



UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO
CAMPUS CARAÚBAS
CURSO DE ENGENHARIA ELÉTRICA

ALEFJOHN FEITOSA AMORIM

**DESENVOLVIMENTO DE UMA PRÓTESE MIOELÉTRICA UTILIZANDO
CONTROLE INTELIGENTE**

CARAÚBAS – RN

2018

ALEFJOHN FEITOSA AMORIM

**DESENVOLVIMENTO DE UMA PRÓTESE MIOELÉTRICA UTILIZANDO
CONTROLE INTELIGENTE**

Monografia apresentada à Universidade Federal Rural do Semi-Árido (UFERSA), como exigência final para obtenção do título de Bacharel em Engenharia Elétrica.

Orientador: Francisco de Assis Brito Filho – UFERSA.

CARAÚBAS – RN

2018

© Todos os direitos estão reservados a Universidade Federal Rural do Semi-Árido. O conteúdo desta obra é de inteira responsabilidade do (a) autor (a), sendo o mesmo, passível de sanções administrativas ou penais, caso sejam infringidas as leis que regulamentam a Propriedade Intelectual, respectivamente, Patentes: Lei nº 9.279/1996 e Direitos Autorais: Lei nº 9.610/1998. O conteúdo desta obra tomar-se-á de domínio público após a data de defesa e homologação da sua respectiva ata. A mesma poderá servir de base literária para novas pesquisas, desde que a obra e seu (a) respectivo (a) autor (a) sejam devidamente citados e mencionados os seus créditos bibliográficos.

A523d Amorim, Alefjohn Feitosa.
DESENVOLVIMENTO DE UMA PRÓTESE MIOELÉTRICA
UTILIZANDO CONTROLE INTELIGENTE / Alefjohn
Feitosa Amorim. - 2018.
81 f. : il.

Orientador: Francisco de Assis Brito Filho .
Monografia (graduação) - Universidade Federal
Rural do Semi-árido, Curso de Engenharia
Elétrica, 2018.

1. Eletromiográfico. 2. Redes Neurais
Artificiais. 3. Variáveis Estatísticas. 4. Prótese.
I. Filho , Francisco de Assis Brito, orient. II.
Título.

O serviço de Geração Automática de Ficha Catalográfica para Trabalhos de Conclusão de Curso (TCC's) foi desenvolvido pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (USP) e gentilmente cedido para o Sistema de Bibliotecas da Universidade Federal Rural do Semi-Árido (SISBI-UFERSA), sendo customizado pela Superintendência de Tecnologia da Informação e Comunicação (SUTIC) sob orientação dos bibliotecários da instituição para ser adaptado às necessidades dos alunos dos Cursos de Graduação e Programas de Pós-Graduação da Universidade.

ALEFJOHN FEITOSA AMORIM


**DESENVOLVIMENTO DE UMA PRÓTESE MIOELÉTRICA UTILIZANDO
CONTROLE INTELIGENTE**

Monografia apresentada à Universidade Federal Rural do Semi-Árido (UFERSA), como exigência final para obtenção do título de Bacharel em Engenharia Elétrica.


Orientador: Francisco de Assis Brito Filho – UFERSA.

APROVADO EM 12/04/2018

Assinatura dos membros da Banca Examinadora.



D.Sc. Francisco de Assis Brito Filho
Presidente



D.Sc. Tania Luna Laura
Membro



D.Sc. Ernano Arrais Junior
Membro

CARAÚBAS – RN

2018

À meu pai, João Pereira e a minha mãe,
Alessandra de Brito. As duas pessoas que mais
admiro, respeito e amo.

DEDICO

AGRADECIMENTOS

Agradeço inicialmente as pessoas mais importantes da minha vida, meu pai João Pereira e minha mãe Alessandra, pelos ensinamentos, conselhos e amor a mim dedicados.

Aos meus amigos e companheiros de graduação Anderson, Esdras, Gonçalo, Allan, Gabriel e Garibaldi que me incentivaram e prestaram ajuda nos momentos importantes.

Aos meus familiares pelo apoio aos projetos que desenvolvi durante a graduação.

À minha namorada Daniela, pelo amor, companheirismo e apoio a mim dedicado.

A minha equipe Acceptor Aerodesing, que me ensinou a real importância do trabalho em equipe.

Em especial ao Gleidson Leite, amigo e companheiro, que aceitou desenvolver este trabalho ao meu lado, sendo sempre de grande auxílio e indispensável.

Aos meus companheiros do projeto APCASE, pela dedicação e ajuda prestada.

Ao meu orientador, Brito Filho, por ter acreditado na realização deste trabalho e ter fornecido todos os subsídios necessários para a realização do mesmo.

“O sucesso nasce do querer, da determinação e persistência em se chegar a um objetivo. Mesmo não atingindo o alvo, quem busca e vence obstáculos, no mínimo fará coisas admiráveis.”

(José de Alencar)

RESUMO

Nos últimos anos tem-se desenvolvido amplamente o número de tecnologias assistenciais com base em sinais eletromiográficos (EMG) destinadas à pessoas com membros amputados (superiores e inferiores), porém tais tecnologias, como próteses, possuem diversas limitações, sejam pela maneira de acionamento ou mesmo pelo elevado custo. Este trabalho apresenta o desenvolvimento de uma metodologia de aquisição, processamento e classificação do eletromiográfico (EMG) para dois canais, utilizando o amplificador de instrumentação AD620. A obtenção do sinal EMG foi realizada para um voluntário saudável, utilizando eletrodos de superfície Ag-AgCl não invasivos, posicionados nos músculos do antebraço esquerdo, para a captura dos sinais de quatro movimentos distintos: mão aberta, contração mão, contração garra e contração polegar. Tais sinais possuem como objetivo final o acionamento de uma prótese mioelétrica fabricada com o auxílio de uma impressora 3D. Após realizado a obtenção desses sinais, foi desenvolvido uma metodologia de processamento que permitiu realizar a extração de sete variáveis estatísticas a cada janelamento, onde o mesmo era composto de 100 amostras do sinal EMG e obtido a cada 0,1 segundo, com uma sobreposição de 50 %. Os sinais processados foram classificados com o auxílio das Redes Neurais Artificiais, especificamente do tipo multicamadas. As médias de acerto em relação aos movimentos abordados foram: 100 % para mão aberta, 98,99 % para contração mão, 99,99 % para contração polegar e 98,74 % para contração garra, resultando assim uma acurácia média de 99,43 %. Portanto, essa abordagem representa um passo significativo no desenvolvimento de próteses mioelétricas impressa em 3D mais intuitivas e de baixo custo, com a possível extensão para o controle de vários dispositivos auxiliares.

Palavras-Chave: Eletromiográfico, Redes Neurais Artificiais, Variáveis Estatísticas, Prótese.

ABSTRACT

In recent years, the number of EMG-based care technologies for people with amputated limbs (upper and lower) has developed widely, but such technologies, such as prostheses, have several limitations, either by even at high cost. This work presents the development of an electromyographic (EMG) acquisition, processing and classification methodology for two channels using the AD620 instrumentation amplifier. Obtaining the EMG signal was performed for a healthy volunteer using non-invasive Ag-AgCl surface electrodes positioned in the muscles of the left forearm to capture the signals of four distinct movements: open hand, contraction hand, contraction claw and thumb contraction. These signs have as final objective the activation of a myoelectric prosthesis manufactured with the aid of a 3D printer. After obtaining these signals, a processing methodology was developed that allowed the extraction of seven statistical variables to each window, where it was composed of 100 samples of the EMG signal and obtained every 0.1 second, with an overlap of 50%. The processed signals were classified with the aid of Artificial Neural Networks, specifically the multilayer type. The means of adjustment in relation to the movements were: 100% for open hand, 98.99% for hand contraction, 99.99% for thumb contraction and 98.74% for claw contraction, resulting in an average accuracy of 99.43 %. Therefore, this approach represents a significant step in the development of more intuitive and low cost 3D printed myoelectric prostheses, with the possible extension to the control of several auxiliary devices.

Keywords: Electromyographic, Artificial Neural Networks, Statistical Variables, Prosthesis

LISTA DE ABREVIATURAS

DASDV – *Difference Absolute Standard Deviation Value*

ELM - Extreme Learning Machines

EMG – Eletromiográfico

ISEK – *International Society of Electrophysiology and Kinesiology*

LDA - Linear Discriminant Analysis

LOG – *Log Detector Value*

LR - Logistic Regression

MAV – *Mean Absolut Value*

MLP – *Multilayer Perceptron*

MYOP – *Myopulse Percentage Rate*

RMS – *Root Mean Square*

RNA – Rede Neural Artificial

SENIAM – *Surface EMG for a Non-invasive Assesment of Muscle*

SVM - Suport Vector Machine

UFERSA – Universidade Federal Rural do Semiárido

VAR – *Variance of EMG*

WL – *Waveform Length*

LISTA DE TABELAS

Tabela 1 – Descrição dos movimentos que cada músculo abordado na Figura 7.	26
Tabela 2 – Características no domínio do tempo propostas por Phinyomark, Limsakul e Phukpattaranont (2012).	34
Tabela 3 – Saída da RNA e seu respectivo movimento representante.	56
Tabela 4 – Resultados obtidos durante a fase de teste da RNA.....	71
Tabela 5 – Angulações definidas em cada servo motor para reprodução dos 4 movimentos estudados.	72

LISTA DE FIGURAS

Figura 01 - Exemplo de interface homem-máquina.	16
Figura 02 - Exemplo de unidade motora.	20
Figura 03 – Exemplo de um sinal EMG.	21
Figura 04 – Espectro de potência ocupado por um sinal EMG aleatório.	21
Figura 05 – Exemplos de eletrodos para captação do sinal EMG.	23
Figura 06 – Obtenção do sinal EMG em diferentes posições do músculo.	24
Figura 07 – Representação da anatomia de um braço humano.	25
Figura 08 – Exemplo de um sinal EMG com uma alta razão de sinal-ruído.	28
Figura 09 – Exemplo de um sinal EMG com uma baixa razão de sinal-ruído.	28
Figura 10 – Esquemático do circuito de aquisição do sinal EMG.	30
Figura 11 – Sinal EMG adquirido a partir do circuito de aquisição desenvolvido.	31
Figura 12 – Sinal EMG padronizado com 5 contrações musculares de mesma duração.	32
Figura 13 – Modelo matemático de um neurônio artificial proposto por McCulloch e Pitts.	38
Figura 14 – Gráfico da função linear.	40
Figura 15 – Gráfico da função degrau.	40
Figura 16 – Gráfico da função Sigmóide.	41
Figura 17 – Exemplo de rede <i>feedforward</i> de camada única.	42
Figura 18 – Exemplo de rede <i>feedforward</i> de múltiplas camadas.	42
Figura 19 – Exemplo de rede recorrente.	43
Figura 20 – Exemplo de rede MLP.	44
Figura 21 – Eletrodos descartáveis Ag/AgCl utilizados durante a aquisição do sinal EMG.	47
Figura 22 – Analog Discovery 2 da fabricante Digilent utilizada para realizar a conversão A/D do sinal EMG.	48
Figura 23 – Movimentos analisados: (a) Mão aberta; (b) Contração Garra; (c) Contração Mão e (d) Contração Polegar.	48
Figura 24 – Cabos blindados com terminações em P1 utilizados na aquisição do sinal EMG.	49
Figura 25 – Posicionamento dos eletrodos no braço do voluntário.	50
Figura 26 – Exemplo de segmentação de um sinal amostrado.	51
Figura 27 – Segmento de um sinal EMG com um segundo de duração.	54

Figura 28 – Extração mútua das variáveis estatísticas dos dois canais EMG, para formação do vetor característico.....	55
Figura 29 – Matriz de treinamento 2400x14. As linhas representam as janelas obtidas durante a coleta dos quatros movimentos e as colunas representam as características extraídas por janela nos canais 1 e 2.....	57
Figura 30 – Sinal EMG obtido em canal e a extração da característica estatística WL de cada um dos canais.	58
Figura 31 – Robô InMoov desenvolvido pelo francês Gael Langevin.....	59
Figura 32 – Impressora 3D GT Max.	60
Figura 33 – Filamento ABS 1,75mm utilizado para realizar a impressão das peças.	60
Figura 34– Prótese InMooV aberta, com os cinco servos responsáveis pela reprodução dos movimentos.	61
Figura 35– Circuito de aquisição do sinal EMG.	62
Figura 36– Estrutura desenvolvida para acoplar os dois circuitos de aquisição, placa responsável pelas entradas/saídas dados e o sistema de alimentação.....	63
Figura 37– Estrutura montada com as placas de aquisição e entrada/saída de dados: a) Estrutura aberta e b) Estrutura fechada.	63
Figura 38– Coleta realizada no canal 1 para as três aquisições.....	64
Figura 39– Coleta realizada no canal 2 para as três aquisições.....	65
Figura 40– Exemplo de obtenção das 7 variáveis estatísticas para o movimento de contração do polegar obtido no canal 1.....	66
Figura 41– Exemplo de obtenção das 7 variáveis estatísticas para o movimento de contração do polegar obtido no canal 2.....	67
Figura 42– Acurácia e perdas de dados durante a fase de treinamento.	68
Figura 43– Acurácia e perdas de dados durante a fase de validação.....	69
Figura 44– Teste da RNA realizado partir de uma matriz 800x14 representando o movimento de contração garra.....	69
Figura 45– Teste da RNA realizado partir de uma matriz 800x14 representando o movimento de contração mão.	70
Figura 46– Teste da RNA realizado partir de uma matriz 800x14 representando o movimento de contração polegar.....	70
Figura 47– Dispositivos utilizados para realizar o controle da prótese a partir da saída da RNA.	71

