconhecida (uma sequência de contrações), a prótese realiza o movimento correspondente à palavra comando. A figura 10 apresenta um exemplo de comando através do sinal de EMG. No exemplo, de acordo com os limiares A1 e A2, as 3 contrações consecutivas formam a palavra "121".

Figura 9- Ambiente virtual de treinamento MANUS



Fonte: Pons et al., 2005.

Figura 10- Sinal de EMG para o comando da prótese MANUS.



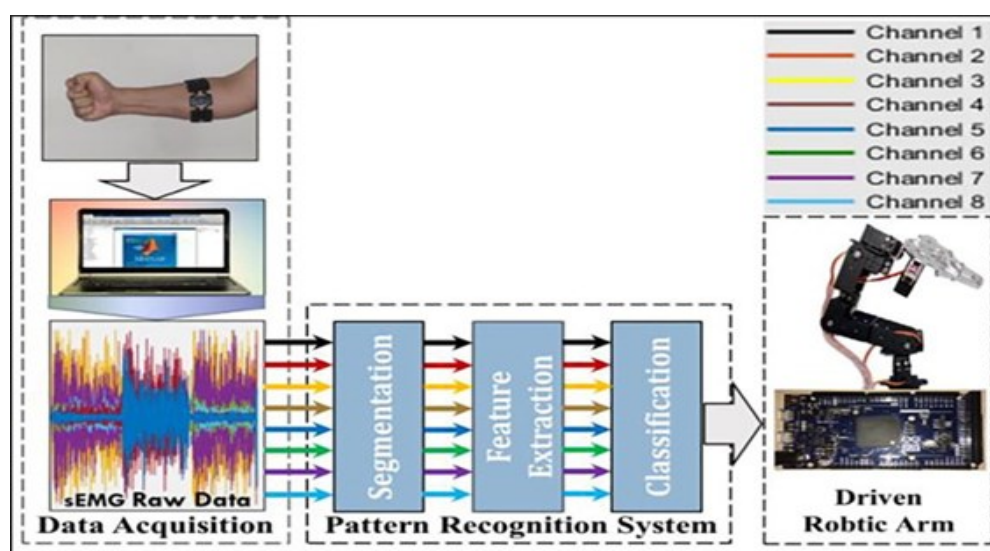
Fonte: Pons et al., 2005.

Mesmo que o controle pelo uso dessa linguagem seja facilmente assimilado pelos usuários, não representa uma forma natural de controle de movimentos.

Em um trabalho equivalente, Hassan, Abou-Loukh e Ibraheem (2006) também

utilizaram o Myo Armband para coleta de dados com seis indivíduos saudáveis para controlar o braço robótico 5-DoF Aideepen ROT3U em tempo real com a plataforma *Arduino UNO* (figura 11). O projeto testou seis métodos de extração de parâmetros: raiz quadrada média (RMS), comprimento da forma de onda (WL), valor absoluto médio (MAV), coeficientes autorregressivos (AR), sinal de inclinação mudanças (SSC) e cruzamentos de zero (ZC). Foram utilizados dois classificadores de máquina de suporte vetorial (SVM), que são: o modelo linear e o *kernel* com função de base radial (RBF). Os resultados obtidos estão descritos nas Tabelas 1 e 2, mostrando que, apesar de serem dependentes do indivíduo, na média os melhores resultados ocorreram para o RMS e SVM com RBF.

Figura 11- Diagrama Funcional do sistema.



Fonte: Hassan, Abou-Loukh e Ibraheem, 2006.

Tabela 1- Acurácia (%) obtida com cada característica utilizando classificador SVM.

Sujeito	RMS	MAV	WL	AR (4)	ZC	SSC
Sujeito1	96,12	96,55	94,20	72,67	48,67	35,78
Sujeito2	93,16	93,08	90,24	66,78	50,74	41,71
Sujeito 3	95,80	95,57	92,06	61,86	40,53	29,97
Sujeito 4	94,21	93,41	92,14	64,63	45,96	38,22
Sujeito 5	95,53	95,59	93,47	66,93	45,71	34,16
Sujeito 6	93,56	93,48	91,50	56,22	41,24	31,29
Média	94,73	94,61	92,29	64,85	45,48	35,18

Fonte: Hassan, Abou-Loukh e Ibraheem, 2006.

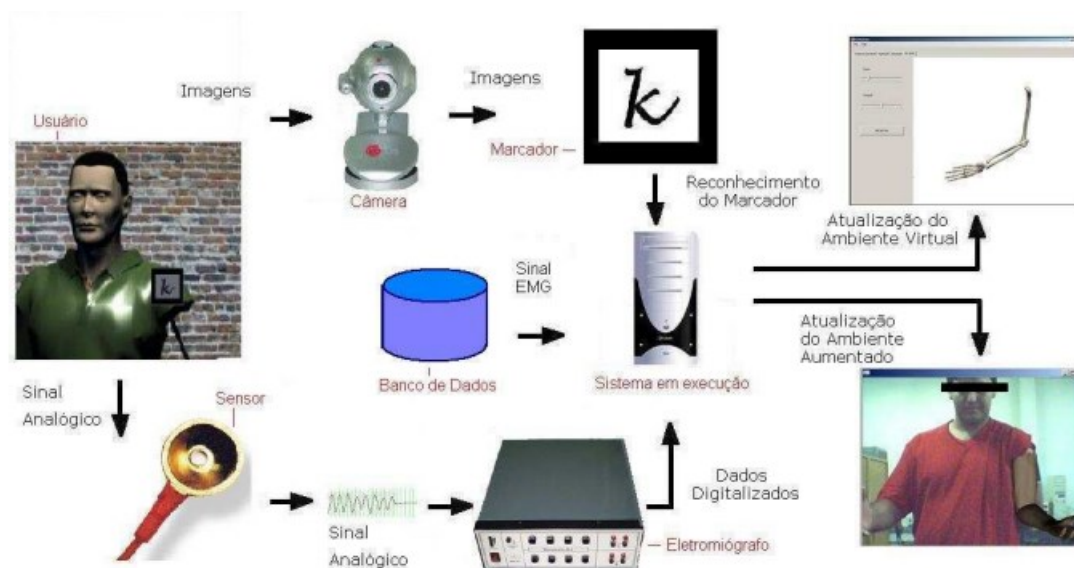
Tabela 2- Comparação entre modelos gaussiano e linear SVM.

Sujeito	Modelo linear SVM (%)	Modelo SVM RBF (%)
Sujeito 1	89,6	96,3
Sujeito 2	89,8	95,05
Sujeito 3	91,5	95,57
Sujeito 4	89,3	95,3
Sujeito 5	91,2	95,72
Sujeito 6	87,5	93,66
Média	89,82	95,27

Fonte: Hassan, Abou-Loukh e Ibraheem, 2006.

Outro trabalho que utilizou plataforma virtual foi o desenvolvido por Nogueira (2007). O sistema usa sinais EMG para controle das próteses e permite a coleta e o processamento de dados no tempo de execução. A figura 12 representa a arquitetura deste sistema. Para a classificação dos movimentos, o modelo auto-regressivo e uma rede neural artificial treinada com retropropagação de erros foram utilizados. O diferencial deste trabalho está na possibilidade de usar a realidade aumentada, como mostrado na figura 13, utilizando o controle de um membro virtual ao invés de uma prótese virtual.

Figura 12- Arquitetura do sistema.



Fonte: Nogueira, 2007.


Figura 13- Ambiente em Realidade Aumentada.



Fonte: Nogueira, 2007.

Rossi et al. (2017) adaptaram uma prótese chamada *Pisa/IIT SoftHand* (figura 14) para ser usada com o *Myo Armband* e contando com uma rede neural desenvolvida a partir dos dados de cinco indivíduos saudáveis treinaram o sistema para executar quatro posturas diferentes da mão. O controle é baseado na combinação das técnicas de fatoração de matriz não negativa (NMF) e regressão linear (LR). Os resultados do experimento mostraram a estratégia de compensação permitiu aos sujeitos manterem a mão em repouso em diferentes posturas, enquanto o comando era enviado para a mão robótica, permitindo a realização de tarefas do dia a dia.

Figura 14- Mão robótica Pisa/IIT SoftHand.

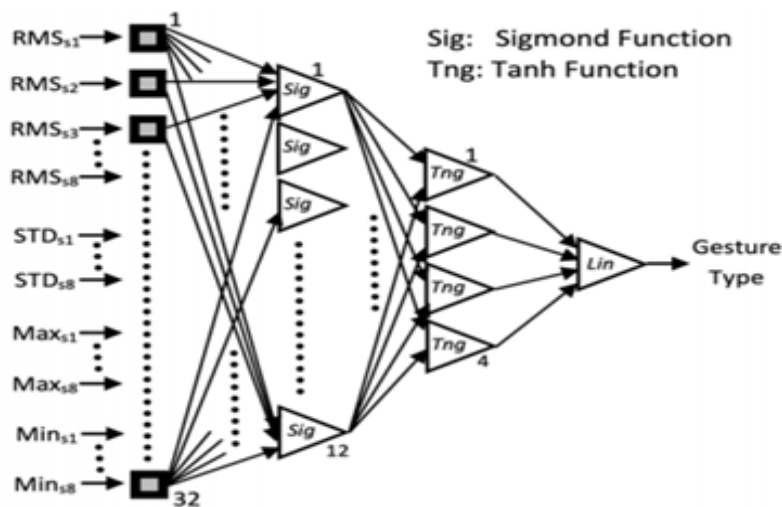


Fonte: Rossi et al., 2017.

Zhang et al. (2019) desenvolveram um modelo para reconhecer os 5 gestos da mão do sistema Myo armband, em tempo real, utilizando uma rede neural com uma camada escondida com um número de neurônios correspondentes à metade do tamanho do vetor de características, utilizando a média do valor absoluto, o comprimento de onda, o número de mudanças no sinal da inclinação dentro da janela de dados, o RMS, e o parâmetro de Hjorth, baseado no cálculo da variância. O estudo contou com 12 indivíduos saudáveis e obteve uma taxa média de reconhecimento de 98,7%.

Uma rede multicamadas foi utilizada por Raheema, Hussain e Al-Khazzar (2020) para controlar uma prótese impressa em 3D através da braçadeira Myo, com uma interface controlada pelo microcontrolador *Arduino UNO*. Os autores usaram vários métodos de extração de características, como por exemplo RMS, desvio padrão (STD), máximos (Max.) e mínimos (Min.) para alimentar os 32 neurônios da camada de entrada da rede, para reconhecer cinco gestos (figura 15) com acurácia maior que 99%.

Figura 15- Topologia da Rede Neural implementada através do Arduino



Fonte: Raheema, Hussain e Al-Khazzar, 2020.

Serrezuela, Zamora e Reyes (2021) apresentam uma comparação entre cinco métodos de extração de características de sEMG, captados de indivíduos saudáveis através da braçadeira Myo, sendo eles, valor absoluto médio (MAV), cruzamento zero (ZC), Amplitude Wilson (WAMP), variância (VAR) e comprimento de onda (WL), para reconhecer seis movimentos do membro superior. A extração de cada característica utilizou uma janela de 250ms, e o classificador utilizado foi uma rede neural treinada

através de retropropagação, com vinte neurônios na camada oculta e seis saídas. As porcentagens de acerto obtidas, para cada movimento e em cada método, estão especificadas na tabela 3.

Tabela 3- Porcentagem de acerto para cada movimento e a característica extraída (janela de 250ms).


Característica EMG	Repouso	Aperto	Pronação	Supinação	Extensão	Flexão
MAV	99,53%	90,29%	56,63%	89,87%	90,31%	89,84%
WL	86,23%	60,45%	92,24%	82,50%	84,12%	64,21%
ZC	83,46%	57,81%	60,61%	88,48%	72,91%	65,05%
WAMP	90,26%	94,62%	37,18%	92,01%	83,17%	84,12%
VAR	86,48%	88,93%	66,13%	91,89%	41,78%	64,23%

Fonte: Serrezuela, Zamora e Reyes, 2021.

