



Sistema para Análise de Sinais Eletromiográficos Utilizando Redes Neurais Artificiais

Trabalho de Conclusão de Curso

Engenharia da Computação

**Thiago Brito de Andrade Tenório.
Orientador: Prof. Diego José Rativa Millam.**



UNIVERSIDADE
DE PERNAMBUCO

**Universidade de Pernambuco
Escola Politécnica de Pernambuco
Graduação em Engenharia de Computação**

Thiago Brito de Andrade Tenório

**Sistema para Análise de Sinais
Eletromiográficos Utilizando Redes
Neuras Artificiais**

Monografia apresentada como requisito parcial para obtenção do diploma de Bacharel em Engenharia de Computação pela Escola Politécnica de Pernambuco – Universidade de Pernambuco.

Recife, Novembro 2014.

De acordo

Recife

____/____/____

Orientador da Monografia

Dedico este trabalho a meus familiares e todos aqueles que torceram por mim e me ajudaram de alguma forma.

Agradecimentos

Gostaria de agradecer primeiramente a Deus pela força e coragem para batalhar e atingir meus objetivos. Ao meu querido pai, pelo melhor investimento que eu poderia receber, minha educação e meus princípios. À minha amada mãe, pelo amor e apoio incondicionais, seja nos momentos de alegria ou nos de tristeza. Por último, a todos que torceram e lutaram junto comigo de alguma forma para atingir esse resultado!

Muito Obrigado.

Resumo

Sinais eletromiográficos (EMG) (conhecido como sinais Mioelétricos) são sinais bioelétricos que são originados devido a ativação muscular e, portanto, diretamente relacionado ao homem e movimentos do corpo. Devido ao baixo nível de intensidade, os sinais Mioeletricos contêm um elevado grau de incerteza, são variáveis no tempo, não-lineares, dependes do usuário e são afetados por vários tipos de ruído que faz sua análise e tratamento difícil. Neste trabalho de conclusão de curso é proposta uma metodologia para usar o Valor Médio Absoluto do sinal como uma característica usada para treinamento de uma Rede Neural Artificial do tipo Perceptron Multi-Camadas para análise e classificação. Assim, a rede é usado para determinar se houve intenção de movimento pelo sujeito baseado na intensidade do sinal. O dados mioelétricos foram obtidos a partir da base de dados “rami-khushaba.com/electromyogram-emg-repository” e diversos composições de rede foram testados, obtendo como melhor resultado uma taxa de 91% de acerto para a classificação do sinal EMG.

Abstract

Electromyographic Signals (EMG) (known as Mioelectrical signals as well) are bioelectrical signals that are originated due to muscle activations, and therefore directly related to the human-body movements. Due to the low levels of intensity the Mioelectrical signals contain a considerable degree of uncertainty, are time-varying, non-linear, dependent on the user and are affected by various types of noise which makes their analysis and processing difficult. In this work is proposed a methodology that intends to use the Mean Absolute Value of the signal as a characteristic used to train an Artificial Neural Network of type Multi Layer Parceptron (MLP) for analysis and classification. Hence, the MLP network is used to determine if there was intention of movement by the subject based on the signal intensity. The Mioelectric data has been obtained from the database “rami-khushaba.com/electromyogram-emg-repository”, and various network compositions were tested, getting as best result a 91% accuracy for the classification of the EMG signal.

Sumário

Capítulo 1 Introdução	1
1.1 Motivação	1
1.2 Objetivos	2
1.2.1 Objetivo Geral	2
1.2.2 Objetivos Específicos	2
Capítulo 2 Fundamentação Teórica	3
2.1 Sistema Neuromuscular	3
2.2 Biopotenciais	6
2.2.1 Eletrocardiograma (ECG)	7
2.2.2 Eletromiograma (EMG)	7
2.2.3 Eletroencefalograma (EEG)	7
2.2.4 Eletrooculograma (EOG)	8
2.3 Eletromiografia	8
2.4 Próteses Inteligentes	13
2.5 Redes Neurais Artificiais	15
2.5.1 Neurônio Biológico	15
2.5.2 Neurônio Artificial	16
2.5.3 Multi-Layer Perceptron	17
2.5.4 Algoritmo Backpropagation	19
2.5.5 Critério de Parada	20
Capítulo 3 Metodologia	22
3.1 Base de Dados	22

3.2 Pré-processamento dos Dados	23
3.3 Arquitetura da Rede Utilizada	23
Capítulo 4 Resultados	26
4.1 Neurônios na Camada Escondida da Rede MLP	26
4.2 Desempenho do Sistema	29
Capítulo 5 Conclusão e Trabalhos Futuros	31
Bibliografia	32

Índice de Figuras

Figura 1.	Ilustração esquemática da unidade motora e componentes relacionados	4
Figura 2.	Exemplo de Sinal de EMG – captado durante fechamento da mão	8
Figura 3.	Despolarizada pelo influxo de Na ⁺ para o interior do sarcolema.	9
Figura 4.	Pulso de um Potencial de Ação da Unidade Motora.	10
Figura 5.	Neurônio Biológico	15
Figura 6.	Modelo Matemático de um neurônio biológico Mc-Culloch e Pitts.	16
Figura 7.	Arquitetura MLP com quatro Camadas.	18
Figura 8.	Melhor Ponto de Parada para o Treinamento.	21
Figura 9.	Posição dos Eletrodos para Captação do Sinal EMG	22
Figura 10.	Decaimento do EMQ para 5 Neurônios na camada escondida em função do número de épocas de treinamento.	26
Figura 11.	Decaimento do EMQ para 10 Neurônios na camada escondida em função do número de épocas de treinamento.	27
Figura 12.	Decaimento do EMQ para 15 Neurônios na camada escondida em função do número de épocas de treinamento.	27
Figura 13.	Decaimento do EMQ para 20 Neurônios na camada escondida em função do número de épocas de treinamento.	28
Figura 14.	Decaimento do EMQ para 25 Neurônios na camada escondida em função do número de épocas de treinamento.	28
Figura 15.	Desempenho de Classificação do Movimento da Mão variando os Neurônios da Camada Escondida.	29

Índice de Tabelas

Tabela 1. Tabela de Frequência dos Biopotenciais.....	6
--	---

Tabela de Símbolos e Siglas

EMG – Eletromiográficos/Eletromiograma

EMQ – Erro Médio Quadrático

IC – Inteligência Computacional

MLP – *Multi-Layer Perceptron*

PAUM – Potencial de ação da unidade motora

RMS – Valor Médio da Raiz Quadrada

RNA – Redes Neurais Artificiais

UMs – Unidades Motoras

Capítulo 1

Introdução

1.1 Motivação

Sinais Eletromiográficos (EMG) são sinais bioelétricos originados no cérebro, e são resultado da intenção humana de realizar algum movimento. Quando há uma contração voluntária, uma área no córtex cerebral faz com que o sistema neural motor periférico seja ativado. Este pode estar localizado na medula espinhal ou no tronco cerebral. Ao ser ativado, este sistema faz contato sináptico com os devidos músculos, provocando assim a contração das fibras musculares que constituem esta unidade motora [1]. Tais sinais contêm um considerável grau de incerteza, são variantes no tempo, não lineares, dependentes do usuário em questão e são afetados por diversos tipos de ruídos, o que dificulta sua análise e processamento [2].

Atualmente, o número de incapacitados, multilados e idosos vem crescendo. Esse grupo de pessoas sofre dificuldade em realizar movimentos básicos e essenciais ou por conta da ausência de determinado membro do corpo ou por conta das enfermidades provenientes da idade. Dentre os maiores colaboradores para esse crescente número de incapacitados, está os acidentes com motocicleta. Só no estado de Pernambuco em um período de dez anos, 5080 pessoas foram mortas e o número de feridos e sequelados é aproximadamente cinco vezes este valor [3].

Por meio da captura, através de eletrodos localizados no músculo de atuação, análise e processamento desse sinal EMG, é possível gerar a resposta adequada utilizando dispositivos que auxiliem no movimento desejado pelo paciente, dispositivos esses que podem vir a ser uma prótese robótica ou uma cadeira de rodas por exemplo. Isso levará a uma manipulação mais natural e intuitiva por parte do paciente. Utilizando essa solução, os pacientes voltarão a ser capazes de realizar parte dos movimentos, o que facilitará sua reintrodução na sociedade e promoverá sua independência novamente.

1.2 Objetivos

1.2.1 Objetivo Geral

Produzir um sistema pra classificar sinais de Eletromiografia utilizando técnicas de Inteligência Computacional para definir se existe ou não a intenção de movimento da mão por parte do sujeito. Tal sistema pode ser aplicado à próteses inteligente.

1.2.2 Objetivos Específicos

Extrair do sinal EMG a característica responsável por definir a intenção do movimento, que para o caso abordado será o Valor Médio Absoluto do sinal.

Criar uma estrutura de Rede Neural Artificial para a classificação do sinal EMG, utilizando como entradas do sistema os valores de Valor Médio Absoluto.