Figura 48– Prótese InMoov reproduzindo o movimento de Mão Aberta.	73
Figura 49– Prótese InMoov reproduzindo o movimento de Contração Garra.	73
Figura 51– Prótese InMoov reproduzindo o movimento de Contração Polegar.	74

SUMÁRIO

1.	INTRODUÇÃO.....	16
1.1.	MOTIVAÇÃO	17
1.2.	OBJETIVOS	18
1.2.1.	Objetivo Geral.....	18
1.2.2.	Objetivo Específico	18
2.	FUNDAMENTAÇÃO TEÓRICA.....	19
2.1.	ELETROMIOGRAFIA	19
2.2.	SINAL MIOELÉTRICO	20
2.3.	AQUISIÇÃO DO SINAL EMG	22
2.3.1.	Eletrodos.....	22
2.3.2.	Posicionamento dos eletrodos	24
2.3.3.	Interferência na aquisição.....	26
2.3.4.	Amplificadores	27
2.3.5.	Filtros	29
2.3.6.	Circuito de Aquisição	29
2.4.	PROCESSAMENTO DO SINAL EMG	31
2.4.1.	Segmentação e extração das características do sinal EMG	32
2.4.1.1	Análise no domínio do tempo.....	33
2.4.1.2	Análise no domínio da frequência	36
2.4.2.	Identificação de padrões do sinal EMG.....	37
2.5.	REDES NEURAIS ARTIFICIAIS	37
2.5.1	Neurônio Artificial.....	38
2.5.2	Classificação das RNA.....	41
2.5.3	Rede de múltiplas camadas.....	44
3.	METODOLOGIA.....	46
3.1	PROTOCOLO DE COLETA DE DADOS	46
3.1.1	Configuração da coleta.....	47
3.1.2	Movimentos e músculos analisados	48
3.1.3	Preparo do voluntário	49
3.1.4	Duração e repetições de cada movimento durante a coleta	50
3.2	PROCESSAMENTO DO SINAL	51
3.2.1	Janelamento do sinal	51

3.2.2	Obtenção das características estatísticas do sinal EMG	52
3.2.3	Classificação do sinal EMG	55
3.2.4	Desenvolvimento da prótese.....	59
4.	RESULTADOS	62
4.1	CIRCUITO DE AQUISIÇÃO	62
4.2	AQUISIÇÃO DO SINAL EMG	64
4.3	PROCESSAMENTO DO SINAL EMG	65
4.4	CLASSIFICAÇÃO DO SINAL EMG.....	68
4.5	CONTROLE DA PRÓTESE	71
5.	CONCLUSÃO.....	75
3.1	TRABALHOS FUTUROS	76
6.	REFERÊNCIAS.....	77

1. INTRODUÇÃO

Segundo Soares e Noleto (2016), com o contínuo desenvolvimento tecnológico estamos criando novas formas de interação com as máquinas de maneira mais precisa e sofisticada, onde a construção desse tipo de interface homem-máquina nos permite desenvolver novos tipos de controle, baseado não apenas no acionamento de botões ou chaves, mas sim na detecção de movimentos a partir dos sinais biológicos. O desenvolvimento desse tipo de sistema promove grandes mudanças em diversos cenários do mercado, como jogos eletrônicos, indústria, engenharia e medicina. Na Figura 1 pode-se observar um exemplo de interface homem-máquina.

Figura 01 - Exemplo de interface homem-máquina.



Fonte: Gutierrez, (2016).

A engenharia biomédica é uma área que detém os princípios e conceitos das ciências exatas e ciências da saúde, em suma é a aplicação sistemática das ciências da engenharia com a finalidade de projetar, desenvolver, adaptar, testar, avaliar, aplicar e fornecer soluções tecnológicas para solucionar problemas confrontados por indivíduos com deficiência nas áreas funcionais, tais como mobilidade, visão, audição e comunicação.

O estudo das próteses mioelétricas (próteses controladas a partir de sinais musculares) se tornou um dos principais focos da área da bioengenharia, de tal modo que seu objetivo primordial é reproduzir de forma eficiente os movimentos de um membro a partir dos sinais EMG (eletromiográficos) coletados do próprio usuário da prótese. Isso é possível, pois mesmo

com ausência do membro, estudos científicos mostram que esses sinais são característicos e permanecem mesmo após a amputação (BERMUDEZ, 2014).

Neste trabalho pretende-se desenvolver uma prótese mioelétrica de baixo custo utilizando controle inteligente para o processamento dos sinais EMG. Para isso será necessário a fabricação de um circuito de aquisição, onde o sinal EMG será devidamente tratado.

1.1. MOTIVAÇÃO

A utilização de biosinais, como o eletromiográfico, vem se mostrando um grande aliado no desenvolvimento de tecnologias assistivas, as quais têm por finalidade melhorar a qualidade de vida de pessoas que possuem algum membro amputado. Entretanto esses estudos ainda estão longe de se tornarem verdadeiramente eficientes, ao ponto de replicar minuciosamente os movimentos de um membro amputado e tornar as próteses economicamente acessíveis.

As dificuldades encontradas no estudo de tecnologia assistivas baseadas em biosinais se resumem na difícil tarefa de processar o sinal obtido e extrair as devidas características que iram permitir a identificação do movimento e na criação de próteses capazes de reproduzir o movimento de forma satisfatória e em tempo real. Algumas empresas conceituadas já produzem próteses baseadas em biosinais verdadeiramente funcionais, porém o custo para sua aquisição é bastante elevado.

A utilização de redes neurais artificiais vem se mostrando como uma ótima opção para aplicações que necessitam de reconhecimento de padrões, já que os métodos comuns não suprem a necessidade desse tipo de aplicação, pois para processar e classificar biosinais é necessário um algoritmo complexo capaz de distinguir e classificar sinais em um curto intervalo de tempo.

1.2. OBJETIVOS

Neste tópico serão abordados os objetivos, geral e específico, relacionados ao trabalho proposto.

1.2.1. **Objetivo Geral**

Desenvolver um sistema que seja capaz de captar, processar e classificar, juntamente com o apoio de algoritmos computacionais inteligentes (RNAs), o sinal EMG, para aplicação no controle de uma prótese de um braço humano, replicando todos os movimentos em estudo, com uma taxa de acerto aceitável.

1.2.2. **Objetivo Específico**

- Realizar estudos sobre biosinais, com foco no sinal EMG;
- Desenvolver uma placa de aquisição para o sinal EMG;
- Desenvolver uma metodologia de processamento do sinal, baseada no particionamento do sinal no tempo e na criação de variáveis estatísticas como dados característicos de cada movimento;
- Aplicar uma rede neural artificial capaz de utilizar os dados característicos de cada movimento como dados de treinamento;
- Criar um algoritmo que seja capaz de utilizar a saída da RNA para comandar os atuadores da prótese.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. ELETROMIOGRAFIA

De acordo com Marchetti e Duarte (2006) a eletromiografia é uma técnica de monitoramento da atividade elétrica das membranas excitáveis de um determinado músculo, representando a medida dos potenciais de ação gerados na contração muscular.

A eletromiografia apresenta inúmeras aplicações, notadamente na clínica médica, para diagnóstico de doenças neuromusculares; na reabilitação, na reeducação da ação muscular; na anatomia, com o intuito de revelar a ação muscular em determinados movimentos; e na biomecânica no sentido de servir como ferramenta indicadora de alguns fenômenos (AMADIO & DUARTE, 1998).

Após a captação do sinal eletromiográfico, é necessário realizar seu devido tratamento a fim de se interpretar as alterações fisiológicas decorrentes das contrações. Existem dois tipos básicos de análises a que o sinal de eletromiografia pode ser submetido: análise no domínio do tempo do sinal e análise no domínio da frequência do sinal (AZEVEDO, 2007).

De acordo com Amadio e Serrão (2007), a análise no domínio do tempo do sinal, permite principalmente a visualização do padrão de ativação muscular durante uma contração, podendo servir como referência para comparações entre diferentes tipos de contrações, exercícios e sobrecargas. Este método permite ainda que relações entre força e atividade elétrica muscular possam ser observadas, apesar de ser uma vertente ainda controversa na literatura científica que aborda o assunto (MOHAMED *et al.*, 2002; ONISHI *et al.*, 1999).


Assim, a eletromiografia agrupa procedimentos de medição da atividade elétrica muscular. Ela requer um sistema de coleta de sinais elétricos, através de eletrodos do tipo agulha, fio ou de superfície, e o eletromiograma é o resultado de sua coleta (AMADIO & SERRÃO, 2007). O conjunto de sinais coletado pela eletromiografia é influenciado por muitas variáveis de interpretações complexas, das quais podem servir de indicadores para medição de habilidades atléticas, período de atividade muscular, detecção de padrões em movimento, níveis de contração muscular e sinergias envolvidas em um movimento específico (AMADIO & DUARTE, 1998).

Para padronização conceitual e protocolar esse tipo de avaliação foi criado a Sociedade Internacional de Cinesiologia e Eletrofisiologia - ISEK, onde a mesma estabelece padrões que devem ser seguidos para esse tipo de análise através do *Standards for Reporting EMG Data*.

2.2. SINAL MIOELÉTRICO

O menor sistema que descreve o controle neural do processo de contrações musculares é a unidade motora. Esse sistema é composto por um corpo celular e os dendritos de um neurônio motor, seus ramos do axônio e as fibras musculares que são inervadas por estes (ENOKA, 1994; KONRAD,2005). A Figura 2 denota um exemplo de unidade motora.

Figura 2 - Exemplo de unidade motora.




Fonte: Konrad, (2005).

Assim como toda célula do corpo humano, os neurônios apresentam um potencial de membrana ocasionado por diferentes concentrações iônicas de líquidos presentes no meio intracelular e extracelular, de modo que esses potenciais são de suma importância para a transmissão dos sinais neurais e, portanto, para a contração e relaxamento do músculo. De acordo com Guyton (1998), esse processo ocorre a partir do deslocamento do interior para o exterior da membrana dos íons de potássio, que possuem inicialmente carga positiva.

Quando há estímulos químicos, elétricos ou mecânicos nas células dos órgãos efetores, há variações das contrações de potássio nas membranas, ocasionando a geração de um potencial de ação, também conhecido como impulso nervoso. Logo, a quantidade de neurônios que estejam transmitindo tal impulso irá definir o quão intenso será a sensação.


Segundo Barion e Dourado (2015), o sinal mioelétrico (EMG) é o conjunto de sinais elétricos gerados na contração dos músculos e controlados pelo sistema nervoso. Esse sinal possui amplitudes aleatórias que chegam a ordem de 10 mV pico-a-pico, de modo que cada conjunto muscular apresenta um padrão para cada movimento, relacionando amplitude do sinal com o tempo de contração. Já a frequência do sinal varia de 6 Hz a 500 Hz, com a maior potência localizada na faixa de 20 a 150 Hz (LUCA, 2002). A Figura 3 e 4 apresenta um exemplo de um sinal EMG e o espectro de potência ocupado pelo mesmo respectivamente.

Figura 3 – Exemplo de um sinal EMG.



Fonte: Barion e Dourado, (2015).

Figura 4 – Espectro de potência ocupado por um sinal EMG aleatório.



Fonte: Barion e Dourado, (2015).

2.3. AQUISIÇÃO DO SINAL EMG

De acordo com Marchetti e Duarte (2006), o sinal EMG captado do corpo humano, a partir da técnica da eletromiografia, é um sinal analógico que então deve ser convertido para um sinal digital para que seja possível realizar seu devido processamento em algum software. Porém antes mesmo da aquisição de fato devem-se ser ajustados alguns parâmetros com o intuito de se obter um sinal adequado. Alguns dos principais parâmetros são:

- Eletrodos;
- Posicionamento dos eletrodos;
- Interferência na aquisição;
- Amplificadores;
- Filtros;
- Conversores Analógico/Digital (A/D);
- Frequência de amostragem.

2.3.1. Eletrodos

Corroborando com Marchetti e Duarte (2006), os eletrodos são dispositivos de entrada e saída de dados analógicos (corrente elétrica) de um sistema elétrico, de tal modo que podemos definir que o eletrodo é uma conexão entre o corpo e o sistema de aquisição, devendo ser colocado próximo o bastante do músculo responsável pela determinada contração que se deseja obter o sinal EMG. A área da interface eletrodo-tecido é denominada de superfície de detecção, comportando-se como um filtro passa-baixa cujas características dependem do tipo de eletrodo utilizado (DE LUCA, 1997).

