



Universidade Federal da Paraíba
Centro de Energias Alternativas e Renováveis
Departamento de Engenharia Elétrica



Marcelo Pereira Rufino

**IMPLEMENTAÇÃO DE UMA REDE NEURAL
ARTIFICIAL PARA CLASSIFICAÇÃO DE SINAIS
MIOELÉTRICOS**

João Pessoa – PB
Novembro de 2017

MARCELO PEREIRA RUFINO

**IMPLEMENTAÇÃO DE UMA REDE NEURAL
ARTIFICIAL PARA CLASSIFICAÇÃO DE SINAIS
MIOELÉTRICOS**

Trabalho de conclusão de curso
apresentado ao Curso de
Engenharia Elétrica como um
dos pré-requisitos para a
obtenção do título de
Engenheiro Eletricista sob
orientação do Prof. Dr. José
Maurício Ramos de Souza Neto

João Pessoa – PB
Novembro de 2017

R926i Rufino, Marcelo Pereira

Implementação de uma Rede Neural Artificial para Classificação de Sinais Mioelétricos.

31f. il.:

Orientador: Prof. José Maurício Ramos de Souza Neto
Dr.

Monografia (Curso de Graduação em Engenharia Elétrica) Campus I -
UFPB / Universidade Federal da Paraíba.

1. Redes Neurais 2. Reconhecimento de padrão 3. Sinais Mioelétricos
I. Título.

BS/CT/UFPB

CDU: 2.ed. 621(043.2)

MARCELO PEREIRA RUFINO

**IMPLEMENTAÇÃO DE UMA REDE NEURAL ARTIFICIAL PARA
RECONHECIMENTO DE PADRÃO DE SINAIS MIOELÉTRICOS**

Prof. Dr. José Maurício Ramos de Souza Neto (Orientador)
Universidade Federal da Paraíba

Prof. Dr Helon David de Macedo (Avaliador)
Universidade Federal da Paraíba

Prof. Dr Walson Terllizzie Araújo Lopes (Avaliador)
Universidade Federal da Paraíba

João Pessoa – PB
Novembro de 2017.

*Em memória de minha avó Maria,
Para sempre lembrada com carinho.*

AGRADECIMENTOS

Gostaria de agradecer a todos os professores do CEAR por todas as lições e aprendizado, ao grupo PET Elétrica UFPB por fornecer um espaço para o estudo. Sou grato à minha família, que é indispensável em todos os momentos e aos meus colegas de curso, pelo companheirismo. Agradeço a minha namorada Thaís, por toda a paciência enquanto empenhava-me neste trabalho e ao meu orientador Maurício, por sempre ter acreditado na minha capacidade.

RESUMO

No Brasil há a estimativa de que a cada 100.000 habitantes 13,9 apresentam alguma forma de amputação. Pensando nesta população, neste trabalho foi criada uma rede neural capaz de reconhecer diferentes padrões de movimento realizados pela mão utilizando sinais mioelétricos fornecidos pelo projeto CopyMyo. Neste projeto foi feita a aquisição de dados por meio 128 eletrodos em 10 diferentes pessoas saudáveis reproduzindo 5 movimentos diferentes da mão. Utilizando a *Toolbox* de redes neurais do MATLAB® foi possível criar uma rede *feedforward* de reconhecimento de padrões treinada com algoritmo *Backpropagation* de múltiplas camadas. Foram feitos por tentativa e erro diferentes ensaios de tratamento de dados e foi verificado que é possível identificar um movimento utilizando a energia acumulada, a frequência média variância e número de cruzamentos em zero no final dos sinais mioelétricos.

Palavras-Chaves: Redes Neurais, Reconhecimento de padrões, Sinais mioelétricos, Energia acumulada.

ABSTRACT

In Brazil there is an estimate that every 100,000 inhabitants 13.9 have some form of amputation. With the thought about this population, in this work, a neural network has been created capable of recognize patterns in the movements done by a hand using the myoelectric signals provided by the CapyMyo Project. In this work, the acquisition of data has been done by 128 electrodes capturing 5 different movements of the hand from 10 different health people. Using MATLAB®'s Neural Network Toolbox was possible to create a pattern recognition feedforward network with the Backpropagation algorithm and multiple layers. By trial and error different tests were done and it was verified that is possible to recognize a movement using the accumulated energy, mean frequency, variance and zero crossing by the end of the myoelectric signal.

Keywords: Neural Networks, pattern recognition, Myoelectric signals, accumulated energy.

LISTA DE FIGURAS

| | |
|---|----|
| Figura 1 - Estrutura do Neurônio biológico..... | 3 |
| Figura 2 - Modelo matemático de um neurônio artificial..... | 4 |
| Figura 3 - Exemplos de funções de ativação. | 6 |
| Figura 4 - Exemplo de RNA de camada única. | 7 |
| Figura 5 - RNA de múltipla camada feedforward. | 8 |
| Figura 6 - RNA de múltipla camada feedback. | 8 |
| Figura 7 - A retropropagação dos erros durante treinamento..... | 11 |
| Figura 8 - Eletrodo de agulha. | 13 |
| Figura 9 - Eletrodo de superfície. | 13 |
| Figura 10 - Disposição dos eletrodos no antebraço. | 15 |
| Figura 11 - Sistema de aquisição de dados utilizado..... | 15 |
| Figura 12 – Movimentos dedos da mão a serem reconhecidos. | 16 |
| Figura 13 - Índices de correlação entre eletrodo N°10 e vizinhos em uma amostra | 17 |
| Figura 14 – Eletrodos em vermelho | 18 |
| Figura 15 – Exemplo de RNA para processamento temporal de dados | 19 |
| Figura 16 –Energia acumulada em um dos sensores | 20 |
| Figura 17 – Frequência média de um dos sinais mioelétricos | 20 |
| Figura 18 - Número de cruzamentos em zero de um dos sensores..... | 21 |
| Figura 19 – Diagrama da RNA do 2° ensaio | 23 |
| Figura 20 - Diagrama da RNA do 3° ensaio | 23 |
| Figura 21 – Erro e número de neurônios com uso da energia acumulada..... | 24 |
| Figura 22 – Erro e número de neurônios com a frequência média..... | 25 |
| Figura 23 – Erro e número de neurônios com variância | 25 |
| Figura 24 – Erro e número de neurônios | 26 |

SUMÁRIO

| | | |
|----------|--|-----------|
| 1 | INTRODUÇÃO | 1 |
| 1.1 | Motivação | 1 |
| 1.2 | Objetivo Geral..... | 1 |
| 1.2.1 | Objetivo Específicos..... | 2 |
| 1.3 | Organização do Trabalho..... | 2 |
| 2 | FUNDAMENTAÇÃO TEÓRICA | 3 |
| 2.1 | Introdução | 3 |
| 2.2 | Redes Neurais Artificiais | 3 |
| 2.2.1 | Funções de ativação..... | 5 |
| 2.2.2 | Arquiteturas de Redes Neurais | 6 |
| 2.2.3 | Treinamento de redes neurais | 9 |
| 2.3 | Número de neurônios em camada escondida..... | 11 |
| 2.4 | Sinais mioelétricos | 12 |
| 2.5 | Energia de um sinal..... | 13 |
| 3 | METODOLOGIA | 14 |
| 3.1 | Introdução | 14 |
| 3.2 | Dados | 14 |
| 3.3 | Toolbox de Redes Neurais do MATLAB® | 16 |
| 3.4 | Redes neurais | 17 |
| 4 | ANÁLISE DE RESULTADOS | 22 |
| 4.1 | Introdução | 22 |
| 4.2 | Análise de cada ensaio | 22 |
| 5 | CONCLUSÕES | 27 |
| 6 | REFERÊNCIAS | 28 |
| | APÊNDICE A | 29 |
| | APÊNDICE B..... | 29 |

1 INTRODUÇÃO

1.1 Motivação

Com o decorrer da história, percebe-se que a tecnologia sempre foi uma grande aliada ao desenvolvimento de soluções para questões que afligem milhares de pessoas. A porta de entrada para um desses resultados é a reabilitação, uma vez que está interligada à ciência na busca de instrumentos que permitam a inserção de cidadãos no mercado de trabalho e outros âmbitos que melhoram a qualidade de vida. A partir da aquisição de sinais mioelétricos, é possível adentrar a um extenso mundo de dispositivos que são indispensáveis para deficientes físicos, especialmente os de derivação por amputação.

Amputação é o processo de retirada, geralmente cirúrgica, total ou parcial de um membro. As razões mais comuns para retirada de órgão apendicular são acidentes de trabalho e tumores (CARVALHO, 2003). De acordo com dados do censo realizado em 2010 pelo Instituto Brasileiro de Geografia e Estatística (IBGE), no Brasil 6,95% da população apresenta alguma deficiência motora com um nível de alguma dificuldade, a estimativa é de 13,9 a cada 100.000 habitantes apresentam alguma amputação.

As próteses mioelétricas desenvolvidas para suprir a demanda de quem tem órgão apendicular amputado são mecanismos que servem como uma substituição da região perdida, e são controladas pelos sinais presentes componente residual corpóreo.

De acordo com Moleta (2007), durante a flexão dos dedos da mão, acontece uma despolarização no grupo muscular do antebraço próximo ao cotovelo, e uma repolarização nos músculos mais próximos ao pulso.

Este trabalho utiliza estes sinais de despolarização no antebraço em redes de neurais de reconhecimento de padrões com o intuito de identificar diferentes movimentos realizados pelos dedos da mão.

1.2 Objetivo Geral

O objetivo deste trabalho é buscar uma forma de implementação simplificada de redes neurais que produza resultados análogos aos apresentados por Geng *et al.*, (2016), sendo capaz de reconhecer padrões em movimentos dos dedos da mão.

1.2.1 Objetivo Específicos

- Estudar as qualidades e particularidades de uma rede neural artificial;
- Utilizar dados de sinais mioelétricos que correspondentes a diferentes movimentos realizados pelos dedos da mão;
- Realizar um tratamento adequado dos dados para que possam ser corretamente inseridos numa rede neural;
- Buscar uma forma de otimizar o número de neurônios presentes em uma camada escondida para que se tenha uma resposta com o menor erro possível.

1.3 Organização do Trabalho

Este trabalho está organizado da seguinte forma:

Na seção 2 faz-se uma breve introdução à história das redes neurais e suas diferentes características e sobre o que são os sinais mioelétricos utilizados nesse trabalho.