Capítulo 2

Fundamentação Teórica

2.1 Sistema Neuromuscular

A junção entre o sistema nervoso e o sistema muscular é também chamado de sistema neuromuscular. O mecanismo de contração muscular se inicia no sistema nervoso, por meio da liberação de neurotransmissores que são sintetizados pelo sistema nervoso. A troca de sinais no sistema nervoso é realizada pelos neurônios, pelos quais são conduzidos os impulsos nervosos e os neurotransmissores. Cada neurônio se liga a um determinado número de fibras musculares e essa união é chamada de unidade motora: a estimulação das fibras nervosas resulta em estimulação “tudo ou nada” de todos os seus terminais, causando contração de todas as células musculares da unidade ou de nenhuma delas. O neurotransmissor liberado pelo sistema nervoso que cria a ativação celular é chamado de Acetilcolina, e tem como objetivo iniciar o processo da contração muscular. As primeiras adaptações ao treinamento são adaptações neurais, são adaptações que auxiliam a maneira de recrutar as unidades motoras. Algumas das adaptações são: recrutamento de um maior número de unidades motoras, melhora no sincronismo de recrutamento das unidades motoras, maior frequência no disparo dos impulsos nervosos, que tem como consequência a melhora do gesto motor e da coordenação motora inter e intra-muscular [4]. O primeiro crescimento da capacidade de gerar força se dá pelas adaptações neurais, e posteriormente pela adaptação das estruturas musculares. Por isso, a força do indivíduo é elevada, mesmo não possuindo ainda o processo conhecido como Hipertrofia Muscular.

É definido como Unidade Motora o conjunto de todas as fibras musculares de um dado músculo (desde algumas até centenas, dependendo do músculo) inervadas por um único nervo motor, juntamente com o neurônio, do qual este nervo se origina como mostrado na (Figura 1) [5]. Um músculo, em geral, e seu nervo motor apresentam milhares de unidades motoras.

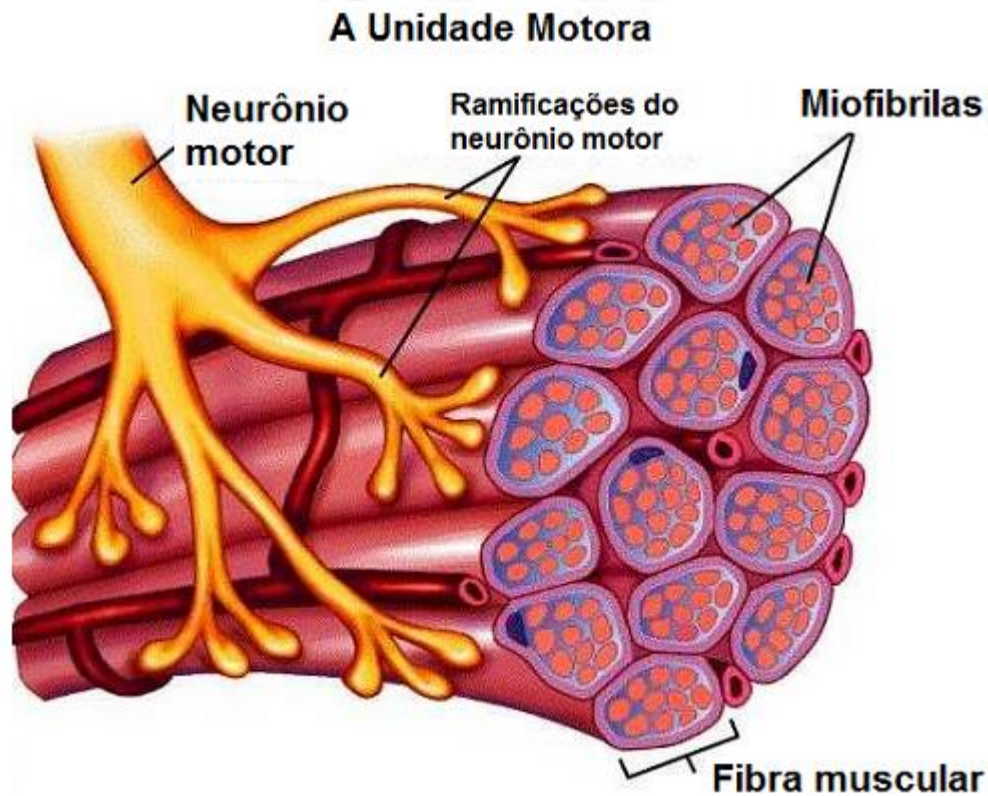


Figura 1. Ilustração esquemática da unidade motora e componentes relacionados.

[Fonte: http://henrysamenezes.blogspot.com.br/2013_10_01_archive.html]

Ambos os neurónios motor como as unidades motoras inervadas por estes podem variar em tamanho. Neurónios motores pequenos inervam relativamente poucas fibras musculares, compondo unidades motoras capazes de gerar menor força. Já neurónios motores grandes inervam uma maior quantidade de fibras musculares, compondo unidades motoras maiores e com mais potência.

As unidades motoras também diferem em relação ao tipo de fibras musculares que inervam. Na maioria do músculo esquelético, as unidades motoras pequenas inervam as fibras musculares classificadas como “vermelhas”, que contraem lentamente e geram uma força relativamente menor.

Por outro lado, por causa da sua composição abundante em mioglobina, capilares e mitocôndrias, estas fibras vermelhas são mais resistentes à fadiga. São, por isso, importantes para as atividades que exigem uma contração muscular regular, tal como caminhar ou manter uma postura erecta.

Os neurônios motores de maior dimensão inervam as fibras musculares “brancas”, que contraem rapidamente e geram mais força. Por outro lado, tais fibras têm escassas mitocôndrias e, conseqüentemente, fatigam-se mais rápido. São particularmente importantes para atividades breves que necessitam de uma grande quantidade de energia e força, como por exemplo, saltar.

Uma outra classe de unidades motoras possui características que se situam entre as duas abordadas anteriormente. Tais unidades motoras são de tamanho médio e não geram força de forma tão rápida como as descritas no parágrafo anterior [6].

Além da estimulação endógena, as fibras nervosas podem ser despolarizadas por uma fonte externa, como por exemplo, um estimulador de nervos. As fibras nervosas possuem diferentes limiares para reagirem ao estímulo de uma corrente exógena. As diferenças podem ser atribuídas a fatores tais como a distância entre as fibras e o eletrodo de estimulação. Todas as fibras de um feixe nervoso respondem a uma dada corrente apenas quando a intensidade desta corrente for máxima ou supramáxima.

A quantidade de acetilcolina liberada é influenciada pela concentração de cálcio ionizado no extracelular e pelo tempo de duração de seu fluxo para dentro da célula nervosa. Desta forma, a quantidade de vesículas de acetilcolina liberada é função do número total de íons cálcio no extracelular. O fluxo de cálcio para dentro do neurônio se estabelece favorável ao seu gradiente eletroquímico e cessa no momento em que ocorre o fluxo tardio de potássio para fora do neurônio. Assim, a 4-aminopiridina aumenta o conteúdo liberado porque bloqueia o fluxo de potássio, o que acarreta em aumento do fluxo de cálcio para dentro do neurônio.

A entrada de cálcio é um evento crítico para a liberação de acetilcolina. A presença do cálcio intracelular ativa um grupo de proteínas especializadas, dentre elas sinaptofisina e sinapsina I, algumas vezes diretamente e outras indiretamente, através de outras proteínas como a calmodulina. Esse processo resulta na ativação da fusão das vesículas de acetilcolina na membrana pré sináptica e a liberação de seus conteúdos na fenda sináptica [5].

2.2 Biopotenciais

O ser humano é uma fonte abundante e complexa de sinais elétricos devido a atividade celular dos mais diversos sistemas que compõem nosso corpo, e como qualquer medição tem o propósito de uma compreensão maior daquilo que se está medindo, e nesse caso em específico o apelo é ainda maior, pois compreende-se o ser humano como sistema. Existem 4 tipos principais de biopotenciais que podem ser medidos em um ser humano como mostra a (Tabela 1) e os sinais de cada um são: o eletrocardiograma(ECG), o eletromiograma(EMG), o eletrooculograma(EOG) e o eletroencefalograma(EEG).

Sinal	Gama de Frequências (Hz)	Gama de Amplitudes (mV)
ECG	0,01 – 100	0,05 – 3
EEG	0,1 – 80	0,001 – 1
EOG	0,01 – 10	0,001 – 0,3
EMG	50 - 3000	0,01 – 100

Tabela 1. Tabela de Frequência dos Biopotenciais.

[Fonte: http://fisica.uc.pt/data/20082009/apontamentos/apnt_182_9.pdf]

Tais biopotenciais devem ser associados com a atividade elétrica em nível celular, potenciais esses surgidos pela diferença de concentração de íons no interior e no exterior da célula. O gradiente de concentração eletroquímica através da membrana semipermeável da célula gera o potencial de Nernst, que é causado pela grande concentração de íons K⁺ no interior e Na⁺ no exterior, esse é conhecido como potencial de repouso. Algumas células são excitáveis e causam o potencial de ação, que resulta de um fluxo intenso de íons através dessa membrana em resposta a um estímulo elétrico ou transiente de carga sobre essa célula. A excitação de

células, correspondente à atividade de cada um dos sistemas citados anteriormente, gera corrente no volume condutor do seu entorno se manifestando como potencial no corpo. Alguns dos problemas comuns para a medição desses potenciais são a interferência biológica (pele, eletrodo, movimento) e o ruído externo [7].