Concluída a rede neural, o projeto foi implementado em uma prótese construída de termoplástico de polilactídeo (PLA), e seu sistema de controle foi implementado no microcontrolador *Arduino UNO*, utilizando o método MAV para extração de características, o sistema apresenta acurácia média de 94,94%. A figura 16 mostra o modelo copiando alguns dos gestos.

Os trabalhos desenvolvidos por Nogueira (2007), Raheema, Hussain e Al-Khazzar (2020) são os mais próximos ao que foi estudado neste trabalho, pois são os usam elementos mais parecidos com os utilizados aqui, rede neural para a classificação, tratamento do sinal por RMS e modelos virtuais. Os outros trabalhos, mesmo que não apresentem tanta semelhança quanto os mencionados, ainda utilizam um ou outro aspecto semelhante, podendo assim ser possível a comparação entre apenas o sistema de comparação, ou apenas o algoritmo de filtro do sinal de EMG.

Figura 16- Posição dos dedos e da prótese em diferentes gestos. (a) Mão aberta, (b) pegada de precisão e (c) mão fechada.



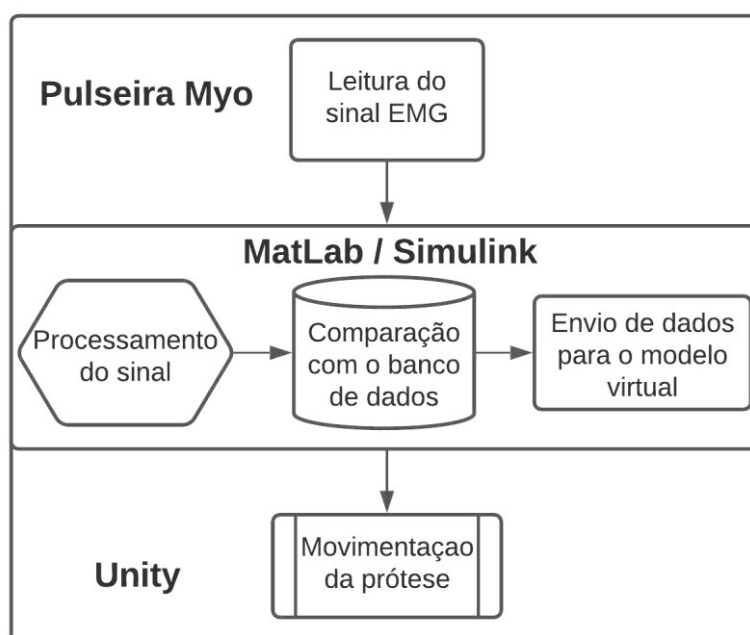
Fonte: Serrezuela, Zamora e Reyes, 2021.

4 METODOLOGIA

Este trabalho consiste em um sistema de processamento do sinal de EMG em tempo real, utilizando o ambiente de programação *MatLab* e a plataforma de simulação *Simulink*, disponibilizados pela *MathWorks*, de forma a reconhecer a intenção de movimento do usuário e a visualização gráfica dos movimentos sendo realizados por um modelo virtual de mão, desenvolvido utilizando a plataforma de modelagem 3D *Blender*, e a plataforma de animação *Unity*.

Assim sendo, foi necessária a construção de sistemas de aquisição de dados utilizando o *Myo Armband* e também de um sistema de ativação de processos de animação em 3D; o fluxograma do sistema implementado é mostrado pela figura 17.

Figura 17- Fluxograma do sistema desenvolvido.



Fonte: Autor.

4.1 MYO ARMBAND

A *Myo Armband* (figura 18) é uma pulseira mioelétrica desenvolvida pela *Thalmic Labs*, composta por oito eletrodos de aço inoxidável, que captam a atividade elétrica de diversos músculos do braço com uma frequência de amostragem de 200 Hz, com filtro passa faixa de 5 a 100Hz e 8 bits de resolução. Ela também possui um giroscópio, acelerômetro (com frequência de amostragem de 50Hz) e *bluetooth* (BLE 4.0) integrados,

o que permite a localização completa dos movimentos do braço e uma conexão para transferência de dados sem o uso de cabos (*bluetooth*), com uma autonomia de 16h (CÔTÉ-ALLARD et al., 2019).

Figura 18- Myo Armband.



Fonte: Visconti et al., 2018.

4.1.1 Aquisição de dados

Primeiro foi definido o padrão de posição do uso da pulseira, o que é necessário pois como existem oito sensores que captam o sinal de EMG cada sensor sempre estará posicionado sobre o mesmo músculo, padronizando o processo de aquisição dos dados e, portanto, na construção da rede neural e nos testes executados não haverá conflito de dados captados pela pulseira. A figura 19 mostra como está posicionada a pulseira no usuário.

Figura 19- Posição padrão do Myo para este trabalho.



Fonte: Autor.

A *Thalmic Labs* também desenvolveu um *software* chamado *Myo Data Capture* que faz a leitura e armazenamento dos dados de EMG registrados pela pulseira. Com o auxílio desse programa os dados são registrados em uma tabela do Microsoft Excel (figura 20), onde o *timestamp* é um parâmetro de tempo da pulseira, representando os dados colhidos para cada instante de tempo; os dados emg1 até emg8 representam os valores de EMG obtidos pelos eletrodos em determinada amostra de tempo.

Figura 20- Extração de dados.

	A	B	C	D	E	F	G	H
1	timestamp, emg1, emg2, emg3, emg4, emg5, emg6, emg7, emg8							
2	1603286862620676,-15,-1,-5,-1,-1,1,0,-2							
3	1603286862620676,8,1,5,2,1,-1,1,2							
4	1603286862621673,-1,-1,-2,-3,-1,-2,-1,0							
5	1603286862621673,-2,-2,-5,-2,-5,-3,0,-1							
6	1603286862635143,8,-1,3,2,3,-1,0,2							
7	1603286862635143,-20,-2,-3,-2,-1,-2,-2,-4							
8	1603286862636140,14,-2,-2,0,-3,-2,-1,4							
9	1603286862636140,-10,-14,-3,0,-4,1,-1,-3							
10	1603286862657896,5,3,-1,0,3,0,1,1							
11	1603286862657896,4,-2,-1,-3,-3,-4,-1,-1							
12	1603286862658898,-2,2,-2,-2,-3,-2,-2,-4							

Fonte: Autor.

O método utilizado até então é válido apenas para a construção do banco de dados dos movimentos estabelecidos para a criação de um padrão de reconhecimento, pois não possível a sua implementação em tempo real; na fase de testes será implantado um método descrito mais à frente.

Após a aquisição dos dados é necessário um processamento e extração de características deste sinal antes de realizar a classificação dos movimentos através da RNA. No final, será feita uma análise e classificação dos sinais de entrada para determinar qual movimento foi executado; a rede neural será responsável por analisar e classificar estes sinais, determinando assim o movimento correspondente.

4.1.2 Extração de Característica

O sinal de EMG, obtido pela pulseira, consiste em oito sinais com valores

visualmente aleatórios, como já foi visto no item 2.3.3. Assim é necessário a extração de uma característica do sinal antes de inseri-lo na Rede Neural. A característica escolhida para este trabalho consiste na envoltória do sinal absoluto, obtida através do RMS (vide item 2.3.5.1), devido à sua simplicidade e pelo fato de representar a média da atividade fisiológica do músculo. Sendo assim, foi criada uma função em *MatLab* para a obtenção do RMS de uma janela de dados, importada para utilização no *Simulink*, que será o ambiente de aquisição e processamento do sinal em tempo real.

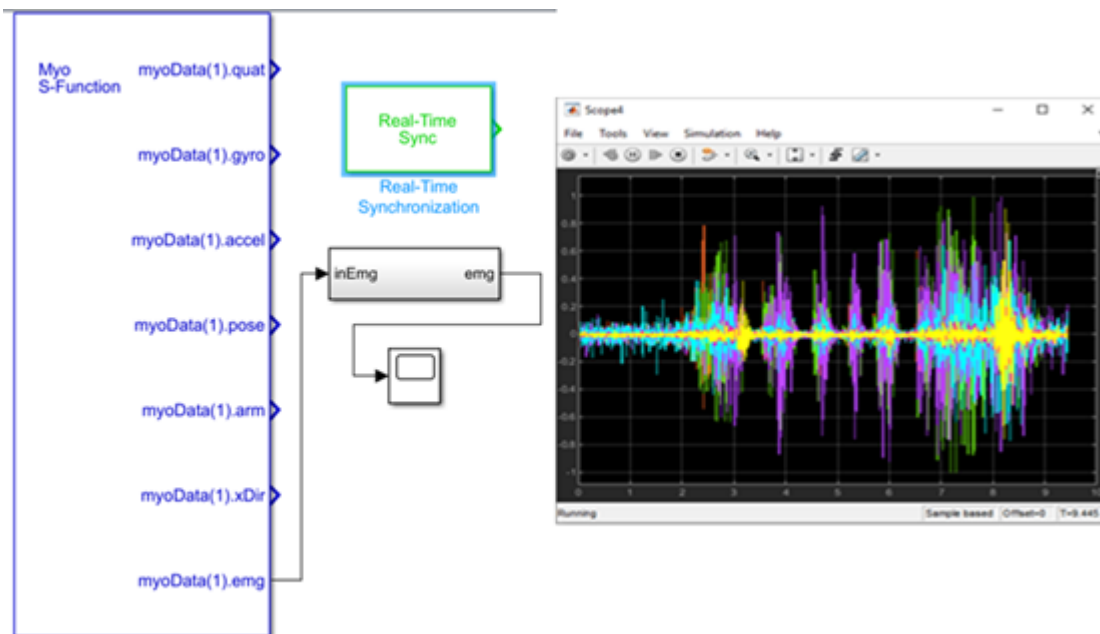
A janela de dados escolhida foi de 250 amostras, pois de acordo com vários testes realizados, este valor é obtida uma envoltória mais limpa, e não se gera um atraso significativo para o sistema, tornando possível para RNA executar a classificação da atividade muscular em um dos movimentos programados sem um atraso muito grande nas transições.

4.1.3 Aquisição de dados em tempo real

No processo de testes e funcionamento do modelo virtual é preciso implementar outro método para efetuar a leitura dos dados EMG. Este método consiste, principalmente, no uso de um kit de desenvolvimento de software chamado *MyoMex* fornecido pela *MathWorks*, assim como um conjunto de ferramentas disponíveis para o *MatLab* e *Simulink* como: *MinGW-w64*, *Simulink Desktop Real-Time*.

Com o auxílio dessas ferramentas é possível montar um diagrama de blocos no *Simulink* para captar o sinal, em tempo real, e assim enviar para a rede neural, os dados vindos do Myo, como mostra o modelo utilizado no *Simulink*, na figura 21.

Figura 21- Modelo de blocos do Simulink para aquisição do EMG.