Na seção 3

mostra-se qual foi a metodologia adotada pelo banco de dados utilizado para aquisição dos sinais mioelétricos e descreve como foram organizados os dados para serem inseridos na rede neural.

Na seção 4 estão apresentados os resultados de cada um dos métodos testados com suas respectivas justificativas.

E por fim, na seção 5 estão as considerações finais e perspectivas para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

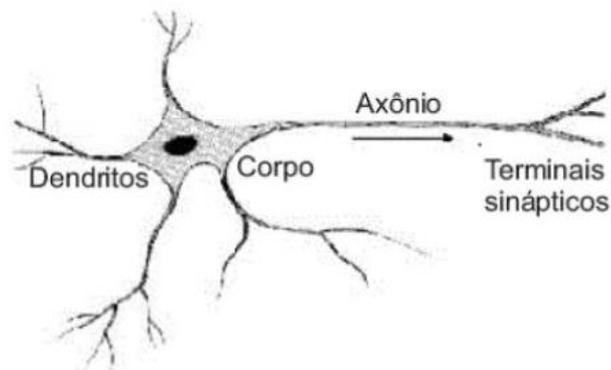
2.1 Introdução

Uma breve introdução teórica sobre redes neurais compreendendo uma revisão teórica e uma explanação de suas principais características é apresentada nesta seção. Além disso, serão abordados as propriedades dos sinais mioelétricos.

2.2 Redes Neurais Artificiais

O cérebro de um ser humano adulto saudável é formado por cerca de 86 bilhões de células nervosas (HERCULANO-HOUZEL, 2009). As principais dessas células são os neurônios cuja estrutura é formada por dendritos, pelo seu corpo celular e pelo axônio, conforme Figura 1. Os dendritos são prolongamentos finos e em geral ramificados que formam a porta de entrada de informações para o neurônio. Por outro lado, o axônio é formado por uma fibra tubular bastante fina representando a saída. O corpo celular tem por função reunir as informações vindas dos dendritos. Informações são transmitidas pelos neurônios por meio das sinapses cujo efeito é variável, permitindo que a célula possa se adaptar. Desta forma um determinado neurônio é capaz de transmitir um impulso nervoso ao comparar sinais oriundos de outros neurônios. Além disso, apesar de simples, a transmissão de impulsos nervosos ao ser realizada por todos os 86 bilhões trabalhando em paralelo permite ao corpo humano realizar as mais complexas atividades.

Figura 1 - Estrutura do Neurônio biológico.

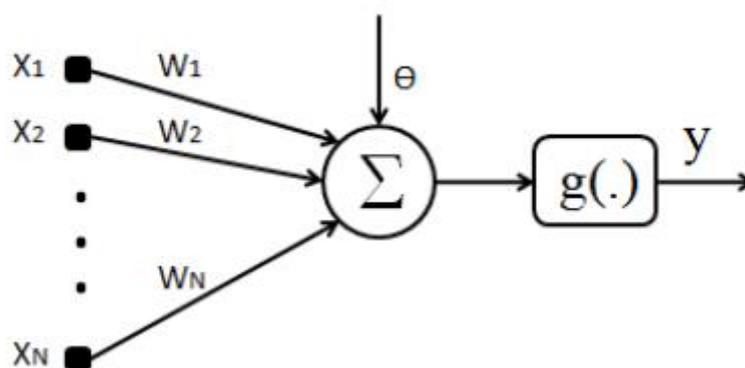


Fonte: (COSTA, 2016)

As redes neurais artificiais (RNAs) são formadas pela conexão de unidades de processamento mais simples, chamadas de nodos ou neurônios artificiais que tem por objetivo reproduzir o funcionamento do cérebro humano. Sua capacidade de processamento é dada por treinamento que atribui valores a pesos entre conexões dos nodos (GURNEY, 1997).

No modelo matemático do neurônio artificial, apresentado na Figura 2, as entradas X_N representam conexões vindas de outros neurônios, os pesos dessas conexões aqui chamados de W_N fazem analogia as sinapses biológicas, o somatório representa a união das entradas no corpo celular e a função de transferência do neurônio artificial representa um limiar de ativação para atuação da célula nervosa.

Figura 2 - Modelo matemático de um neurônio artificial.



Fonte: (Aguiar, 2010)

Estudos RNAs começaram com os trabalhos de McCulloch e Pittsno (1943), no qual foi feito um modelo matemático que caracterizava o funcionamento de um neurônio biológico capaz de diferenciar duas entradas *booleanas*, entretanto não possuía parâmetros livres e, portanto, não poderia ser treinado. Em 1949, o neuro-psicologista Donald Hebb propôs que a capacidade de aprendizagem está diretamente ligada a alteração da eficiência sináptica, ou seja, apenas quando ambos neurônios estão prontos é que ocorreria a *snapse* (TEES R. C., 2002 apud AGUIAR, 2010). A descoberta de Hebb se tornou a base de como os neurônios são capazes de aprender.

Frank Resenblatt e sua equipe no Instituto de Tecnologia de Massachusetts desenvolveram o primeiro neurocomputador, o *Mark I Perceptron*, que funcionava com o uso de 512 potênciomentros. Resenblatt é considerado como fundador da neurocomputação, por seu trabalho utilizar os conceitos desenvolvidos anteriormente por McCulloch e Hebb a respeito das sinapses (PAULA, 2002).

O trabalho de Minsky e Parpet (1969) provou que o modelo neural desenvolvido por Resenblatt era capaz apenas de solucionar problemas como separabilidade linear e problemas para resolver casos do tipo OU-Exclusivo. Esta pesquisa foi responsável por uma década de pouco investimento em neurocomputação que apenas retornou quando já tinha um grande avanço em termos computacionais. Desde o trabalho publicado por Hopfield (1982), que utilizava uma técnica inovadora com redes retroalimentadas e criticava os trabalhos de Minsky e Parpet, houve um crescente interesse pelas redes neurais e desde então inúmeras diferentes formas de se utilizar as redes foram criadas (KRIESEL, 2007).

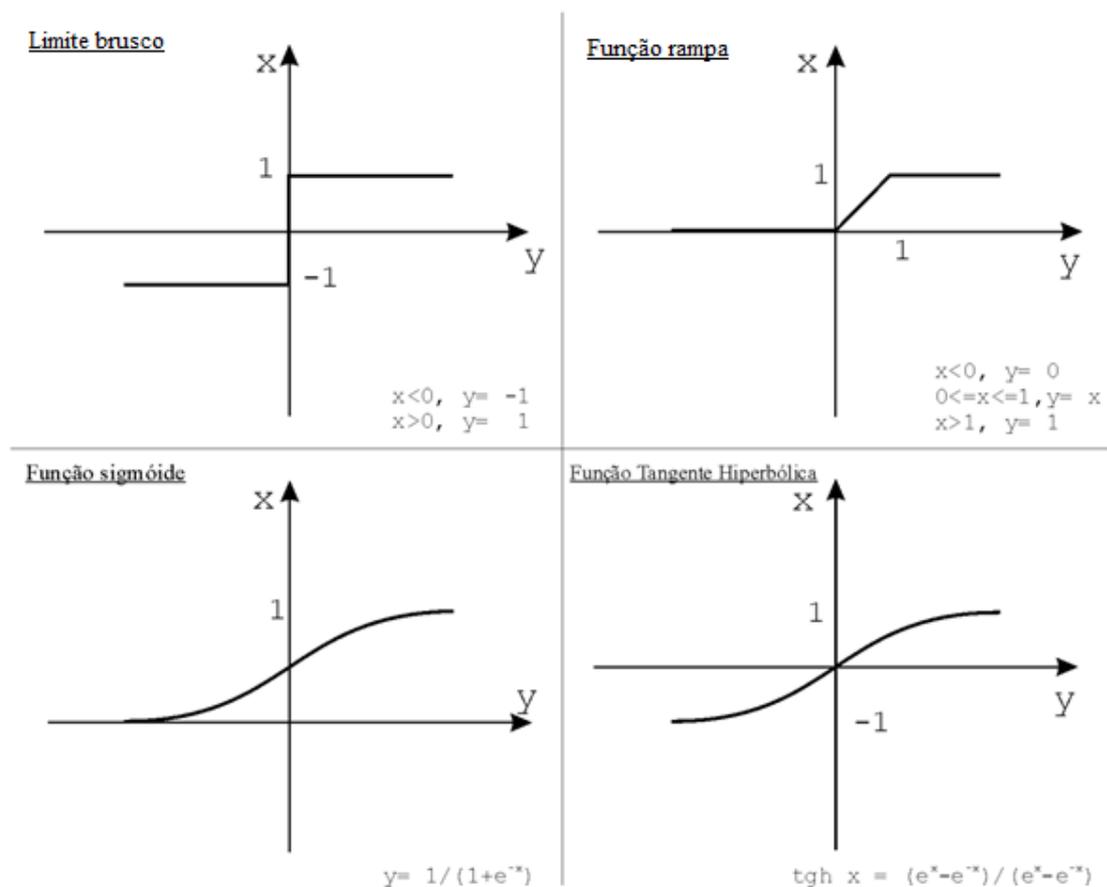
2.2.1 Funções de ativação

Uma das principais características dos neurônios artificiais são as suas funções de ativação que tem por objetivo simular o funcionamento não linear de um neurônio biológico. Elas têm como finalidade processar os sinais que chegam ao neurônio vindo das sinapses, decidindo se o neurônio irá ativar. Em caso que o neurônio não seja ativado, ou seja o valor mínimo não seja atingindo, ele não deverá ter efeito em um neurônio posterior.

Entre os diversos tipos possíveis de funções de ativação, mostradas na Figura 3, a do tipo degrau pode ser mais adequada em tratamento de sistemas binários. Por outro lado, a função sigmoide é a mais utilizada na literatura por ser ideal para o tratamento

de dados contínuos, pois ela é capaz de simular com uma maior fidelidade o funcionamento de um neurônio biológico. Ambas funções são empregadas em camadas escondidas ou de contexto, sendo mais comum o emprego de uma função linear para a saída da rede neural (GRECO, 2011).

Figura 3 - Exemplos de funções de ativação.