2.2.1 Eletrocardiograma (ECG)

Entre os biopotenciais produzidos no corpo, o ECG é o mais intenso com sua amplitude na escala de alguns milivolts. É originado da atividade cardíaca e possui um comportamento que traduz a contração e relaxação periódica do músculo cardíaco.

O sinal é capturado posicionando sensores nos braços, nas pernas e no dorso. Ele é suscetível a distorções, causados por movimentos de músculos e da pele, já que o sinal na superfície da pele é de baixa amplitude, contudo devem e podem ser minimizados pela utilização de conectores específicos como os revestidos de prata (Ag), com cloreto de prata (AgCl) ou com sintetizados de Ag-AgCl. Duas aplicações características de amplificadores de ECG são em instrumentos como marca-passos e defibriladores [7].

2.2.2 Eletromiograma (EMG)

Menos conhecido e cujo comportamento difere dos outros biopotenciais por ser não-periódico. Um sinal elétrico é produzido quando existe contração de um músculo, esses sinais possuem alta frequência e podem disponibilizar alguma informação sobre a força aplicada pelo músculo. Como o sinal é de mais alta frequência e amplitude, é menos suscetível a distorções devido ao potencial da pele ou a movimentos. Esse fator pode ser reduzido ainda filtrando o sinal de frequências abaixo dos 20 Hz com um filtro passa-alta [7].

2.2.3 Eletroencefalograma (EEG)

É o mais tênue e complexo existente entre os biopotenciais. Tem como forte característica a amplitude muito baixa, na ordem de microvolts. Para captura, eletrodos banhados a ouro são colocados diretamente no escalpo para um contato de muito baixa resistência. Como reflete a ação de milhões de neurônios, é bastante complexo de ser interpretado, já que inclui sinal do tecido cerebral, do fluido e do

escalpo. Porém, alguns comportamentos podem ser interpretados através da modificação do comportamento da onda e principalmente através da modificação das frequências captadas, que podem traduzir os diferentes estados do sono e eventuais patologias associadas ou uso de medicamentos [7].

2.2.4 Eletrooculograma (EOG)

O movimento dos globos oculares no ambiente condutor do crânio gera um campo elétrico. Pode ser encarado como um dipolo se movimentando e criando um sinal, o qual pode ser utilizado para identificar o movimento dos olhos e disfunções no mesmo. Possui baixa amplitude, na faixa entre 10 – 100 μV , e baixa frequência essencialmente a 10 Hz. Portanto, se faz necessário o uso de amplificadores com alto ganho, e boa resposta a baixas frequências [7].

2.3 Eletromiografia

Trata-se de um método de registro dos potenciais elétricos gerados nas fibras musculares em ação, ver exemplo de sinal capturado na Figura 2. Enquanto técnica, consiste na aquisição e tratamento do sinal elétrico produzido na musculatura a partir da estimulação de unidades motoras (UMs).

Sinais EMG são usadas em diversas aplicações clínicas e biomédicas. É utilizado como ferramenta de identificação para enfermidade neuromuscular, avaliação de dor lombar, cinesiologia e distúrbios de controle motor, sendo também usado como sinal de controle para dispositivos protéticos [8].




Figura 2. Exemplo de Sinal de EMG – captado durante fechamento da mão.

[Fonte: http://tecmarketing.up.com.br/painelgpa/uploads/imagens/files/EngComputacao/Projetos%20Finais/2004/Noite/2004_RecEMG_Nilton.pdf]

Na biomecânica, a captura de sinais eletromiográficos permite a análise de quais músculos são requisitados em determinado movimento, o nível de ativação muscular durante a execução do movimento, a intensidade e duração da solicitação muscular, além de possibilitar inferências relativas à fadiga muscular [8].

A membrana pós-sináptica de uma fibra muscular é despolarizada pela entrada de Na^+ para dentro do sarcolema, cujo movimento de íons cria um campo eletromagnético na periferia das fibras musculares como mostra a Figura 3. O potencial de ação da unidade motora (PAUM) é o acúmulo temporal e espacial dos potenciais de ação individuais de todas as fibras de uma Unidade Motora. Para ter domínio da uma contração muscular, uma seqüência de estímulos é enviado pelo sistema nervoso, para que as Unidades Motoras sejam repetidamente ativadas, culminando em um pulso de PAUM, Figura 4, que indicará a taxa de disparo de impulsos eletromiográficos [8].




Figura 3. Despolarizada pelo influxo de Na^+ para o interior do sarcolema.

[Fonte: <http://www.cpaqv.org/mtpmh/eletromiografia.pdf>]

Na obtenção do sinal de Eletromiografia, a amplitude do PAUM depende de diversos elementos como a taxa de disparo, características da membrana da fibra muscular, diâmetro da fibra muscular, distância entre a fibra muscular ativa e o local de detecção do sinal EMG, a área de superfície de captação dos eletrodos e a

extensão em que os eletrodos estão distribuídos sobre o músculo, ou seja, o local de posicionamento dos eletrodos. O tecido existente entre a fibra muscular e o local do eletrodo cria um efeito de filtro passa-baixa, cuja largura de banda diminui com o aumento da espessura do tecido, isso quer dizer que quanto maior a espessura desse tecido, maior será a impedância, ou ruído, para captação do sinal EMG.

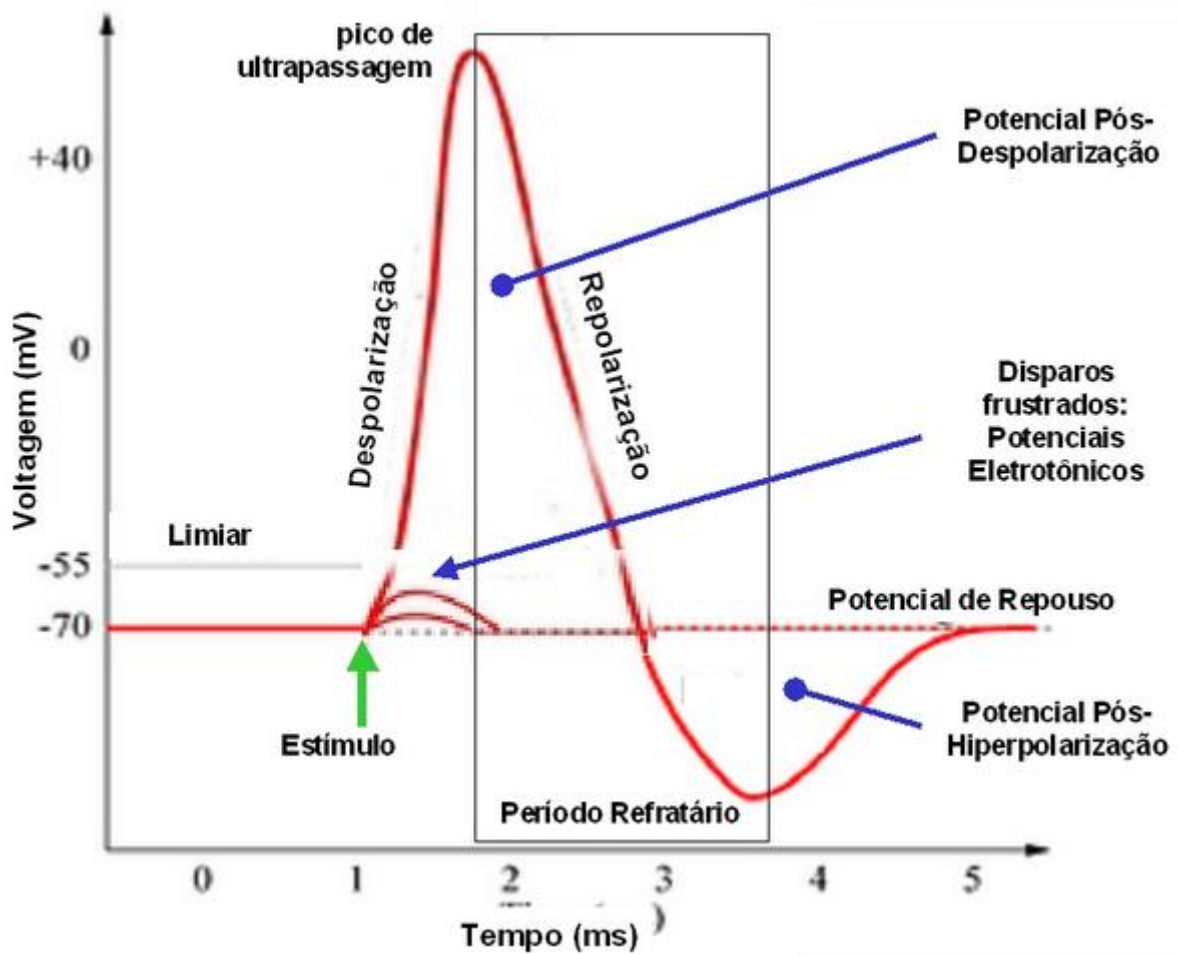


Figura 4. Pulso de um Potencial de Ação da Unidade Motora.

