

Classificador de Gestos por Redes Neurais Artificiais utilizando Sinais Mioelétricos

Michelle G. B. da Fonseca, Edmar Egídio P. de Souza, André Gustavo S. Conceição e Eduardo F. de Simas Filho

Resumo— Neste trabalho é apresentado um sistema de classificação, baseado em Redes Neurais Artificiais, para discriminação de gestos de mão utilizando sinais eletromiográficos (EMG), que são obtidos através de uma braçadeira MyoTM composta por oito eletrodos que realizam a aquisição da informação da contração muscular durante a execução de movimentos padrões. É realizado um pré-processamento nos sinais adquiridos, extraindo sete características para cada eletrodo. Visando analisar o melhor desempenho do classificador, dois algoritmos de treinamento foram utilizados, o *Resilient Backpropagation (Rprop)* e *Levenberg Maguard (LM)*, onde o algoritmo Rprop obteve cerca de 91,3% de acerto de classificação entre as quatro classes de movimentos estudados, em relação ao algoritmo LM. Os resultados experimentais são apresentados para validar o método proposto.

Palavras-Chave— Classificação de Gestos, Reconhecimento de Padrões, Redes Neurais Artificiais, Sinais Eletromiográficos.

Abstract— In this work, a classification system based on Artificial Neural Networks is presented for discriminating hand gestures using electromyographic (EMG) signals obtained through a MyoTM armband, composed of eight electrodes that perform the acquisition of muscle contraction information during the execution of standard movements. Preprocessing is performed on the acquired signals, extracting seven characteristics for each electrode. In order to analyze the best performance of the classifier, two training algorithms were used - *Resilient Backpropagation (Rprop)* and *Levenberg Maguard (LM)* where the Rprop algorithm obtained about 91.3% of the classification accuracy of the four classes of studied, in relation to the LM algorithm. Experimental results are presented to validate the proposed method.

Keywords— Artificial Neural Network, Classification of Gestures, Electromyography Signals, Pattern Recognition.

I. INTRODUÇÃO

Este artigo objetiva a classificação de gestos da mão usando eletromiografia. O sinal de eletromiografia (EMG) é uma técnica eletro-diagnóstica usada para avaliar e registrar a atividade elétrica produzida pelos músculos esqueléticos humanos [1]. É um biossinal com várias aplicações potenciais, incluindo o diagnóstico de doenças neuromusculares, o controle de dispositivos como próteses, robôs, computadores, etc. O uso de sinais EMG com reconhecimento eficiente de gestos da mão pode ajudar no desenvolvimento de uma interface homem-máquina, possibilitando aumentar a autonomia das pessoas com necessidades especiais.

O objetivo do reconhecimento de gestos é criar um sistema capaz de identificar gestos humanos específicos e usá-los para transmitir informações ou controlar vários dispositivos. Este trabalho visa o reconhecimento do padrão de gestos das mãos motivado pela interação humano-robô.

O desenvolvimento de sistemas de controle baseados em sinais EMG concentra-se no aumento da autonomia e aceitação social de pessoas com mobilidade reduzida, melhorando sua qualidade de vida. No entanto, a parte mais difícil para o desenvolvimento de interfaces com controle mioelétrico é o reconhecimento dos padrões de sinal EMG [2]. Isto é devido às grandes variações nos sinais EMG, com assinaturas diferentes para gestos similares, dependendo da idade, atividade muscular, camada de gordura da pele e estilo de execução de gestos.

Para o reconhecimento de gestos foi proposta uma estratégia para extração de características, com o objetivo de reunir em algumas variáveis discriminantes utilizadas mais facilmente para detecção do movimento. Esta estratégia se mostrou mais eficiente em relação à uma análise diretamente sobre os sinais extraídos pelos eletrodos [2].

Neste trabalho, é proposto a utilização de uma Rede Neural Artificial (RNA), treinada para realizar a classificação dos gestos a partir das características extraídas dos sinais das classes de movimentos. A estratégia proposta permite o reconhecimento de quatro movimentos em pessoas com características diferentes como idade e gênero.

Este trabalho está dividido da seguinte forma: a Seção II discute os antecedentes para aquisição do sinal EMG, extraindo características para realizar o reconhecimento de padrões gestuais e a rede neural artificial a ser utilizada. Na Seção III, está a metodologia que descreve o desempenho dos testes. A Seção IV apresenta os resultados dos testes descritos na Seção III. Finalmente, a Seção V apresenta as conclusões e propostas para trabalhos futuros.