Existem diversos tipos de eletrodos, moldados para diferentes tipos de aquisição, tarefa, natureza da pesquisa e músculo a ser estudado. Se tratando de músculos profundos ou pequenos, utilizam-se eletrodos do tipo agulha (intramuscular), pois possuem uma pequena área de detecção colaborando assim para os estudos de determinadas unidades motoras (MARCHETTI & DUARTE, 2006).

Outro tipo de eletrodo bastante utilizado no exame eletromiográfico são os eletrodos de superfície. Esse tipo de eletrodo é aderido à pele, de modo a constituir uma interface pele-eletrodo, com o intuito de captar a corrente gerada pela contração muscular. São compostos

geralmente por um sistema Ag-AgCl associado a um gel condutor (eletrólito), que de acordo com De Luca (1997) qualquer combinação metal/gel que permita uma reação eletrolítica pode servir. A Figura 5 apresenta alguns tipos de eletrodos comerciais.

Figura 5 – Exemplos de eletrodos para captação do sinal EMG.



Fonte: Próprio Autor.

Para correta determinação do tipo de eletrodo a ser utilizado devem-se ser considerados dois pontos principais, sendo a primeira, a distância entre os eletrodos. Esta distância inter-eletrodo é definida como a distância de centro a centro entre as áreas condutivas dos mesmos, afetando o comprimento de banda das frequências e a amplitude do sinal EMG. Aplicando uma pequena distância entre os eletrodos verifica-se a alteração do comprimento de onda para altas frequências e uma diminuição considerável na amplitude do biosinal, portanto a distância pode ser fixada para comparações quantitativas entre aquisições no músculo (MARCHETTI e DUARTE, 2006). A recomendação da distância entre os eletrodos proposta pelo SENIAM (*Surface EMG for a Non-invasive Assesment of Muscle*) é de 20 mm à 40 mm (centro a centro) (HERMES *et al.*, 2000).

O segundo ponto a ser tratado é o tamanho e a forma das superfícies de detecção, de modo que quanto maior for o tamanho dessa superfície, maior será a amplitude do sinal EMG obtido e menor será o ruído elétrico proveniente da interface entre a pele e a superfície de detecção, entretanto, este deve ser pequeno o bastante para evitar o *cross-talk* de outros músculos (DELSYS, 2006; HERMES *et al.*, 2000).

Segundo Winter (1990) e Hermes (2000), no quesito de tratamento de qualidade durante aquisição do sinal EMG por parte dos eletrodos, se faz necessário minimizar a influência da impedância gerada entre a pele e o eletrodo, bem como o cuidado com procedimentos pré-aquisição, tais como a realização da limpeza do local que se deseja obter o sinal, remoção dos pelos e leve abrasão para remoção das células mortas.


2.3.2. Posicionamento dos eletrodos

Segundo Soares e Noleto (2016), para se obter uma coleta de dados satisfatória é necessário seguir algumas recomendações acerca do posicionamento do eletrodo utilizado. Podemos destacar algumas dessas recomendações, sendo elas:

- Escolha da região de fácil identificação para o movimento proposto;
- Posicionamento do eletrodo no ventre do músculo;
- Posicionar os pares de eletrodos paralelamente à fibras musculares.

Deve-se também ter uma preocupação com o fenômeno denominado *cross-talk*, ocorrendo quando dois músculos estão muito próximo, acarretando uma interferência no sinal coletado (SOARES & NOLETO, 2016). Isso pode ser evitado pelo uso do tamanho adequado dos eletrodos e o espaçamento entre eles (FAVIEIRO, 2012). A Figura 6 apresenta a obtenção do sinal EMG vista de diferentes posições dos eletrodos de captação, onde pode-se verificar que a tal variação de posição afeta tanto a amplitude do sinal captado quanto ao espectro densidade de potência (*Power Spectrum Density*, PSD) do sinal obtido.


Figura 6 – Obtenção do sinal EMG em diferentes posições do músculo.



Fonte: Favieiro, (2012).

Diante disso é necessário escolher os músculos responsáveis pelos movimentos que serão estudados. Na Figura 7 juntamente com a Tabela 1 estão especificados os músculos do braço humano e seus respectivos movimentos.

Figura 7 – Representação da anatomia de um braço humano.



Fonte: Kamem e Gabriel, (2010).

Tabela 1 – Descrição dos movimentos reproduzidos a partir dos músculos abordados na Figura 7.

Músculo	Ação
Biceps braquial	Flete e supina o antebraço; flexiona o braço.
Braquial	Flete o antebraço.
Braquiorradial	Flete o antebraço.
Triceps braquial	Estende o antebraço; estende o braço.
Flexor radial do carpo	Flete e abduz a mão.
Flexor ulnar do carpo	Flete e aduz a mão.
Palmar longo	Flexiona a mão.
Flexor superficial dos dedos	Flete as falanges médias de cada dedo.
Extensor radial do carpo	Estende e abduz a mão.
Extensor ulnar do carpo	Estende e aduz a mão.
Extensor dos dedos	Estende as falanges.

Fonte: Kamem e Gabriel, (2010).

2.3.3. Interferência na aquisição

O processo de aquisição do sinal EMG pode sofrer inúmeros tipos de interferências, diminuindo a precisão do sistema de controle. Essas interferências podem ser provenientes de equipamentos externos, inerente ao próprio equipamento de aquisição ou até mesmo caracterizado pelo biótipo de quem está sendo analisado (SOARES & NOLETO, 2016).

As interferências externas ou de ambiente são provenientes da radiação eletromagnética gerada por equipamentos elétricos que utilizam a rede como fonte de alimentação, portanto deve-se evitar qualquer tipo gerador de interferência eletromagnéticas durante a coleta de dados.

Por fim o sinal EMG é bastante influenciado pela velocidade de propagação dos seus respectivos potenciais de ação nas fibras musculares, de tal modo que a condução pode ir de 100 m/s a 2 m/s (SOARES & NOLETO, 2016). De acordo com Phinyomark *et al.* (2012), a velocidade de condução nas fibras:

- Diminui com a fadiga do músculo;
- Diminui com o tamanho do músculo;
- Diminui com doenças neuromusculares;
- Aumenta com a temperatura;
- Aumenta com o diâmetro da fibra muscular;
- Maior em adultos;
- Aumenta com a força exercida.

Pode-se afirmar que o sinal EMG possui uma peculiaridade em comparação com outros biosinais, pois há uma grande dificuldade de generalização de um trabalho em cima dos dados adquiridos. Isso ocorre, pois, alguns parâmetros não podem ser mantidos constantes devido sua ligação intrínseca com algumas características específicas de cada paciente, como o tamanho do músculo, espessura da camada adiposa e o nível de contração muscular mantido durante a aquisição.


2.3.4. Amplificadores

De acordo com Marchetti e Duarte (2006), devido à baixa amplitude do sinal EMG durante a fase de aquisição, se faz necessário amplificar o sinal, entretanto deve-se tomar algumas precauções para que o mesmo não modifique as características do biosinal. De acordo com ISEK, alguns parâmetros do amplificador devem ser observados para garantir uma amplificação adequada do sinal, dos quais podemos destacar (MERLETTI, 1999):

- Impedância de entrada;
- Razão sinal-ruído;
- Taxa de rejeição de modo comum;
- Largura de Banda;
- Ganho.


A qualidade do sinal EMG amplificado pode ser mensurado qualitativamente através da razão sinal-ruído, onde quanto maior a razão, maior a redução do ruído (DELSYS, 2006). As Figuras 8 e 9 denotam um exemplo de um sinal com uma razão de sinal-ruído alta e baixa.

Figura 8 – Exemplo de um sinal EMG com uma alta razão de sinal-ruído.



Fonte: Marchetti e Duarte, (2006).

Figura 9 – Exemplo de um sinal EMG com uma baixa razão de sinal-ruído.



Fonte: Marchetti e Duarte, (2006).

A determinação da habilidade de um amplificador diferencial em eliminar o sinal de modo comum chama-se taxa de rejeição de modo comum (*Common Mode Rejection Ratio*, CMRR). O sinal de modo comum é aquele detectado em ambos os eletrodos, tais como interferências da rede elétrica, músculos distantes ou batimentos cardíacos, considerados ruídos (MARCHETTI & DUARTE, 2006). Quanto mais alta a CMRR, melhor o cancelamento do sinal de modo comum, de modo que um CMRR de 32.000 vezes ou 90 decibéis (dB) é geralmente suficiente para suprimir ruídos elétricos (DELSYS, 2006).

2.3.5. Filtros

O filtro é um dispositivo designado para atenuar faixas específicas de frequências, de modo que se pode destacar duas utilidades importantes de sua implementação, a separação e recuperação do sinal. A separação do sinal é utilizada para selecionar uma faixa de frequência desejada, separando-a de alguma interferência, ruído ou outro sinal. A recuperação do sinal é utilizada quando o sinal base foi distorcido de alguma forma. Portanto, a proposta dos filtros é permitir a passagem de algumas frequências inalteradas e atenuar outras (KONRAD, 2005).

Os filtros podem ser analógicos ou digitais, e podem ser implementados tanto em sinais analógicos, quanto em sinais digitais, de modo que os sinais analógicos são amostrados e representado por uma matriz numérica.

De acordo com o ISEK, a filtragem do sinal EMG deve ser especificada por:


- O tipo de filtro utilizado;
- Passa-Alta e Passa Baixa;
- Ordem dos filtros utilizados.

A densidade de potência do sinal EMG tem contribuições insignificantes fora do intervalo de 5-10 Hz a 400-450 Hz (KONRAD, 2005).

2.3.6. Circuito de Aquisição

O circuito de aquisição utilizado nesse trabalho foi desenvolvido com base no circuito produzido por PRADHAN *et al.*, (2016), no qual pode-se ser observado na Figura 10.

Figura 10 – Esquemático do circuito de aquisição do sinal EMG.




Fonte: Próprio Autor.

Esse circuito é composto inicialmente por um amplificador diferencial, com ganho de 107,38 V/V e utilizando como entrada diferencial os eletrodos de superfície. No mesmo amplificador diferencial observa-se que na realimentação do ganho encontra-se um circuito definido como *Right Leg Drive Circuit* (RLD), conforme Zinvi Fu et al. (2017), esse circuito configura a tensão de modo comum do usuário para aumentar o CMRR efetivo do circuito.

A saída do primeiro estágio de amplificação tem-se um integrador com uma frequência de corte de 15,91 Hz, para remoção do *offset* gerado pela fonte CC. Antes do segundo estágio de amplificação com ganho variável a partir de um potenciômetro de 10 kΩ, utilizou-se um filtro passa-alta de primeira ordem com uma frequência também ajustável a partir de um potenciômetro de 10 kΩ. Após o ganho do segundo estágio, um filtro passa-baixa de segunda ordem é introduzido no circuito com uma frequência de corte de 742 Hz. O sinal adquirido neste circuito pode ser observado na Figura 11.

Figura 11 – Sinal EMG adquirido a partir do circuito de aquisição desenvolvido.



Fonte: Próprio Autor.

2.4. PROCESSAMENTO DO SINAL EMG


De acordo com Soares e Noleto (2016), após a aquisição do sinal EMG é feito a manipulação do mesmo, onde normalmente esse processo é realizado com auxílio de ferramentas computacionais, para determinar as características intrínsecas do sinal obtido. Com o sinal EMG obtido, inicia-se a fase de processamento, onde esses dados serão a base para aplicações almejadas, seja elas um diagnóstico de patologias ou controle de próteses artificiais. No caso do controle da prótese, o sinal EMG é obtido para se determinar o movimento que será reproduzido pela prótese a partir das contrações musculares geradas pelo próprio usuário da prótese.

O processamento do sinal EMG pode ser dividido em duas etapas, sendo a primeira a segmentação e extração das características do sinal e a segunda o processamento propriamente dito, com o uso de técnicas da área de inteligência computacional para realizar a classificação do movimento (SOARES & NOLETO, 2016).

2.4.1. Segmentação e extração das características do sinal EMG

A segmentação de um sinal EMG baseia-se no fracionamento do mesmo, possibilitando assim a extração das informações necessárias para aplicação em questão. Referindo-se a sinais EMG, se faz necessário o reconhecimento de regiões distintas do sinal, como a região de repouso e a de contração muscular, ou até mesmo a diferenciação de duas contrações musculares distintas. Portanto para um processamento ser eficiente é primordial a utilização de técnicas que possibilitem descrever com detalhes o comportamento do sinal obtido. Na Figura 12, pode-se observar um sinal EMG obtido durante 38 segundos, no qual está destacado as áreas de contração e repouso muscular.

Figura 12 – Sinal EMG padronizado com 5 contrações musculares de mesma duração.



Fonte: Soares e Noleto, (2016).

O sinal EMG pode seguir certos padrões definidos, pois a coleta de dados na eletromiografia permite definir a duração da coleta, quantidade de contrações nesse intervalo e a duração dessas contrações e dos intervalos. Tais definições possibilitam a observação clara e precisa das contrações e repouso durante o intervalo de aquisição, tornando assim o processamento mais fácil, pois tanto o período de contração quanto de repouso já é conhecido durante o intervalo obtido. Pode-se afirmar que em trabalhos com metodologias de processamento bem definidas, a segmentação do sinal EMG é facilmente obtida apenas com a análise visual do sinal no tempo (SOARES & NOLETO, 2016).