[Fonte: <http://fach-uefs-mascarenhasrb.blogspot.com.br/>]

Além do fato de a Eletromiografia ser dependente de propriedades fisiológicas, é também influenciada pelas propriedades não fisiológicas como a configuração do eletrodo: Tamanho, forma, colocação, tipo de filtro utilizado para a detecção do sinal. Com relação à captação do sinal EMG em músculos de elevada e diversificada penetração e que, inevitavelmente, apresentam fibras musculares de menor comprimento, com por exemplo o músculo quadríceps femoral, faz-se necessário maior rigor no controle dos locais em que são posicionados os eletrodos, evitando-se

assim a captura do sinal Eletromiográfico originada de diferentes UMs e respectivas fibras musculares em momentos diversos da investigação. A localização mais adequada do eletrodo é fixada entre o ponto motor e o tendão de inserção do músculo. Além disso, suas barras de captação devem estar perpendiculares às fibras musculares e suas superfícies de captação separadas por no máximo 40 mm, de forma a obter uma padronização mais fidedigna dos dados analisados, o SENIAM (Surface EMG for a Non-Invasive Assessment of Muscles) detalha esses procedimentos (recomendações de configuração e posicionamento dos eletrodos) [8].

O estudo da Eletromiografia depende do objetivo que incentivou a sua coleta. O sinal pode ser processado e posteriormente analisado nos domínios temporal e da frequência do sinal.

Em relação ao estudo no domínio do tempo, a intensidade do sinal advindo de músculos superficiais é minimizada por elementos como a resistência da pele e do tecido adiposo subcutâneo, que são diferentes de uma localização para outra. Neste sentido, não é correto comparar valores de EMG absolutos entre dois indivíduos distintos, de um músculo para outro, e até para o mesmo músculo se a colocação dos eletrodos é modificada. No domínio do temporal, o sinal consegue apontar o momento em que certo músculo iniciou e finalizou a sua ativação, mas também a amplitude do sinal EMG necessária para sua ativação. Neste tipo de análise específica é possível utilizar essencialmente os valores em RMS, a integral e o valor corrigido pela frequência média, que fornece entendimento da amplitude do sinal.

No domínio da frequência, é possível destrinchar o conteúdo de frequência deste sinal Eletromiográfico. Uma forma normalmente usada para caracterizá-la é a frequência média, que simboliza o valor central do espectro de frequência. Como outra alternativa, a frequência mediana é a frequência que reparte o espectro em duas metades com base no conteúdo de energia do sinal. Estes componentes refletem a velocidade de condução da fibra muscular e o recrutamento das UMs reduz com a exposição do indivíduo à fadiga muscular, demonstrando alterações antes de qualquer mudança de força, conseqüentemente são interpretados principalmente como um sinal de início de fadiga contrátil [8].

Uma estimativa alternativa reúne dados de Eletromiografia e dados anatômicos para se criar métodos de estimar a força muscular. Para este caso, a Eletromiografia é utilizada para o estudo do mecanismo fisiológico da modulação da força aplicada a certa resistência empregada a uma articulação. A força requisitada por um músculo em atividade é o somatório da atividade global de todas suas fibras musculares. Por outro lado, a Eletromiografia de superfície fornece apenas uma visão pontual da atividade elétrica gerada pelo músculo, pois o eletrodo de superfície não permite captar todo o sinal gerado no volume muscular. O estudo da determinação das amplitudes e direcionamento das forças que atuam nas articulações do corpo tem sido um assunto de extrema relevância, mas detêm algumas dificuldades na área da biomecânica. A medição das forças exercidas nas articulações e uma estimativa de como as mesmas são distribuídas para os músculos adjacentes, ligamentos e superfícies articulares são essenciais para compreender a função articular. Esta informação também é necessária no projeto de implantes ortopédicos e tratamentos cirúrgicos, no aperfeiçoamento de modelos biomecânicos, com foco na compreensão básica do sistema mecânico musculoesquelético humano e em processos de adaptações neuromusculares ao treinamento.

Já está bem claro também que a atividade elétrica no músculo é definida pela quantidade de fibras musculares solicitadas juntamente com a frequência média de excitação, os mesmos elementos que determinam a força muscular. A existência da correlação entre sinal Eletromiográfico e a força produzida durante qualquer contração muscular é aplicada no contexto de quanto mais longa a duração do PAUM, maior é a porcentagem de aumento na amplitude de EMG causada pela sincronização.

Filtros são usados para atenuar sinais e isolar uma determinada faixa de valores em várias áreas do conhecimento. Na Eletromiografia, quando a frequência do ruído difere da frequência do sinal de interesse, o uso de filtros permite a captura da parte útil do sinal.

- Fibras lentas na UMs: 70 – 125 Hz
- Fibras rápidas na UMs: 125 – 250 Hz
- Rede elétrica de 220 V: 60 Hz

2.4 Próteses Inteligentes

As próteses, que no passado se limitavam a substituir o membro perdido, evoluíram a tal ponto que não só tornam a vida de amputados mais plena, mas revolucionam o entendimento do corpo humano. Desde para-atletas a crianças que voltam a ouvir por conta de implantes cocleares, a utilização de próteses inteligentes promete ser uma das áreas mais inovadoras da ciência no século XXI [9].

Tais próteses inteligentes, funcionarão em conjunto com um sistema de controle que é em síntese um sistema de entrada(s)-saída(s). O sistema a ser controlado é, em geral, chamado de processo. O processo é um sistema dinâmico e seu comportamento pode ser descrito matematicamente por um conjunto de equações diferenciais.

A idéia básica de um sistema de controle é unir a entrada da leitura dos elementos sensores com a saída dos elementos atuadores. Estes sistemas recebem as informações lidas dos sensores para saber o atual estado do processo, executa cálculos e lógicas pré-definidas e envia o resultado para os atuadores, de modo que a situação atual do processo seja modificada para que se atinja um ponto de operação próximo do desejado [10].

Por 22 anos, o cientista brasileiro Miguel Nicolelis, diretor do laboratório de Neuroengenharia da Duke University, na Carolina do Norte, nos Estados Unidos, dedicou-se a achar um meio de fazer o cérebro e as máquinas trocar informações em tempo real [11]. Em 2008, ele obteve sua primeira conquista, mostrando ao mundo que era possível mover um robô apenas com a força do pensamento. Na época, apresentou um sistema capaz de transformar os impulsos elétricos emitidos pelo cérebro de uma fêmea do macaco rhesus em comandos digitais. Enviados pela internet ao Japão, os sinais fizeram um robô andar. Nicolelis e sua equipe da Duke University surpreenderam novamente ao anunciar que conseguiram fazer as máquinas conversar diretamente com algumas áreas do cérebro. Desta vez, outra fêmea do macaco rhesus moveu um braço virtual com a força do pensamento para selecionar figuras na tela de um computador. Usou para isso o mesmo sistema testado em 2008. Mas a experiência foi além: o animal não só selecionou os objetos na tela como foi capaz de sentir, no cérebro, a diferença entre eles. Apesar de idênticas na forma, cada figura emitia um sinal elétrico diferente, que indicava sua

textura. No cérebro, esses estímulos foram interpretados como sensações táteis com a ajuda de um microchip implantado com essa função. “Foi a primeira vez que se estabeleceu uma comunicação bilateral entre o cérebro e uma máquina”, disse Nicolelis [11].

O propósito de Nicolelis, que está à frente de uma iniciativa internacional chamada Walk Again (andar de novo), é aplicar a nova tecnologia para construir uma geração de próteses inteligentes, acionadas diretamente pelo pensamento, sem que os estímulos passem por outras partes do corpo. Assim, ele pretende devolver a mobilidade a pessoas tetraplégicas. Nesses casos, como as estruturas nervosas estão lesadas, as instruções dadas pelo cérebro para a realização de movimentos não chegam aos membros. Os achados do estudo conduzido na universidade americana estão sendo recebidos como avanço importante pela comunidade científica. Atualmente, muitos laboratórios procuram decifrar as mensagens motoras do cérebro para controlar cursores e membros robóticos, enquanto outros estudam como usar a estimulação elétrica dos tecidos para levar informações à mente.

Uma das possíveis aplicações dessas descobertas recentes será no aprimoramento de algumas próteses que utilizam sinais dos músculos para realizar movimentos de braços, por exemplo. A esperança é que esses estudos permitam intensificar a transmissão de dados e melhorar a eficiência dos aparelhos. Em relação ao futuro, seu impacto pode ser ainda mais extenso. “Conseguimos a liberação mais completa do cérebro que se pode imaginar. O órgão exerceu a capacidade perceptual sem precisar do corpo”, diz Nicolelis, que vislumbra diversos cenários nos quais a tecnologia interativa poderá ser empregada. Entre eles, o cientista cita o controle de instrumentos cirúrgicos inseridos no corpo e a opção de movimentar com o pensamento guindastes no fundo do mar ou robôs em áreas de risco [11].

Existe algumas limitações para a análise de sinais EMG. O tecido adiposo (gordura) pode afetar registros de EMG. Com o aumento do tecido adiposo abaixo da superfície onde será captado o sinal, a amplitude do sinal EMG diminui. Gravações de sinais EMG são tipicamente mais precisos para indivíduos com baixa gordura corporal e pele mais complascente, como jovens quando comparado com uma pessoa mais velha. Outra limitação é que o EMG de superfície é limitado devido

à falta de confiabilidade para captura do sinal de músculos profundos, já que tais músculos requerem fios intramusculares que são invasivos e dolorosos.