II. AQUISIÇÃO E PROCESSAMENTO DE SINAIS

A. Sensor MyoTM

O sensor MyoTM é uma braçadeira que usa a técnica conhecida como eletromiografia (EMG), por isso é capaz de capturar sinais elétricos dos músculos do antebraço que podem ser usados para controlar outros dispositivos com esses gestos. Tem a vantagem de dispensar o uso de câmeras, que dependem de bom brilho, distância e caminho sem obstruções, como a maioria dos sistemas de controle de gestos [3], dispensa também o uso de gel condutor na utilização dos eletrodos, o

que facilita a realização dos testes, evitando causar desconforto nas pessoas participantes.

EMG é uma técnica de eletro-diagnóstico para avaliar e registrar a atividade elétrica produzida pelos músculos esqueléticos humanos. A técnica de EMG é utilizada para detectar o potencial elétrico gerado pelas células musculares quando elas são ativadas eletricamente ou neurologicamente [1]. Também pode ser definido como a medida da atividade elétrica muscular, que geralmente é representada em função do tempo, definida em termos de amplitude (utilizada neste trabalho), frequência e fase [2].

Devido ao fato de que os movimentos das mãos são realizados por vários músculos localizados no antebraço, o uso de sinais mioelétricos tornou-se uma boa opção para controlar uma prótese manual. Vale ressaltar que os sinais desses músculos, que realizarão um movimento semelhante na mão natural, podem ser usados para controlar a prótese, tornando mais fácil para o usuário adaptar-se a ele [4].

Para caracterizar adequadamente a atividade muscular do antebraço, este sensor é dividido em oito blocos diferentes, conforme Figura 1 [5], cada um contendo um sensor EMG de grau médico. Também possui um giroscópio, um acelerômetro e um magnetômetro, cada um com três eixos. Esta atividade muscular obtida é manipulada por um processador ARM Cortex M4, que se comunica com seus dispositivos usando o Bluetooth.

A braçadeira vem programada com cinco gestos padrão, porém que precisam de calibração para serem utilizados, são eles: *Fist*, *Fingers Spread*, *Wave In*, *Wave Out* e *Double Tap*, respectivamente, conforme Figura 2.

Este trabalho envolve o reconhecimento do padrão de quatro gestos: Desvio ulnar, desvio radial, mão fechada, mão com *gripper*, conforme Figura 3. O reconhecimento desses movimentos neste trabalho foi feito através dos dados brutos fornecidos pelos eletrodos contidos no Myo™, e qualquer outro movimento pode ser realizado sem a calibração do usuário, como normalmente é feito ao usar esta braçadeira para controlar os dispositivos.



Fig. 1. Braçadeira Myo™ e a Sequência do Sensor EMG [5].



Fig. 2. Gestos: *Fist*, *Fingers Spread*, *Wave In*, *Wave Out* e *Double Tap*, respectivamente [5].

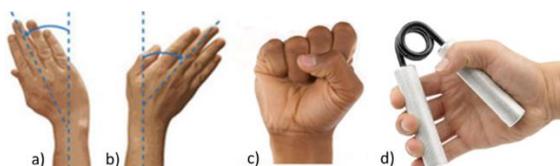


Fig. 3. Gestos. a) Desvio Radial b) Desvio Ulnar c) Mão fechada d) Mão com Gripper.

B. Reconhecimento de Padrão de Gestos

O processo de reconhecimento de padrões pode ser definido como o “processo pelo qual um padrão/ sinal recebido é atribuído a uma classe dentre um número predeterminado de classes (categorias)” [4].

Este processo pode ser dividido em duas etapas: extração de características e classificação. O sinal mioelétrico é redundante e ruidoso, ou seja, existe uma parte que não contribui com informação útil. A fase de extração de características tem por objetivo selecionar um conjunto de características que seja mais representativo e que contenha a maior parte da informação útil contida nos dados originais, e dessa forma obter um conjunto de dimensão menor e mais fácil de manipular na fase de classificação. Essa por sua vez, corresponde à identificação das características como pertencentes a uma determinada classe dentre certo conjunto que pode ou não ser especificado à priori [6].