Fonte: Autor

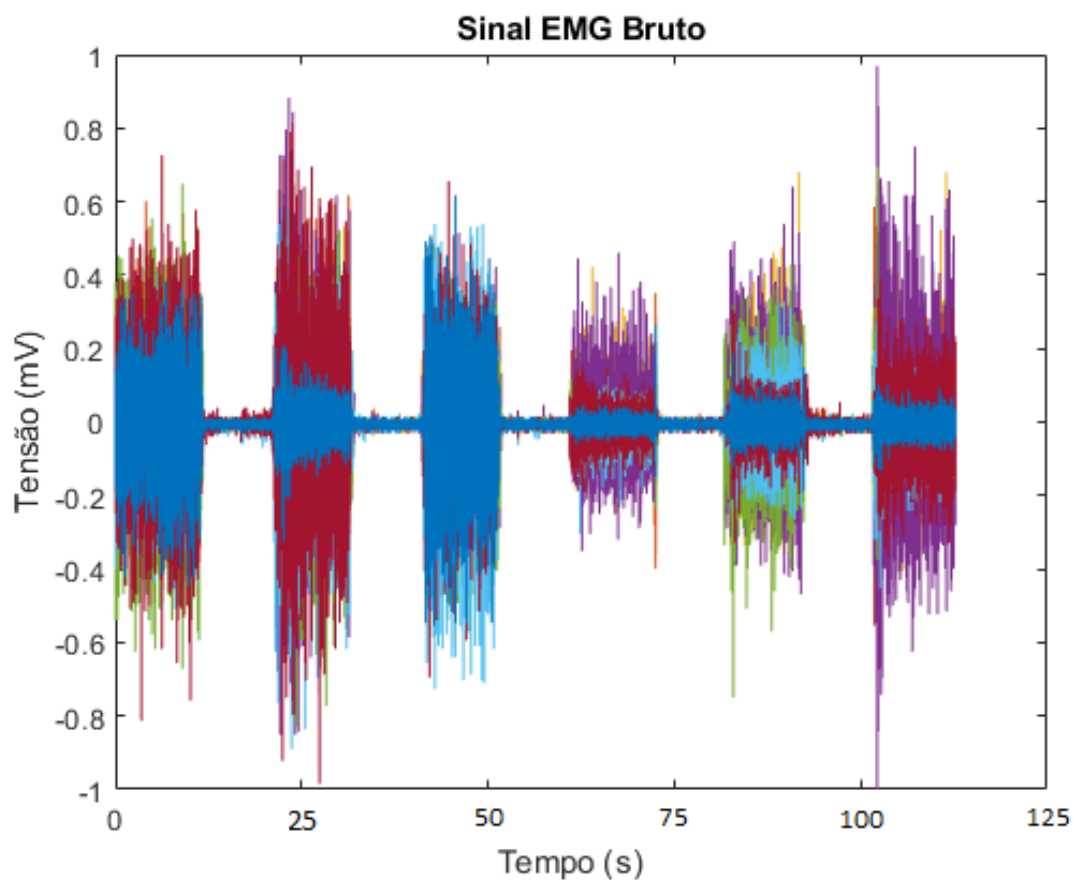
O bloco *Myo S-Function*, disponível na biblioteca do MyoMex, corresponde a um conjunto de funções para a captação do sinal EMG transmitido pela braçadeira Myo. O bloco *inEMG*, também disponível pelo MyoMex, é utilizado para que o sinal bruto sofra um ganho de 1/128, valor especificado pela biblioteca utilizada, sendo normalizado com uma amplitude de -1 a 1. O *Real Time Sync*, disponibilizado no próprio Simulink, é responsável por sincronizar o tempo de simulação com o tempo do relógio do computador. E por fim, o *scope* é utilizado apenas para visualizar o sinal EMG, sendo substituído, posteriormente, pela entrada da rede neural.

4.2 ORGANIZAÇÃO DOS DADOS

Após a coleta dos dados, para cada um dos movimentos programados, é necessária a construção de uma matriz na qual serão englobadas todas as repetições de cada um dos movimentos utilizados, com um período de repouso (braço relaxado) entre cada período de contração. Assim sendo, as linhas desta matriz consistem nos dados dos sensores do Myo, portanto, oito linhas onde cada uma representa um sinal de EMG diferente, e as colunas representam as amostras no tempo destes sinais. A figura 22 apresenta uma repetição de cada movimento em sequência; com cada movimento tendo duração de 10 segundos seguidos de um período, também com 10 segundos de repouso (relaxado). Cada

uma das cores vistas na imagem representa a leitura de um dos sensores do Myo.

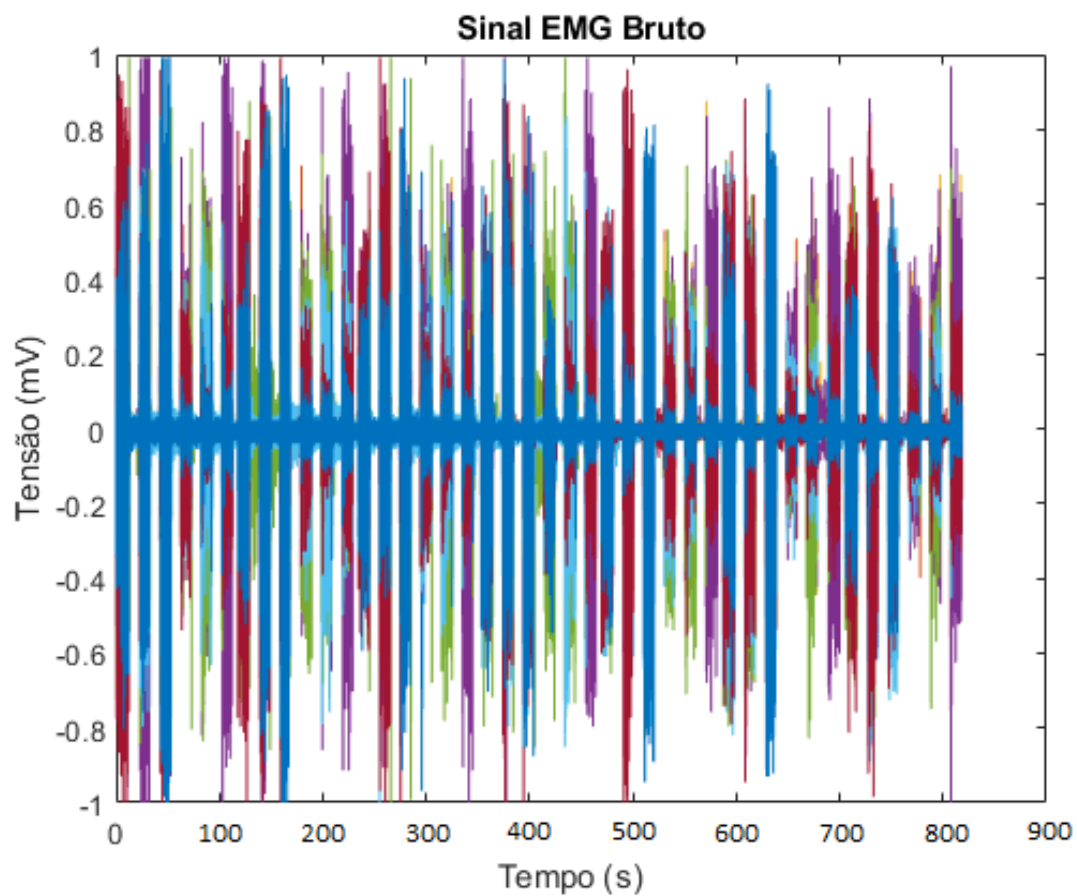
Figura 22- Sinal EMG Bruto com Apenas uma Repetição.



Fonte: Autor.

A figura 23 apresenta o gráfico montado ao plotar todas as repetições de todos os movimentos em uma única matriz apresentando uma sequência de seis movimentos diferentes seguida por mais uma sequência com os mesmos seis movimentos e assim por diante. Os dados foram normalizados, através de definições de ganho, para que o sinal não ultrapasse 1 mV, com o mesmo ganho sendo aplicado igualmente a todos os canais, assim tornando mais fácil a comparação dos resultados com outros trabalhos.


Figura 23- Sinal de EMG bruto com todas as repetições.



Fonte: Autor.

Os movimentos registrados e observados nos sinais são apresentados na figura 24 que consiste nos movimentos de Apontar, Digitar, Joia, Preensão Lateral, Extensão Paralela e Preensão Palmar, nesta ordem.

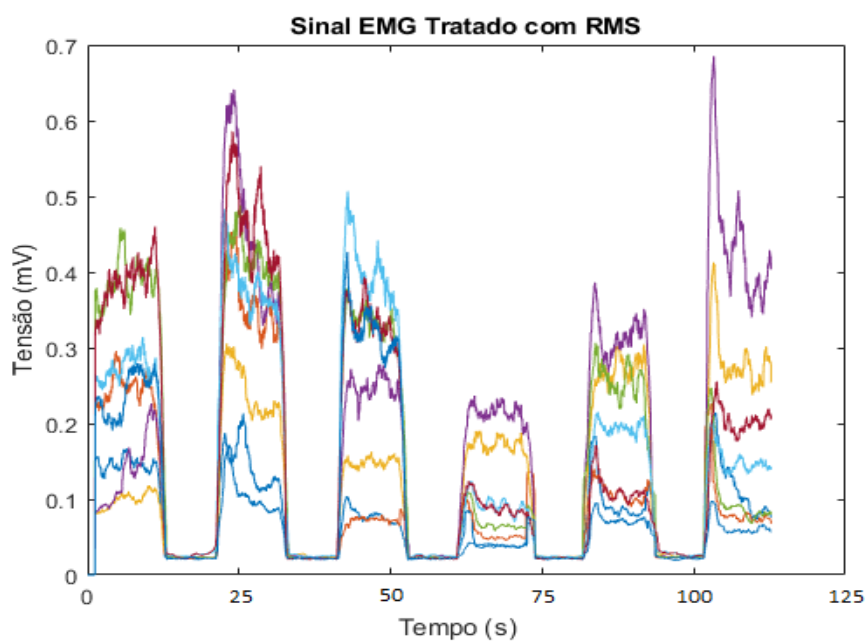
Figura 24- Representação visual dos movimentos programados.



Fonte: Autor.

O tratamento por RMS, evidenciado na figura 25 destaca a envoltória do sinal de EMG em valores absolutos, mostrando o nível médio de atividade de cada músculo monitorado. Através da amplitude de cada um dos sensores ou agrupamento de sensores é possível identificar o movimento realizado pelo indivíduo de teste.

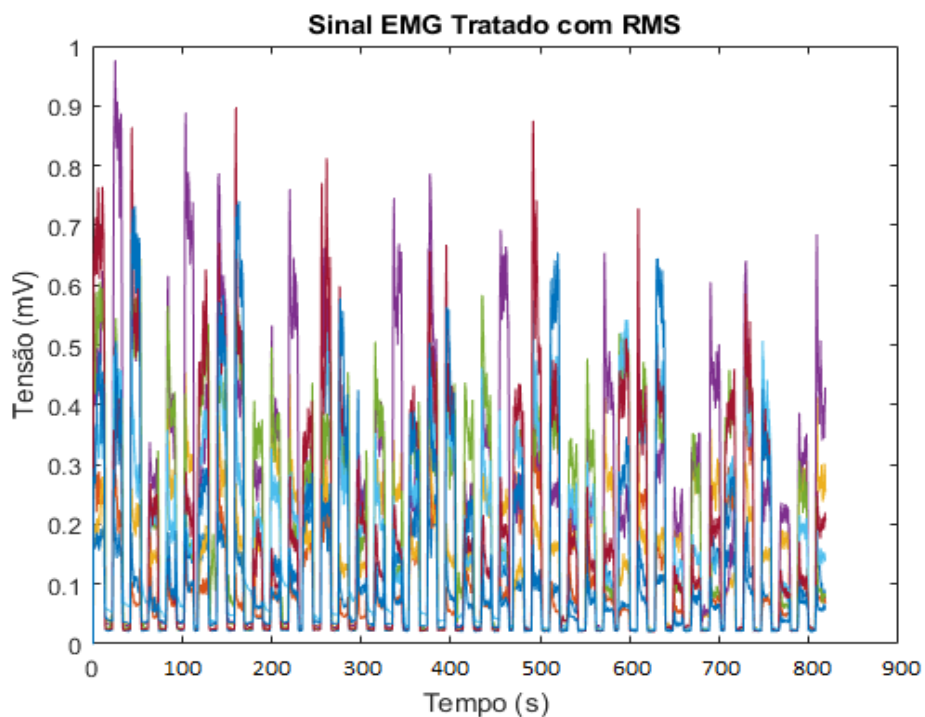
Figura 25- Sinal de EMG tratado com RMS.



Fonte: Autor.

A figura 26 apresenta um gráfico com todas as repetições agrupadas, da mesma forma como foi agrupado na figura 23, após o tratamento do sinal por RMS.

Figura 26- Sinal de EMG tratado, com todas as repetições.




Fonte: Autor.

4.3 RECONHECIMENTO E CLASSIFICAÇÃO DE PADRÕES

O modelo de rede utilizado foi o *Feed-Foward*, e para sua definição é necessário especificar algumas configurações, como o número de neurônios das camadas de entrada, da camada escondida, e da camada de saída, o número máximo de iterações e o algoritmo de treinamento que no caso é supervisionado. A figura 27 apresenta o modelo virtual da rede.

Figura 27- Modelo da RNA criada.