2.5 Redes Neurais Artificiais

Redes Neurais Artificiais é uma técnica de Inteligência Computacional (IC) inspirada no funcionamento do cérebro humano e, como tal, é composta por unidades básicas de processamento (os neurônios artificiais) [12]. Uma RNA é um sistema composto por unidades de processamento interconectadas, chamadas de neurônios, distribuídas em diferentes camadas trabalhando em união para a resolução de um problema.

2.5.1 Neurônio Biológico

O cérebro humano é composto por cerca de 10 bilhões de neurônios que se interconectam formando uma rede capaz de processar milhões de informações simultaneamente [13].

De forma simplificada, pode-se dizer que o neurônio biológico, ver (Figura 5), é composto pelo corpo celular, de onde saem ramificações que são os dendritos. Desse corpo celular, sai um prolongamento chamado axônio. A passagem do impulso nervoso entre dois neurônios se dá na região de sinapse, formada pela união dos axônios de um neurônio e os dendritos do outro. Essa transmissão ocorre do axônio de um neurônio para os dendritos do neurônio seguinte, e não no sentido contrário [13].

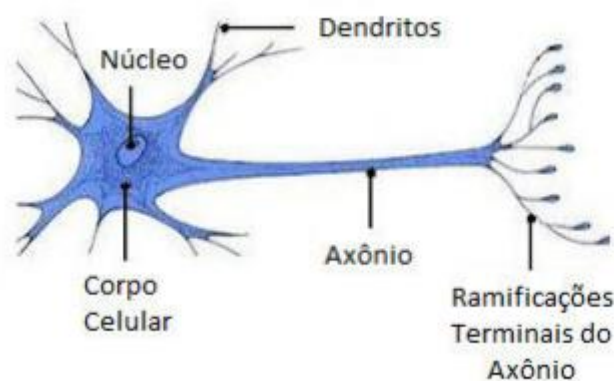


Figura 5. Neurônio Biológico

[Fonte: <http://psico12paratodos.blogspot.com.br/2013/05/neuronio.html>]

Um ponto importante para a compreensão do funcionamento de um neurônio biológico é que a informação é apenas repassada para outros neurônios se a intensidade do estímulo atingir o limiar excitatório (Lei do Tudo ou Nada). Portanto, se o estímulo for abaixo do desejado, isto é, se sua intensidade for inferior ao limiar excitatório, não ocorrerá impulso nervoso. Caso se atinja esse limiar, o potencial de ação do neurônio continuará o mesmo, não importando a intensidade do estímulo [14].

2.5.2 Neurônio Artificial

A primeira proposta de modelo matemático do neurônio biológico foi feita por Mc-Culloch e Pitts em 1943 [15]. O modelo é bastante simples, ver (Figura 6), formado por um conjunto de entradas, uma unidade de processamento e uma ou mais unidades de saídas, que correspondem, respectivamente, aos dendritos, corpo celular e os terminais axônicos do neurônio biológico [12].

O modelo proposto representa o neurônio biológico utilizando uma regra de propagação e uma função de ativação $f(net)$. A emissão de sinal por esse neurônio está baseada em um limiar em analogia com a Lei do Tudo ou Nada [13].




Figura 6. Modelo Matemático de um neurônio biológico Mc-Culloch e Pitts.

Cada entrada (X_i) é multiplicada por um peso (W_i) que representa a relevância daquela entrada para o neurônio. Ou seja, quanto mais importante aquela entrada, maior será seu peso. A soma do produto $X_i \cdot W_i$, dada pela Equação (2.1), é usada como parâmetro para a função de ativação $f(net)$. Esta função, por sua vez, retorna o valor de saída do neurônio.

$$net(i) = \sum_{i=0}^n x_i \cdot w_i \quad (2.1)$$

Os pesos do neurônio devem possuir valores que, ao multiplicá-los pela entrada, o valor de saída obtido se aproxime ao máximo da saída desejada. Logo, a inteligência do modelo de um neurônio artificial está nos pesos que o constitui [15].

A grande vantagem no uso de redes neurais artificiais para solução de problemas complexos provém, principalmente, de sua capacidade de aprendizagem através de exemplos e generalização da resposta adquirida durante o treinamento da rede. O treinamento, por sua vez, é um conjunto de regras adicionadas às RNAs, de modo a aumentar a sua capacidade de generalização. Ao ajustar os pesos das conexões entre os neurônios é possível atingir a generalização.

Os primeiros modelos de RNAs propostos foram o Perceptron e o Adaline. O Perceptron lida apenas com saídas discretas, enquanto o Adaline permite respostas no universo contínuo. Essa diferença ocorre na escolha das funções de ativação do neurônio.

Assim, a partir da união de neurônios artificiais, em uma ou mais camadas, é possível a construção das Redes Neurais Artificiais. Existem vários tipos de RNAs e uma das mais usadas é rede Perceptron Multi-Camadas [13].

2.5.3 Multi-Layer Perceptron

As redes Perceptron Multi-Camadas, ou *Multi-Layer Perceptron*(MLP), podem ser considerados uma generalização da rede Perceptron simples que apresentam, além das camadas de entrada e saída, a adição de pelo menos uma camada intermediária ou camada escondida.

A camada de entrada é formada por um conjunto de nós fontes, onde cada neurônio representa uma variável considerada como entrada para o problema. A camada intermediária e permite que as redes MLP sejam capazes de resolver

problemas considerados linearmente não separáveis. Os neurônios desta camada possuem geralmente uma ou mais funções de ativação sigmoideal que podem ser a logística ou a tangente hiperbólica. Já a camada de saída é responsável pela resposta da rede e representa a variável desejada. Em geral, essa variável é aquela que se deseja prever ou classificar. Os neurônios desta camada, além da função de ativação sigmoideal, também podem apresentar uma função do tipo linear.

A Figura 7 representa uma rede MLP com quatro camadas.




Figura 7. Arquitetura MLP com quatro Camadas.

A rede MLP é do tipo *feedforward*, ou seja, a informação se propaga em uma única direção. Sempre da camada de entrada para as camadas intermediárias e, em seguida, para a camada de saída.

Assim como o Perceptron e Adaline, é necessário a utilização de um algoritmo que estabeleça o conjunto de pesos finais para a rede MLP.

Esse processo é chamado de treinamento da rede. Nesse momento, os pesos que conectam os neurônios de uma camada com os neurônios da camada subsequente da rede são modificados para melhor se adequar ao problema. No entanto, a adição de uma ou mais camadas intermediárias torna o treinamento das redes MLP mais complexo.

Existem três tipos de aprendizado: supervisionado, não-supervisionado e por reforço [12]. As redes MLP aprendem de forma supervisionada.

No aprendizado supervisionado há o papel do “professor”, que conhece as respostas corretas para cada momento da rede. Dessa maneira, pode-se calcular o erro na saída da rede e, a partir dele, corrigir os pesos de forma que a rede se adeque melhor ao problema. A dificuldade em redes de múltiplas camadas está em corrigir os pesos dos neurônios, já que não se conhece o erro nas camadas intermediárias [12].

O algoritmo bastante utilizado para treinamento das redes MLP é conhecido como algoritmo *backpropagation* e resolve o problema da fase de treinamento citado anteriormente ao realizar uma propagação recursiva dos erros [13].

2.5.4 Algoritmo Backpropagation

O algoritmo backpropagation baseia-se no aprendizado por correção de erro (em que o erro é retro-propagado da camada de saída, passando pelas camadas intermediárias até a camada de entrada).

Basicamente, esse algoritmo consiste de dois passos: fase *forward*, que corresponde à propagação do sinal e a fase *backward*, que corresponde ao reajuste dos pesos. Há ainda dois importantes parâmetros nesse algoritmo: a taxa de aprendizado e o momento.

A taxa de aprendizado corresponde ao tamanho do passo em direção à correção do erro. Já o momento é utilizado para acelerar a convergência da rede e diminuir a incidência de mínimos locais [16].

O reajuste dos pesos é dado pela Equação (2.2):

$$W_{i,j}^m(t+1) = W_{i,j}^m(t) + \alpha \delta_i^m f^{m-1}(Net_j^{m-1}) + \beta \Delta W_{i,j}^m(t-1) \quad (2.2)$$

onde $W_{i,j}^m(t+1)$ é o novo valor atribuído ao i -ésimo peso do neurônio j , $W_{i,j}^m(t)$ é o valor atual do i -ésimo peso do neurônio j no instante t , α é a taxa de aprendizagem, δ_i^m mede a sensibilidade do neurônio ao qual o peso em questão liga o neurônio j e β é o momento.

Caso o neurônio de índice j seja um da camada de saída, a sensibilidade é calculada de acordo com a Equação (2.3):

$$\delta_i^m = (d_i - y_i)f'(net_i) \quad (2.3)$$

Onde d_i é a saída desejada, y_i é a saída encontrada após o treinamento da rede e $f'(Net_i)$ é a derivada da função de ativação da camada de saída.

Caso contrário, δ_j é obtido usando a Equação (2.4):

$$\delta_j^{m-1} = f'^{m-1}(Net_j^{m-1}) \sum_{i=1}^N W_{ij}^m \cdot \delta_i^m \quad (2.4)$$

onde δ_i^m é a sensibilidade propagada pelo i -ésimo neurônio da camada imediatamente à frente, W_{ij}^m é o peso j do neurônio i e N é o número de neurônios na camada de saída.