Neste artigo utilizou-se sete atributos que caracterizam os sinais medidos pela braçadeira: Valor Médio Absoluto (MAV), Valor Quadrático Médio (RMS), Variância (VAR), Comprimento da Forma de Onda (WL), *Zero Crossing* (ZC) e *Slope Sign Change* (SSC) e Amplitude de Willison (WA) [1;7], descritas brevemente abaixo:

Média de valor absoluto (Mean Absolute Value - MAV): é o valor médio retificado (ARV) e pode ser calculada utilizando a média móvel de onda completa retificada EMG. Mais especificamente, é calculada tomando a média do valor absoluto do sinal de EMG. Uma vez que representa a maneira simples de detectar os níveis de contração muscular, torna-se um recurso popular para aplicações controlada por mioelétrica. É definida como:

$$MAV = \frac{1}{N} \sum_{n=1}^N |x_n| \tag{1}$$

onde N denota o tamanho do sinal e x_n representa o sinal EMG num segmento.

Média Quadrática (Root Mean Square - RMS): ele é representado como processo aleatório de amplitude modulada cuja Gaussiana RMS está relacionado com a força de contração constante e não-fatigante. Pode ser expresso como:

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2} \tag{2}$$

Variância do EMG (Variance - VAR): utiliza a energia do sinal de EMG como um recurso. Geralmente, a variância é o valor médio do quadrado do desvio dessa variável. No entanto, média de sinal EMG está perto de zero. Variância de EMG pode ser calculada pela:

$$VAR = \frac{1}{N-1} \sum_{n=1}^N x_n^2 \tag{3}$$

Forma de Comprimento de Onda (WL): é o comprimento acumulado da forma de onda durante o segmento de tempo. WL está relacionada com a amplitude de onda, frequência e tempo. É dada por:

$$WL = \sum_{n=1}^N |x_{n+1} - x_n| \tag{4}$$

Zero crossing (ZC): é o número de vezes que o valor da amplitude do sinal de EMG cruza o zero no eixo Y. Este recurso fornece uma estimativa aproximada das propriedades de domínio de frequência. É dada por:

$$ZC = \sum_{i=1}^{N-1} [sgn(x_i \times x_{i+1}) \cap |x_i - x_{i+1}| \geq lim.] \tag{5}$$

$$sgn(x) = \begin{cases} 1, & \text{se } x \geq \text{limiar} \\ 0, & \text{outro valor} \end{cases}$$

Slope Sign Change (SSC): é semelhante ao ZC, porém trata-se do número de alterações entre inclinação positiva e negativa entre os três segmentos consecutivos são realizados com a função de limiar para evitar a interferência no sinal EMG.

$$SSC = \sum_{i=2}^{N-1} [f[(x_i - x_{i-1}) \times (x_i - x_{i+1})]]$$

$$f(x) = \begin{cases} 1, & \text{se } x \geq \text{limiar} \\ 0, & \text{outro valor} \end{cases} \tag{6}$$

Amplitude de Willison (WA): é o número de vezes resultante da diferença entre a amplitude do sinal EMG entre dois segmentos adjacentes que excede um limite pré-definido.

$$WA = \sum_{i=1}^{N-1} [f|x_n - x_{n+1}|] \tag{7}$$

C. Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são estruturas computacionais inspiradas no funcionamento do cérebro humano, apresentando capacidade de aprendizagem e generalização. Atualmente são largamente utilizadas em problemas de classificação e regressão [8]. A Figura 4 mostra o diagrama de funcionamento do neurônio artificial. Neste modelo, x_i são as entradas, w_i são os pesos, estes são combinados para produzir um estado de ativação do neurônio através da Função de Ativação ou Limite Lógico. Uma vez que o limiar desta função é satisfeito, a saída do neurônio será produzida e usada como entrada para a próxima camada [9].

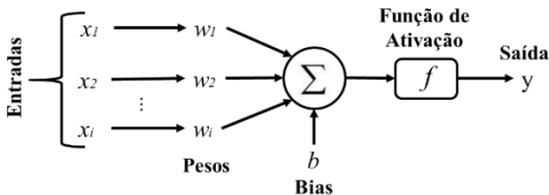


Fig. 4. Equação do Neurônio Artificial.