Fonte: (PAULA, 2002)

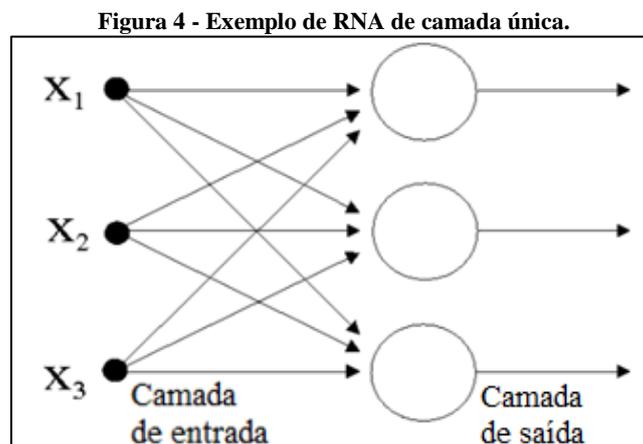
2.2.2 Arquiteturas de Redes Neurais

A arquitetura de uma RNA é a forma como os neurônios estão dispostos na rede. Essa disposição dos neurônios também acontece no cérebro humano, fazendo com que os dados possam ser processados adequadamente.

Existem diversas maneiras de organizar os neurônios de uma rede, e por essa razão há uma necessidade de se classificar as redes. A classificação de redes neurais é

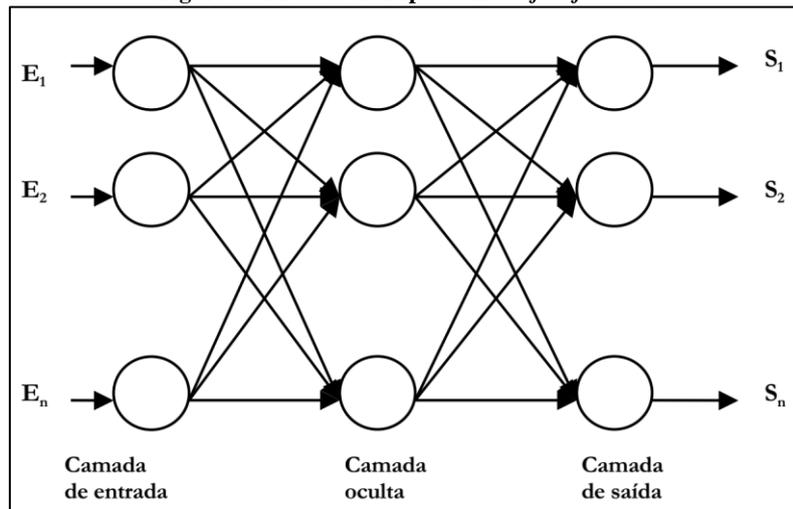
feita conforme seu número de camadas, podendo ser de camada única ou de múltiplas camadas. Dentro das redes múltiplas há outra classificação conforme sua alimentação, se as redes são cíclicas (*feedback*) ou acíclicas (*feedforward*) (PEREIRA, 2016).

Redes de camada única, como exemplificado na Figura 4, são um marco na história de RNA por serem as primeiras redes criadas, a exemplo do *Perceptron*, elas apresentam apenas uma única camada de entrada e uma única camada de saída, elas são utilizadas exclusivamente para solução de problemas linearmente separáveis, que são problemas separáveis em um hiperplano por uma linha.



Em uma rede tipo *feedforward* não há realimentação, o neurônio de uma camada mais próxima da saída não pode ser conectado a um neurônio que estiver mais próximo a camada de entrada, fazendo assim com que o sinal se propague apenas em uma direção, da entrada para a saída. Além das camadas de entrada e saída, deve haver uma ou mais camadas de neurônios ocultas.

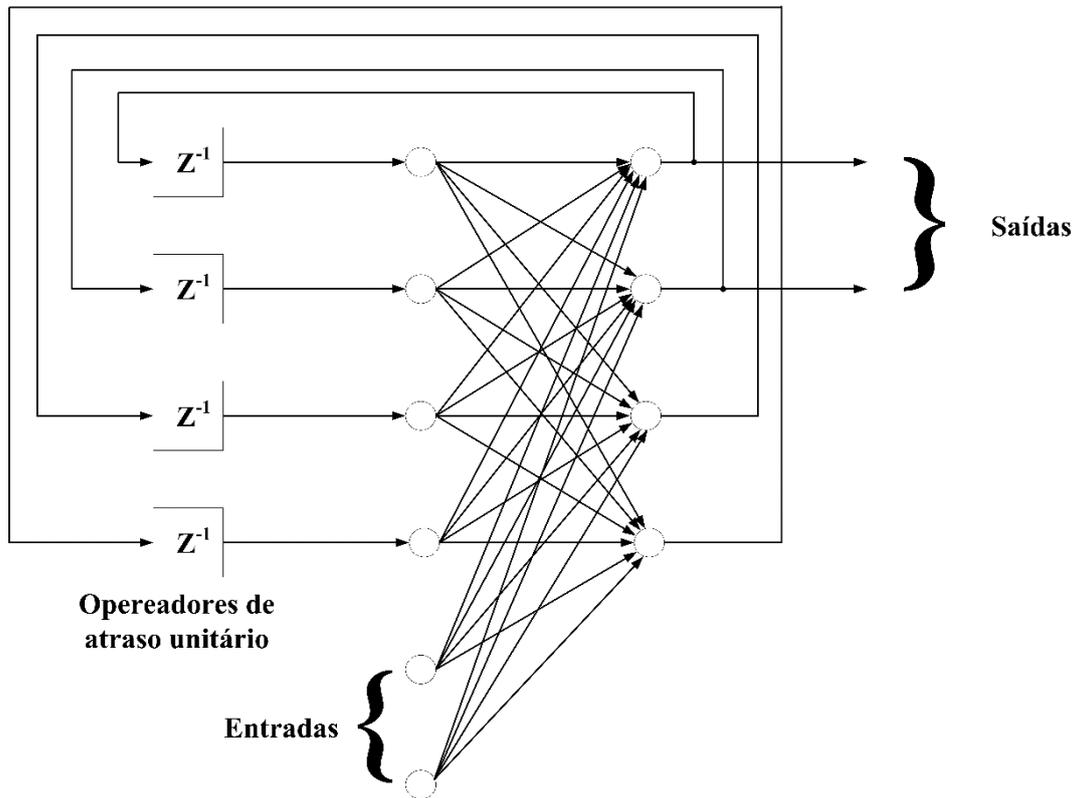
Figura 5 - RNA de múltipla camada *feedforward*.



Fonte: (FERREIRA, 2004)

Uma rede do tipo *feedback* sempre apresenta uma ou mais realimentações que formam ciclos, conectando neurônios mais próximos a saída a um ou mais neurônios antecedentes. Pode-se ter uma ou várias camadas, incluindo camadas escondidas. De acordo com Haykin (2001), é possível ainda se ter uma realimentação levando os valores da saída a entrada da RNA. É mostrado na Figura 6 uma rede do tipo *feedback* para exemplificar tais redes.

Figura 6 - RNA de múltipla camada *feedback*.



Fonte: Adaptado de (HAYKIN, 2001)

2.2.3 Treinamento de redes neurais

Treinamentos de RNAs são realizados seguindo algoritmos responsáveis por adequar a rede para que ela possa desempenhar a sua função. Uma rede neural é dita treinada quando seus pesos sinápticos e valores de polarização estão devidamente calibrados. Esse é um processo que leva um determinado tempo para ser realizado dependendo da capacidade de processamento da máquina utilizada.

As sinapses ou pesos da RNA são ajustadas usando a Equação (1):

$$w(t+1) = w(t) + \delta w(t) \quad (1)$$

Na Equação (1) o valor de $w(t+1)$ representa o valor do peso da sinapse após a iteração, o valor de $w(t)$ antes da iteração e o valor de $\delta w(t)$ é o seu ajuste correspondente que varia de acordo com o algoritmo utilizado na realização do treinamento.

O treinamento começa no momento em que os dados chegam na entrada, a rede passa a alterar seus parâmetros, de polarização e sinapses, e atua de uma nova forma. O

treinamento pode encerrar em três hipóteses: pelo número de épocas, que são o número de iterações do treinamento, por um valor de erro mínimo aceitável ou no caso do *Toolbox* de Redes Neurais do MATLAB®, quando há um incremento no erro da entropia cruzada durante a validação (MATHWORKS, 2017).

Pode-se dividir os algoritmos de treinamento de RNAs em 3 classes: supervisionados, não supervisionados e de reforço. De acordo com Pereira (2016), algoritmos supervisionados utilizam o erro, que é a diferença entre a saída desejada e a saída real, para atualizar os valores das sinapses conforme apresentado na Equação (2).

$$w(t+1) = w(t) + n \cdot e(t) \cdot E(t) \quad (2)$$

Na Equação (2), n representa a taxa de aprendizado, $e(t)$ representa o erro entre a saída desejada e saída real da rede e $E(t)$ representa o valor de entrada atual.

Segundo Pereira (2016) o erro por cada época pode ser calculado de acordo com a Equação (3).

$$e(t)^2 = \frac{1}{2} \sum_{i=1}^p (y_d^i - y)^2 \quad (3)$$

No qual o valor de p representa a quantidade de épocas já decorridas, y_d^i e y representam as saídas desejada e real respectivamente. Com este valor de erro é possível decidir se ele é baixo o suficiente para encerrar o treinamento ou continuar para que ele diminua.

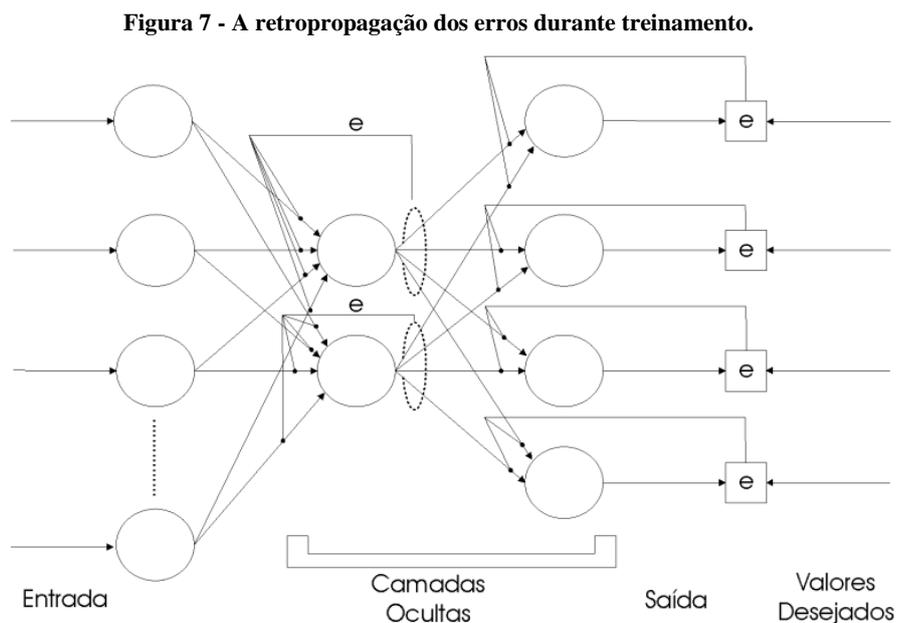
Algoritmos não supervisionados são utilizados para agrupamento de dados e requerem dados de entrada aproximados, pois não existe um cálculo contínuo da função de erro.