De acordo com Chowdhury (2013), apesar de toda a informação requerida pelo processamento já estar presente no sinal segmentado, se usarmos o sinal EMG como entrada de qualquer classificador o acerto será mínimo, pois de acordo com Soares e Noleto (2016), isso se deve a complexidade do sinal EMG, além da presença de ruídos que influenciam diretamente o resultado do classificador. Para contornar tal situação é necessário realizar a extração de características do sinal.

Existem muitos métodos de processamento que podem ser utilizados para interpretação dos dados. Duas importantes características do sinal EMG são a frequência e a amplitude (MARCHETTI & DUARTE, 2006). Duas formas comuns para representar as tais informações contidas nos sinais podem ser chamadas de análise no domínio temporal e no domínio da frequência (ROBERTSON *et al.*, 2004).

Em conformidade com Soares e Noleto (2016), estas características são extraídas para cada janela que compõe o movimento, de tal modo que número total então de características irá depender do comprimento dessas janelas. Tais janelas devem ser escolhidas de maneira a proporcionar uma visão abrangente do sinal e ao mesmo tempo específica, promovendo dados suficientes para a classe de movimento desejada sem provocar confusão entre os movimentos ou o repouso.

2.4.1.1 Análise no domínio do tempo

De acordo com Marchetti e Duarte (2006), a informação representada no domínio do tempo descreve quando algo ocorre e qual a amplitude de sua ocorrência, de modo que cada amostra do sinal indica o que está acontecendo em um determinado instante de tempo. A amplitude é um indicador da magnitude da atividade muscular, produzida predominantemente por aumentos na atividade das unidades motoras e em sua taxa de disparo (ROBERTSON, 2004).

Corroborando com Phinyomark, Limsakul e Phukpattaranont (2012), os recursos do domínio do tempo têm sido amplamente utilizados nas pesquisas e práticas médicas e de engenharia. Uma grande desvantagem das características deste grupo vem de uma propriedade não estacionária do sinal EMG, alterando as propriedades estatísticas em relação ao tempo, mas os recursos do domínio do tempo assumem os dados como um sinal estacionário (Lei, Wang, & Feng, 2001).

Portanto, a variação desse tipo de características pode ser obtida facilmente quando o sinal EMG de superfície é gravado através de movimentos dinâmicos. Além disso, devido aos seus cálculos baseados em valores de amplitude de sinal EMG, muitas interferências que são adquiridas através da gravação são uma grande desvantagem, particularmente para recursos extraídos da propriedade de energia (PHINYOMARK, LIMSAKUL & PHUKPATTARANONT, 2012).

No entanto, os recursos neste grupo também foram amplamente utilizados devido aos seus desempenhos de classificação em ambientes de baixo ruído e sua menor complexidade computacional em comparação com os recursos no domínio da frequência e no domínio da escala de tempo (PHINYOMARK, LIMSAKUL & PHUKPATTARANONT, 2012).

A Tabela 2 denota vinte e dois recursos do domínio do tempo propostos por Phinyomark, Limsakul e Phukpattaranont (2012), através de uma revisão extensiva e cuidadosa das literaturas.

Tabela 2 – Características no domínio do tempo propostas por Phinyomark, Limsakul e Phukpattaranont (2012).

Variável	Descrição	Equação
IEMG	<i>Integrated EMG</i>	$IEMG = \sum_{i=1}^N x_i $
MAV	<i>Mean absolute value</i>	$MAV = \frac{1}{N} \sum_{i=1}^N x_i $
MAV1	<i>Modified mean absolute value type 1</i>	$MAV1 = \frac{1}{N} \sum_{i=1}^N w_i x_i ;$ $w_i = \begin{cases} 1, & \text{if } 0.25N \leq i \leq 0.75N \\ 0.5, & \text{otherwise} \end{cases}$
MAV2	<i>Modified mean absolute value type 2</i>	$MAV2 = \frac{1}{N} \sum_{i=1}^N w_i x_i ;$ $w_i = \begin{cases} 1, & \text{if } 0.25N \leq i \leq 0.75N \\ 4i/N, & \text{elseif } i < 0.25N \\ 4(i - N)/N, & \text{otherwise} \end{cases}$
SSI	<i>Simple square integral</i>	$SSI = \sum_{i=1}^N x_i^2$
VAR	<i>Variance of EMG</i>	$VAR = \frac{1}{N-1} \sum_{i=1}^N x_i^2$

TM3	<i>Absolute value of the 3rd temporal moment</i>	$TM3 = \left \frac{1}{N} \sum_{i=1}^N x_i^3 \right $
TM4	<i>Absolute value of the 4rd temporal moment</i>	$TM4 = \frac{1}{N} \sum_{i=1}^N x_i^4$
TM5	<i>Absolute value of the 5rd temporal moment</i>	$TM5 = \left \frac{1}{N} \sum_{i=1}^N x_i^5 \right $
RMS	<i>Root mean square</i>	$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
V	<i>V-Order</i>	$V = \left(\frac{1}{N} \sum_{i=1}^N x_i^p \right)^{\frac{1}{p}}$ $x_i = (\gamma m_i^\alpha) n_i$
LOG	<i>Log detector</i>	$LOG = e^{\frac{1}{N} \sum_{i=1}^N \log(x_i)}$
WL	<i>Waveform length</i>	$WL = \sum_{i=1}^{N-1} x_{i+1} - x_i $
AAC	<i>Avarege amplitude change</i>	$AAC = \frac{1}{N} \sum_{i=1}^{N-1} x_{i+1} - x_i $
DASDV	<i>Difference absolute standard deviation value</i>	$DASDV = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (x_{i+1} - x_i)^2}$
ZC	<i>Zero crossing</i>	$ZC = \sum_{i=1}^{N-1} [\text{sgn}(x_i \times x_{i+1}) \cap x_i - x_{i+1} \geq \text{threshold}]$ $\text{sgn}(x) = \begin{cases} 1, & \text{if } x \geq \text{threshold} \\ 0, & \text{otherwise} \end{cases}$
MYOP	<i>Myopulse percentage rate</i>	$MYOP = \frac{1}{N} \sum_{i=1}^N [f(x_i)];$ $f(x) = \begin{cases} 1, & \text{if } x \geq \text{threshold} \\ 0, & \text{otherwise.} \end{cases}$
WAMP	<i>Willison amplitude</i>	$WAMP = \sum_{i=1}^{N-1} [f(x_n - x_{n+1})];$ $f(x) = \begin{cases} 1, & \text{if } x \geq \text{threshold} \\ 0, & \text{otherwise.} \end{cases}$
SSC	<i>Slope sign change</i>	$SSC = \sum_{i=2}^{N-1} [f[(x_i - x_{i-1}) \times (x_i - x_{i+1})]]$ $f(x) = \begin{cases} 1, & \text{if } x \geq \text{threshold} \\ 0, & \text{otherwise.} \end{cases}$

MAVSLP	<i>Mean absolute value slope</i>	$MAVSLP_k = MAV_{k+1} - MAV_k; \quad k = 1, \dots, K-1$
MHW	<i>Multiple hamming Windows</i>	$MHW_k = \sum_{i=0}^{N-1} (x_i w_{i-i_k})^2, \quad k = 1, \dots, K$
MTW	<i>Multiple trapezoidal Windows</i>	$MTW_k = \sum_{i=0}^{N-1} (x_i^2 w_{i-i_k}), \quad k = 1, \dots, K$

Fonte: Próprio Autor.

2.4.1.2 Análise no domínio da frequência

Conforme Marchetti e Duarte (2006), a informação representada pelo domínio da frequência, se tratando de sinais EMG, é considerado um método alternativo, de modo que envolve, geralmente, a determinação do espectro de frequência através da transformada de Fourier. Como os sinais biológicos associados ao movimento humano não são funções puras de seno e cosseno, faz-se necessário combinar funções diferentes para representar o sinal EMG (DELSYS, 2006; ENOKA, 2000; HERMES *et al.*, 2000).

De acordo com Enoka (2000), existem três características que influenciam o conteúdo de frequências caracterizadas por:

- Taxa de disparo das unidades motoras (UMs);
- Tempo relativo de disparo dos potenciais de ação por diferentes UMs;
- Forma dos potenciais de ação.

Pelo fato do sinal EMG possuir uma grande quantidade de potenciais de ação variando em forma, o conteúdo de frequências dos sinais EMG varia entre 1-500 Hz. Segundo Marchetti e Duarte (2006), quando a forma dos potenciais de ação se altera, suas frequências também mudam. Isso acontece frequentemente em contrações até a fadiga, com um declínio dos potenciais de ação em amplitude e aumento em sua duração, alterando desta forma para a esquerda, o espectro de densidade de potência (*Power Spectrum Density*, PSD), e consequentemente, modificando a média e a mediana das frequências (ENOKA, 2000; HERMES *et al.*, 2000).

2.4.2. Identificação de padrões do sinal EMG

Após a escolha do tipo de análise a ser utilizada para o processamento e suas respectivas variáveis estatísticas, inicia-se a etapa final que se baseia no reconhecimento de padrões contidos no sinal EMG para que seja possível realizar uma classificação correta. Segundo Soares e Noleto (2016), para tal feito existem diversos tipos de classificadores e dentre os mais comuns usados em aplicações EMG, tem-se:

- Redes Neurais Artificiais (RNA);
- Análise de Discriminante Linear (*Linear Discriminant Analysis* - LDA);
- Máquinas de Vetor de Suporte (*Support Vector Machine* - SVM);
- Regressão Logística (*Logistic Regression* - LR);
- Máquinas de Aprendizado Extremo (*Extreme Learning Machines* – ELM).

Para a escolha do tipo de classificador deve-se ser considerado alguns pontos importantes como sua eficiência, tempo de aprendizagem e complexidade do algoritmo quando o objetivo final é a implementação em hardware.

De acordo com Chowdhury (2013), as Redes Neurais Artificiais são exaltadas como bem-sucedidas em várias literaturas pela sua capacidade de representar a relação linear e não-linear entre os dados. Segundo Asghari (2007), Hudgins *et al.* foi o pioneiro em reconhecer os padrões do sinal EMG utilizando uma RNA do tipo MLP (*MultiLayer Perceptron*) com uma taxa de acerto de aproximadamente 91 %.

A taxa de acerto na classificação do sinal EMG está ligado intrinsicamente com todo o processo no qual esse sinal está vinculado, de modo que a escolha do tipo de análise, das características extraídas e do tipo de janelamento pode afetar diretamente o desempenho do classificador.

2.5. REDES NEURAIAS ARTIFICIAIS

Segundo Brandão (2005), as Redes Neurais Artificiais (RNA) são estruturas matemáticas capazes de aprender, memorizar e generalizar determinadas situações e problemas a elas apresentadas. As RNAs podem ser definidas também como sistemas paralelos compostos por unidades elementares, denominadas neurônios artificiais, que calculam determinadas

funções matemáticas geralmente não lineares, cujo funcionamento baseia-se no cérebro humano.

As soluções obtidas por meio da utilização de RNA podem se equivaler ou até mesmo superar as soluções apresentadas pelos modelos dos classificadores tradicionais. O procedimento pelo qual a RNA encontra a solução de um determinado problema, baseia-se em um processo de aprendizado, onde uma série de amostras de entradas e saídas é apresentada às suas unidades elementares que por si só encontram as características necessárias para representar a informação fornecida (BRANDÃO, 2005), de tal modo que posteriormente seja possível definir um sistema resultante que consiga generalizar tal problema.

As RNAs têm como capacidade principal o aprendizado através de exemplos que lhe são apresentados e generalizar tais informações obtidas, tornando possível a classificação de amostras de dados desconhecidos, mas que se assemelham com as informações contidas durante a etapa de treinamento.

2.5.1 Neurônio Artificial

O neurônio artificial foi proposto inicialmente por McCulloch e Pitts, em 1943, apesar de simples, engloba todas as características de uma rede neural biológica, e é ainda o modelo mais usado para criar arquiteturas de RNAs (SILVA, 2010). Pode-se observar na Figura 13 um exemplo de um neurônio artificial modelado por McCulloch e Pitts.




Figura 13 – Modelo matemático de um neurônio artificial proposto por McCulloch e Pitts.

Fonte: Holanda, (2013).

Esse tipo de neurônio possui características específicas, são elas:

- Entradas de $X_1 \dots X_n$, representam os pulsos recebidos pela entrada da rede ou por outros neurônios.
- Os pesos sinápticos $W_1 \dots W_n$, representam a sensibilidade da membrana do neurônio.
- A soma do produto das entradas X_i com seu respectivo peso W_i , é efetuada pelo bloco de soma aditiva $\sum_{i=1}^n W X_i$.
- O parâmetro θ representa o limiar de disparo de um neurônio, e a subtração deste com a função aditiva representa a comparação do potencial pós-sináptico com o limiar de disparo.
- A saída u , representa que o limiar foi ultrapassado pela função aditiva, logo um sinal é emitido.
- A função $f(u)$ representa a concentração de neurotransmissores na membrana pré-sináptica de onde será implementada uma função de ativação.
- A saída y representa o valor de saída do neurônio;

Esse modelo ainda pode ser representado na sua forma algébrica pelas Equações 1 e 2, na qual pode se obter uma saída y do neurônio em função das entradas X_n , dos pesos sinápticos W_n , do bias θ e através de uma função de ativação (AMORIM, 2015).

$$u = \sum_{i=1}^n X_i W_i - \theta \quad (1)$$

$$y = f(u) \quad (2)$$


A variação da função de ativação também conhecida como função de transferência, dos parâmetros W_i e θ , e da quantidade de neurônios permite que a rede neural seja capaz de desempenhar funções que exigem um maior grau de complexidade (HAYKIN, 2001). Essa variação é denominada treinamento.