Durante o processo de treinamento da rede, os pesos são alterados iterativamente, de acordo com uma regra de aprendizagem específica. Normalmente, utiliza-se a minimização do erro médio quadrático entre a saída da rede e o alvo associado a classe de padrões (*target*). O sinal de excitação do neurônio é o resultado do produto escalar da entrada pelos pesos: $\sum_{i=0}^n X_i W_i$ [10].

Bias é um nó adicional na entrada e camadas ocultas e está conectado aos pesos da camada subsequente, a função de ativação é definida permanentemente com valor [11].

As camadas intermediárias são formadas por neurônios artificiais como qualquer outra camada, mas os sinais são passados para os outros neurônios obedecendo as funções de transferência que cada neurônio possui [10;12] O treinamento para o reconhecimento de padrões é realizado com base nas correções dos pesos nas conexões para relacionar as características e classes que promovem a melhor discriminação possível entre os diferentes padrões de classe.

O algoritmo *Backpropagation* é amplamente utilizado para o treinamento de redes neurais. É constituído por duas etapas: Propagação e Retropropagação de um conjunto de sinais através da rede. O primeiro é realizar a aquisição de dados e

propagá-lo em toda a rede, produzindo uma saída que é comparada à saída desejada e um valor de erro é calculado. Com este valor de erro calculado, o processo de *backpropagation* é iniciado, onde este erro é propagado de volta para a rede e usado para ajustar os pesos, visando minimizar o erro em cada tentativa e fazer com que o resultado seja próximo ao alvo [13].

O Algoritmo *Levenberg-Marquardt* – LMA é utilizado em muitos softwares para resolver problemas de ajuste de curva. Ele utiliza recursos matemáticos mais robustos como a introdução de um coeficiente para aproximação da matriz Hessiana em uma matriz definida positiva, para busca dos mínimos da função e testa outras condições de otimalidade.

III. METODOLOGIA

Na Figura 5 é possível verificar o diagrama de blocos com as etapas para executar o reconhecimento de gestos até a interação homem-máquina. Inicialmente, o usuário usa a braçadeira Myo™ e executa o movimento. Em seguida, os sinais brutos são coletados. Posteriormente, realiza-se a extração de atributos e finalmente, a rede neural artificial é treinada.

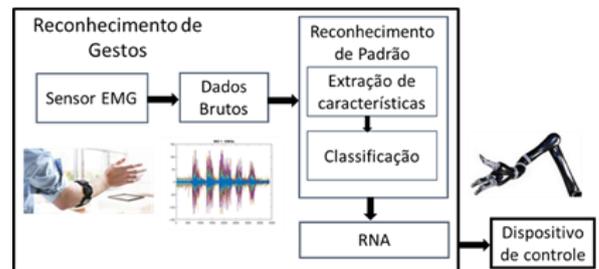


Fig. 5. Diagrama de Blocos para Reconhecimento de Gestos.

Os sinais EMG foram adquiridos por meio da braçadeira Myo™ em vinte pessoas, entre homens e mulheres, com idade de 20 a 30 anos. Os participantes realizaram 10 testes de cada movimento (Desvio Ulnar, Desvio Radial, Mão Fechada e Mão com *Gripper*) em cada dia de testes, sendo conseguido o máximo de 5 dias para a realização dos mesmos, porém nem todas as pessoas participaram de todos os dias. Nesta situação, obteve-se um total de 2000 amostras entre os quatro movimentos, ou seja, 500 amostras de cada. Um exemplo do sinal dos oito eletrodos para o movimento de Mão com *Gripper* pode ser visualizado na Figura 6.

Os dados brutos foram extraídos dos oito sensores EMG contidos na braçadeira e, todos eles foram normalizados entre zero e um, onde os sinais brutos foram divididos pelo valor máximo encontrado em cada ensaio. Em cada eletrodo foram extraídas sete características, conforme mencionadas na seção anterior e foram calculadas com o auxílio da ferramenta matemática MATLAB e que podem ser visualizadas no exemplo da Tabela I.

Nesta tabela também é possível verificar como os dados foram organizados em cada teste e foram normalizados devido ao fato da amplitude variar de pessoa para pessoa.