Um algoritmo de reforço trabalha de modo diferente dos anteriores, nele há um incremento em sinapses que participam da saída e diminui as que não influenciam na saída ou produzem uma saída considerada errada.

2.2.3.1 *Backpropagation*

O algoritmo de *backpropagation* ou algoritmo de retropropagação é um dos mais utilizados para realizar treinamento de redes *feedforward*, na qual o fluxo de dados é unidirecional no sentido da saída. Quando um sinal entra na rede, ele passa pelos neurônios e é produzida uma saída, que é comparada com o sinal desejado e estipula-se

um valor de erro. Esse valor de erro passa a se propagar em sentido contrário, da saída para a entrada, alterando os valores de pesos das sinapses para que se tenha uma resposta mais coerente. Para esses novos valores nas sinapses, um novo erro é calculado e continua-se o ciclo treinamento que vai encerrar quando atingir um valor predeterminado de épocas ou uma quantidade de erro máxima. Na Figura 7 é apresentado a retropropagação dos erros.



Fonte: adaptado de (PAULA, 2002)

Segundo Paula (2002), o *backpropagation* surgiu em 1974 com o trabalho de Werbos (1974) em Harvard, e desde então surgiram diversas variações do algoritmo. Em um estudo recente apresentado por Khadse, Chaudhari e Borghate (2017) foi comparado o desempenho de sete diferentes algoritmos: Levenberg–Marquardt (LM), *conjugate gradient backpropagation* (CGB), *scaled conjugate gradient backpropagation* (SCGB), *one-step secant* (OSS), *gradient descent with momentum* (GDM), *Bayesian regularization* (BR), *gradient descent with adaptive learning rate* (GDX) e foi apresentado que o método SCGB apresenta um melhor desempenho, com uma menor taxa de erro, entre estes algoritmos de treinamento.

2.3 Número de neurônios em camada escondida

Um dos parâmetros de uma RNA de múltiplas camadas é o número de neurônios em camadas escondidas. Esse número não pode ser muito grande, pois pode causar um problema de sobre treinamento e não deve inferior ao necessário por causar um problema de. De acordo com Panchal, F. e Panchal, C (2014) não há uma fórmula exata que dará o número correto de neurônios em camada escondida para se ter uma quantidade menor de erro, o que se deve fazer é por tentativa e erro, tentar utilizar um número pequeno de neurônios, e ir aumentando gradualmente e acompanhar os resultados. A fórmula que é sugerida para se aproximar do número de neurônios escondidos é dada pela Equação (4).

$$N_{es} = \frac{2}{3}(N_{en} + N_{sa}) \quad (4)$$

Em que N_{es} representa o número de neurônios em camada escondida, N_{en} representa o número de neurônios na entrada e N_{sa} os neurônios na saída.

Ainda segundo Panchal, F. e Panchal, C (2014) outra abordagem poderia empregar o uso de uma “regra do polegar” na qual:

- O número de neurônios da camada escondida deve estar entre o número de neurônios na camada de entrada e saída.
- O número de neurônios da camada escondida deve ser menor que duas vezes o tamanho da camada de entrada.

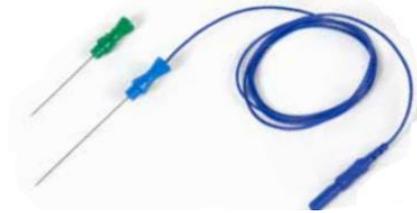
2.4 Sinais mioelétricos

Para que o corpo humano realize uma contração muscular, sinais nervosos são direcionados a uma unidade motora, que é formada pelos neurônios, fibras musculares e junções neuromusculares. Forma-se então um campo elétrico a partir da junção dos sinais de cada fibra muscular que é chamado de sinal mioelétrico, que tem uma banda de frequência entre 2 e 500 Hz, e uma amplitude de sinal de 50 μ V a 5mV. (SERAFIM e NETO, 2013)

Para que seja feita a leitura dos sinais mioelétricos é necessário o uso de eletrodos que podem ser colocados diretamente em contato com o músculo com o uso de uma agulha (Figura 8) ou na sua superfície com o eletrodo (Figura 9). De acordo com Coimbra (1994), eletrodos de agulha apresentam um melhor desempenho, proporcionando uma melhor leitura do sinal mioelétrico sendo utilizados na detecção de

distúrbios neuromusculares. Por sua vez, os eletrodos de superfície são amplamente utilizados devido a sua simplicidade e por não necessitarem serem inseridos na pele.

Figura 8 - Eletrodo de agulha.



Fonte: (TECHNOMED EUROPE, 2016)

Figura 9 - Eletrodo de superfície.



Fonte: Do Autor

2.5 Energia de um sinal

Um sinal dito finito no tempo é aquele que tende a zero quando tempo tende ao infinito pode ter seu tamanho medido utilizando sua energia. A energia não pode ser definida apenas como a área entre o sinal e o eixo do tempo, pois os valores positivos e negativos do sinal se anulariam. A energia de um sinal $x(t)$ contínuo no tempo é dada então como área do valor quadrático do sinal para que seja sempre positiva conforme a Equação (5). O valor da energia deve ser calculado em módulo caso $x(t)$ seja complexo. (LATHI, 2007)

$$E_x = \int_{-\infty}^{\infty} |x(t)|^2 dt \quad (5)$$

Caso o sinal seja discreto ao longo do tempo e finito, a sua energia é expressa pela Equação (6):

$$E = \sum_{n=-\infty}^{\infty} |x(n)|^2 \quad (6)$$

3 METODOLOGIA

3.1 Introdução

Nessa seção é apresentado como os dados dos sinais mioelétricos foram coletados bem como detalhes sobre a rede neural utilizada para reconhecimento do padrão de movimentos das mãos.

3.2 Dados

Os dados aqui utilizados para treinar a rede neural foram disponibilizados pelo projeto CapgMyo (2016) o qual produziu um trabalho em que se obteve um resultado de 88% para um reconhecimento instantâneo dos movimentos da mão. No projeto CapgMyo foi utilizado uma rede convolucional com *deep learning* (rede capaz de receber como entrada uma matriz de dados) capaz de reconhecer sinais mioelétricos por meio imagem formadas por eletrodos em um dado instante (GENG, et al., 2016). Uma breve comparação será feita após a apresentação dos resultados deste projeto. Os dados foram coletados com uso de 128 eletrodos de superfície, um método conhecido como eletromiografia de superfície de alta densidade (HD-sEMG) pela sua quantidade de sensores, e foram organizados numa forma de matriz 16x8. A grande vantagem de se poder utilizar um maior número de eletrodos é garantia que mesmo havendo uma mudança de posição destes entre uma coleta de dados e outra por um descuido, pode-se garantir que esses dados serão coletados por um eletrodo vizinho.

Dez pessoas com idades entre 23 e 26 anos foram convidadas a realizar os movimentos para que fosse possível adquirir informações dos sinais mioelétricos. Todas elas assinaram um termo de compromisso de acordo com a Declaração de Helsinki e aprovado pelo Comitê de Ética da Universidade de Zhejiang na China (DU, et al, 2016).

Os eletrodos utilizados, apresentados na Figura 10, possuem um diâmetro de 3 mm, foram dispostos com uma distância de 7,5 mm horizontal e 10,05 mm vertical, foram cobertos com um gel condutivo de impedância inferior que 3 k Ω . Para a aquisição foram utilizados 8 módulos com 16 canais cada, organizados em forma de uma matriz 8x2. O conjunto de aquisição foi disposto ao redor do antebraço direito proximo ao cotovelo conforme a Figura 11.

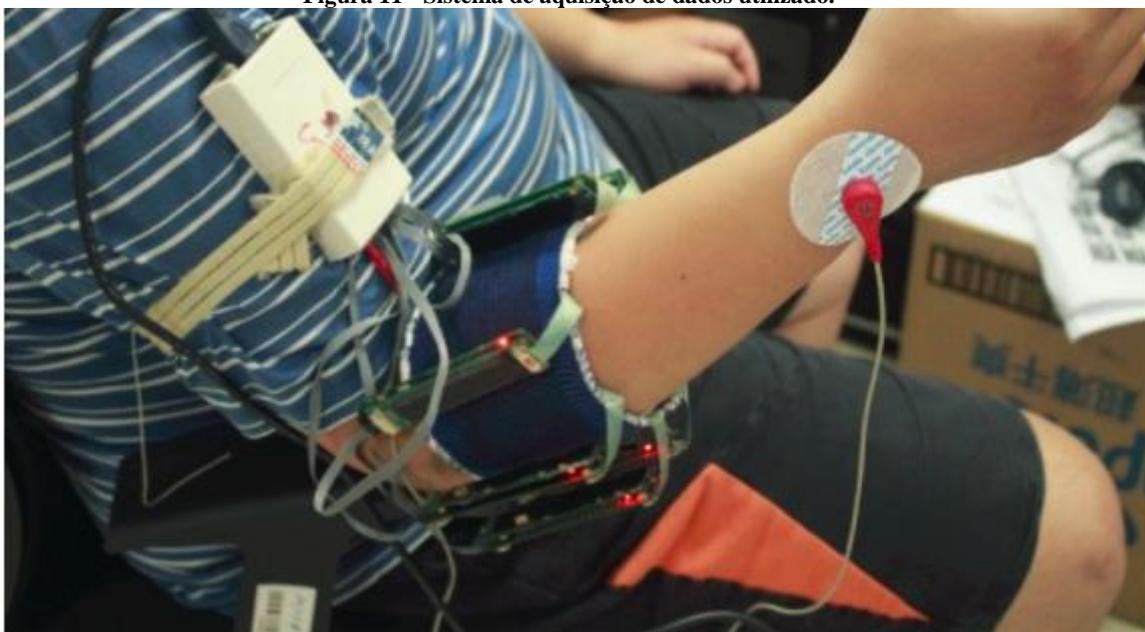
Os sinais mioelétricos passaram por um filtro do tipo passa faixa com banda de 20-380 Hz, para remoção de ruídos, e por um rejeita faixa de 45-55 Hz, para remover interferência da rede elétrica. Foram amostrados a uma frequência de 1000 Hz utilizando 16 bits na conversão. Esse conjunto de dados foi acumulado em um controlador ARM e transmitido para o PC pelo WiFi.