Segundo Haykin (2001) a função de ativação, representada por $f(u)$, define a saída do neurônio em termos do campo local induzido, ou seja, ela é escolhida de acordo com a necessidade do problema em que a rede está trabalhando. Segundo Soares (2013), dentre as funções de ativação, as mais utilizadas são:

- **Função Linear:** Esse tipo de função não limita a saída da rede e é utilizada para armazenamento de dados, de modo que o neurônio que possua essa função atue como um aproximador linear, como mostra a Figura 14.

$$f(u) = u \quad (3)$$

Figura 14 – Gráfico da função linear.




Fonte: Amorim, (2016).

- **Função Limiar ou Degrau:** Nesse tipo de função o neurônio vai gerar uma saída com valor 1 quando o resultado da função aditiva for maior ou igual a zero, como mostra a Figura 15.

$$f(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases} \quad (4)$$

Figura 15 – Gráfico da função degrau.




Fonte: Amorim (2016).

- **Função Sigmóide:** Segundo Braga *et al.* (2007) esse tipo de função é a mais utilizada na construção de redes neurais. Isso ocorre devido sua característica de ser uma função estritamente crescente, exibindo um comportamento balanceado linear e não-linear, como mostra a Figura 16.

$$f(u) = \frac{1}{(1 + e^{-u})} \quad (5)$$

Figura 16 – Gráfico da função Sigmóide.



Fonte: Amorim, (2016).

2.5.2 Classificação das RNA


Segundo Brandão (2005), as RNAs podem ser classificadas em:

a) Tipos de Arquiteturas

Segundo Haykin (2001) o algoritmo de aprendizado utilizado para treinar a rede, está ligada diretamente a maneira pela qual os neurônios estão estruturados. Em geral, podemos identificar três tipos de classes de arquiteturas de redes fundamentalmente diferentes:

- **Redes Alimentadas Adiante com Camada Única:** Conhecida também como rede *feedforward* de camada única, esse tipo de rede neural é alimentado de forma acíclica. Tal arquitetura possui apenas um neurônio artificial em sua camada, como pode-se observar na Figura 17.


Figura 17 – Exemplo de rede *feedforward* de camada única.



Fonte: Matsunaga, (2012).

- **Redes Alimentadas Diretamente com Múltiplas Camadas:** Esse tipo de rede, também é conhecida como *feedforward* de múltiplas camadas, é alimentada de forma acíclica e possui várias camadas ocultas. Tais camadas de neurônios se encontram entre a camada de entrada e saída, tornando a rede capaz de extrair características de ordem mais elevadas, como mostra a Figura 18.


Figura 18 – Exemplo de rede *feedforward* de múltiplas camadas.



Fonte: Matsunaga, (2012).

- **Rede Recorrentes:** Esse tipo de rede, também conhecida como *feedback*, possui pelo menos uma camada de nós computacionais, porém se distingue das demais, pelo fato de ter os laços de realimentação. Segundo Haykin (2001) a presença desses laços tem um impacto profundo na capacidade de aprendizagem da rede e no seu desempenho, como indica a Figura 19.

Figura 19 – Exemplo de rede recorrente.



Fonte: Silva, (2010)

b) Tipos de Aprendizagem em Redes Neurais

Aprendizagem é um processo pelo qual os parâmetros livres (pesos sinápticos e bias) de uma rede neural artificial são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre (HAYKIN, 2001). De modo geral, podemos citar como os principais tipos de aprendizagem:

- **Aprendizagem Supervisionada:** Conhecida também como aprendizagem com um professor. Para aplicação desse tipo de aprendizagem é necessário um mentor, pessoa ou professor, que seja capaz de fornecer à rede neural uma resposta desejada para um vetor de treinamento inicial.
- **Aprendizagem Não-Supervisionada:** Conhecida também como aprendizagem auto organizada. Nesse tipo de aprendizagem não há um mentor para supervisionar o processo de aprendizado. Neste caso são fornecidas condições para a realização uma

medida independente da tarefa da qualidade da representação que a rede deve aprender, de modo que os parâmetros livres da rede sejam otimizados em relação a esta medida.


2.5.3 Rede de múltiplas camadas

Conforme dito anteriormente, as RNAs com arquitetura simples, ou seja, apenas com uma camada de neurônios são capazes de resolver problemas linearmente separáveis, entretanto mesmo existindo muito problemas lineares, existe, por outro lado, uma outra vasta gama de problemas não linearmente separáveis, dois quais uma RNA de camada única não seria capaz de obter uma solução coerente.

Este problema foi proposto por Minsky e Pappert na década de 70, quando, em suas publicações, depreciaram a habilidade das RNA de encontrar soluções para problemas simples, como por exemplo, a modelagem do “Ou Exclusivo” da lógica digital (BRANDÃO, 2005). A MLP (*Multi Layer Perceptron*) foi um tipo de RNA com múltiplas camadas, desenvolvida para contorna os problemas confrontados pela RNA simples, ou seja, solucionar problema não lineares.

A MLP, como já citado, apresenta uma arquitetura de multicamadas, denominadas camadas intermediárias (ou ocultas), de modo que o número de neurônios e da quantidade de camadas ocultas dependem diretamente da complexidade do problema ao qual a rede será exposta. A Figura 20 ilustra uma rede MLP.

Figura 20 – Exemplo de rede MLP.



Fonte: Soares, (2013).

Segundo Soares (2013), as camadas intermediárias trabalham como um reconhecedor de características, que ficam armazenadas nos pesos sinápticos, tornando a MLP uma rede excepcional da qual pode-se destacar três características distintivas:

- O modelo de cada rede inclui uma função de ativação não-linear;
- A rede possui no mínimo uma camada de neurônios ocultas, variando de acordo com a complexidade do problema;
- A rede apresenta um alto grau de conectividade, determinado pelas sinapses da rede.

O número de neurônios da camada intermediária determinado durante o treinamento é puramente empírico, ou seja, deve-se realizar variações no número de camadas oculta e na quantidade de neurônios presentes em cada uma até que a rede MLP consiga convergir para a solução ideal.

O treinamento que é normalmente utilizado para a MLP é realizado pelo algoritmo de propagação de erro (*backpropagation*). Esse tipo de treinamento baseia-se em um algoritmo supervisionado que realiza o ajuste dos pesos sinápticos, a partir do erro existente entre a i -ésima entrada e a i -ésima saída. Este algoritmo possui duas fases durante a fase de treinamento, denominadas *forward* e *backward*. A fase *forward* é utilizada para definir a saída a partir dos valores de entrada, já a fase *backward*, compara a saída obtida durante a fase *forward* com a saída desejada e retorna atualizando os valores das variáveis livres.

Segundo Brandão (2005), deve-se tomar cuidado para o caso de *overfitting* (ou superajuste), que é o caso onde existe uma grande quantidade de neurônios e camadas ocultas, aumentando a complexidade da rede, para solucionar um problema simples, de modo que a MLP ao invés de generalizar as informações ela acaba memorizando os padrões apresentados, não sendo capaz de classificar corretamente padrões semelhantes. Por outro lado, caso o número de neurônios e camadas ocultas seja inferior ao desejado, pode ocorrer o *underfitting*, onde a RNA não conseguir convergir para uma solução devido à sobrecarga de informações a serem armazenadas em poucos parâmetros livres.

O treinamento da MLP tem como objetivo principal a minimização da função erro quadrático médio (*MSE – Mean Square Error*), definida pela Equação 6. O treinamento da RNA deve ocorrer até que seja completo o número de interações predeterminado ou quando o *MSE* se encontra abaixo do que um valor pré-estabelecido (BRANDÃO, 2005).

$$mse = \frac{1}{k} \sum_{\rho} \sum_{i=1}^k (d_i^{\rho} - y_i^{\rho})^2 \quad (6)$$

A variável ρ representa o número de padrões apresentados a rede, k é o número de unidades de saída, d_i é a i -ésima saída desejada e y_i é a i -ésima saída gerada pela rede.

3. METODOLOGIA

3.1 PROTOCOLO DE COLETA DE DADOS

Durante a fase de coleta do sinal EMG seguiu-se um protocolo baseado em toda fundamentação deste trabalho, com o intuito de obter um sinal adequado e evitar discrepâncias entre os sinais obtidos de um mesmo movimento. Pode-se definir o protocolo como uma série de pontos que devem ser analisados e executados de forma sequencial, dos quais são eles:

- Configuração da coleta;
- Músculos e movimento analisados;
- Preparo do voluntário;
- Duração e repetições de cada movimento durante a coleta;

Neste trabalho os dados coletados foram extraídos do braço esquerdo de apenas um voluntário não deficiente, usando como referência o mesmo braço. A escolha da utilização de apenas um voluntário deve-se ao fato deste trabalho ter como um dos principais objetivos o desenvolvimento de uma metodologia de processamento voltada para cada usuário em particular, ou seja, para cada voluntário usuário da prótese são realizados todos os procedimentos necessários, desde a aquisição, processamento, classificação e validação.


Essa metodologia possibilita o desenvolvimento de uma análise voltada unicamente para cada usuário da prótese, aumentando assim a taxa de acerto. Uma justificativa relevante para a utilização desse tipo de metodologia deve-se as diferentes características fisiológicas encontradas em cada indivíduo, como a camada adiposa presente entre a epiderme e o músculo a ser estudado, o tamanho do músculo, deficiências motoras e funcionais, diferenças nos níveis de contração durante a aquisição, dentre outros. Outro fator relevante é o tempo gasto durante

todo o desenvolvimento desta metodologia, que embora transpareça ser grande, é estimado entre 6 a 7 minutos, possibilitando assim uma rápida análise individual.

3.1.1 Configuração da coleta

Para aquisição do sinal EMG utilizou-se eletrodos descartáveis passivos de superfície do tipo Ag/AgCl, devido sua facilidade de uso e qualidade do sinal captado. Para a aquisição do sinal EMG na sua forma digital utilizou-se a Analog Discovery 2 da fabricante Digilent para realizar a conversão. Adotou-se uma frequência de amostragem de 1 kHz, corroborando assim com o teorema de Nyquist-Shannon, que afirma que o sinal amostrado deve ter uma frequência no mínimo duas vezes maior do que a frequência do sinal original. A aquisição do sinal EMG foi feita a partir de dois canais desenvolvidos neste trabalho. Os dados foram adquiridos em janelas de 0,1s com sobreposição de 50 %, contendo 100 amostras cada. As Figuras 21 e 22 apresentam os eletrodos utilizados durante a coleta e a Analog Discovery 2 respectivamente.

Figura 21 – Eletrodos descartáveis Ag/AgCl utilizados durante a aquisição do sinal EMG.



Fonte: Próprio Autor.

Figura 22 – Analog Discovery 2 da fabricante Digilent utilizada para realizar a conversão A/D do sinal EMG.




Fonte: Próprio Autor.

3.1.2 Movimentos e músculos analisados

Com o intuito principal de desenvolver uma prótese para pessoas com membros amputados, foram estudados quatro movimentos possíveis de serem reproduzidos pela prótese utilizada neste trabalho, dos quais são: Mão Aberta (MA), Contração da Mão (CM), Contração Garra (CGA) e Contração Polegar (CPO). De acordo com a Figura 7 e a Tabela 1 apresentadas no Capítulo 2, para estes movimentos tem-se que realizar a análise dos seguintes músculos: palmar longo, extensor dos dedos e flexor superficial dos dedos. A Figura 23 ilustra os movimentos que serão analisados.

Figura 23 – Movimentos analisados: (a) Mão aberta; (b) Contração Garra; (c) Contração Mão; (d) Contração Polegar.



Fonte: Próprio Autor.

É relevante ressaltar que a utilização dos eletrodos de superfície juntamente com a disposição muscular interfere na precisão da coleta de dados quando se deseja estudar um músculo específico, isso ocorre devido a um fenômeno denominado *cross-talk* que ocorre quando os músculos estão muito próximos gerando assim uma interferência durante a coleta. Isso pode ser justificado pela falta de precisão desse tipo de eletrodo e a distância que os músculos se encontram, do qual poderia ser contornado com a utilização de eletrodos do tipo agulha. Entretanto, para este trabalho os resultados ainda se apresentaram satisfatórios no quesito de qualidade do sinal obtido para cada respectivo movimento, pois este trabalho baseia-se no estudo do sinal EMG resultante do movimento de um conjunto específico de músculos responsáveis pela realização de um movimento desejado e não em apenas um músculo em específico.