Dois algoritmos distintos foram utilizados para treinar a RNA proposta. O *Resilient Backpropagation* e *Levenberg-Marquardt*. Visando verificar a relevância dos atributos extraídos dos sinais EMG, foram realizados treinamentos utilizando todas as características, retirando-se apenas o WL e desconsiderando o WL e o WA. Essas características foram retiradas de forma aleatória em busca de um melhor resultado,

devido ao fato de terem a ver com a amplitude do sinal para cada pessoa, logo elas foram as primeiras a serem escolhidas.

Os sinais adquiridos foram pré-processados, extraindo-se as características para cada eletrodo. Considerando os 8

eletrodos disponíveis na pulseira, e as 7 variáveis extraídas, cada amostra possui 56 atributos, que serão as entradas para RNA realizar a classificação dos gestos.

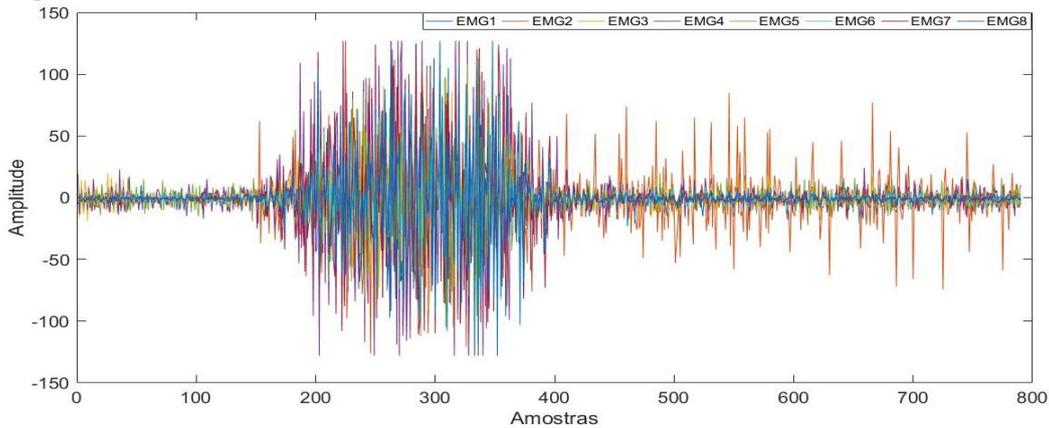


Fig. 6. Exemplo de Sinal EMG para Mão com Gripper.

TABELA I. EXEMPLO DA EXTRAÇÃO DE CARACTERÍSTICAS DOS DADOS BRUTOS PARA O MOVIMENTO MÃO COM GRIPPER NORMALIZADOS ENTE 0 E 1.

Mão com Gripper - Pessoa 1 - Dia 1 - Teste 1								
Extração Características	Sinais EMG Normalizados							
	EMG1	EMG2	EMG3	EMG4	EMG5	EMG6	EMG7	EMG8
MAV	0,1066	0,1594	0,0949	0,1462	0,1071	0,0855	0,1131	0,0932
RMS	0,1948	0,2445	0,1772	0,2685	0,1913	0,1639	0,2407	0,2038
VAR	0,0380	0,0597	0,0314	0,0721	0,0366	0,0268	0,0580	0,0416
WL	0,1640	0,2525	0,1601	0,2495	0,1850	0,1348	0,1794	0,1481
SSC	0,4810	0,5228	0,4873	0,5671	0,5620	0,4405	0,4177	0,4076
ZC	0,6089	0,5810	0,6152	0,6544	0,6620	0,6177	0,6380	0,6278
WA	0,9582	0,9734	0,9570	0,9734	0,9582	0,9278	0,9063	0,9177

Foram realizados 100 treinamentos para cada um dos testes, onde se escolheu o melhor classificador treinado, com base no Produto das Eficiências - PE obtidos na fase de teste. Com o classificador treinado, são extraídas as informações da matriz de confusão que mostra as eficiências de classificação de cada classe de entrada da RNA.

Na Figura 7 é possível verificar a Arquitetura de Rede Neural Artificial, que tem 56 atributos de entrada, uma camada oculta com 10 neurônios, onde w representa os pesos e b, o viés (bias), uma camada de saída onde é realizada a função de ativação e a saída com 4 dados (as classes). Ao aumentar ou diminuir a quantidade de neurônios ocultos, reduziu-se bastante a acurácia da RNA.