Figura 10 - Disposição dos eletrodos no antebraço.



Fonte: (DU, *et al*, 2016)

Figura 11 - Sistema de aquisição de dados utilizado.



Fonte: (DU, *et al*, 2016)

Um vídeo tutorial foi exibido a cada uma das pessoas antes da aquisição para que elas pudessem se familiarizar com o procedimento. Foi utilizado uma lixa suave e álcool para limpar a pele antes de se aplicar o conjunto de eletrodos para se ter uma

menor impedância na pele. Em uma tela foi exibido os diferentes movimentos que o indivíduo deveria fazer, cada um dos movimentos teve uma duração de 3 segundos e para se garantir que não houvesse erros devido a tempo de reação dos movimentos, foi feita uma janela no sinal de um segundo no meio, correspondendo a 1000 amostras de tempo.

Cada movimento foi repetido dez vezes, com tempo de sete segundos para descanso entre repetições. Os movimentos utilizados foram as flexões de cada um dos dedos da mão direita conforme mostrado na Figura 12.

Figura 12 – Movimentos dedos da mão a serem reconhecidos.



Fonte: (DU, *et al*, 2016)

3.3 Toolbox de Redes Neurais do MATLAB®

As 5 classes de movimentos realizados pelas 10 diferentes pessoas com 10 repetições formam um banco de dados com 500 amostras a serem utilizadas pela RNA. Na Toolbox de Redes Neurais do MATLAB® os dados dos sinais mioelétricos são divididos em 3 conjuntos: treinamento, validação e testes conforme a Tabela 1. O conjunto de treinamento é utilizado apenas para treinar a rede neural. O conjunto de validação é utilizado para verificar a generalização de uma rede neural e encerrar o treinamento. O conjunto de testes não interfere no treinamento e é utilizado como medida de averiguação da qualidade da resposta de uma RNA. Os resultados descritos na próxima seção 4 utilizam a resposta dos dados de teste para qualificar as redes neurais.

Tabela 1 - Divisão dos dados no MATLAB®.

| Conjunto | % dos Dados | Quantidade de amostras |
|-------------|-------------|------------------------|
| Treinamento | 80 | 400 |
| Validação | 10 | 50 |
| Teste | 10 | 50 |

3.4 Redes neurais

Neste trabalho foi utilizada uma rede neural multicamadas para reconhecimento de padrões. A alimentação da rede é *feedforward*, com função de ativação sigmoide e treinamento utilizando *backpropagation* com o gradiente conjugado escalonado. A *Toolbox* de Redes Neurais do MATLAB® permite a criação dessa rede com grande facilidade utilizando o comando “*nprtool*” com um guia passo-a-passo.

Algumas abordagens de como tratar os dados a serem entrados na rede neural para realizar o reconhecimento de padrão foram feitas e são aqui descritas:

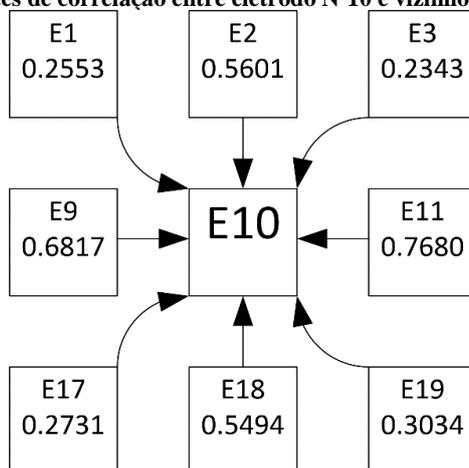
1º Ensaio:

A primeira tentativa foi entrar com os dados sem um tratamento prévio, um vetor de 128 mil pontos correspondendo a imagem de 1000x128 pixels formados pelos 128 eletrodos durante as 1000 amostras durante o tempo de 1 segundo, um exemplo desses dados estão ilustrados no apêndice A.

2º Ensaio:

A correlação é um grau de associação entre duas variáveis, calculadas no MATLAB ® pela função “*corrcoef*”. Foi observado que os sinais mioelétricos produzidos por eletrodos vizinhos apresentaram um índice de correlação em entre 50% e 70%, que é o grau de associação médio considerável. Conforme exemplificado na Figura 13.

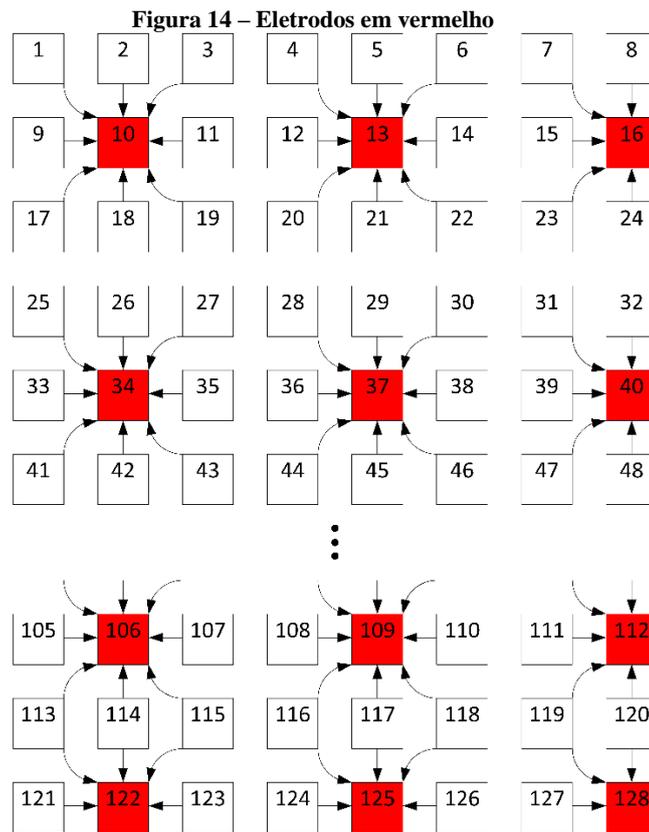
Figura 13 - Índices de correlação entre eletrodo N°10 e vizinhos em uma amostra



Fonte: Do Autor

Baseado nessa informação idealizou-se reduzir o número de dados ignorando uma vizinhança de sensores, sendo esses dados apenas representados pelo valor do eletrodo central. Reduzindo assim a imagem de 128x1000 para 18x1000, sendo selecionados os eletrodos em vermelho conforme a Figura 14.

O resultado desse método é uma redução de 85,6% dos dados conforme pode-se observar no apêndice B.

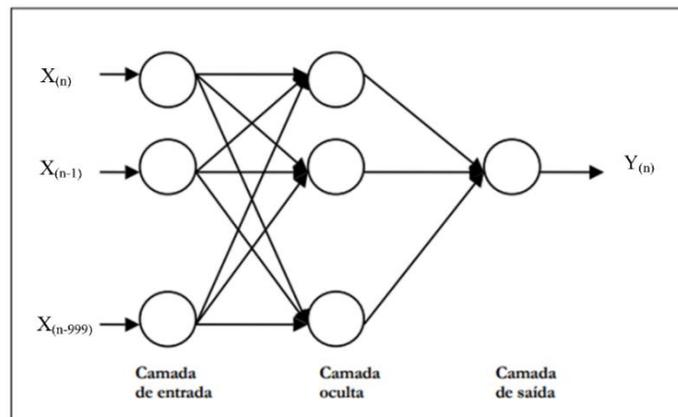


Fonte: do Autor

3º Ensaio:

Como apresentado por Ferreira (2014), uma das formas de se trabalhar com processamento temporal em redes neurais é utilizar janelas de tempo, onde os dados de entrada são uma sequência temporal de informação, conforme mostrado na Figura 15.

Figura 15 – Exemplo de RNA para processamento temporal de dados

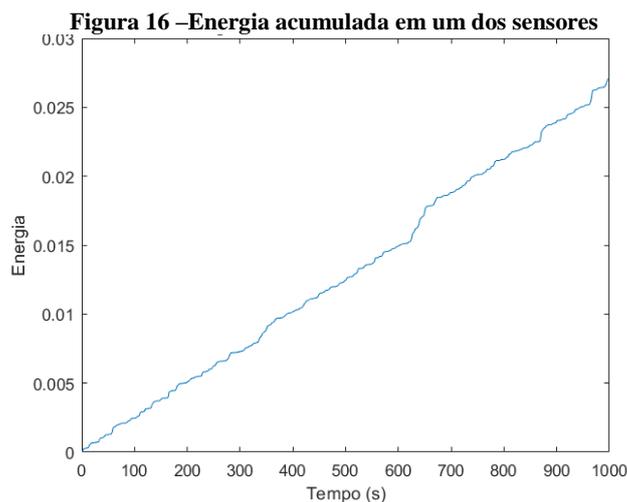


Fonte: Adaptado de (FERREIRA, 2004)

A partir dessa ideia veio a necessidade de se ter apenas um vetor representando todos os eletrodos durante o espaço de tempo. Foram então feitas média aritmética, geométrica e harmônica utilizando os comandos “mean” “geomean” “harmmean” respectivamente entre os 128 sensores ao longo dos 1000 pontos do tempo para que se tivesse apenas um vetor de dados ao longo do tempo.