2.5.5 Critério de Parada

No processo de aprendizagem supervisionada, o conjunto de padrões é mostrado à RNA várias vezes, o número de vezes que o conjunto de padrões é apresentado à RNA é conhecido como o número de épocas do treinamento. Os pesos podem ser modificados a cada amostra, ou a cada época e encontrar o momento de parada ideal não é uma tarefa tão simples, pois pode causar duas reações indesejadas: se treinada demasiadamente, a RNA decora os padrões e perde sua capacidade de generalizar. Esse fenômeno recebe o nome de *overfitting*. Se treinada menos do que o necessário, a rede não aprende ou não generaliza o suficiente. Um dos critérios de parada mais utilizados é o da validação cruzada.

O critério de parada de validação cruzada divide o conjunto de dados em três partes: treinamento, validação e teste. O conjunto de treinamento é utilizado para ajustar os pesos da rede, segundo o algoritmo de treinamento. Depois de cada época, a rede treinada é testada utilizando o conjunto de validação cruzada de forma a verificar a diferença entre a saída calculada e a desejada. Como o conjunto de validação cruzada nunca é utilizado para corrigir os pesos, eles são sempre inéditos para a rede. Por isso, enquanto o erro de validação cruzada estiver diminuindo, a rede continua aprendendo e sendo capaz de generalizar padrões não apresentados.

A partir do momento em que o erro de validação começa a aumentar enquanto o de treinamento continua a diminuir, é sinal de que a rede pode estar decorando os padrões de treinamento. É nesse momento que o treinamento deve ser parado. Posteriormente, o conjunto de testes é introduzido na rede para avaliar o seu desempenho. A figura 8, mostra o melhor ponto de parada:

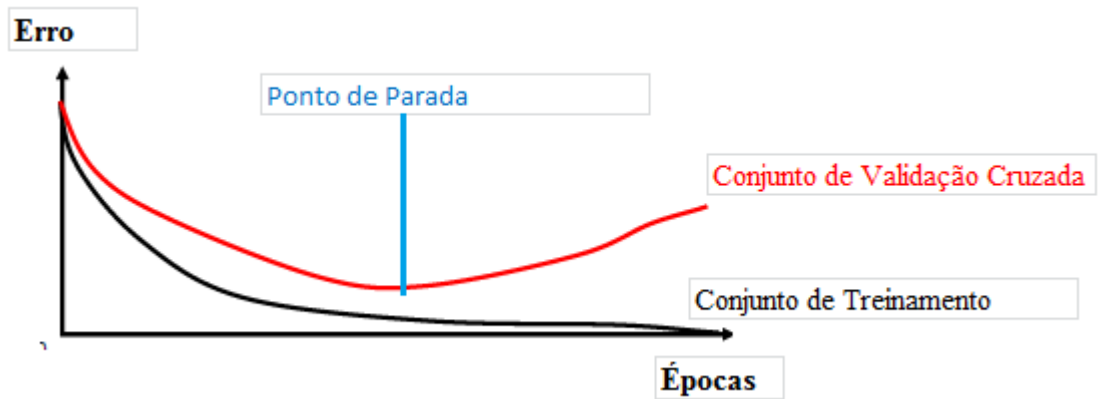


Figura 8. Melhor Ponto de Parada para o Treinamento.

Capítulo 3

Metodologia

3.1 Base de Dados

A base de dados utilizada neste trabalho foi retirada do website <http://www.rami-khushaba.com/electromyogram-emg-repository.html>. Na coleta dos dados, os sinais foram extraídos de 8 indivíduos saudáveis, 6 homens e 2 mulheres, os quais eram estimulados a realizar movimentos com os dedos das mãos.

Os sinais EMG foram coletados usando sensores específicos de sinais EMG. Dois adesivos de pele foram aplicados a cada sensor para firmar-los junto à pele e um adesivo condutor de referência foi utilizado no punho dos participantes. A posição dos eletrodos está mostrada na Figura 9.




Figura 9. Posição dos Eletrodos para Captação do Sinal EMG

[Fonte: <http://www.rami-khushaba.com/electromyogram-emg-repository.html>]

Os sinais foram amostrados à uma taxa de 4000 Hz e posteriormente filtrados por um filtro passa-banda 20-450 Hz. Os sinais coletados pelos eletrodos foram amplificados obtendo um ganho total de 1000. Os sujeitos foram instruídos a abrir e fechar a mão por um período de 5 segundos de duração para captação do sinal, e 40 amostras foram colhidas para ambos os casos de movimento da mão e para mão relaxada. Sinais EMG podem ter um potencial entre 50uV até 30mV, dependendo do músculo.

3.2 Pré-processamento dos Dados

A primeira etapa na fase de pré-processamento dos dados é a normalização dos dados. A normalização é importante para que as variáveis em intervalos diferentes recebam a mesma atenção durante o treinamento, ou seja, evita que valores altos influenciem demais os cálculos da RNA enquanto valores baixos passem despercebidos.

Outra grande importância da normalização reside no fato de que as redes neurais não tem a capacidade de generalizar quando utilizadas em um conjunto de entradas que apresente um intervalo de variação distinto ao do treinamento.

As variáveis têm que ser normalizadas de tal maneira que seus valores sejam proporcionais aos limites das funções de ativação utilizadas na camada de saída.

A normalização é dada por:

$$y = \left(\frac{(b-a)(x_i - x_{min})}{x_{max} - x_{min}} \right) + a \quad (3.1)$$

onde y é o valor normalizado, b é o intervalo máximo da normalização, a é o intervalo mínimo da normalização, x_i é o valor da entrada, x_{min} é o valor mínimo das variáveis de entrada e x_{max} é o valor máximo das variáveis de entrada.

Neste trabalho, tanto as entradas foram submetidas ao procedimento de normalização, como os valores de saídas desejadas também foram limitadas. Portanto, quando a rede produz uma saída para determinada entrada, realiza-se uma transformação inversa para obtenção de seu valor na escala original.

3.3 Arquitetura da Rede Utilizada

A seguir são apresentados os parâmetros de configuração utilizados nas RNAs deste trabalho.

Rede MLP:

- Número de neurônios na camada de entrada: (1);
- Número de neurônios na camada escondida: {5,10,15,20,25};
- Número de neurônios na camada de saída: (1);
- Função de ativação da camada escondida: (Equação (3.2));
- Função de ativação da camada de saída: (Equação (3.3));
- Critério de parada: (validação cruzada);
- Taxa de aprendizado: (0,05);
- Momento: (0,1);
- Inicialização dos Pesos aleatoriamente com valores no intervalo: [-0,5;0,5];

Além desses critérios, é importante definir a quantidade de dados dedicados ao treinamento, à validação e ao teste. Serão dedicados 50% dos dados para treinamento, feito de forma “*On Line*”, onde o reajuste dos pesos é feito a cada exemplo apresentado, 25% para validação e 25% para testes.

O algoritmo utilizado é o *backpropagation* e a função de ativação escolhida para os neurônios da camada escondida e da camada de saída são Sigmoides Logística e Degrau, descrita na equação 3.2 e 3.3, respectivamente:

$$y = 1/(1 + e^{-Net(i)}) \quad (3.2)$$

$$y = \begin{cases} 0, & \text{se } Net(i) < 0 \\ 1, & \text{se } Net(i) \geq 0 \end{cases} \quad (3.3)$$

onde y = valor de saída e $Net(i)$ é a média ponderada dos pesos com as entradas do i -ésimo neurônio.

A Equação (3.2) retorna valores pertencentes ao intervalo [0,1] enquanto que a Equação (3.3) retorna os valores {0,1}.

A medida de erro adotada é o Erro Médio Quadrático (EMQ), mostrado na Equação (3.4).

$$EMQ = \sqrt{\frac{\sum(d-y)^2}{N}} \quad (3.4)$$

onde d é a saída desejada, y é a saída fornecida pelo treinamento e N o número total de saídas do conjunto calculado. Também foi definido como 6 o número de aumentos do EMQ da validação seguidos de diminuição do EMQ do treinamento para interromper o treinamento visando evitar *overfitting* da rede, um valor acima deste implicaria apenas em mais gasto computacional com pouca chance de melhoramento dos resultados.

A escolha da quantidade de entradas foi baseada no fato de que apenas 1 característica, Valor Médio Absoluto, já seria suficiente para o objetivo do trabalho de classificar a intenção ou não de movimento da mão. A inclusão de mais algumas características traria um aumento de custo computacional e não traria ganhos significativos de desempenho.

Para a camada intermediária, foi decidido utilizar apenas uma camada escondida, quantidade suficiente para aproximação de qualquer função não-linear, e a quantidade de neurônios foi decidida após testes com variação na quantidade de neurônios na camada escondida, testados de 5 a 25 neurônios iterativamente, com passo de 5 neurônios adicionais.

Capítulo 4

Resultados

4.1 Neurônios na Camada Escondida da Rede MLP

O número de neurônios na camada escondida ficou por ser decidido na escala [5,25] como descrito na sessão 3.3. A mesma metodologia foi utilizada para 8 indivíduos diferentes e os resultados estão representados nas Figuras (10 a 14), as quais mostram o decaimento do Erro Médio Quadrático para o conjunto de treinamento em relação ao número de ciclos decorridos na RNA:




Figura 10. Decaimento do EMQ para 5 Nodes na camada escondida em função do número de épocas de treinamento.