3.1.3 Preparo do voluntário

Com o intuito de evitar possíveis distorções geradas durante a captação do sinal EMG, se faz necessário realizar alguns procedimentos afim de preparar o voluntário. Primeiro foi realizado a limpeza na superfície da pele no local da captação, retirando os pêlos e aplicando álcool etílico. Posteriormente, com a finalidade de diminuir a impedância entre a superfície da pele e o eletrodo, utilizou-se gel condutor. Com isso os eletrodos foram posicionados de acordo com os músculos a serem estudados, sempre na direção vertical as fibras musculares e com uma distância máxima de 4 centímetros entre os eletrodos. Por fim conectou-se os eletrodos aos cabos blindados com terminações em plug P1 de forma a minimizar as possíveis interferências externas. A Figura 24 apresenta os cabos blindados utilizados para aquisição do sinal EMG.


Figura 24 – Cabos blindados com terminações em P1 utilizados na aquisição do sinal EMG.



Fonte: Próprio Autor

Durante a aquisição o voluntário ficará sentado e com o braço apoiado, de tal modo que ele fique relaxado verticalmente, sempre com cuidado para o eletrodo de referência presente no cotovelo não ser pressionado durante a aquisição, gerando assim interferências. A Figura 25 mostra a disposição dos eletrodos no braço do voluntário.

Figura 25 – Posicionamento dos eletrodos no braço do voluntário.



Fonte: Próprio Autor

3.1.4 Duração e repetições de cada movimento durante a coleta

Cada movimento em estudo foi realizado 4 vezes com uma duração de 5 segundos e com um intervalo entre dois movimentos também de 5 segundos, considerado que em todos os intervalos o movimento de mão aberta seria realizado, não houve necessidade de realizar uma aquisição voltada unicamente para esse movimento, portanto totalizaram-se três aquisições com uma duração de 40 segundos cada. Toda a coleta do sinal foi acompanhada com um cronômetro, com a finalidade de indicar para o voluntário, o tempo exato da execução do movimento e do repouso.

Após finalizar a aquisição de um movimento, ou seja, os quarenta segundos, aplicou-se um intervalo de um minuto com o intuito de evitar fadiga muscular que poderia vim a afetar os dados coletados. Logo, finalizando as três aquisições e considerando também o intervalo proposto, tem-se uma duração média de todo processo de aquisição de 5 minutos.

Todos os dados coletados foram armazenados, gerando assim um banco de dados referente a cada movimento e que posteriormente será utilizado para o processamento e treinamento da RNA.


3.2 PROCESSAMENTO DO SINAL

3.2.1 Janelamento do sinal

Após feita a coleta dos quatros movimentos em estudo, se faz necessário realizar um pré-processamento deste sinal, para que seja possível extrair as características estatísticas. Este pré-processamento baseia-se na segmentação do sinal coletado. Na metodologia adotada neste trabalho optou-se por aplicar um janelamento de 0,1 segundos com um sombreamento de 50%, resultando em 20 janelas por segundo, ou seja, 800 janelas durante os 40 segundos de coleta.

Os intervalos de descanso entre as contrações indicam o repouso muscular e também são importantes para este estudo. Logo tanto os movimentos quanto o repouso são segmentados, afim de se obter uma classificação para cada um, ou seja, além do movimento em questão ser classificado e identificado o repouso também será identificado e classificado como o movimento de mão aberta. A Figura 26 ilustra um exemplo de segmentação realizada em sinal amostrado durante os 40 segundo, contendo 40.000 amostras.

Figura 26 – Exemplo de segmentação de um sinal amostrado.



Fonte: Próprio autor.

3.2.2 Obtenção das características estatísticas do sinal EMG

Extração de características é uma técnica para transformar o sinal EMG original em uma forma reduzida comumente chamada de vetor de características (SOARES & NOLETO, 2016). Com o objetivo de controlar uma prótese em tempo real, deve-se ter a preocupação com tempo de resposta dos procedimentos realizados durante todo o processamento do sinal. Toda a metodologia descrita neste trabalho, desde aquisição do sinal, processamento, classificação e controle da prótese, deve durar no máximo 300 ms para que não seja perceptível pelo usuário da prótese (BARROS, 2005). Portanto as técnicas adotadas para extração do sinal devem possuir uma matemática simples e eficiente.

Para este trabalho foram analisadas as seguintes características no domínio do tempo:

- *Waveform Length* – WL;
- *Root Mean Square* – RMS;
- *Mean Absolut Value* – MAV;
- *Difference Absolute Standard Deviation Value* – DASDV;
- *Log Detector* – LOG;
- *Variance of EMG* – VAR;
- *Myopulse Percentage Rate* – MYOP.

Abaixo são apresentados os cálculos para obtenção de cada característica estatística, onde x_i é a i -ésima amostra de amplitude do sinal EMG e N é o comprimento da janela de amostras na qual está sendo extraído a característica.

Segundo Soares e Noleto (2016), o comprimento da forma de onda (WL) serve para analisar a complexidade da forma de onda para cada segmento. É calculado como a soma do valor absoluto das diferenças de comprimento entre duas amostras adjacentes como visto na Equação 7.

$$WL = \sum_{i=1}^{N-1} |x_{i+1} - x_i| \quad (7)$$

A raiz do valor quadrático médio (RMS) é uma característica popular na análise do sinal EMG, onde sua modelagem é feita como um processo aleatório gaussiano modulado em amplitude, que se relaciona com força constante e contração não fatigante (PHINYOMARK,

LIMSAKUL & PHUKPATTARANONT, 2012). A Equação 8 ilustra a definição matemática do RMS.

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (8)$$

A média do valor absoluto (MAV) é calculado como a somatória do modulo das amplitudes sobre o tamanho da janela, como pode ser visto na Equação 9.

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (9)$$

O valor de desvio padrão absoluto de diferença (DASDV) é semelhante ao RMS, ou seja, é um valor de desvio padrão do comprimento de onda do sinal EMG, do qual pode ser definido matematicamente pela Equação 10 (PHINYOMARK, LIMSAKUL & PHUKPATTARANONT, 2012).

$$DASDV = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (x_{i+1} - x_i)^2} \quad (10)$$

O detector de logaritmo fornece uma estimativa da força de contração muscular utilizada na reprodução do movimento em estudo, sua modelagem matemática pode ser observada na Equação 11 (PHINYOMARK, LIMSAKUL & PHUKPATTARANONT, 2012).

$$LOG = e^{\left[\frac{1}{N} \sum_{i=1}^N \log(|x_i|)\right]} \quad (11)$$

A Variância do sinal (VAR) é outro índice de potência, definida como uma média de valores quadrados do desvio dessa variável, do qual pode ser definida pela Equação 12 (PHINYOMARK, LIMSAKUL & PHUKPATTARANONT, 2012).

$$VAR = \frac{1}{N-1} \sum_{i=1}^N x_i^2 \quad (12)$$


A taxa média de pulso mioelétrico (MYOP) é a média do número de vezes em que a amplitude do sinal EMG ultrapassa o valor limite, esse valor limite é definido arbitrariamente e deve ser escolhido de acordo com o objetivo (SOARES & NOLETO, 2016). Sua modelagem matemática pode ser observada na Equação 13.

$$MYOP = \frac{1}{N} \sum_{i=1}^N [f(|x_i|)]; \quad f(x) = \begin{cases} 1, & x \geq \text{limite} \\ 0, & x < \text{limite} \end{cases} \quad (13)$$

Todas essas características são extraídas de cada janela, ou seja, como uma aquisição possui 40 segundos de duração e como está sendo amostrada a uma taxa de 1 kHz, considerando também a sobreposição de 50 %, tem-se um total de 800 janelas para cada movimento em estudo, portanto é gerado um total de 5.600 características estatísticas para cada movimento analisado.


O Janelamento é realizado para os dois canais desenvolvidos nesse trabalho, logo para cada janela gerada por ambos canais é gerado um vetor contendo quatorze características estatísticas, sendo sete de cada canal. A Figura 27 e 28 apresentam respectivamente, um exemplo de segmentação com uma sobreposição de 50%, gerando 20 janelas em um segundo e a extração mútua das variáveis estatísticas dos dois canais EMG, formando assim o vetor característico do sinal EMG.

Figura 27 – Segmento de um sinal EMG com um segundo de duração.



Fonte: SOARES e NOLETO, (2016).

Figura 28 – Extração mútua das variáveis estatísticas dos dois canais EMG, para formação do vetor característico.



Fonte: Próprio Autor.

3.2.3 Classificação do sinal EMG

O processo de classificação do sinal EMG fundamenta-se no reconhecimento padrão de características extraídas desse sinal durante a fase de processamento, ou seja, esse processo pode ser interpretado como resultado adquirido a partir da observação de algumas variáveis específicas associadas a um dado movimento.

Deve-se salientar que para o reconhecimento de padrões do sinal EMG alguns fatores de complexidade devem ser levados em conta como a mudança na posição dos eletrodos durante a captação do sinal, interferências de sinais externos, características fisiológicas do usuário da prótese e os tipos de movimentos a serem analisados. Diante desses fatores surgiu a necessidade da utilização de um classificador com habilidades de extrair as principais características responsáveis pelo reconhecimento padrão de cada movimento a partir das variáveis estatísticas.

Logo, baseado nas necessidades descritas, uma rede neural artificial do tipo MLP foi escolhida devido sua alta capacidade de aprendizado e classificação de sistemas não-lineares.

A rede neural implementada neste trabalho foi a Scikit-Learn desenvolvida em Python 3 pela empresa Google em 2007. A arquitetura dessa RNA baseia-se em uma camada de entrada com 14 neurônios, alimentados pelo vetor característico extraído dos dois canais e 02 camadas ocultas com 50 neurônios cada. A camada de saída possui apenas um neurônio, de modo que os resultados gerados por essa rede se resumam a um número inteiro que pode variar de 0 a 3, onde cada um desses números representam um movimento. Pode-se observar na Tabela 3 a saída da RNA e qual movimento essa saída representa.

Tabela 3 – Saída da RNA e seu respectivo movimento representante.

SAIDA DA RNA	MOVIMENTO
0	Mão Aberta
1	Contração mão
2	Contração Garra
3	Contração polegar

Fonte: Próprio Autor.

A escolha da arquitetura das camadas ocultas foi baseada em testes realizados, pois existem diversas possibilidades de configurações para uma rede neural classificar um único problema, provocando assim diferenciação entre as redes aplicadas e consequentemente ocasionando ou não melhorias nos resultados. Entretanto, como o foco deste trabalho não é o desenvolvimento de uma RNA específica para essa aplicação, foram feitos testes até a convergência do resultado esperado, determinando assim a configuração da rede utilizada.

Para realizar o treinamento da RNA, utilizou-se dos dados do voluntário coletados durante a fase de aquisição. Corroborando com toda a metodologia de coleta descrita no tópico 3.1.4, foram obtidos, 120 segundos (40x3) de dados para cada canal, considerando que cada segundo é composto por 20 janelas, e cada janela é constituída por 7 variáveis estatísticas, tem-se ao total um conjunto de 33.600 dados para o treinamento da rede.

Estes dados foram organizados em forma de matriz, em que cada linha representa uma janela e a coluna representa cada variável estatística extraída de cada canal, logo tem-se uma

matriz de treinamento de 2400x14. A Figura 29 a matriz de dados feita para realizar o treinamento da RNA.

Figura 29 – Matriz de treinamento 2400x14. As linhas representam as janelas obtidas durante a coleta dos quatros movimentos e as colunas representam as características extraídas por janela nos canais 1 e 2.


		CANAL 1							CANAL 2			
		WL ₁	RMS ₁	MAV ₁	DASDV ₁	LOG ₁	VAR ₁	MYOP ₁	WL ₂	RMS ₂	MAV ₂	. . .
JANELAS	1	WL ₁	RMS ₁	MAV ₁	DASDV ₁	LOG ₁	VAR ₁	MYOP ₁	WL ₂	RMS ₂	MAV ₂	. . .
	2	WL ₁	RMS ₁	MAV ₁	DASDV ₁	LOG ₁	VAR ₁	MYOP ₁	WL ₂	RMS ₂	MAV ₂	. . .
	3	WL ₁	RMS ₁	MAV ₁	DASDV ₁	LOG ₁	VAR ₁	MYOP ₁	WL ₂	RMS ₂	MAV ₂	. . .
	.	.	.	.	.	.	.	.	.	.	.	.
	.	.	.	.	.	.	.	.	.	.	.	.
	.	.	.	.	.	.	.	.	.	.	.	.
2400		WL ₁	RMS ₁	MAV ₁	DASDV ₁	LOG ₁	VAR ₁	MYOP ₁	WL ₂	RMS ₂	MAV ₂	. . .

Fonte: Próprio Autor.

As janelas estão ordenadas de acordo com cada movimento coletado, logo a cada 800 janelas tem-se um movimento específico, onde inicia-se com o movimento de contração mão, contração garra e contração polegar, sempre considerando que em cada intervalo de contração o movimento de mão aberta será reproduzido. A partir da plotagem dessas características estatísticas foi possível estabelecer um limiar que identificaria a região contendo contração e a região em repouso. Tal limiar possui um papel de suma importância para o treinamento da RNA, pois a partir dessa metodologia foi possível estabelecer um treinamento supervisionado.