Fonte: Autor

A rede consiste em oito entradas, onde cada entrada representa um dos sensores da pulseira EMG, duas camadas de neurônios escondidos, onde a primeira camada simula uma camada de entrada, realizando assim um pré-processamento do sinal dentro da rede, e seis saídas equivalentes ao número de movimentos. O número de neurônios na primeira camada escondida foi escolhido como oito sendo igual ao número de entradas e o número de neurônios na segunda camada escondida foi escolhido um número alto, mil, a fim de melhorar o agrupamento de valores sem a necessidade de um alto poder de processamento. O algoritmo de treinamento foi escolhido do tipo gradiente decrescente, pois ele diminui o valor de erro a cada iteração e consiste no algoritmo de treinamento padrão na biblioteca de rede neural do *MatLab*. O valor máximo de iterações foi definido como 100.000 para um melhor resultado, entretanto, o próprio algoritmo de treinamento de RNA do *MatLab* define que caso o valor do erro suba em sete iterações consecutivas o treinamento é interrompido e termina, isso indica que o melhor estado da rede foi atingido.

O método de treinamento para redes *Feed-Foward* é supervisionado; portanto, é necessária a construção manual de um vetor objetivo (vetor *target*) de treinamento, que especifica a qual classificação os dados de entrada pertencem, que será utilizado no cálculo do erro das saídas da rede e este será utilizado no cálculo de atualização dos pesos sinápticos de cada um dos elementos processadores da rede. O treinamento consiste na comparação da matriz de dados de saída com este vetor objetivo, e para cada iteração os pesos são atualizados de maneira a minimizar os erros de correspondência.


Foi construído um vetor *target* para cada indivíduo cujos dados foram utilizados; a figura 28 apresenta uma visualização gráfica de um destes vetores, onde cada linha da matriz corresponde a uma saída e conseqüentemente um dos movimentos programados. Os picos representam os movimentos sendo realizados e os vales a ausência do movimento em questão. A figura 29 apresenta o vetor *target* com todas as repetições em seqüência para os dados extraídos de um dos autores.

Para uma análise estatística mais precisa, foi utilizado o método de *Cross-Validation*, que consiste na separação dos dados em dois grupos aleatórios distintos utilizados para treinamento e teste, e repetindo este processo dez vezes (10-folds). O resultado final é a média das acurácias de cada processo.

O algoritmo de *Cross-Validation* utilizado, separa um vetor base em dois vetores aleatoriamente, um para ser utilizado no treinamento da rede, e outro para ser utilizado

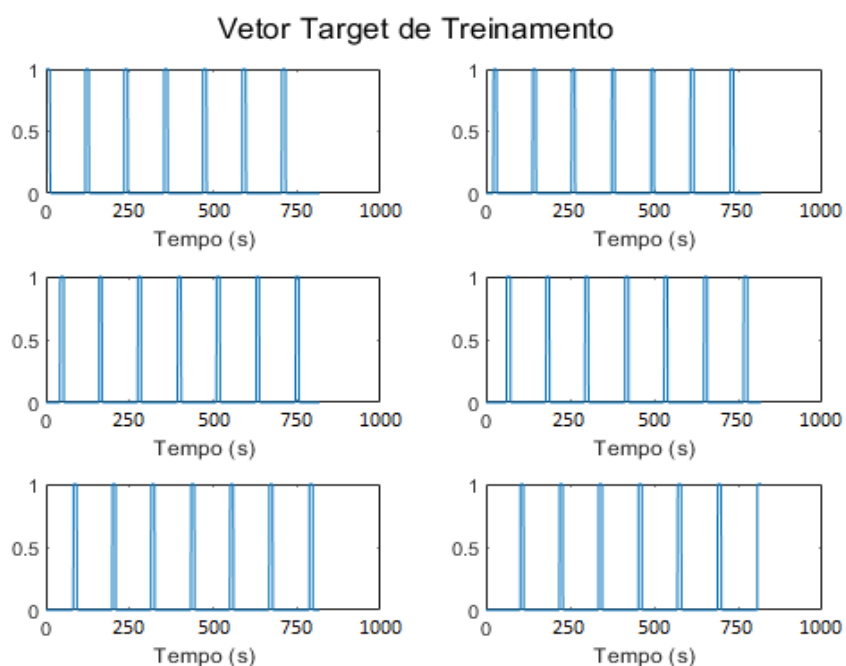
em testes; então é gerada uma RNA totalmente nova, com pesos sinápticos aleatórios, que é treinada e testada, nesta ordem, com os vetores separados, repetindo este processo dez vezes, como mencionado, e em todas as vezes, o vetor base utilizado na separação é exatamente o mesmo.

Figura 28- Vetor target de treinamento.



Fonte: Autor.

Figura 29- Vetor target com todas as repetições em sequência.



Fonte: Autor.

4.4 PROCESSO DE CRIAÇÃO E ANIMAÇÃO


Para criação de protótipo virtual foram usadas duas plataformas de modelagem que são o *Blender* e o *Unity*.

O *Blender* é um pacote de criação 3D gratuito, multiplataforma, de código aberto, que suporta modelagem, animação, simulação, renderização, composição e rastreamento de movimento 3D, até mesmo edição de vídeo e criação de jogos. A ferramenta permite uma modelagem mais próxima da realidade com fidelidade proporcionando um melhor estímulo visual.

O *Unity* é uma plataforma de desenvolvimento totalmente integrada, com funcionalidade pronta para ser usada na criação de conteúdo 3D interativo. A plataforma permite montar a sua arte e os recursos nas cenas e ambientes, adicionar elementos físicos, luz, vídeo, áudio e efeitos especiais pós-processamento, fazer teste, editar e otimizar.

Buscando uma forma otimizada como alternativa, optou-se por um modelo desenvolvido através do *Blender* e disponibilizado gratuitamente pela loja online *CGTrader*, como mostrado na figura 30.

Figura 30- Modelo animado de uma mão.



Fonte: Autor.

Após ter escolhido o modelo a ser trabalhado é preciso definir os parâmetros de movimentos para que ele possa executar as tarefas de um modo que pareça natural. Para isso, o primeiro passo é identificar as articulações dos dedos, baseado nos estudos da anatomia da mão, e aplicar no modelo 3D. A figura 31 mostra o modelo da mão articulada com a influência de cada articulação já atribuída ao modelo para se mover junto aos “ossos”.

Figura 31- Modelo finalizado.




Fonte: Autor.

Em seguida, foi definida uma série de movimentos que o modelo deve replicar conforme comando recebido do sistema de controle de reconhecimento e classificação de padrões de EMG, ou seja, a saída da RNA. Foram escolhidos movimentos com base na utilização em tarefas diárias em função da percepção do cotidiano pelo grupo (figura 24).

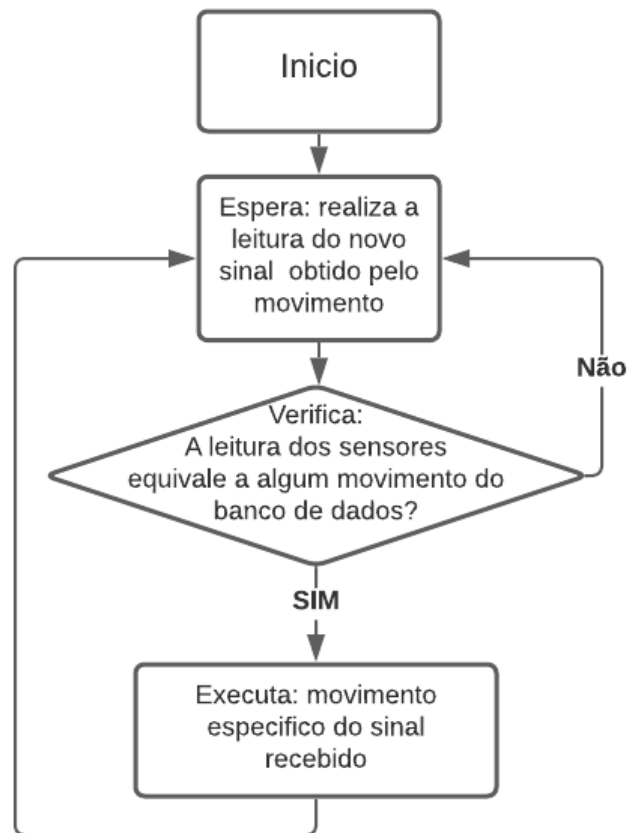
Após a criação das animações, o projeto do *Blender* foi exportado para o *Unity*, onde foi possível, após o processamento do sinal no Simulink, a implementação de um bloco que cria um servidor UDP para envio dos dados de saída da rede. Na plataforma *Unity* foi criado um código em C# que recebe os dados do servidor e realiza a tomada de decisão, definindo qual movimento o modelo virtual deve executar, de acordo com o fluxograma da Figura 33.

Figura 32- Movimentos animados (Apontar; Digitar; Jóia; Preensão lateral; Extensão Paralela; Preensão Palmar).



Fonte: Autor

Figura 33- Fluxograma de movimentação.



Fonte: Autor.

5 RESULTADOS E DISCUSSÃO

5.1 REDE NEURAL


Foram realizados diversos treinamentos diferentes com a Rede Neural gerada a partir dos dados informados no item 4.2. Os treinamentos realizados consistem em duas redes, uma especializada para apenas um único indivíduo, e outra mista, utilizando dados de três indivíduos.

Os dados de treinamento foram montados tanto de forma sequencial, com todas as repetições e movimentos sempre com a mesma sequência (vide item 4.2), no caso dos dados obtidos de um dos autores, quanto de forma aleatória, como para o caso dos dados obtidos pelo banco de dados Ninaweb. Para os testes pós treinamento, os dados foram apresentados a rede de forma sequencial para uma melhor visualização do resultado.

5.1.1 Rede Especializada

As redes geradas com treinamento específico apresentam uma ótima resposta nos testes, como pode ser observado pela figura 34. Os dados utilizados nesta primeira parte da análise são referentes aos dados de EMG extraídos de um dos autores.

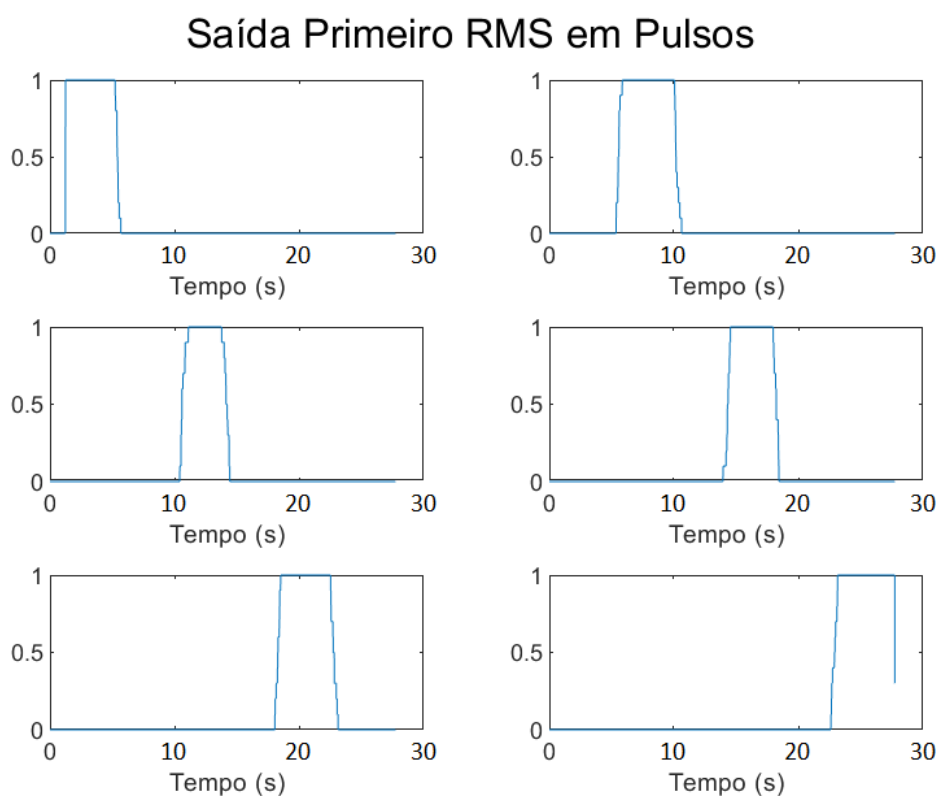
Figura 34- Saída Bruta média da Cross-Validation.