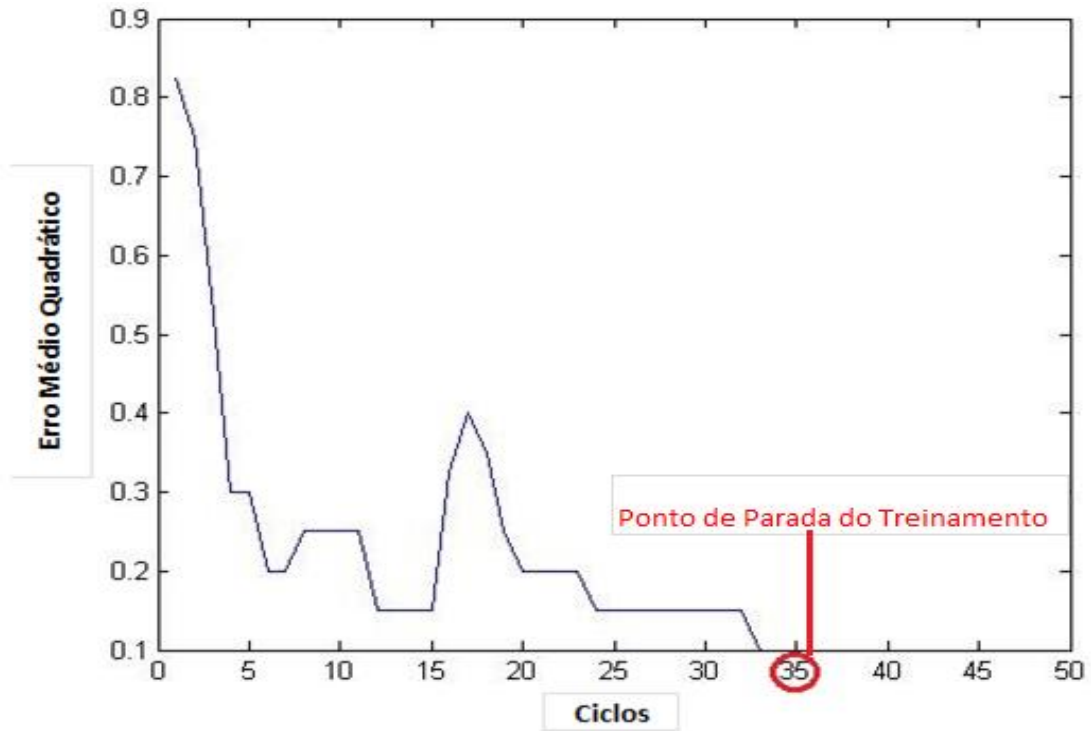


Figura 11. Decaimento do EMQ para 10 Nodes na camada escondida em função do número de épocas de treinamento.

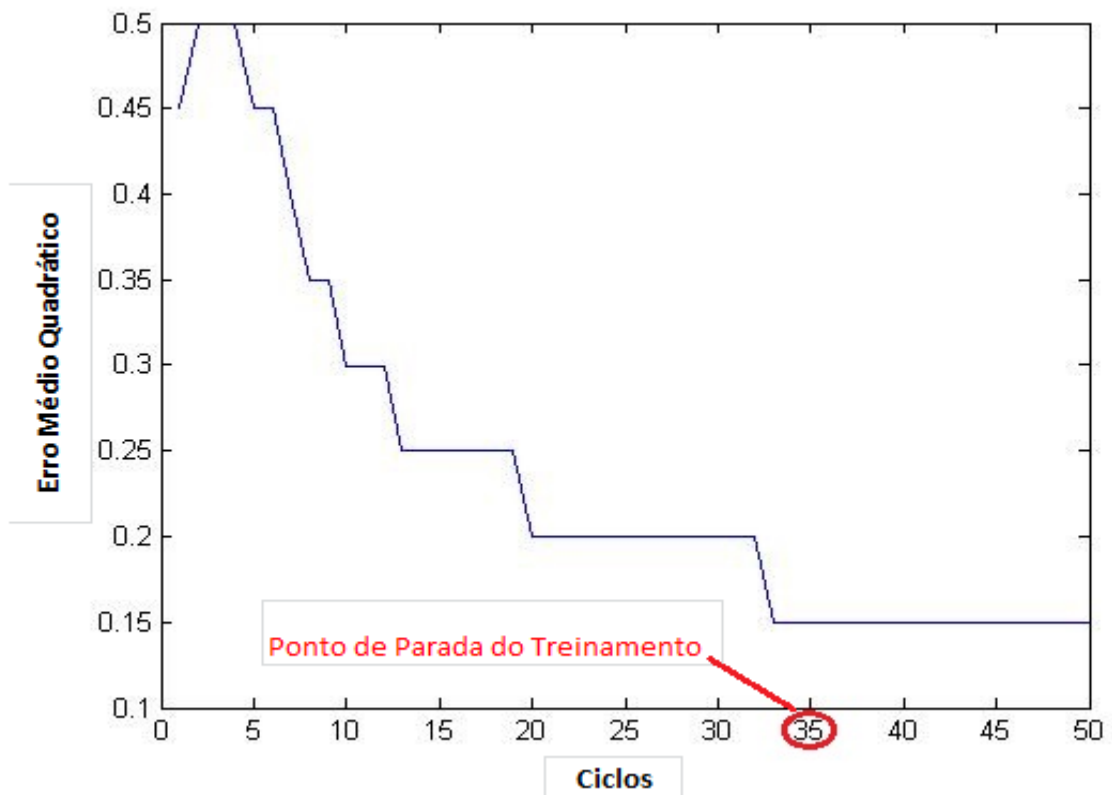


Figura 12. Decaimento do EMQ para 15 Nodes na camada escondida em função do número de épocas de treinamento.

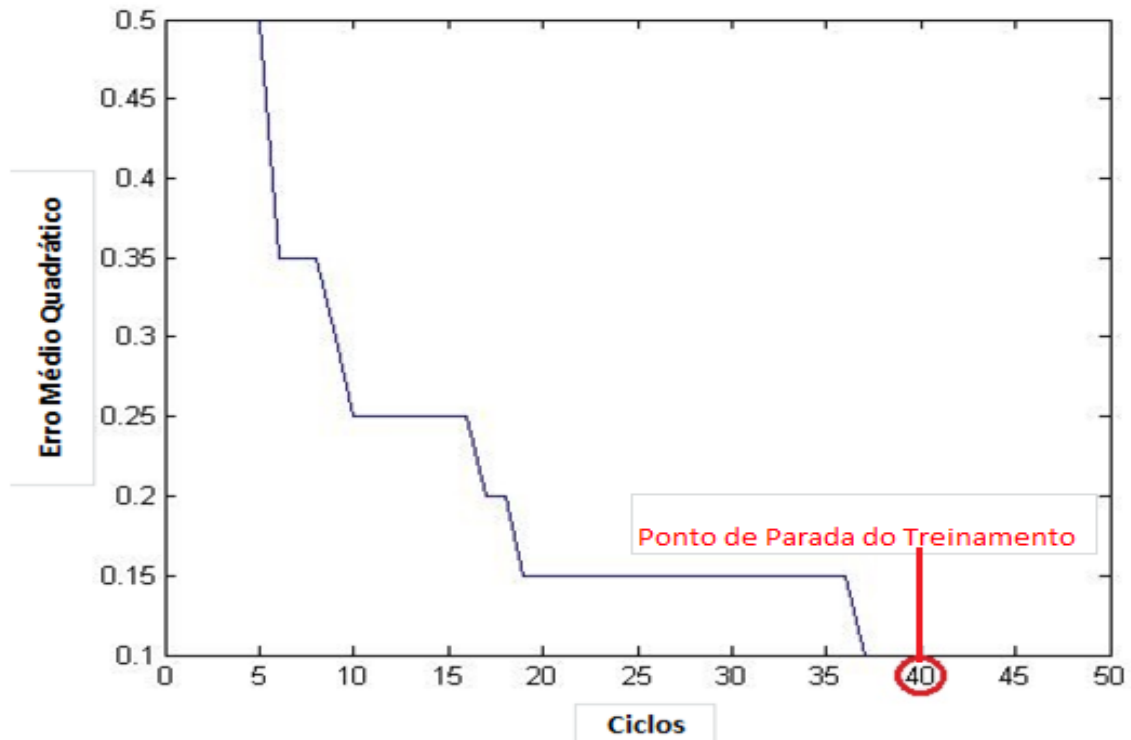


Figura 13. Decaimento do EMQ para 20 Nodes na camada escondida em função do número de épocas de treinamento.