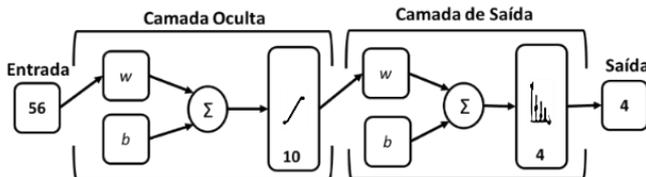


Fig. 7. Arquitetura da Rede Neural Artificial.

Utilizou-se a matriz de confusão para comparação de desempenho. Ela é simétrica e é interpretada principalmente através da sua diagonal, onde exibe a quantidade de amostras e a porcentagem que representam em cada uma das classes e o resultado de eficiência da matriz. As linhas e colunas mostram se houve algum falso positivo durante a execução do treinamento.

IV. RESULTADOS E DISCUSSÕES

Foram realizados vários testes de Treinamento da RNA para quatro classes de movimentos (Desvio Ulnar, Desvio

Radial, Mão Fechada e Mão com Gripper), que são as saídas da rede apontadas na Figura 7.

Algumas combinações de características foram feitas para a melhor validação, utilizando isso como método quantitativo de análise desses atributos. Conforme a Tabela 2, a rede obteve melhor desempenho utilizando o método *Resilient Backpropagation* – RP e quando se exclui a característica WL, tendo como entrada da rede 48 atributos, já que são utilizadas 6 características e para cada um dos 8 eletrodos. Foram realizados treinamentos com a exclusão do WL e do WA, pode-se notar que a característica WA não tem influência significativa devido às diferenças mínimas nos resultados sem ele. Já quando treinado com o LMA, a rede apresenta desempenho pouco menor, porém o tempo que leva para a realização do mesmo conjunto de dados de sinais EMG é 20 vezes superior à anterior.

O melhor resultado foi de 91,3% de acurácia para o treinamento com método RP e sem a característica WL, conforme pode ser visto na matriz de confusão na Figura 8. A classe 4 obteve melhor desempenho de classificação em todos os treinos, sendo o melhor resultado 96,8% no treino com o método RP sem WL e WA, conforme Figura 9.

TABELA 2. RESUMO DOS RESULTADOS DO TREINAMENTO DA RNA UTILIZANDO DOIS MÉTODOS DIFERENTES.

Algoritmo	Características utilizadas	Matriz de Confusão Geral (%)	PE
LMA	Todas	87,4	93,2
	Exceto WL	89,4	93,5
	Exceto WL e WA	88,7	93,4
RP	Todas	89,9	93,6
	Exceto WL	91,3	94,2
	Exceto WL e WA	91,1	93,7

Resilient Backpropagation						Levenberg-Marquardt							
Matriz de Confusão						Matriz de Confusão							
Classe de Saída	1	219 21,9%	9 0,9%	14 1,4%	0 0,0%	90,5%	9,5%	231 23,1%	19 1,9%	19 1,9%	2 0,2%	85,2%	14,8%
	2	15 1,5%	236 23,6%	8 0,8%	2 0,2%	90,4%	9,6%	10 1,0%	217 21,7%	8 0,8%	0 0,0%	92,3%	7,7%
	3	15 1,5%	5 0,5%	220 22,0%	10 1,0%	88,0%	12,0%	9 0,9%	12 1,2%	211 21,1%	13 1,3%	86,1%	13,9%
	4	1 0,1%	0 0,0%	8 0,8%	238 23,8%	96,4%	3,6%	0 0,0%	2 0,2%	12 1,2%	235 23,5%	94,4%	5,6%
		87,6%	94,4%	88,0%	95,2%	91,3%	12,4%	5,6%	12,0%	4,8%	8,7%		
		1	2	3	4			1	2	3	4		
		Classe Alvo						Classe Alvo					

Fig. 8. Matrizes de confusão dos métodos RP e LMA – treino sem WL.

Matriz de Confusão							
Classe de Saída	1	222 22,2%	13 1,3%	14 1,4%	0 0,0%	89,2%	10,8%
	2	10 1,0%	228 22,8%	8 0,8%	1 0,1%	92,3%	7,7%
	3	17 1,7%	8 0,8%	222 22,2%	10 1,0%	86,2%	13,8%
	4	1 0,1%	1 0,1%	6 0,6%	239 23,9%	96,8%	3,2%
		88,8%	91,2%	88,8%	95,6%	91,1%	11,2%
		1	2	3	4		
		Classe Alvo					

Fig. 9. Classe com melhor desempenho.