4º Ensaio:

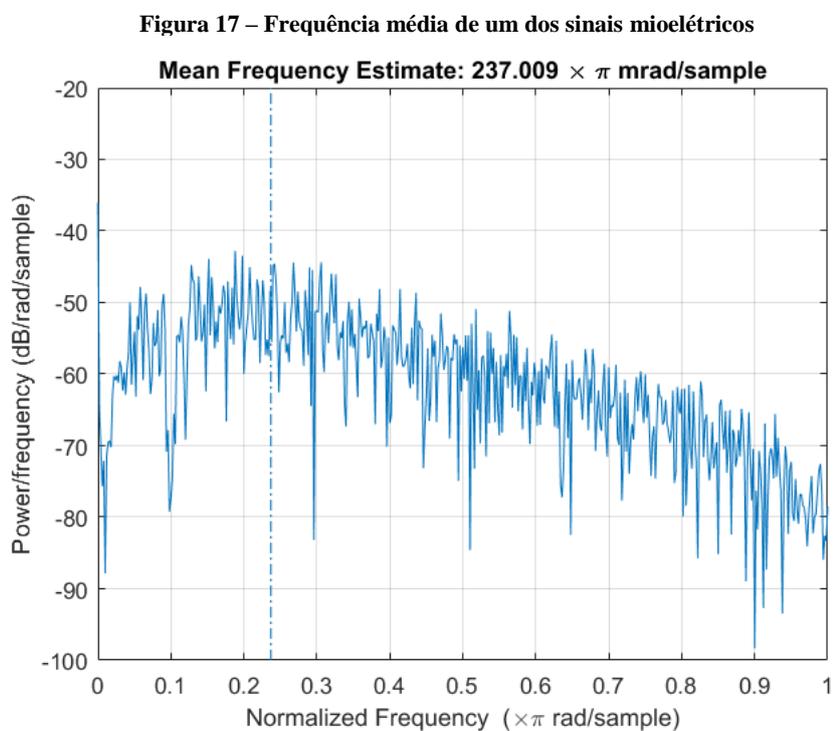
Dados de energia acumulado de uma eletroencefalografia (EEG) foram utilizados na predição de uma epilepsia (Gigola, *et al.*, 2004 apud Gajic, *et al.*, 2014), com essa ideia utilizou-se a possibilidade de tratar os dados a energia acumulada de cada um dos 128 eletrodos ao final dos 1000 pontos de aquisição, entrando na rede neural com esse vetor de 128 valores de energia utilizando a Equação (6) apresentada na seção 2. É apresentado na Figura 16 um exemplo da energia acumulada em um dos sinais.



Fonte: Do Autor

5º Ensaio:

No trabalho apresentado por Phinyomark *et al.*, (2012), a frequência média foi utilizada para encontrar um padrão em sinais mioelétricos. Foi utilizado então a média da frequência dos sinais produzidos pelos 128 sensores usando o comando “meanfreq” no MATLAB®, entrando na rede neural com esse vetor de 128 valores de frequência. Apresenta-se na Figura 17 um exemplo de frequência média utilizado neste ensaio.



Fonte: Do Autor

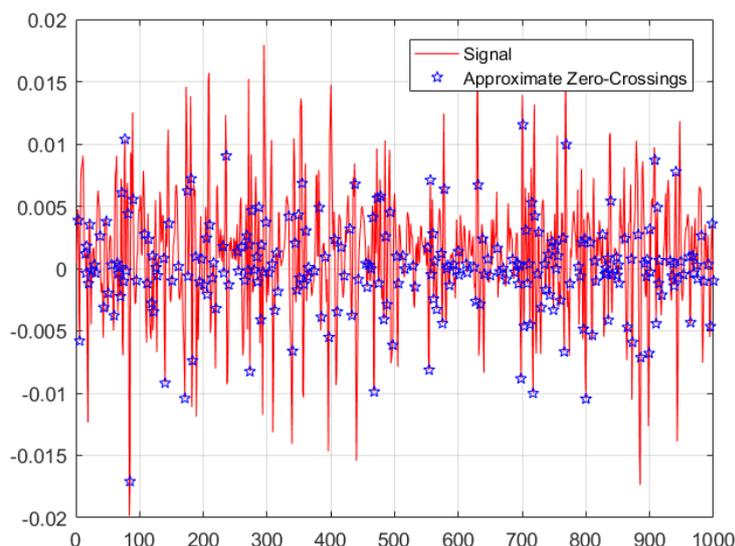
6º Ensaio:

No trabalho apresentado por Geethanjali (2016) várias formas de tratamento de dados mioelétricos foram estudadas, entre elas usar a variância. A variância mostrou que pode ser utilizada para encontrar um padrão em sinais mioelétricos. Foi utilizado então valores de variância dos sinais produzidos pelos 128 sensores ao longo das 1000 amostras no tempo usando o comando “var” no MATLAB®, entrando na rede neural com esse vetor de 128 valores de variância.

7º Ensaio:

No trabalho apresentado por Geethanjali (2016) uma outra forma de abordagem para tratamento de sinais mioelétricos é utilizar o número de cruzamento no zero. Dessa forma, foi utilizado o número de vezes que o valor da tensão dos sinais mioelétricos cruzavam o zero, a Figura 18 mostra marcações onde há um cruzamento ao longo das mil amostras no tempo de um dos sensores. Foram então introduzidos na RNA um vetor de 128 valores da quantidade de cruzamentos em zero.

Figura 18 - Número de cruzamentos em zero de um dos sensores.



Fonte: Do Autor

4 ANÁLISE DE RESULTADOS

4.1 Introdução

Esta seção apresenta os resultados, utilizando como base para avaliar o desempenho de cada RNA o valor de erro em classificação durante testes após o treinamento. Além disso, foram avaliadas as redes utilizando métodos para aproximação do número ideal de neurônios na camada escondida com o uso de métodos estudados na seção 2. Todos os treinamentos foram realizados utilizando uma máquina com processador i7-4510u @ 2Ghz e 4GB de memória RAM.

4.2 Análise de cada ensaio

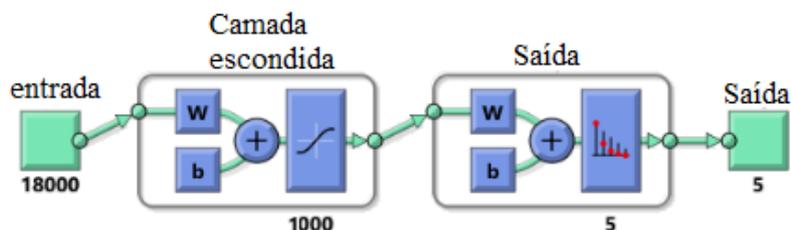
1º Ensaio:

No primeiro ensaio realizado, esperava-se ter a melhor resposta por não haver perda de dados. Infelizmente, não possível realizar o treinamento dessa rede por falta de memória de acesso aleatório (RAM) necessária. De acordo com o que foi abordado no Capítulo 2, com 128 mil neurônios de entrada, usando a Equação (4) seriam necessários algo entorno dos 85 mil neurônios na camada escondida extrapolando o limite máximo de 10 mil do MATLAB®.

2º Ensaio:

No segundo ensaio, mesmo reduzindo para 18 mil pontos de entrada, a quantidade de memória RAM da máquina ainda é insuficiente para treinar a rede com a quantidade de neurônios adequada proposta pela Equação (4), cerca 12mil. A rede foi treinada então com 1000 neurônios, devido a limitações de RAM, na camada escondida e apresentou um erro elevadíssimo, 80% dos dados foram classificados incorretamente durante testes. Essa quantidade de erros indica que os dados não poderiam ser assim reduzidos para este treinamento. Entre o eletrodo central e aqueles em suas diagonais na Figura 13 a correlação do sinal mioelétrico é baixa, sinalizando a necessidade de se utilizar mais eletrodos para realizar esse procedimento, mas ao mesmo tempo sendo inviabilizada essa opção por falta de memória RAM. É apresentado na Figura 19 o diagrama da rede neural utilizada neste ensaio

Figura 19 – Diagrama da RNA do 2º ensaio

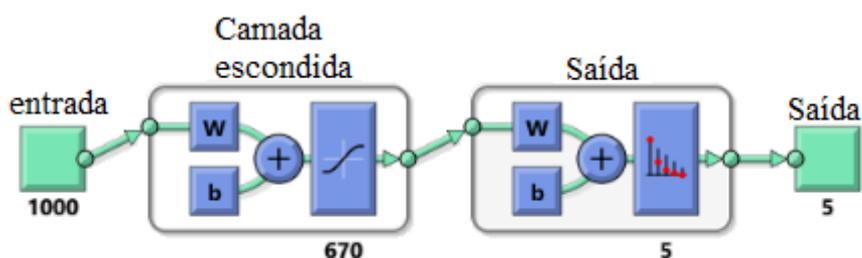


Fonte: do Autor.

3º Ensaio:

No terceiro ensaio, como dito anteriormente foram feitas as médias aritmética, geométrica e harmônica dos 128 sensores, e a entrada passou a ser um vetor de 1000 pontos representando o tempo. O resultado também foi um erro elevado: 86%, 79% e 93% de classificações equivocadas durante testes para as médias aritmética, geométrica e harmônica respectivamente. A razão disso é que os sinais de cada um dos sensores são bastante diferentes, tendo valores de correlação abaixo dos 10% para sensores distantes fazendo com estes valores de média representem apenas um valor aleatório, impossibilitando que a RNA encontre um padrão. Variando o número de neurônios não houve melhorias mesmo com o número de neurônios utilizado na Equação (4).

Figura 20 - Diagrama da RNA do 3º ensaio

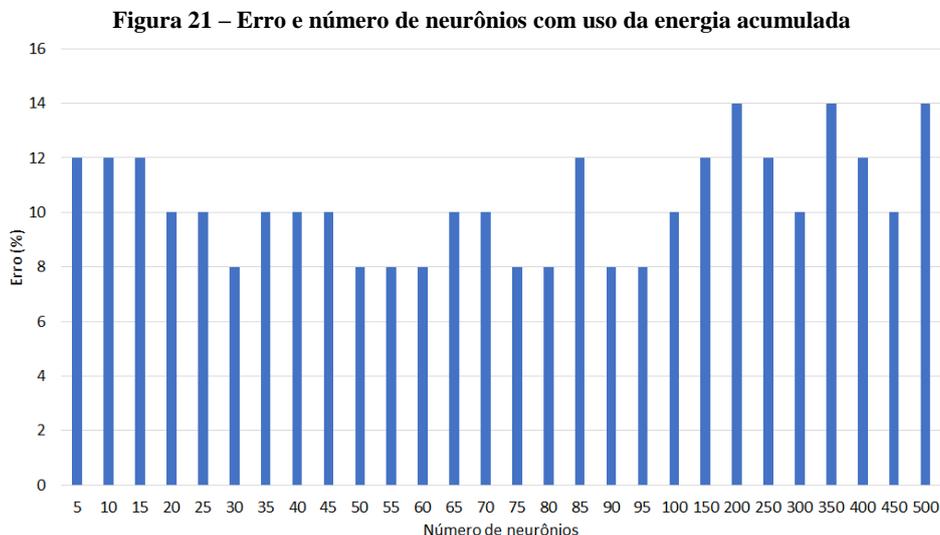


Fonte: do Autor

4º Ensaio:

Com o uso da energia acumulada em cada um dos sensores foi possível adquirir resultados que tiveram um erro em torno dos 10%, comprovando a sua eficiência do método em reconhecer o padrão dos movimentos dos dedos da mão. Nesse método foram utilizados 128 valores da energia acumulada ao final de cada gesto realizado como valores de entrada na RNA. Aplicando a Equação (4), tem-se um valor de

aproximadamente 89 neurônios na camada escondida. Apresenta-se no gráfico da Figura 21 uma porcentagem dos dados que foram classificados incorretamente durante testes variando-se o número de neurônios. Cada treinamento desta RNA levou em torno de 1 segundo.