Fonte: Autor.

Cada gráfico da figura 34 representa um dos seis movimentos diferentes, Apontar, Digitar, Joia, Preensão Lateral, Extensão Paralela e Preensão Palmar, nesta ordem, como visto no item 3.2. Como pode ser notado, a rede apresenta uma boa distinção dos movimentos programados, mas com bastante ruído, principalmente para os quatro primeiros movimentos. Esses ruídos representam erros de classificação da rede. Com o intuito de minimizar esse problema, foi implementado um algoritmo de tratamento do sinal de saída com aplicação de RMS para obtenção da envoltória e aplicado um limiar, a partir do qual a saída é fixada em 1, e caso o contrário é fixada em 0, ao mesmo tempo que se exclui possíveis conflitos do sinal, ou seja, a retirada da execução de mais de um movimento ao mesmo tempo (quando mais de um movimento é definido em 1, todos eles são alterados para 0). A figura 35 apresenta a saída com este tratamento.

Figura 35- Saída média da Cross-Validation tratada.



Fonte: Autor.

Como visto na figura 35, o sinal de saída que já conseguia diferenciar bem os movimentos discriminados pela RNA, está com uma visualização melhor e mais limpa, tornando assim a classificação e a implementação das animações mais fidedigna.

Nas figuras 34 e 35, também é possível notar um pequeno atraso no início do primeiro movimento; isto se dá devido ao janelamento de 250 dados para o cálculo do RMS, com um tempo total de atraso de processamento de 1,25 segundos, devido ao janelamento, este atraso tem um impacto direto na utilização do sistema, podendo gerar um desconforto ao usuário deste sistema, é possível diminuir este atraso ao diminuir a janela do RMS, podendo vir a diminuir o desempenho da rede, aumentar a frequência de aquisição do sEMG, entre outras possibilidades, sendo necessário um estudo para determinar o melhor curso de ação para este caso.

O desempenho da Rede também é observado através da Matriz de Confusão. A figura 36 apresenta a Matriz de Confusão exportada pela ferramenta de treinamento de RNA do *MatLab*. A partir da Matriz de Confusão apresentada, é possível observar que a rede tem uma alta taxa de acerto, principalmente para os movimentos 1 e 3, com 98,4% e 96,8% de acurácia, que correspondem aos movimentos de Apontar e Digitar, mas com uma alta taxa de erro para o movimento 4, que é o movimento de prensão lateral, que foi confundido com o movimento de apontar, resultando em uma acurácia média de 97,0%.


Figura 36- Matriz Confusão da Rede especializada.

1	12521 22.6%	14 0.0%	166 0.3%	17 0.0%	6 0.0%	3 0.0%	98.4% 1.6%
2	203 0.4%	8903 16.0%	52 0.1%	221 0.4%	0 0.0%	0 0.0%	94.9% 5.1%
3	215 0.4%	3 0.0%	6629 11.9%	0 0.0%	0 0.0%	0 0.0%	96.8% 3.2%
4	268 0.5%	35 0.1%	121 0.2%	6722 12.1%	1 0.0%	33 0.1%	93.6% 6.4%
5	269 0.5%	0 0.0%	26 0.0%	0 0.0%	8301 15.0%	0 0.0%	96.6% 3.4%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10764 19.4%	100% 0.0%
	92.9% 7.1%	99.4% 0.6%	94.8% 5.2%	96.6% 3.4%	99.9% 0.1%	99.7% 0.3%	97.0% 3.0%
	1	2	3	4	5	6	
	Target Class						

Fonte: Autor.

Também é possível uma análise do módulo do erro de amplitude da Rede através do Histograma de Erro também exportado pela ferramenta de treinamento, como mostrado pela figura 37, estando a maior parte das iterações concentradas em torno do valor de erro de 5,014%. Este erro consiste na diferença do valor na saída da rede, valores entre 0 e 1, e o valor para as mesmas amostras na entrada da rede, do vetor *target* utilizado o treinamento, valores de 0 ou 1, nunca valores intermediários.

Figura 37- Histograma de Erro da rede especializada.

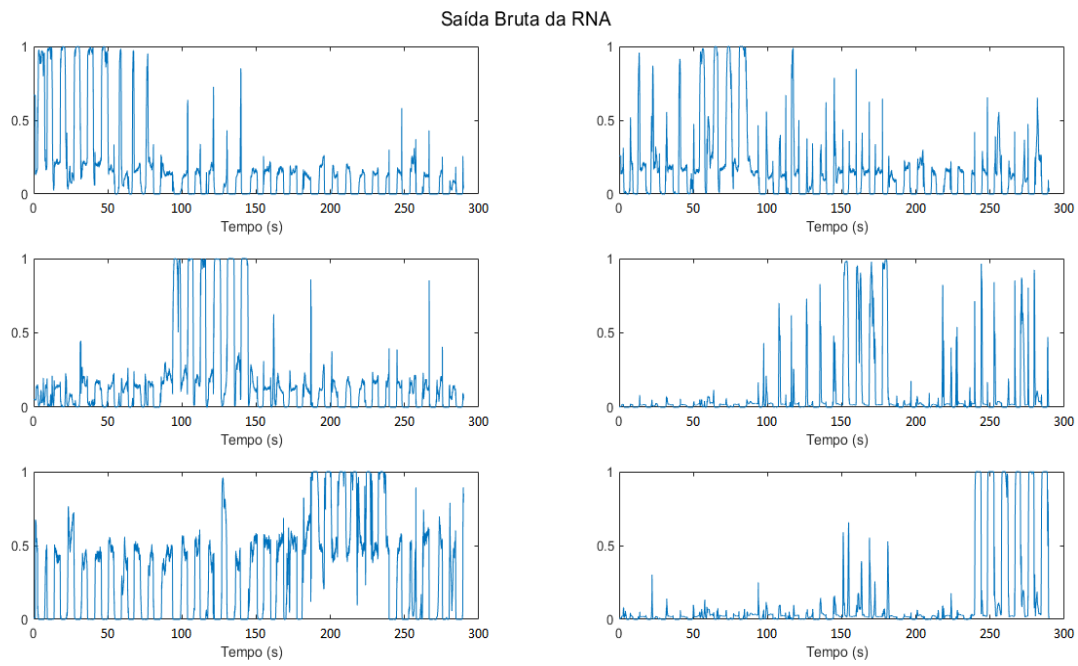


Fonte: Autor.

Para uma melhor avaliação da Rede Especializada para apenas um indivíduo, o treinamento e teste foi repetido, utilizando uma rede nova, ou seja, uma rede com as mesmas configurações, mas cujos pesos sinápticos foram reinicializados para valores aleatórios, para outro indivíduo, considerando os dados adquiridos de um banco de dados gratuito disponibilizado na internet (Ninaweb DB5 - PIZZOLATO et al., 2017). Dos dados disponibilizados, foram utilizados os trechos que representam os movimentos que mais se assemelham aos utilizados neste trabalho. A figura 38 apresenta a saída da rede para os dados do Indivíduo 1, enquanto a figura 39 apresenta a saída da rede após o

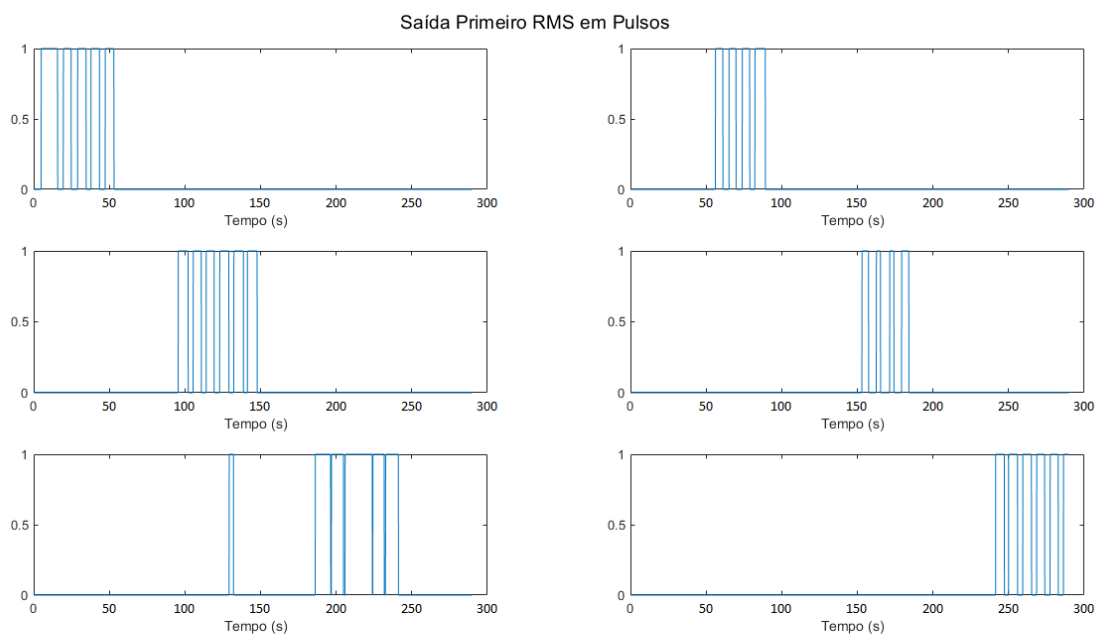
tratamento de RMS, conversão para pulsos de amplitude igual a um e a retirada de movimentos em conflito, em comparação com vetor.

Figura 38- Saída da rede para o Indivíduo 1.

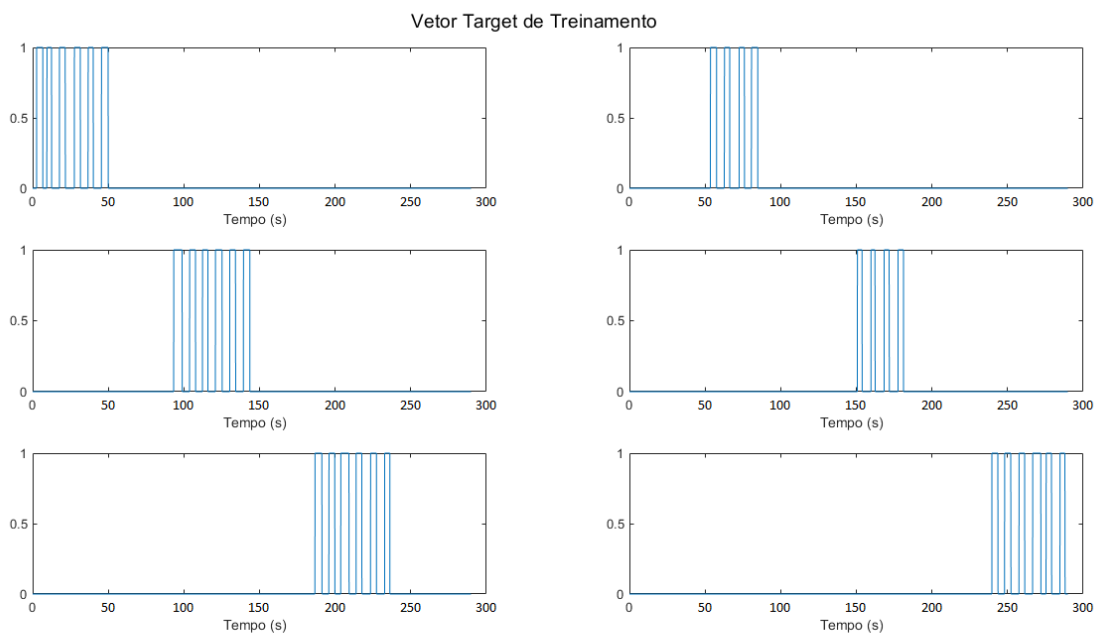


Fonte: Autor.

Figura 39- Saídas da Rede Neural para o Indivíduo I: a) Saída tratada; b) Vetor target.



a) Saída da Rede tratada para o Indivíduo 1




b) Vetor target para teste do Indivíduo 1.