V. CONCLUSÕES

O método *Resilient Backpropagation* apresentou melhor desempenho quando comparado ao algoritmo *Levenberg-Marquardt*, sendo o seu tempo de treinamento reduzido a diferença mais significativa.

Mesmo realizando testes com pessoas diferentes, em dias diferentes – o que ocasiona a retirada da braçadeira e a sua posterior recolocação, podendo os eletrodos estarem posicionados de forma pouco precisa, a rede se mostrou eficaz.

Outra vantagem dessa classificação utilizando RNA é que diferentemente do processo padrão do Myo™, dispensa-se o processo de calibração do usuário.

Mesmo com o uso da interface padrão do Myo™ realizando a calibração para os gestos pré-programados dele, não se obtém 100% de acurácia, logo o resultado obtido com gestos diferentes e sem calibração com os classificadores apontados pode ser considerado satisfatório.

A matriz de confusão, apresentada em cada teste, mostra não só a eficácia da rede, mas também é possível visualizar que o movimento Mão com *Gripper* (classe 4) é o que tem o melhor índice de reconhecimento, chegando a atingir 96,8% de acerto de classificação, conforme Figura 9.

Outros trabalhos estão sendo realizados para a obtenção da correlação entre os eletrodos para cada movimento, ou seja, quais grupos musculares são acionados.

AGRADECIMENTOS

Os autores agradecem à Fundação de Apoio ao Pesquisador do Estado da Bahia - FAPESB pelo apoio financeiro.

REFERÊNCIAS

- [1] MeSH - Medical Subject Headings. Disponível em: <https://www.nlm.nih.gov/mesh/>. Acesso em: 25 jul. 2016.
- [2] R. Ahsan; M. I Ibrahimy e O. O. Khalifa. Electromyography (EMG) signal based hand gesture recognition using Artificial Neural Network (ANN). 4th International Conference on Mechatronics, Malasia, 2011.
- [3] D. Prindle. “Myo gesture control armband review. Digital Trends, 2015. Disponível em: <http://www.digitaltrends.com/pc-accessory-reviews/myo-gesture-control-armband-review/#/7>. Acesso em: 04 mar. 2016.
- [4] R. L. Ortolan. Estudo e Avaliação de Técnicas de Processamento do Sinal Mioelétrico para o Controle de Sistemas de Reabilitação. Dissertação de Mestrado em Engenharia Elétrica apresentada à Escola de Engenharia de São Carlos, São Carlos – SP, 2002.
- [5] Myo armband. Disponível em: <https://www.myo.com>. Acesso em: 01 mar. 2016.
- [6] A.K. Jain et al. Statistical pattern recognition: a review. IEEE Trans. Pattern Analysis, 2000.
- [7] A. Phinyomark et al. Feature reduction and selection for EMG signal classification. Elsevier. Department of Electrical Engineering, Faculty of Engineering – Prince of Songkla University, Thailand, 2012.
- [8] S. Haykin. Neural Networks: Principles and Practice. McMaster University, Ontário, Canadá, 2001.
- [9] J. M. Barreto. Introdução às Redes Neurais Artificiais. Laboratório de Conexão e Ciências Cognitivas da Universidade Federal de Santa Catarina, Florianópolis – SC, 2002.
- [10] S. P. Zambiasi. Introdução às Redes Neurais Artificiais. Universidade Federal de Santa Catarina, Florianópolis – SC, 2002. Disponível em: <http://www.gsigma.ufsc.br>. Acesso em 20 nov. 2016.
- [11] H. C. Tissot.; L. C. Camargo e A. T. R. Pozo. Treinamento de Redes Neurais Feedforward: comparativo dos algoritmos Backpropagation e Differential Evolution. Departamento da Computação da Universidade Federal de Curitiba, Curitiba – PR, 2012.
- [12] N. K. Kasabov. Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering. The MIT Press, 1996.
- [13] L. R. Souza. Algoritmo para Reconhecimento e Acompanhamento de Trajetórias de Padrões em Vídeos. Universidade Federal do Vale do São Francisco, Juazeiro – BA, 2011