A variável estatística utilizada para definir o limiar responsável por identificar as regiões de contração e repouso foi o WL (*Waveform Length*), pois a partir de uma análise gráfica foi possível observar que essa característica se comporta constante no momento de repouso e resulta em uma variação contínua durante a contração muscular, decaindo logo no momento de relaxamento. Esse fenômeno pode ser observado na Figura 30, onde tem-se o sinal EMG coletado dos dois canais e a variável características extraídos dos mesmos, tornando evidente que a partir de um limiar definido visualmente é possível identificar a região de contração e repouso.

Figura 30 – Sinal EMG obtido em canal e a extração da característica estatística WL de cada um dos canais.



Fonte: Próprio Autor.

Vale ressaltar que essa metodologia de estabelecer um limiar a partir de uma variável estatística está ligada intrinsecamente com as características fisiológicas de cada voluntário, ou seja, todo processo desenvolvido para identificar o movimento só é válido para o usuário em questão. Para que o sistema seja aplicado a outros usuários é necessário realizar novas aquisições com o novo usuário, de modo a extrair as características estatísticas e encontrar a variável que possui um comportamento similar ao sinal original, tornando possível assim a definição de um novo limiar.

Durante a fase de treinamento da RNA realizou-se a aquisição do sinal EMG dos dois canais, gerando assim uma matriz de 2.400x14, já para teste da RNA outra aquisição foi realizada considerando a mesma metodologia adotada para o treinamento, entretanto foram geradas 3 matrizes 800x14, onde cada uma representa um movimento (sempre considerando

que o movimento de mão aberta está presente em todos as 4 matrizes, representando o intervalo de repouso entre as contrações).

Essa metodologia de teste foi adotada devido a possibilidade de observar graficamente a eficiência da rede em classificar cada movimento específico. Com tal método de validação pôde-se também estabelecer uma análise quantitativa de acertos, de modo que cada resultado obtido para cada uma das 800 janelas de cada movimento será comparado com o resultado desejado, resultando uma porcentagem de acertos para cada movimento.

3.2.4 Desenvolvimento da prótese

A prótese do braço esquerdo utilizada neste trabalho foi obtida a partir do InMoov (primeiro robô de tamanho real impresso em código aberto 3D), criado por Langevin, (2012). O site desse projeto possui todas as peças desse robô para serem baixadas gratuitamente no formato próprio para impressão 3D (.stl), bem como todo o procedimento para efetuar sua montagem. Vale ressaltar que, como a finalidade deste trabalho se detém ao desenvolvimento de uma prótese do braço esquerdo, logo nenhuma outra parte desse robô foi fabricada. A Figura 31 apresenta o robô InMoov completo.

Figura 31 – Robô InMoov desenvolvido pelo francês Gael Langevin.



Fonte: Langevin, (2012).

Para fabricação da prótese utilizou-se da impressora 3D GT Max que se encontra no laboratório da Engenharia Mecânica da UFERSA (Universidade Federal Rural do Semi-Árido), Campus Caraúbas. A Figura 32 e 33 apresentam respectivamente a impressora 3D GT Max e o filamento ABS 1,75 mm (utilizado para impressão da prótese).

Figura 32 – Impressora 3D GT Max.



Fonte: <https://www.gtmax3d.com.br/kwpdxeyth-impressora-3d-pro-gtmax3d-core-a1>.

Figura 33– Filamento ABS 1,75mm utilizado para realizar a impressão das peças.



Fonte: Próprio Autor


Com a RNA treinada, validada, testada e com a prótese fabricada inicia-se o desenvolvimento de uma metodologia destinada para o controle desta prótese a partir dos dados de saída da RNA.

A partir do resultado obtido da RNA, desenvolveu-se um código que permitiu fazer a conexão entre a RNA criada em Python 3 e o controlador utilizado, que no caso foi o Arduino UNO. A escolha da utilização do Arduino UNO para controle dos atuadores da prótese deve-se ao seu baixo custo e facilidade de programação.

Como a prótese InMooV possui cinco servos atuadores (um para cada dedo) como pode-se observar na Figura 34, houve também a necessidade de desenvolver um código que possibilitasse o controle da angulação dos cinco servos, de modo a reproduzir os quatros movimentos em estudo. Para isso foi necessário realizar diversos testes, com o intuito de encontrar a angulação exata de cada servo para reproduzir os quatros movimentos em estudo.

Para alimentação dos servos atuadores utilizados na prótese utilizou-se uma fonte de alimentação externa, pois a corrente exigida por cada um poderia chegar até 600 mA, como essa corrente é dependente diretamente da carga imposta pela aplicação, logo pôde-se observar com os testes realizados que a alimentação do Arduino UNO não poderia suprir tal necessidade, exigindo assim uma alimentação externa.

Figura 34 – Prótese InMooV aberta, com os cinco servos responsáveis pela reprodução dos movimentos.




Fonte: Próprio Autor.

4. RESULTADOS

4.1 CIRCUITO DE AQUISIÇÃO

A partir do circuito descrito no sub-tópico 2.3.6, foi possível desenvolver duas placas de aquisição como apresentado na Figura 35. Cada placa é responsável por um canal, de modo que cada uma possui dois potenciômetros para ajustar filtro passa-alta e para regular o ganho do sinal obtido.


Figura 35– Circuito de aquisição do sinal EMG.



Fonte: Próprio Autor.


Após a fabricação das placas de aquisição, projetou-se uma estrutura para conter tais placas, juntamente com outra placa responsável pela entrada e saída de dados. Na mesma estrutura se encontra um espaço destinado para comportar a alimentação do circuito, que se dá através de duas baterias de 9 V. A Figura 36 e 37 ilustra respectivamente o projeto 3D de tal estrutura feita com o auxílio do software CAD 3D Autodesk Inventor e a estrutura fabricada e montada.

Figura 36– Estrutura desenvolvida para acoplar os dois circuitos de aquisição, placa responsável pelas entradas/saídas dados e o sistema de alimentação.



Fonte: Próprio Autor.

Figura 37– Estrutura montada com as placas de aquisição e entrada/saída de dados: a) Estrutura aberta e b) Estrutura fechada.



a)

b)


Fonte: Próprio Autor.

4.2 AQUISIÇÃO DO SINAL EMG

Com o circuito de aquisição finalizado, inicia-se a fase de aquisição do sinal EMG do voluntário. Tal etapa tem por finalidade construir um banco de dados contendo os 4 movimentos em estudo, tornando possível realizar o treinamento supervisionado da RNA utilizada neste trabalho. Corroborando com o tópico 3.1, pode-se determinar que a etapa de aquisição é composta por três aquisições de 40 segundos, sendo elas a aquisição da contração da mão, contração garra e contração polegar. Como descrito no tópico 3.1.4, o movimento de mão aberta estará presente em todas as aquisições, pois determinou-se nesse trabalho que esse movimento representaria o intervalo entre os outros movimentos.


Como este trabalho possui dois canais de aquisição do sinal EMG, a aquisição dos três movimentos será realizada simultaneamente para os canais 1 e 2, como pode-se observar nas Figura 38 e 39.

Figura 38– Coleta realizada no canal 1 para as três aquisições.



Fonte: Próprio Autor.

Figura 39– Coleta realizada no canal 2 para as três aquisições.



Fonte: Próprio Autor.


A partir de uma análise gráfica dos canais 1 e 2, pode-se constatar que a reprodução de um dado movimento específico possui diferentes formas de onda durante sua aquisição de 40 segundos. Isso ocorre devido a dificuldade em reproduzir o mesmo movimento com a mesma intensidade de contração e duração, porém mesmo com tais dificuldades verificou-se uma similaridade entre as contrações obtidas durante uma aquisição. Portanto, pode-se afirmar que a partir de tal análise constatou-se a existência de um padrão no sinal EMG para os movimentos em estudo. Vale destacar que o posicionamento dos eletrodos dos canais 1 e 2, está diretamente ligado a forma de onda coletada, ou seja, caso haja uma mudança repentina no local de captação do sinal EMG, isso acarretará uma alteração do sinal captado, podendo comprometer todo o sistema de classificação.

4.3 PROCESSAMENTO DO SINAL EMG

Após realizado as três aquisições do sinal EMG, inicia-se a fase de processamento. Nessa etapa, como descrito no sub-tópico 3.2.2, para cada aquisição obtida será feito a extração de sete características estatísticas: RMS, MAV, VAR, LOG, MYOP, WL e DASDV. Esse processamento tem por finalidade obter essas 7 variáveis para posteriormente aplicá-las à


entrada da RNA utilizada, com intuito de obter os parâmetros livres da rede durante o treinamento supervisionado. A Figura 40 e 41 denotam, respectivamente, um exemplo de processamento realizado para o movimento de contração polegar do canal 1 e 2.

Figura 40– Exemplo de obtenção das 7 variáveis estatísticas para o movimento de contração do polegar obtido no canal 1.



Fonte: Próprio Autor.

Figura 41– Exemplo de obtenção das 7 variáveis estatísticas para o movimento de contração do polegar obtido no canal 2.



Fonte: Próprio Autor.

De acordo com as Figura 40 e 41, pode-se observa que as variáveis estatísticas possuem um comportamento similar ao sinal EMG, de modo que no momento da contração muscular verifica-se uma variação mais acentuada em todas as características estatísticas. Isso ocorre, pois, essas variáveis estatísticas são utilizadas para análise no domínio do tempo, ou seja, a partir de uma variação de amplitude gerada durante a aquisição é gerado sete valores estatísticos referente a tal variação. Logo, quanto mais intenso for a contração muscular, maior vai ser os valores estatísticos gerados referente a essa variação.

Feito uma análise entre o sinal EMG dos dois canais, nota-se que para o canal 1 o movimento de contração do polegar obteve uma maior amplitude quando comparada com o

canal 2, tal diferença foi causada pela localização dos eletrodos de captação dispostos no braço do voluntário. Esse fato é responsável pela menor variação das variáveis estatísticas do canal 2, em comparação ao canal 1.


4.4 CLASSIFICAÇÃO DO SINAL EMG

Essa etapa é composta por dois momentos:

- Treinamento e validação da RNA a partir de um banco de dados composto por uma matriz de treinamento 2400x14;
- Teste realizado a partir de outro banco de dados composto por 3 matrizes de 800x14, onde cada matriz é um dado movimento.


Durante o treinamento da RNA, como descrito no tópico 3.2.3, utilizou-se as variáveis estatísticas como entrada da rede e a variável WL como identificador de contração, para que fosse possível a realização do treinamento supervisionado. Foi utilizado 90% do banco de dados durante a fase de treinamento e 10% para realizar a validação após o treinamento. A Figura 42 e 43 demonstram, respectivamente, os resultados obtidos de acurácia e perda dos dados durante a fase de treinamento e validação durante o treinamento.

Figura 42– Acurácia e perdas de dados durante a fase de treinamento.



Fonte: Próprio Autor.

Figura 43– Acurácia e perdas de dados durante a fase de validação.




Fonte: Próprio Autor.

Pode-se constatar que durante a fase de treinamento a RNA obteve aproximadamente uma acurácia de 99 % e uma perda de dados de 3 % com menos de 10 iterações. Já durante a fase de validação, a RNA necessitou de 20 iterações para conseguir obter resultados constantes, resultando em uma acurácia de aproximadamente 98 % e uma perda de dados de 3 %.


Após realizado o treinamento e validação da RNA, inicia-se a fase de teste da rede a partir de um banco de dados contendo 3 matrizes 800x14, onde cada matriz representa a aquisição de um dos três movimentos, como pode-se observar nas Figuras 44, 45 e 46.

Figura 44– Teste da RNA realizado partir de uma matriz 800x14 representando o movimento de contração garra.




Fonte: Próprio Autor.

Figura 45– Teste da RNA realizado partir de uma matriz 800x14 representando o movimento de contração mão.



Fonte: Próprio Autor.

Figura 46– Teste da RNA realizado partir de uma matriz 800x14 representando o movimento de contração polegar.



Fonte: Próprio Autor.

A partir de uma análise das Figuras 44, 45 e 46, pode-se denotar os resultados obtidos, em termos de acurácia e perda de dados durante a classificação. A Tabela 4 ilustra tais resultados.

Tabela 4 – Resultados obtidos durante a fase de teste da RNA.

MOVIMENTO	ACURÁCIA	ERRO
Contração Garra	98,74%	1,15%
Contração Mão	98,99%	0,005%
Contração Polegar	99,99%	0,11%
Mão Aberta	100%	0%


Fonte: Próprio Autor.

Fundamentado nos resultados da Tabela 4, constata-se a eficiência da RNA para a identificação dos 4 movimentos em estudo. Com uma acurácia média de 99,43 % e um erro de 0,31% a rede MLP se mostrou capaz de obter ótimos resultados, comprovando que os sinais EMG são passíveis de serem classificados a partir de algoritmos modernos, permitindo assim o desenvolvimento de próteses mioelétricas baseadas em controle inteligente.