Fonte: Autor.

Na figura 39 é possível observar que, a rede especializada realmente apresenta ótimos resultados, em comparação com o vetor *target*, apresentado pela figura 39, apesar de alguns erros observados no quinto movimento, e devido ao *delay* do sistema, algumas repetições acabaram sendo tratadas como apenas uma repetição pela rede.

Ao observar o histograma de erro apresentado pela figura 40, é possível notar que o valor de erro predominante, igual a 4,57%, é bem próximo do observado para a rede treinada utilizando dados de um dos autores, igual a 5,014%.

Figura 40- Histograma de Erro para o Indivíduo 1.



Fonte: Autor.

Assim como o erro predominante, a taxa de acerto da rede para este indivíduo, sendo ela 94,6%, também se mostra próximo do valor observado anteriormente, como mostrado na figura 41 pela matriz de confusão.

Figura 41- Matriz de Confusão para o Indivíduo 1.

Output Class	1	2	3	4	5	6	Accuracy
1	12123 21.8%	222 0.4%	676 1.2%	399 0.7%	158 0.3%	163 0.3%	88.2% 11.8%
2	306 0.6%	8733 15.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	96.6% 3.4%
3	319 0.6%	0 0.0%	6318 11.4%	0 0.0%	0 0.0%	0 0.0%	95.2% 4.8%
4	372 0.7%	0 0.0%	0 0.0%	6561 11.8%	0 0.0%	0 0.0%	94.6% 5.4%
5	356 0.6%	0 0.0%	0 0.0%	0 0.0%	8150 14.7%	0 0.0%	95.8% 4.2%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10637 19.2%	100% 0.0%
	90.0% 10.0%	97.5% 2.5%	90.3% 9.7%	94.3% 5.7%	98.1% 1.9%	98.5% 1.5%	94.6% 5.4%
Target Class	1	2	3	4	5	6	

Fonte: Autor.

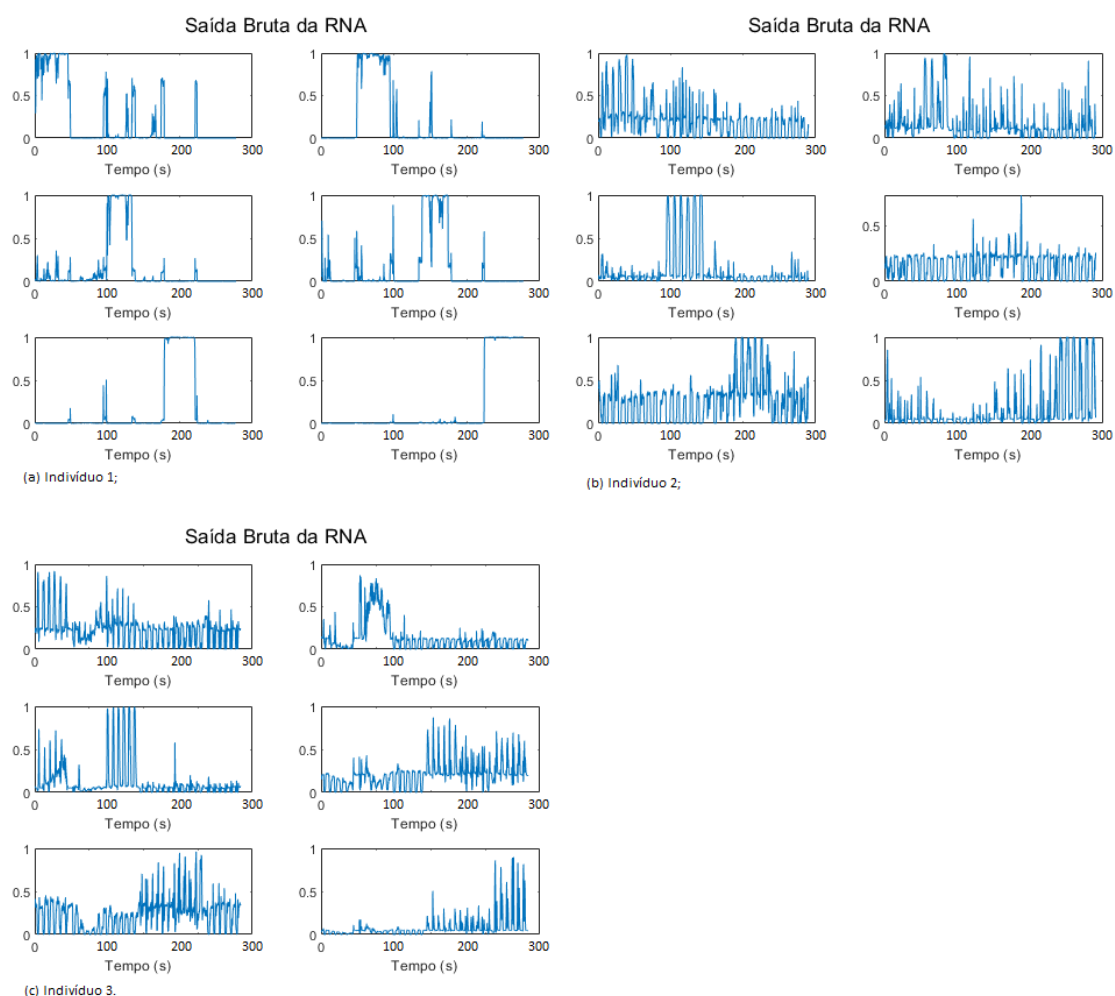
Apesar dos movimentos terem sido diferentes, as acurácias obtidas aqui, de 97% para os dados do autor e 94,6% para os dados do indivíduo 1, são compatíveis ou superiores aos verificados na literatura consultada. Serrezuela, Zamora e Reyes (2021) também utilizaram redes neurais, mas não utilizaram o RMS como características, tendo obtido uma acurácia média de 94,94%. Hassan, Abou-Loukh e Ibraheem (2006) obtiveram os melhores resultados com o RMS como característica, mas utilizaram o SVM como classificador e a melhor acurácia média foi de 96,3% para o sujeito 1, enquanto Zhang et al. (2019) conseguiram a melhor taxa de reconhecimento com uma rede neural, com 98,7%, mas utilizando uma combinação de características e dentre elas o RMS.

5.1.2 Rede Mista

A rede mista apresentou um desempenho mais baixo do que a especializada, tendo em vista que considerou dados de 3 pessoas diferentes, estes dados foram adquiridos

através do quinto banco de dados disponibilizado pela NinaWeb (PIZZOLATO et al., 2017). Foram pegos o Indivíduo 1, assim como no item 4.1.1, e o Indivíduo 5, como também os dados do autor já utilizados anteriormente. Assim sendo, foi necessário o aumento do número de neurônios da camada escondida para o dobro utilizado para a rede especializada. A figura 42 apresenta a saída de teste para esta rede, para cada um dos indivíduos.

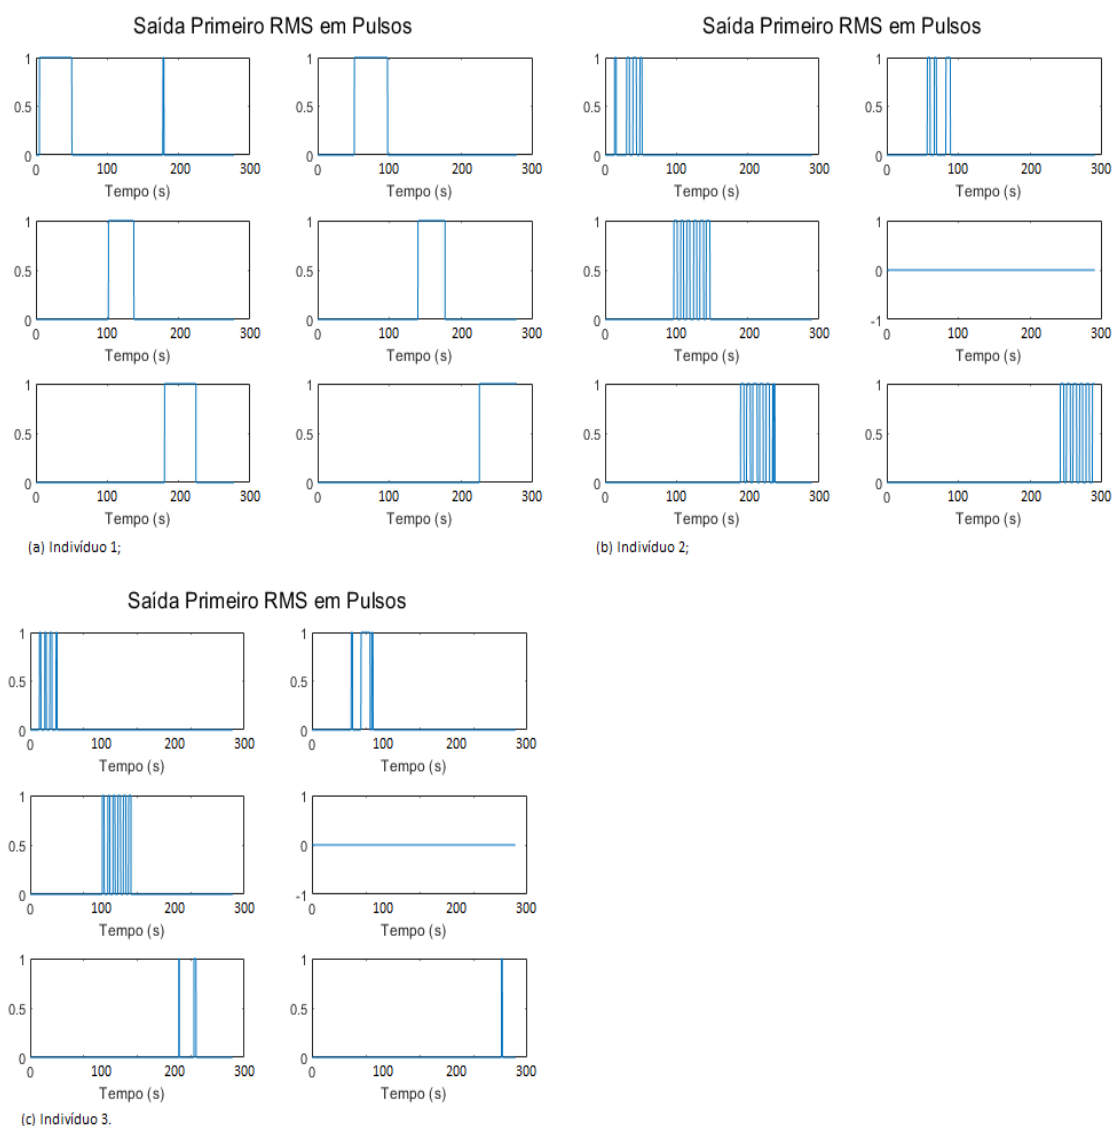
Figura 42- Saída bruta da rede mista.



Fonte: Autor.

Como é possível observar, o desempenho da rede caiu muito em comparação com a rede especializada (vide item 4.1.1), podendo melhorar com a aplicação do tratamento do sinal de saída, como mostrado pela figura 43.

Figura 43- Saída tratada da rede mista.



Fonte: Autor.

É possível observar na figura 43 que, para o Indivíduo 2, o movimento 4 (ordem de cima para baixo, esquerda para a direita) não é reconhecido e partes dos movimentos 1 e 2 também, para o Indivíduo 3 os movimentos 4, 5 e 6 não são reconhecidos, além da perda de partes do sinal do movimento 2. Portanto, ao considerar dados de pessoas diferentes no treinamento da rede, ocorre uma perda na performance da mesma. A taxa de acerto da Matriz confusão, apresentada pela figura 44, também confirma isto, apresentando uma acurácia média entre os dados dos 3 indivíduos de 54%.

Figura 44- Matriz de Confusão da rede mista.