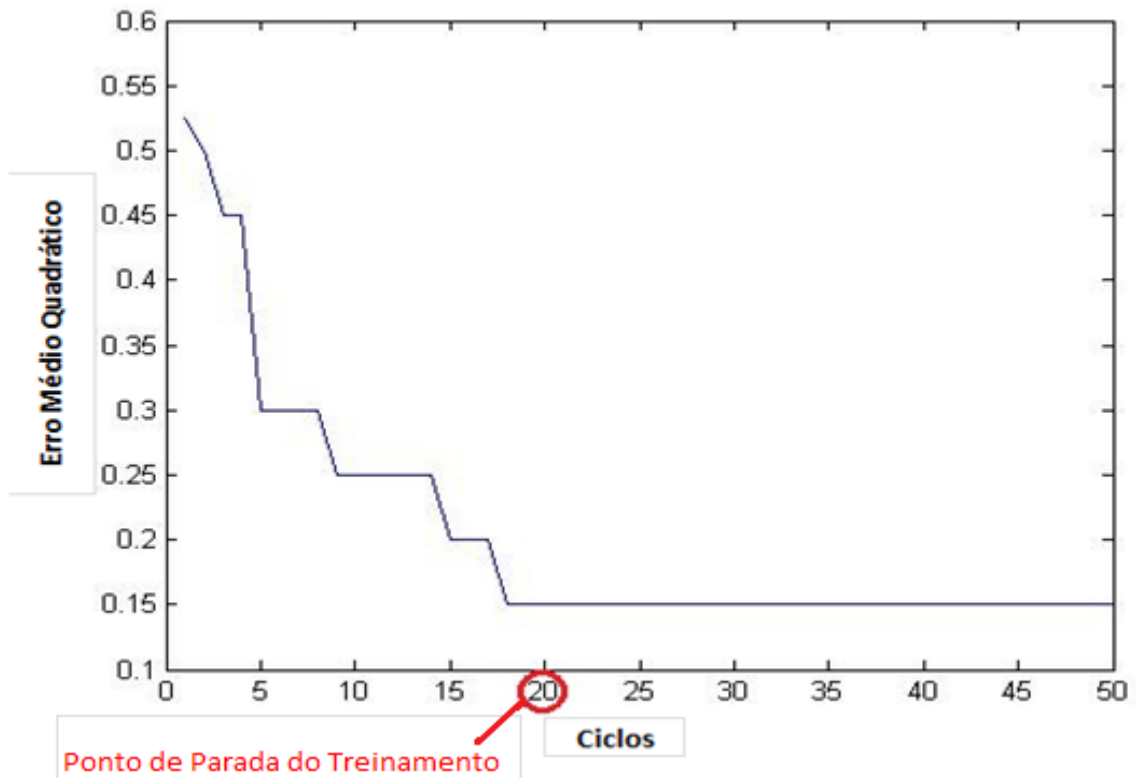


Figura 14. Decaimento do EMQ para 25 Nodes na camada escondida em função do número de épocas de treinamento.

Os experimentos foram repetidos 30 vezes, afim de realizar estudos estatísticos dos resultados, dentro de um período de 50 ciclos para o treinamento. Os gráficos resultantes representam o comportamento predominante para o decaimento do Erro Médio Quadrático e o ponto de parada do treinamento representa a época em que os melhores pesos das ligações foram encontrados de acordo com o critério de Validação Cruzada.

4.2 Desempenho do Sistema

Com relação ao desempenho em relação à classificação do movimento da mão, a Figura 15 expressa os resultados obtidos:

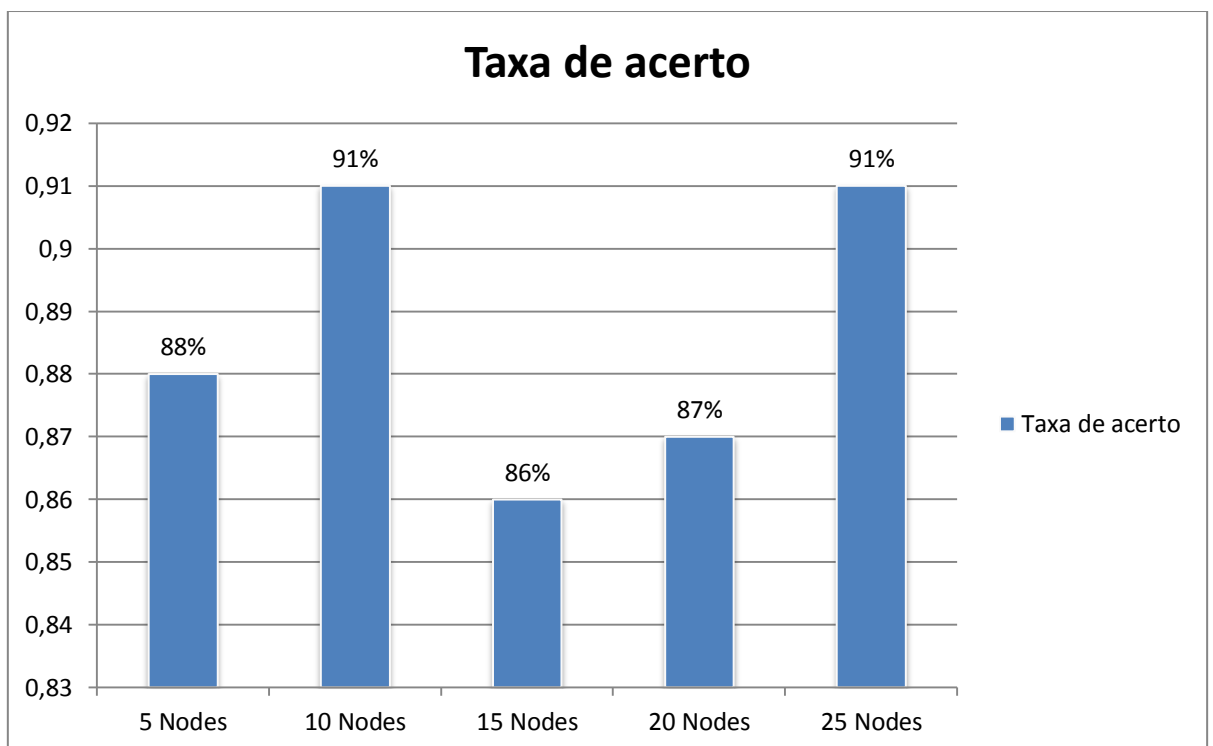


Figura 15. Desempenho de Classificação do Movimento da Mão variando os Nodos da Camada Escondida.

Pelos resultados, fica mostrado que a melhor estrutura MLP para resolução do nosso problema é aquela composta de 25 Nodos na camada escondida, pois além de obter desempenho máximo de acerto nas classificações de movimento da mão, diante das outras estruturas de rede, seu treinamento tende a atingir os pesos

ótimos no vigésimo ciclo, apesar de possuir o maior número de neurônio dentre as outras estruturas.

Capítulo 5

Conclusão e Trabalhos Futuros

A utilização da característica Valor Médio Absoluto do sinal EMG, juntamente com a técnica de Redes Neurais Artificiais, utilizando o método *Backpropagation* como forma de treinamento, se mostra bastante eficiente na análise e classificação de sinais Eletromiográficos. Diversas estruturas de rede MLP foram testadas e todas obtiveram sucesso de classificação acima de 85%, obtendo como melhor caso a taxa de 91% de acerto.

Como trabalhos futuros, deseja-se fazer análise e processamento de sinais Eletromiográficos utilizando mais características do sinal e fazendo a captura em tempo real. Desta forma poderemos fazer controle não só da intenção de movimento como também da força aplicada no movimento pelo sujeito. Este sistema será implantado em um dispositivo que realize os movimentos básicos de abrir e fechar uma mão robótica.

Bibliografia

- [1] <http://www.saudemedicina.com/eletromiografia-emg/>.
- [2] Hsie-Jen and Kuu-Young. **An Adaptive Upper-Arm EMG-Based Robot Control System. International Journal of Fuzzy Systems**, Setembro 2010.
- [3] http://www.diariodepernambuco.com.br/app/noticia/vida-urbana/2014/04/08/interna_vidaurbana,498300/em-onze-anos-o-numero-de-obitos-por-acidentes-com-moto-cresceu-cinco-vezes-em-pe.shtml.
- [4] <http://www.webartigos.com/artigos/sistema-neuromuscular/72580/>.
- [5] Maria Angela Tardelli. **Transmissão Neuromuscular: Anatomia, Fisiologia e Bloqueio**. UNIFESP.
- [6] <http://tafitness.net/unidades-motoras-musculacao/>.
- [7] http://cta.if.ufrgs.br/projects/instrumentacao_fisica/wiki/Medi%C3%A7%C3%A3o_de_Biopotenciais_-_o_Estado_da_Arte.
- [8] <http://www.cpaqv.org/mtpmh/eletromiografia.pdf>.
- [9] <http://institutomaragabrigilli.org.br/apoio-e-pesquisas/132-protese-vao-alem-da-substituicao-de-membros-e-dao-inicio-a-mutacao-do-corpo-em-maquina>.
- [10] http://pt.wikipedia.org/wiki/Engenharia_de_controle_e_automa%C3%A7%C3%A3o.
- [11] http://www.istoe.com.br/reportagens/166394_A+UM+PASSO+DA+PROTESE+INTELIGENTE.
- [12] BRAGA, A. de P.; CARVALHO, A. P. de Leon Filho de; LUDERMIR, T. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC, 2000.
- [13] VALENÇA SILVA, J. M. **Fundamentos das Redes Neurais**. Livro Rápido, 2011.
- [14] http://tcc.ecomp.poli.br/20141/TCC_MarceloLuizPereiraFreire.pdf.

- [15] MCCULLOCH, W. S.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity. Bulletin os Mathematical Biophysics**, 1943, p. 115-133.
- [16] HAYKIN, S. **Redes Neurais: Princípios e Práticas**. Bookman, 2007.