4.5 CONTROLE DA PRÓTESE

Após a RNA ser validada e testada, inicia-se a fase de aplicação do controle da prótese a partir da saída gerada pela rede. Nessa etapa se faz necessário a utilização de uma fonte DC externa para alimentação dos servos motores presentes na prótese e da placa Arduino UNO para realizar a conexão entre a saída da RNA e os servos motores, como descrito no tópico 3.2.4. A Figura 47 ilustra todos os dispositivos necessários para realizar o controle da prótese.

Figura 47– Dispositivos utilizados para realizar o controle da prótese.



Fonte: Próprio Autor.

A partir da Tabela 3 presente no tópico 3.2.3, nota-se a necessidade de desenvolver um código para controle da angulação de cada servo presente na prótese, e que varie de acordo com a saída da RNA. Para isso se fez necessário definir angulações específicas de cada servo motor responsável por cada dedo da prótese, para seja possível reproduzir diferentes movimentos. A Tabela 5 denota todas as angulações encontradas para cada servo motor, após feito diversos testes.


Tabela 5 – Angulações definidas em cada servo motor para reprodução dos 4 movimentos estudados.

	MA	CM	CPO	CGA
Servo Polegar	0°	120°	120°	120°
Servo Indicador	20°	130°	20°	130°
Servo Médio	20°	170°	20°	20°
Servo Anelar	20°	150°	20°	20°
Servo Mínimo	5°	140°	5°	5°

Fonte: Próprio Autor.


De acordo com a Tabela 5, pode-se reproduzir os 4 movimentos estudados nesse trabalho como mostra a Figura 48, 49, 50 e 51.

Figura 48– Prótese InMoov reproduzindo o movimento de Mão Aberta.




Fonte: Próprio Autor.

Figura 49– Prótese InMoov reproduzindo o movimento de Contração Garra.



Fonte: Próprio Autor.

Figura 50– Prótese InMoov reproduzindo o movimento de Contração Mão.



Fonte: Próprio Autor.

Figura 51– Prótese InMoov reproduzindo o movimento de Contração Polegar.



Fonte: Próprio Autor.

5. CONCLUSÃO

Neste trabalho foi desenvolvido uma metodologia de aquisição, processamento e classificação de sinais eletromiográficos, com o intuito de controlar uma prótese. Para tal feito, inicialmente foi necessário desenvolver um circuito de aquisição composto por dois canais EMG e para a conversão desse sinal analógico para digital foi utilizado a Analog Discovery 2. Após feita a aquisição houve a necessidade de desenvolver um código para realizar o processamento e classificação do sinal obtido, para isso utilizou-se a linguagem de programação Python 3. Para controle da prótese utilizou-se a placa Arduino UNO juntamente com uma fonte externa DC para alimentar os servos motores presentes na prótese.

O emprego das variáveis estatísticas possibilitou desenvolver uma metodologia de processamento bastante complexa, tornando possível o processamento do sinal EMG em tempo real. Sua aplicação propiciou também aplicar um identificador de contração para tornar possível a utilização de um treinamento supervisionado, com base na variável estatísticas WL.

A rede Skiti-Learn utilizada na etapa de classificação, foi treinada de forma *off-line*, a partir das variáveis estatísticas obtidas durante o processamento do sinal. Durante essa fase de treinamento utilizou-se um banco de dados, do qual 90 % desses dados foram destinados para o treinamento e 10 % para a validação do treinamento. A partir disso foi possível observar que a RNA obteve uma acurácia média de 99 % e uma perda de dados de 3 % com menos de 10 interações durante o treinamento, já durante a fase de validação observou-se que a mesma obteve uma acurácia média de 98 % e uma perda de dados de 3 % com 20 interações, constatando assim a possibilidade da utilização dessa rede para aplicação deste trabalho.

A Tabela 4 permite observar que a rede *Perceptron* de Multicamadas sintetizada a partir da Skiti-Learn apresentou uma acurácia de 100 % para movimento de mão aberta, 98,99 % para contração mão, 98,74 % para contração garra e 99,99 % para contração polegar, resultando em uma acurácia média de 99,43 %. Tal resultado evidência a eficácia da RNA utilizada, para o proposito em questão.

A aplicação do Arduino UNO possibilitou realizar a conexão da saída da rede com os atuadores da prótese, de modo que foi possível desempenhar a calibragem da angulação de cada servo separadamente, como pode-se observar na Tabela 5. Tal ajuste possibilitou uma reprodução satisfatória dos movimentos da prótese, como visto nas Figura 48, 49, 50 e 51.

Portanto diante os fatos apresentados, pode-se concluir que a utilização da impressora 3D para fabricação da prótese InMoov, juntamente com o desenvolvimento de metodologias de

aquisição, processamento e classificação possibilitou a criação de um protótipo de baixo custo e funcional, diferentemente das próteses mioelétricas existente no mercado atual, que embora possuem grande funcionalidade seu preço ainda é bastante alto.

3.1 TRABALHOS FUTUROS

O Trabalho apresentado pode ser estendido das seguintes formas:

- Aumentar o número de canais de aquisição do sinal EMG;
- Extração de mais variáveis estatísticas;
- Realizar um estudo minucioso acerca das melhores variáveis estatísticas utilizadas para o controle de uma prótese;
- Utilizar outros tipos de RNAs para realizar a classificação do sinal EMG;
- Aumentar o número de movimentos analisados.
- Fazer um estudo acerca da otimização do tamanho da janela utilizada durante o processamento do sinal;

6. REFERÊNCIAS

AMADIO, A. C.; SERRÃO J. C. **Contextualização Da Biomecânica Para A Investigação Do Movimento: Fundamentos, Métodos E Aplicações Para Análise Da Técnica Esportiva**. São Paulo: Revista Brasileira de Educação Física e Esporte, v. 21, 15 dez. 2007. Disponível em: <<https://www.revistas.usp.br/rbefe/article/download/16665/18378>>. Acesso em: 08 fev. 2018.

AMADIO, A.C.; DUARTE, M. **Fundamentos biomecânicos para análise do movimento**. São Paulo: Lemos, 1998.

AMORIM, A. F. **Identificação Do Glaucoma Utilizando Redes Neurais Com Implementação Em FPGA**. 66f. Monografia (Graduação em Engenharia Elétrica) – Universidade Federal Rural do Semi-Árido, Caraúbas, 2016.

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

AZEVEDO, F.M. **Avaliação do sinal eletromiográfico como parâmetro para determinação do limiar de fadiga muscular**. 2007. 131f. Tese (Doutorado) - Escola de Educação Física e Esporte, Universidade de São Paulo, São Paulo.

BARION, Diego P.; DOURADO, Marília A. L.; **Aquisição do sinal mioelétrico para acionamento de dispositivos**. 2015. 60f. Monografia (Graduação em Engenharia Elétrica com ênfase em eletrônica) - Escola de Engenharia de São Carlos. São Paulo, 2015.

BARROS, Kety R. **Metodologia para Classificação de Sinais EMG para Controle de Prótese com Baixo Esforço Computacional**. 60f. Monografia (Pós-Graduação em Engenharia Elétrica) - Universidade Federal de Uberlândia, Faculdade de Engenharia Elétrica, Uberlândia, 2005.

BERMUDEZ, R.; BALBINOT, A.; SGUCK, A. **Caracterização de Movimentos do Segmento Mão-Braço Através de Wavelets e Redes Neurais Artificiais**. XXIV Congresso brasileiro de Engenharia biomédica. Porto Alegre: 2014.

BRAGA, A.; CARVALHO, A. P. L. F.; LUDEMIR, T. R. **Redes neurais artificiais: teoria e aplicação**. 2 ed. Rio de Janeiro: LTC, 2007. 226p

BRANDÃO A. S. **Redes neurais artificiais aplicadas ao reconhecimento de comando de voz**. 53f. Monografia (Graduação em Engenharia Elétrica) - Universidade Federal de Viçosa, Centro de Ciências Exatas e Tecnológicas, Viçosa, 2005.

CHOWDHURY, R. H. et al. **Surface electromyography signal processing and classification techniques**. Sensors (Basel, Switzerland), v. 13, n. 9, p. 12431–12466, 2013.

DE LUCA, C.J. **The use of electromyography in biomechanics**. In: **Jornal of Applied Biomechanics**. 13,135-163. 1997.

DELSYS. **Neuromuscular research center**. Boston University. Disponível em: <<http://www.delsys.com/library/papers>>. Acesso em 11 janeiro 2018.

ENOKA, R. M. **Bases neuromecânicas da cinesiologia**. São Paulo: Manole. 2000.**Signal**. Physics Letters A, 290(5–6), 297–303.

FAVIEIRO, G. W. **Desenvolvimento De Um Sistema Neuro-Fuzzy Para Análise De Sinais Mioelétricos Do Segmento Mão-Braço**. [s.l.] UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL, 2012.

GUTIERREZ, Peter. **Myo wearable used to control prosthetics**. 2016. Disponível em: <<https://www.iothub.com.au/news/myo-wearable-used-to-control-prosthetics-413793>>. Acesso em: 19 jan. 2016.

GUYTON, A.C.M.D.: **Fisiologia Humana 6ª edição**. Rio de Janeiro: Editora Guanabara. 1998. 543p.

HAYKIN, S. S. **Redes Neurais: Princípios e prática**. 2 ed. Porto Alegre: Bookman, 2001.

HERMES, H. J.; FRERIKS, B. **Development of recommendations for SEMG sensors and sensor placement procedures**. J Electromyogr Kinesiol. 10(5): 361-374, 2000.

HOLANDA, Priscila. C. **Desenvolvimento de uma rede neural multilayer Perceptron embarcada em FPGA**. 68f. Monografia (Graduação em Engenharia Elétrica) – Universidade Federal do Ceará, Fortaleza, 2013.

KAMEM, G.; GABRIEL, D. A. **Essentials of Electromyography**. Local: Humam Kinetics, 2010.

KONRAD, P. **The ABC of EMG: A practical introduction to kinesiological electromyography**. Noraxon Inc. USA. 2005.

LEI, M., WANG, Z., & FENG, Z. **Detecting nonlinearity of action surface EMG Signal**. Physics Letters A. 297–303, 2001.

LUCA, C. J. **Surface Electromyography: detection and recording**. DELSYS. 2002.

MARCHETTI, Paulo Henrique; DUARTE, Marcos. **Instrumentação em Eletromiografia**. São Paulo: Laboratório de Biofísica, Escola de Educação Física e Esporte da Universidade de São Paulo, 2006. 29 p. Disponível em: <<http://ebm.ufabc.edu.br/publications/md/EMG.pdf>>. Acesso em: 02 mar. 2018.

MATSUNAGA, Victoria Yukie. **Curso de Redes Neurais utilizando o MATLAB**. Belém. 2012.

MERLETTI, R. **Standards for Reporting EMG data**. Journal of Electromyography and Kinesiology, February, 1999.

MOHAMED, O.; PERRY, J.; HISLOP, H.: **Relationship between wire EMG activity, muscle length and torque of the hamstrings**. Clinical Biomechanics, Bristol, v.17, p.569-79, 2002.

ONISHI, H.; YAGI, R.; MOMOSE, K.; IHASHI, K.; HANDA, Y.: **Relationship between EMG signals and force in human vastus lateralis muscle using multiple bipolar wire electrodes**. Journal of Electromyography and Kinesiology. New York, v.10, p.59-67, 1999.

Phinyomark, A., Limsakul, C., & Phukpattaranont, P. **EMG feature extraction for tolerance of 50 Hz interference**. In Proceedings of 4th PSU-UNS International Conference on Engineering Technologies. pp. 289–293, 2009.

PHINYOMARK, A.; PHUKPATTARANONT, P.; LIMSAKUL, C. **Feature reduction and selection for EMG signal classification**. Expert Syst. Appl. 2012, 39, 7420–7431.

PRADHAN, A.; NAYAK, S. K.; RAY, S. S.; CHAMPATY, B.; ANIS, A.; TIBAREWALA, D. N. **Acquisition and Classification of EMG using a Dual-Channel EMG biopotential amplifier for controlling assistive devices**. India Conference (INDICON), 2016 IEEE Annual, 2016.

ROBERTSON, D. G. E.; CALDWELL, G. E.; HAMILL, J.; KAMEN, G.; WHITTLESEY, S. N. **Research methods in biomechanics**. United States: Human Kinetics. 2004.

SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.

SOARES, Igor M.; NOLETO, Luan M. B. **Eletromiografia aplicada ao controle de uma prótese virtual**. 2016. 70f. Monografia (Graduação em Engenharia Elétrica) - Universidade Federal de Goiás, Escola de Engenharia Elétrica, Mecânica e de Computação, Goiânia, 2016.

SOARES, Pablo L. B. **Aplicação de rede neurais em um conjunto de wavelets na detecção e atenuação de ruídos em imagens digitais e sísmicas**. 2013. 79f. Dissertação (Mestrado em Ciências da Computação) – Universidade Federal Rural do Semiárido, Mossoró, 2013.

WINTER, D.A. **Biomechanics and motor control of human movement**. 2nd ed. New York: John Wiley, 1990.

ZINVI FU, A.Y. BANI HASHIM, Z. JAMALUDIN, I. S. MOHAMAD, & N. Nasir. (2017). **Optimizing Surface Electromyography Acquisition Without Right Leg Drive Circuit**. International Journal of Engineering Science Technologies. 2017, 13-19.