Confusion Matrix

Output Class	1	29568 15.6%	1130 0.6%	2269 1.2%	1877 1.0%	146 0.1%	746 0.4%	82.7% 17.3%
	2	9097 4.8%	15572 8.2%	338 0.2%	529 0.3%	42 0.0%	213 0.1%	60.4% 39.6%
	3	3789 2.0%	92 0.0%	14257 7.5%	130 0.1%	71 0.0%	2 0.0%	77.7% 22.3%
	4	3731 2.0%	694 0.4%	272 0.1%	9169 4.9%	1666 0.9%	2005 1.1%	52.3% 47.7%
	5	51939 27.5%	48 0.0%	170 0.1%	2120 1.1%	16021 8.5%	895 0.5%	22.5% 77.5%
	6	1759 0.9%	0 0.0%	0 0.0%	742 0.4%	589 0.3%	17357 9.2%	84.9% 15.1%
			29.6% 70.4%	88.8% 11.2%	82.4% 17.6%	62.9% 37.1%	86.4% 13.6%	81.8% 18.2%
		1	2	3	4	5	6	
		Target Class						

Fonte: Autor.

Através do Histograma de Erro, apresentado pela figura 45, pode-se ver que o valor de erro, com a maior quantidade de iterações é de 5%. Apesar de não ser muito diferente do anterior, percebe-se que neste histograma existem mais iterações com erros do que o histograma anterior, e considerando a baixa taxa de acerto desta rede, é possível afirmar que a rede mista possui um desempenho pior.

Figura 45- Histograma de Erro da rede mista.



Fonte: Autor.

Ao aumentar o número de neurônios da camada escondida e/ou também aumentar o número de camadas escondidas, é possível que a performance de uma rede mista aumente, mas isto diminuiria a viabilidade tanto da simulação, quanto da implementação da rede em uma prótese real, sendo necessário um poder de processamento e memória muito maior do que o necessário para uma rede especializada, mas também é possível que esta alteração piore o desempenho da rede, sendo necessário um estudo mais profundo para a melhoria do desempenho para este caso.

Para o caso desta rede mista obtivemos uma acurácia de 53,9%, o que de acordo com a literatura apresentada, é um valor extremamente baixo, onde os valores variam de 94% até a 99%, como por exemplo 94,94% para o caso de Serrezuela, Zamora e Reyes (2021), que utilizaram classificação através de rede neural com outro algoritmo de filtro para o sEMG, e 98,7%, para o caso do Zhang et al. (2019) que também utilizaram RNA, mas utilizaram uma combinação de características.

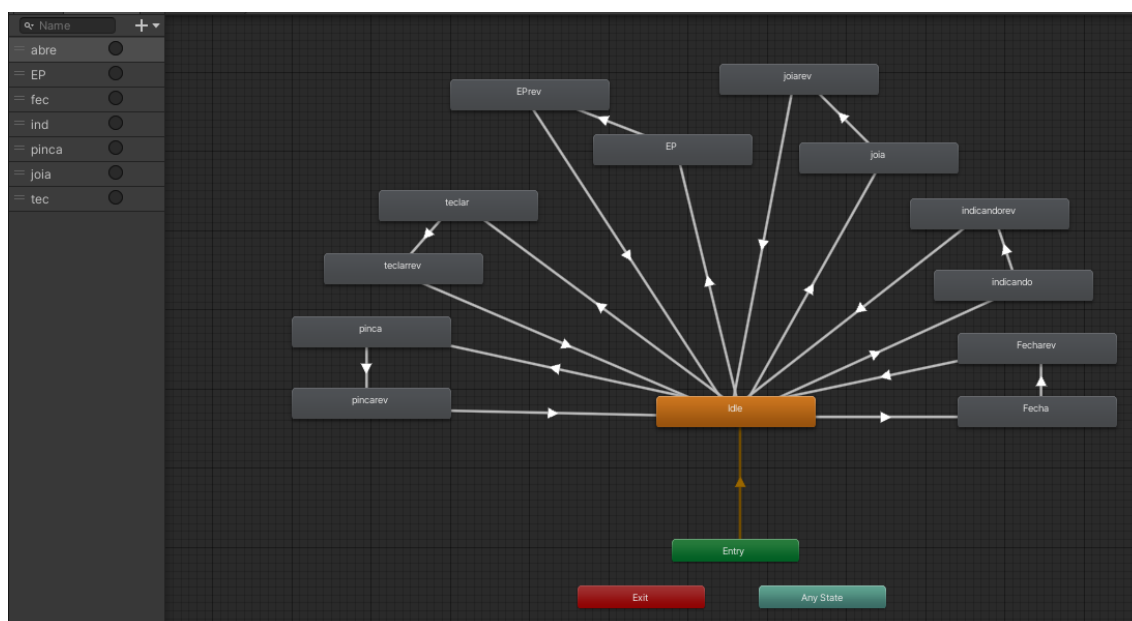
Como já foi mencionado, o valor de acurácia de 53,9% foi obtido com o aumento do número de neurônios da camada escondida de mil para dois mil, tendo um valor de

acurácia ainda menor ao utilizar apenas mil neurônios, assim é possível que ao aumentar a quantidade de neurônios e/ou camadas escondidas, seja possível chegar a um desempenho aceitável da rede mista, mas para isto será necessário um estudo mais a fundo desta variação de indivíduos de teste pois, esta alteração no número de neurônios ou camadas escondidas pode acabar piorando a acurácia ou tornar o sistema inviável para uma aplicação por necessitar um alto poder de processamento.

5.2 – MODELO VIRTUAL

Após ser exportado para o *Unity* foi criado um sistema de controle das animações que resultam da ativação de gatilhos. Sendo assim, ao acionar o gatilho de determinado movimento, o mesmo é realizado, permanecendo na posição até o acionamento de abertura da prótese. A figura 46 mostra o esquemático do controle de acionamentos.

Figura 46- Esquemático das movimentações.



Fonte: Autor.

O sistema fornece um controle perfeito sobre as movimentações da prótese e fácil compreensão sobre seu funcionamento, a animação só é ativada se o sistema estiver em posição inicial (mão aberta) e não migra de um movimento para outro, conseguindo retornar apenas ao inicial. Com o sistema de controle criado, foi feita a comunicação UDP entre o *Simulink* e o *Unity* para recepção do movimento identificado pela rede de

Os blocos *Interpreted Matlab Fcn* são função desenvolvidas para ajudar na classificação da rede neural, essas funções estão na seguinte ordem:

1. *RMSSimulink*, aplicação do filtro de RMS no sinal EMG
2. *RMSSimulinkOut*, janelamento do sinal após sair da rede neural.
3. *ConflitosSimulink*, ajuste do sinal para classificação de saída.
4. *Conversor*, transforma a matriz de saída com 6 valores para um único valor com representação em bits.

As funções aplicadas estão acessíveis nos Apêndices H, I e J, respectivamente.

O bloco NNET corresponde a rede neural especializada treinada para os dados do autor, o bloco (\rightarrow *string*) converte o valor no formato *double* saído do bloco 4 para o formato *string*, o bloco (*string* \rightarrow ASCII) transforma o valor de *string* para o formato padronizado em ASCII e bloco (*UDP Send*) transmite os valores que chegam nele através de um servidor UDP, configurado pelo mesmo bloco, para o modelo implementado no *Unity*. Por último foi colocado um *scope* para verificar o comportamento do sinal, e o display é um método fácil de visualizar qual movimento foi classificado conforme o indivíduo executa alguns gestos. A tabela 4 mostra qual movimento a rede detecta de acordo com o display.

Tabela 4 - Representação dos Displays.

Displays (de cima para baixo)	Movimento detectado
1	Apontar
2	Digitar
3	Joia
4	Preensão Lateral
5	Extensão paralela
6	Preensão palmar

Fonte: Autor.

Caso algum display mostre o valor igual a 1, quer dizer que a rede identificou um movimento correspondente, caso todos fiquem em 0 significa que o braço está relaxado ou nenhum movimento foi detectado, não sendo possível identificar dois movimentos simultaneamente.

Durante os testes do sistema online notamos que houve uma diminuição na taxa de acerto calculado pela rede neural. No modo off-line a acurácia é de 97%, mas em tempo real nota-se que a saída fica oscilando entre os movimentos no menor deslocamento do braço; alterações no posicionamento do Myo também contribui para uma interpretação errônea da parte da rede, sendo necessário o exato encaixe da pulseira no braço do usuário. Para diminuir esses erros foi colocado um temporizador entre a comunicação do Simulink com o Unity, para que a prótese virtual só execute um movimento se receber um sinal contínuo por três segundos. Com o Myo posicionado corretamente e os ajustes efetuados, em média o modelo virtual acertou entre 7 e 8 a cada 10 movimentos feitos pelo usuário.

Com a implementação do temporizador mais o tempo de processamento tem-se um atraso de aproximadamente quatro segundos entre o movimento real e o virtual, o que também foi verificado no modelo de Rossi et al. (2017), onde o atraso é devido às restrições mecânicas da prótese real, portanto, considera-se que isto não é prejudicial no presente momento, podendo ser otimizado futuramente.

6 CONCLUSÃO

O enorme esforço mental empregado pelos usuários de próteses mioelétricas durante a fase de treinamento é um dos fatores que fazem com que muitos pacientes desistam do processo de reabilitação. O ambiente de treinamento virtual utilizado para simular e controlar a prótese através de sEMG pode ser uma contribuição significativa como tecnologia auxiliar na reabilitação após a amputação. Um dos muitos benefícios proporcionados por esses ambientes é que eles podem fornecer aos pacientes um ambiente de treinamento adaptável e versátil, ao mesmo tempo que evitam os riscos inerentes ao ambiente real. O objetivo deste trabalho de projetar um sistema de treinamento em realidade virtual para usuários de próteses mioelétricas foi alcançado. Neste caso, o sistema deve ter bom desempenho de classificação do sinal sEMG (em tempo real) e comunicação rápida entre o classificador de sinal e o ambiente virtual.

Para tanto, utilizou-se tecnologias de processamento digital de sinais e redes neurais artificiais, além de ferramentas para a construção de ambientes virtuais. As técnicas usadas para extração de recursos e classificação de sinal permitiram que o classificador alcançasse 97% de desempenho de classificação em um sistema de 6 movimentos, especializado para apenas um indivíduo, e 53% para a classificação mista com dados de três indivíduos, que pode ser melhorado, ou não, possuindo uma base de dados maior para treinamento o qual também exigiria um poder de processamento maior que o utilizado. Este desempenho de classificação, relacionado ao movimento da mão, está na mesma faixa que os valores obtidos em trabalhos encontrados na literatura para classificação dos movimentos. Também existem métodos para melhorar ainda mais os valores de acurácia obtidos, principalmente para o caso da rede mista, podendo ser feita uma análise da utilização de uma RNA com outras características do sEMG, assim como uma análise da influência do número de neurônios e/ou camadas escondidas na acurácia do sistema, levando em conta que, para determinadas aplicações, o sistema não pode depender de um processamento extremamente alto.

Este sistema também apresentou uma queda da acurácia para os teste realizados em tempo real, o que se deve a alta sensibilidade do classificador utilizado, onde qualquer mudança no posicionamento relativo do músculo com o eletrodo pode causar uma classificação errada do movimento sendo feito, sendo necessário a confirmação em várias etapas do movimento classificado pelo modelo virtual, causando assim um maior atraso da resposta do sistema do que o observado devido ao janelamento do RMS. A avaliação

quantitativa do impacto desse atraso de resposta fornece uma sugestão interessante para trabalhos futuros, possibilitando estudos que visem a diminuição deste tempo de atraso, seja por aumentar a frequência de aquisição do sinal de EMG, pela diminuição da sensibilidade da rede neural, ou outras possibilidades.

O ambiente de treinamento virtual também é uma ferramenta auxiliar no monitoramento e avaliação dos potenciais usuários dessas próteses. A possibilidade de integrar o protótipo proposto neste trabalho ao banco de dados para gerar automaticamente um relatório com os resultados do treinamento é um dos principais fatores que enfatizam sua aplicabilidade e utilização pelos profissionais de saúde.