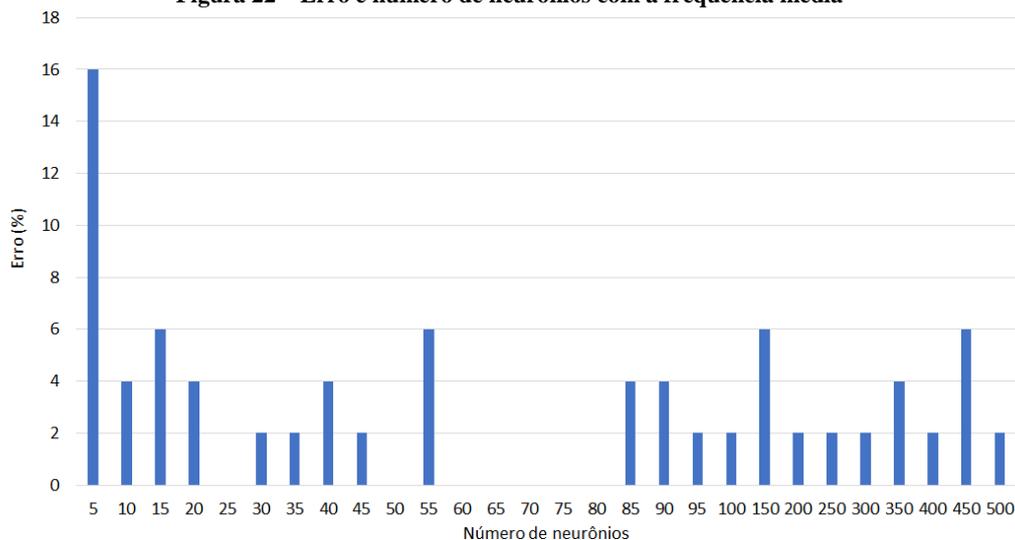


Fonte: do Autor

5º Ensaio:

Com o uso da frequência média dos sinais em cada um dos sensores foi possível adquirir resultados que tiveram um erro máximo de 16%, comprovando a sua eficiência do método em reconhecer o padrão dos movimentos dos dedos da mão. Nesse método foram utilizados 128 valores da frequência média ao final de cada gesto realizado como valores de entrada na RNA. Apresenta-se no gráfico da Figura 22 uma porcentagem dos dados que foram classificados incorretamente durante testes variando-se o número de neurônios.

Figura 22 – Erro e número de neurônios com a frequência média

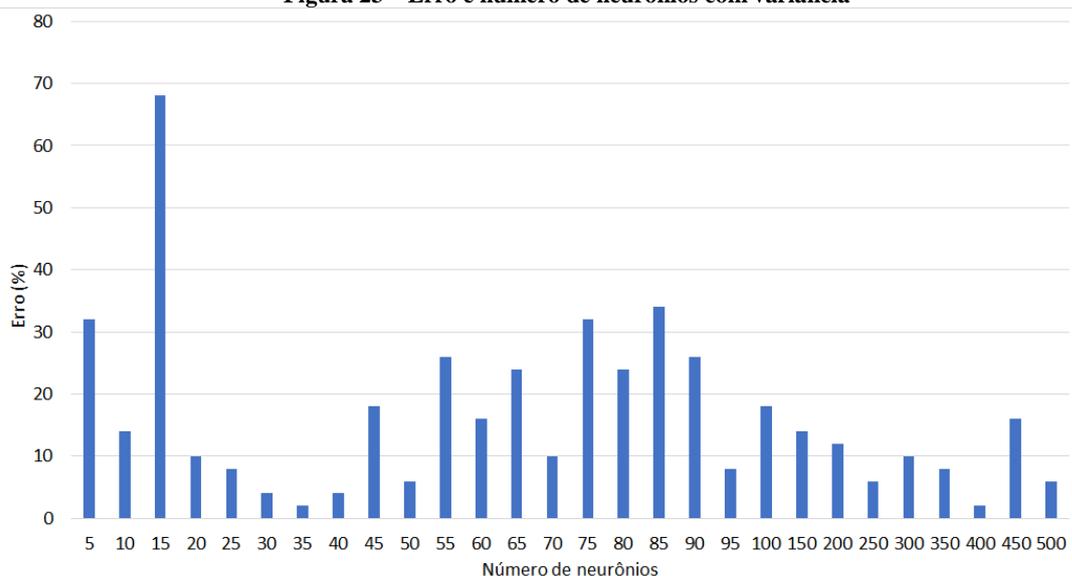


Fonte: do Autor

6º Ensaio:

Com o uso da variância em cada um dos sensores foi possível adquirir resultados que tiveram um erro de 2% utilizando 35 neurônios, comprovando a sua eficiência do método em reconhecer o padrão dos movimentos dos dedos da mão. Nesse método foram utilizados 128 valores de variância dos sinais mioelétricos como valores de entrada na RNA. Apresenta-se no gráfico da Figura 23 uma porcentagem dos dados que foram classificados incorretamente durante testes variando-se o número de neurônios. Cada treinamento desta RNA levou em torno de 1 segundo.

Figura 23 – Erro e número de neurônios com variância

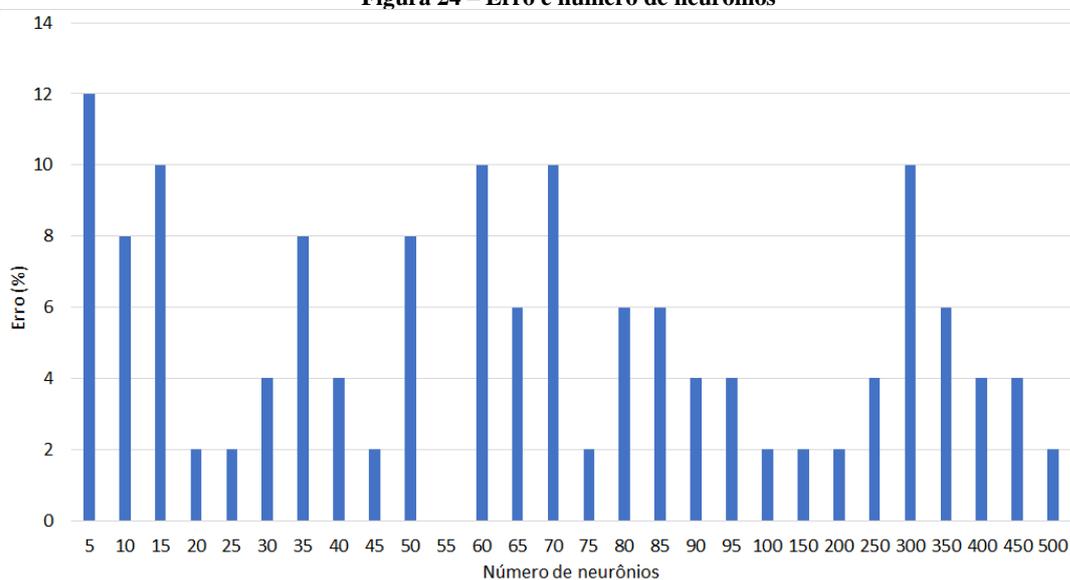


Fonte: do Autor

7º Ensaio:

Com o uso do número de cruzamentos no zero em cada um dos sensores foi possível adquirir resultados que tiveram um erro máximo de 12%, comprovando a sua eficiência do método em reconhecer o padrão dos movimentos dos dedos da mão. Nesse método foram utilizados 128 valores do total de cruzamentos de zero de um sinal mioelétrico durante um gesto realizado como valores de entrada na RNA. Apresenta-se no gráfico da Figura 24 uma porcentagem dos dados que foram classificados incorretamente durante testes variando-se o número de neurônios. Cada treinamento desta RNA levou em torno de 1 segundo.

Figura 24 – Erro e número de neurônios



Fonte: do Autor

5 CONCLUSÕES

Neste trabalho foram estudadas rede neurais para reconhecimento de padrões em sinais mioelétricos utilizando o software MATLAB®. A rede neural utilizada possuía duas camadas *feedforward* e utilizava um algoritmo de treinamento com *backpropagation* com o gradiente conjugado escalonado, com função de ativação dos neurônios escondidos utilizando função sigmóide.

Dentre os modelos de tratamento de dados, por tentativa e erro, foi observado que utilizando a energia acumulada, a frequência média e a variância é possível identificar diferentes movimentos realizados pelos dedos da mão direita com um erro baixo durante testes de classificação. A quantidade de neurônios para a camada escondida desta também foi avaliada por tentativa e erro, resultados entre 25 e 30 neurônios apresentaram uma melhor resposta.

Entretanto, vale ressaltar que utilizando este método de classificação de sinais mioelétricos para o controle de uma prótese não é o ideal, pois aqui é utilizado uma janela de tempo de 1 segundo para identificar o movimento, o que irá causar um atraso. Uma outra técnica apresentada por Geng *et al.*, (2016) permite a identificação instantânea de movimentos da mão, porém em contrapartida necessita de uma unidade de processamento gráfico (GPU) da Nvidia® que tenha tecnologia de processamento paralelo CUDA, e ainda assim dependendo da GPU utilizada tem um tempo de treinamento de 1 a 2 horas comparado com o método aqui utilizado que tem treinamento em 1 segundo.

Para trabalhos futuros é sugerida implementação de um sistema próprio de aquisição de sinais mioelétricos. Assim será possível expandir o banco de dados e em consequência diminuir o erro de classificações. Coletar dados de pessoas com deficiência também deve ser uma meta, pois assim será possível estudar se é possível reconhecer padrões em sinais mioelétricos em um coto. Por fim, é sugerido desenvolver uma prótese que utilize os sinais mioelétricos coletados como forma de controle.

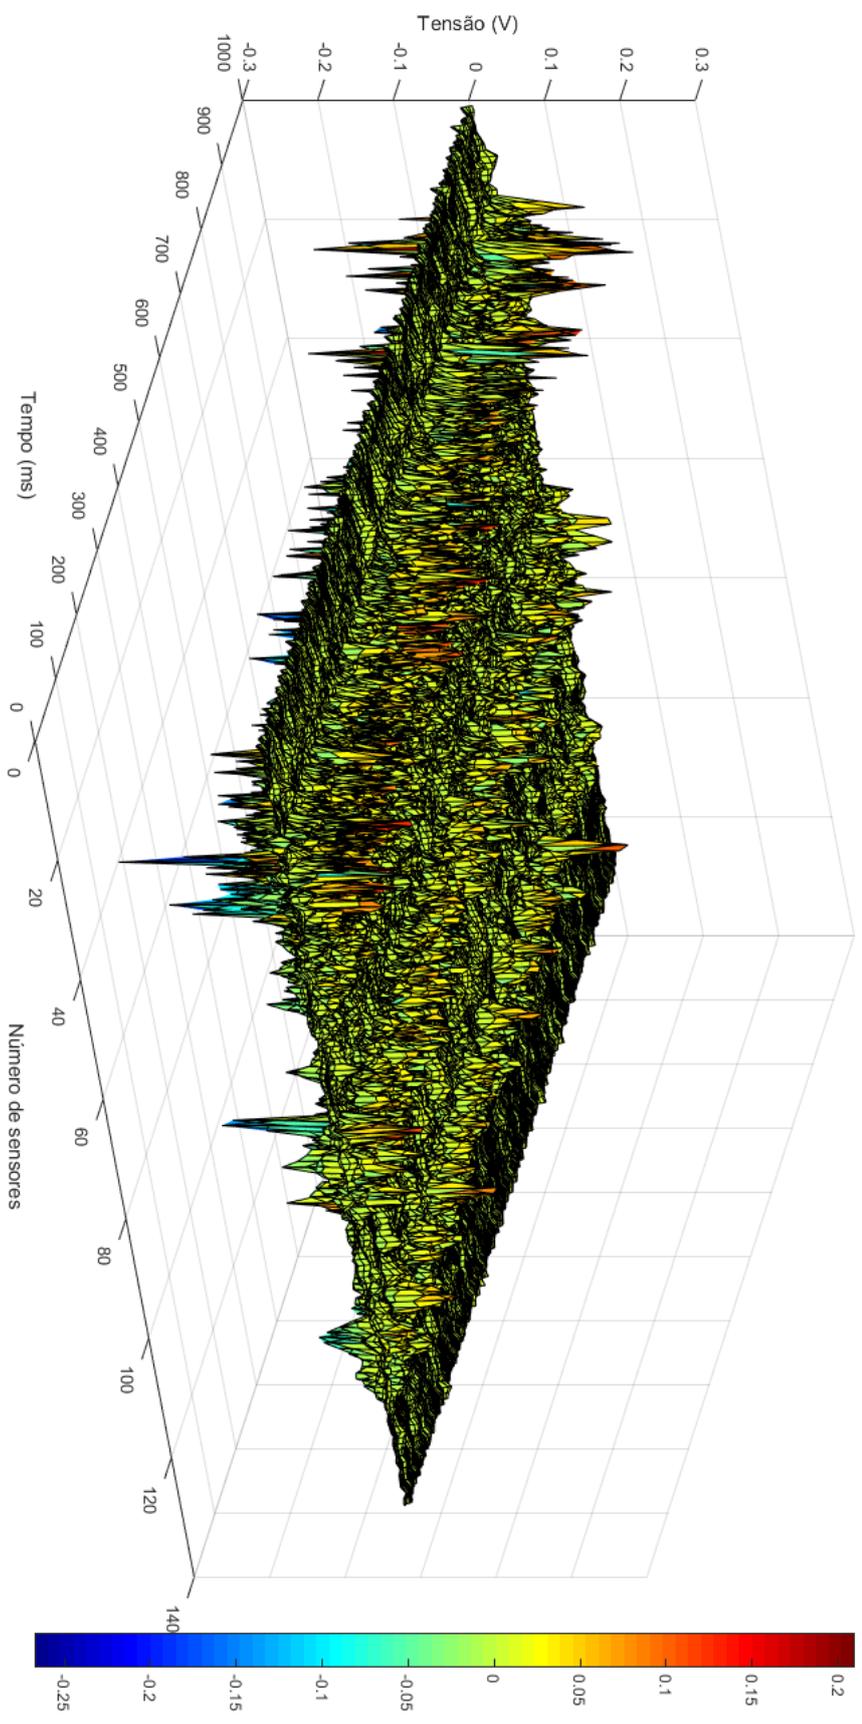
6 REFERÊNCIAS

- AGUIAR, F. G. **Utilização de Redes Neurais para Detecção de Padrões de Vazamentos**. Universidade de São Paulo. São Carlos. 2010.
- BISHOP, C. M. **Neural Networks for Pattern Recognition**. Birmingham: Clarendon Press, 1995.
- BRAGA, A. D. P.; CARVALHO, A. P. D. L. F.; LUDERMIR, T. B. **Redes Neurais Artificiais Teoria e Aplicações**. Livros Técnicos e Científicos Editora S.A. Rio de Janeiro. 2000.
- CARVALHO, J. A. **Amputações de Membros Inferiores: em busca da plena reabilitação**. 2. ed. São Paulo: Manoele, 2003.
- COIMBRA, A. J. F. **Análise computadorizada de sinais bioelétricos**. Universidade Federal de Santa Catarina. Florianópolis. 1994.
- COSTA, R. C. **Modelos Preditivos de Velocidade de Vento para Sistemas Eólicos Baseados em Redes Neurais Artificiais**. UFPB. João Pessoa. 2016.
- DU, Y. et al. A High Density Surface Electromyography Database for Gesture Recognition; Yu Hu. **CapgMyo**, 2016. Disponível em: <<http://zju-capg.org/myo/data/index.html>>. Acesso em: 31 Outubro 2017.
- FERREIRA, A. A. **Comparação de Arquiteturas de Redes Neurais Para Sistemas De Reconhecimento de Padrões em Narizes Artificiais**. Universidade Federal de Pernambuco. Recife. 2004.
- GAJIC, D. et al. Classification of EEG signals for detection of epileptic seizures based on wavelets and statistical pattern recognition. **Biomedical Engineering: Applications, Basis and Communications**, v. 26, n. 2, 2014. ISSN 1450021.
- GENG, W. et al. Gesture recognition by instantaneous surface EMG images. **Scientific Reports**, n. 6, Novembro 2016. ISSN DOI: 10.1038/srep36571.
- GIGOLA, S. et al. Prediction of epileptic seizures using accumulated energy in a multiresolution framework. **Neurosci Methods**, p. 38:107, 2004.
- GRECO, F. S. **Redes Neurais Para Reconhecimento de padrões em vídeo MPEG4**. Universidade Federal do Paraná. Curitiba. 2011.
- GURNEY, K. **An Introduction to Neural Networks**. London: UCL Press Limited, 1997.
- HAYKIN, S. **Redes Neurais Princípios e prática**. 2a. ed. São Paulo: Artmed Editora S.A., 2001.
- HERCULANO-HOUZEL, S. The Human Brain in Numbers: A Linearly Scaled-up Primate Brain. **Frontiers in Human Neuroscience**, Rio de Janeiro, v. 3, n. 31, p. 3-31, Novembro 2009. ISSN doi:10.3389/neuro.09.031.2009.
- HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy of Sciences of the USA**, v. 79, p. 2555-2558, 1982.
- KHADSE, C. B.; CHAUDHARI, M. A.; BORGHATE, V. B. Electromagnetic Compatibility Estimator Using Scaled Conjugate Gradient Backpropagation Based Artificial Neural Network. **IEEE Transactions on Industrial Informatics**, v. 13, n. 3, Junho 2017. ISSN DOI: 10.1109/TII.2016.2605623.
- KRIESEL, D. A Brief Introduction to Neural Networks, 2007. Disponível em: <<http://www.dkriesel.com>>. Acesso em: 15 Outubro 2017.
- LATHI, B. P. **Sinais e Sistemas Lineares**. 2ª. ed. Porto Alegre: ArtMed Editora S.A, 2007.

- MATHWORKS. https://www.mathworks.com/help/pdf_doc/nnet/nnet_ug.pdf. **Neural Network Toolbox User's Guide (R2017b)**, 2017. Acesso em: 28 Outubro 2017.
- MINSKY, M.; PAPER, S. Perceptrons: an introduction to computational geometry. **MIT Press**, Massachusetts, 1969.
- MOLETA, P. Estudo da captação de sinais mioelétricos em instrumentação biomédica. **7o Congresso Nacional de Iniciação Científica**, Faculdade de Valinhos, 2007.
- PANCHAL, F. S.; PANCHAL, M. Review on Methods of Selecting Number of Hidden Nodes in Artificial Neural Network. **International Journal of Computer Science and Mobile Computing**, v. 3, n. 11, p. 455-464, Novembro 2014. ISSN 2320-088X.
- PAULA, M. B. D. **Introdução as Redes Neurais Artificiais**. Universidade Federal de Santa Catarina. Florianópolis. 2002.
- PEREIRA, H. **Prótese Mioelétrica para membro superior implementada em FPGA**. Universidade Federal de Santa Catarina. Araranguá. 2016.
- PITTS, W. S. M. A. W. A Logical Calculus Of The Ideas Immanent In Nervous Activity. **Bulletin of Mathematical Biophysics**, Chicago, v. 5, p. 115-133, 1943.
- SERAFIM, D. C.; NETO, A. J. D. S. Estruturando redes neurais artificiais paralelas e independentes para o controle de próteses robóticas. **Revista das Faculdades Integradas Claretianas**, São Paulo, v. 6, dezembro 2013.
- TECHNOMED EUROPE. EMG - Electromyography. **Technomed Medical accessories**, 2016. Disponível em: <<http://technomed.nl/product-catalog/emg-electromyography>>. Acesso em: 30 Outubro 2017.
- TEES, R. C. Review of the organization of behavior: a neuropsychological theory by Donald O. Hebb (1949). **Canadian Psychological Association**, v. 44, 2002.
- WERBOS, P. **Beyond regression: New tools for prediction and analysis in the behavioral sciences**. Universidade de Harvard. Cambridge. 1974.

APÊNDICE A

Exemplo de dados cru utilizados no 1º ensaio.



APENDICE B

Exemplo de dados reduzidos utilizados no 2º ensaio