REFERÊNCIAS

- ALMEIDA, C. A. P. Investigação de Parâmetros Espectrais do EMG Aplicáveis à Terapia por *Biofeedback*. 2010. 84p. Dissertação (Mestrado de Engenharia Biomédica). Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2010.
- BATTEAU, L. et al. A study on the perception of haptics in surgical simulation. In: Cotin S., Metaxas D. (eds) *Medical Simulation*. 2004. *Lecture Notes in Computer Science*, v. 3078. Springer, Berlin, Heidelberg. p. 185–192, https://doi.org/10.1007/978-3-540-25968-8_21
- BIAGIOTTI, L. et al. How Far Is the Human Hand? A Review on Anthropomorphic Robotic End-effectors. 2003. Disponível em: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.104.7899&rep=rep1&type=pdf>
- BRINKMAN, W.; SANDINO, G. e MAST, C. V. D. Field observations of therapists conducting virtual reality exposure treatment for the fear of flying. In: EUROPEAN CONFERENCE ON COGNITIVE ERGONOMICS: DESIGNING BEYOND THE PRODUCT—UNDERSTANDING ACTIVITY AND USER EXPERIENCE IN UBIQUITOUS ENVIRONMENTS. Helsinki Finland, VTT Technical Research Centre of Finland, 2009, p. 1 - 9.
- BRUCE, M. e REGENBRECHT, H. A virtual reality claustrophobia therapy system. IEEE VIRTUAL REALITY CONFERENCE, Lafayette, LA, USA, IEEE, 2009. p. 179-182, doi: 10.1109/VR.2009.4811020.
- BURDEA, G. Virtual rehabilitation--benefits and challenges. *Methods Inf Med*. v. 42, n. 5, p. 519-23, 2003.
- CAMARGO, L.; STOPPA, M. Controle sem Fio por Dispositivos Móveis de Prótese Biônica de Mão, p. 15 -28. In: *Estudos Interdisciplinares em Ciências Exatas e da Terra*. São Paulo: Blucher, 2016.
- CARDOSO, A. e LAMOUNIER, E. A Realidade Virtual na Educação e Treinamento. In: TORI, R.; KIRNER, C. e SISCOOTTO, S. (Eds) *Fundamentos e Tecnologia de Realidade Virtual e Aumentada*. Porto Alegre: Editora SBC, 2006.
- CARNAP, R. *The Logical Syntax of Language*. New York: Harcourt, Brace and Company. 1938.
- COSTA, R. M. e RIBEIRO, M. W. (Ed.). *Aplicações de Realidade Virtual e Aumentada*. Livro do pré-simpósio do XI Simpósio de Realidade Virtual e Aumentada. Porto Alegre. SBC, 2009.
- CRAELIUS, W.; ABOUDI, R. L.; NEWBY, N. A. Control of a multi-finger prosthetic hand. ICOOR'99 INTERNATIONAL CONFERENCE ON REHABILITATION ROBOTICS. Stanford, California, U.S.A. 1999. p. 255–260.

JOHNSON, N. et al. Membro Superior. In: BONTRAGER, K. L. E LAMPIGNANO, J. P. (Eds.). Tratado de Posicionamento Radiográfico e Anatomia Associada. 8ª ed. Mosby Elsevier. 2015.

ECARD, V. C. Investigação das Propriedades de Sinais Eletromiográficos de Superfície Utilizando Baricentros Estimados Através do Espectro de Potência. 2017. 55p. Trabalho de conclusão de curso (Engenharia Elétrica) – Universidade Federal de Juiz de Fora, Juiz de Fora, 2017.

FÉLIX, A. C. C.; VASCONCELLOS, H. A. S. Interpretação de Sinais EMG para Joelho de Prótese Robótica. 2008. 70p. Trabalho de conclusão de curso (Engenharia de Controle e Automação) - Universidade de Brasília, Brasília, 2008.

GODOI, T. S. M. Prótese Mioelétrica Controlada por Redes Neurais. 2013. 157p. Trabalho de conclusão de curso (Engenharia de Computação) – UniCEUB, Brasília, 2013.

HASSAN, H. F.; ABOU-LOUKH, S. J.; IBRAHEEM, I. K. Teleoperated Robotic Arm Movement Using EMG Signal with Wearable MYO Armband 2006. 41p. Trabalho de conclusão de curso (Engenharia Elétrica) - University of Baghdad, 2006

HAYKIN, S. Redes Neurais. [S.l.]: Bookman, 1ª ed., Canadá, 2001. 56p.

HERLE, S. et al. Classification of surface electromyographic signals for control of upper limb virtual prosthesis using time-domain features. In: IEEE INTERNATIONAL CONFERENCE ON AUTOMATION, QUALITY AND TESTING, ROBOTICS. Cluj-Napoca, Romania, IEEE. 2008, p. 160-165, doi: 10.1109/AQTR.2008.4588902.

HESSE, F.; HERRMANN, J. Homeokinetic proportional control of myoelectric prostheses. IEEE/RSJ INTERNATIONAL CONFERENCE ON INTELLIGENT ROBOTS AND SYSTEMS, Taipei, Taiwan, IEEE, 2010. p. 1786–1791. doi: 10.1109/IROS.2010.5651623.

JACK, D. et al. Virtual reality-enhanced stroke rehabilitation. IEEE Transactions on Neural Systems and Rehabilitation Engineering, v. 9, n. 3, p. 308–318, 2001.

JIANG, N.; ENGLEHART, K.; PARKER, P. Extracting simultaneous and proportional neural control information for multiple-dof prostheses from the surface electromyographic signal. IEEE Transactions on Biomedical Engineering, v. 56, n. 4, p. 1070–1080, 2009.

KONRAD, P. The ABC of EMG: A Practical Introduction to Kinesiological Electromyography. v. 1.4. Estados Unidos da América: Noraxon Inc, 2006. 61p.

LAMOUNIER, E. et al. On the use of virtual and augmented reality for upper limb prostheses training and simulation. ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC), Buenos Aires, Argentina, IEEE, 2010. p. 2451–2454. doi: 10.1109/IEMBS.2010.5626370.

LI, G.; SCHULTZ, A.; KUIKEN, T. Quantifying Pattern Recognition—Based Myoelectric Control of Multifunctional Transradial Prostheses. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 18, n. 2, p. 185–192, 2010. ISSN 1534-4320.

LIGHT, C.; CHAPPELL, P. Development of a lightweight and adaptable multiple-axis hand prosthesis. *Medical Engineering & Physics*, v. 22, n. 10, p. 679-684, 2000. doi: 10.1016/S1350-4533(01)00017-0

LIMA, A.; CUNHA, G. e LANDAU, L. Utilização de recursos de realidade virtual na simulação off shore. *Revista Realidade Virtual, UFRJ*, v. 3, n. 2, p. 1–16, 2010.

MASSA, B. et al. Design and development of an underactuated prosthetic hand. *IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION*, Washington, DC, USA, v. 4, p. 3374–3379, 2002. doi: 10.1109/ROBOT.2002.1014232.

MATTIOLI, F. et al. Classification of emg signals using artificial neural networks for virtual hand prosthesis control. *IEEE. 33RD ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC '11)*. Boston, IEEE. 2011.

MILOCA, S.A.; CHAVES NETO, A.; VOLPI, N. M. P.; CONEJO, P. D. Relação entre variáveis meteorológicas e a qualidade industrial do trigo. *Ciência Rural*, v.37, n.1, p. 31-37, 2007

NIELSEN, J. et al. Simultaneous and proportional force estimation for multifunction myoelectric prostheses using mirrored bilateral training. *IEEE Transactions on Biomedical Engineering*, v. 51, n. 3, p. 681–688, 2011.

NOGUEIRA, K. L. O Uso de Técnicas de Realidade Virtual e Aumentada na Simulação de Prótese de Membros Superiores. *Dissertação (Mestrado) — Universidade Federal de Uberlândia, Uberlândia*, 2007.

NUNES, F. et al. Aplicações Médicas usando Realidade Virtual e Realidade Aumentada. In: *Realidade Virtual: Conceito, Projeto e Aplicações*. Cap. 10. Editora SBC, p. 222-255, 2007.

OKUNO, R.; YOSHIDA, M.; AKAZAWA, K. Compliant grasp in a myoelectric hand prosthesis. *IEEE Engineering in Medicine and Biology Magazine*, IEEE, v. 24, n. 4, p. 48–56, 2005.

PIZZOLATO, S. et al. Comparison of six electromyography acquisition setups on hand movement classification tasks. *PLoS ONE* 12(10): e0186132. 2017. doi: 10.1371/journal.pone.0186132

PONS, J. et al. Virtual reality training and EMG control of the MANUS hand prosthesis. *Robotica*, v. 23, n. 03, p. 311–317, 2005. doi:10.1017/S026357470400133X

QIU, H. e CHEN, L. Real-time virtual military simulation system. *IEEE. 1ST INTERNATIONAL CONFERENCE ON INFORMATION SCIENCE AND*

ENGINEERING (ICISE), Nanjing, China, IEEE, 2009. p. 1391–1394. doi: 10.1109/ICISE.2009.870.

RAHEEMA, M. N.; HUSSAIN, J.; AL-KHAZZAR, A. M. Design of an Intelligent Controller for Myoelectric Prostheses based on Multilayer Perceptron Neural Network. IOP CONFERENCE SERIES: MATERIALS SCIENCE AND ENGINEERING. IOP Publishing. v. 671, n. 1, p. 012064, 2020. doi 10.1088/1757-899x/671/1/012064

ROBINSON, N. A Rare German Prosthetic Hand, circa 1580. MyArmoury, 2006. Disponível em: <http://myarmoury.com/talk/viewtopic.php?t=7161>. Acessado em: out/2020.

ROSSI et al. Preliminary Results Toward a Naturally Controlled Multi-Synergistic Prosthetic Hand. INTERNATIONAL CONFERENCE ON REHABILITATION ROBOTICS (ICORR), London, UK, IEEE, 2017, p. 1356 - 1363.

SEBELIUS, F. et al. Real-time control of a virtual hand. Technology and Disability, IOS Press, v. 17, n. 3, p. 131–141, 2005.

SERREZUELA, R. R.; ZAMORA, R. S.; REYES, E. M. Control Strategy for Underactuated Multi-Fingered Robot Hand Movement Using Electromyography Signal with Wearable Myo Armband In: Villarreal-Gómez, L. e Iglesias, A. L. Biosensors - Current and Novel Strategies for Biosensing. IntechOpen. 2021. Disponível em: <http://dx.doi.org/10.5772/intechopen.93767>.

SORDI, J. D. e VALDAMBRINI, A. Aplicabilidade da realidade virtual no desenvolvimento de protótipos: análise de sua utilização na volkswagen do brasil. In: ABEPRO. Anais do Encontro Nacional de Engenharia de Produção - ENEGEP 2006. [S.l.], 2006.

TORI, R. e KIRNER, C. Fundamentos de Realidade Virtual. In: TORI, R.; KIRNER, C. e SISCOOTTO, S. (Eds) Fundamentos e Tecnologia de Realidade Virtual e Aumentada. Porto Alegre: Editora SBC, 2006.

VISCONTI, P.; GAETANI, F.; ZAPPATONRE, G.; PRIMICERI, P. Technical features and functionalities of myo armband: An overview on related literature and advanced applications of myoelectric armbands mainly focused on arm prostheses, International Journal on Smart Sensing and Intelligent Systems, v. 11, n. 1, p. 1-25, 2018.

WEISS, P. et al. Video capture virtual reality as a flexible and effective rehabilitation tool. Journal of Neuroengineering and Rehabilitation, BioMed Central Ltd, v. 1, n. 1, p. 12, 2004. doi: 10.1186/1743-0003-1-12

YOH, M. The reality of virtual reality. IEEE SEVENTH INTERNATIONAL CONFERENCE ON VIRTUAL SYSTEMS AND MULTIMEDIA, Berkeley, CA, USA, IEEE, 2001. p. 666–674.

ZHANG, K. Y. et al. Real-time Pattern Recognition for Hand Gesture Based on ANN and Surface EMG, IEEE 8th Joint International Information Technology and Artificial

Intelligence Conference (ITAIC). Chongqing, China, IEEE. 2019, p. 799-802. doi: 10.1109/ITAIC.2019.8785894.

ZUO, K. J. e OLSON, J. L. The evolution of functional hand replacement: From iron prostheses to hand transplantation. *Plast Surg*, v. 22, n. 1, p. 44-51, 2014.