

O uso de redes neurais artificiais em sinais EMG

Francisco Vinícius Lopes Costa¹, Francisco Carlos Gurgel da Silva Segundo¹,
Náthalee Cavalcanti de Almeida Lima¹

¹Departamento de Ciências Exatas e Naturais – Universidade Federal Rural do Semi-Árido (UFERSA) – Campus Pau dos Ferros
Caixa Postal 59900-000 – Pau dos Ferros – RN – Brasil

vinicius.lopes.c@hotmail.com, {francisco.segundo, nathalee.almeida}@ufersa.edu.br

Abstract. *This article aims to explore how researchers are applying Artificial Neural Networks (ANN) to work with electromyographic (EMG) signals. Some basic concepts for the continuation of the text, such as concepts related to the structure of an ANN, were initially addressed. In the sequence, it was explained how the EMG signals are classified with the ANNs and finally some analyzes were done about some works that presented the application of ANN to treat the muscular signals.*

Resumo. *Este artigo objetiva explorar como os pesquisadores estão aplicando as redes neurais artificiais (RNA) para trabalharem com sinais eletromiográficos (EMG). Inicialmente foram abordados alguns conceitos fundamentais para o prosseguimento do texto, como por exemplo os conceitos relacionados a estrutura de uma RNA. Na sequência foi explicado como faz-se a classificação de sinais EMG com as RNAs e por fim foram feitas análises acerca de alguns trabalhos que apresentavam a aplicação de RNA para tratar os sinais musculares.*

1. Introdução

Um dos intuitos da tecnologia está em facilitar e melhorar cada vez mais a vida das pessoas, sempre inovando e procurando métodos eficazes para resolução dos mais diversos problemas. A área da saúde é um dos campos ao qual os engenheiros e cientistas demonstram grande dedicação na procura por soluções viáveis. Neste contexto, o uso das redes neurais artificiais (RNA) tem se mostrado uma excelente ferramenta para diversas aplicações que envolvem classificações de padrões.

Em Ferreira e Gouvea Junior (2016) é dito que as RNAs são protótipos computacionais inspirados no neurônio humano, capazes de reconhecer e classificar padrões com base em exemplos por meio de um algoritmo de aprendizagem. Uma característica marcante de uma RNA é a sua capacidade de generalização, ou seja, após um conjunto de padrões de entrada pré-classificados em sua fase de treinamento, a mesma pode receber padrões diferentes dos utilizados na etapa de treino e então classificá-los adequadamente [Almeida e Faceroli 2016].

O principal objetivo deste trabalho é explorar como os atuais pesquisadores estão utilizando as RNAs nos sinais eletromiográficos (EMG). O sinal EMG corresponde a um sinal de controle muscular e consiste em um potencial elétrico produzido pela contração de um músculo [Mattioli *et al.* 2010], [Ferreira e Gouvea Junior 2016]. De acordo com Gouvêa (2012), uma RNA é uma boa opção para reconhecimento de padrões que envolvam sinais EMG, pois pode receber um sinal ainda não conhecido e generalizar com base nos modelos treinados.

O trabalho está dividido em mais quatro seções de conteúdo e uma de referências bibliográficas. Na seção dois são apresentadas as etapas do processo de classificação. A terceira seção traz informações sobre a classificação dos sinais. O quarto tópico destina-se a explicar outras arquiteturas e parâmetros de RNAs para fins semelhantes. Por fim temos as conclusões obtidas e na sequência as devidas referências.

2. Processo Funcional de uma Rede Neural Artificial

As redes neurais artificiais apresentam diversas topologias e diversos algoritmos de aprendizagem e treinamento. O que determina qual topologia e algoritmos utilizar é a aplicação da RNA. E ainda que para aplicações similares, torna-se necessário e essencial testar diversos parâmetros, para que se usufrua da melhor e mais confiável estrutura.

As RNAs são tipicamente organizadas em camadas. Inicialmente há uma camada de entrada, onde há a entrada de dados (padrões) [Carvalho [20--]]. Na sequência, a primeira camada é ligada as camadas intermediárias (podem ou não existir) por meio de conexões ponderadas (pesos sinápticos) [Carvalho [20--]]. Estes pesos se encarregam de multiplicar o sinal de entrada por um valor (peso) que traduz a sua influência na saída da unidade [Carvalho [20--]]. A figura 1 mostra uma RNA genérica.

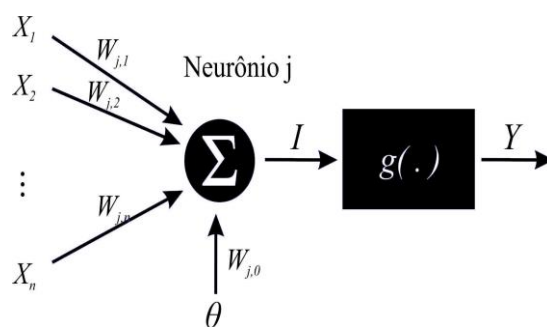


Figura 1. Modelo genérico de uma RNA

Fonte: Silva (2010).

A função de ativação que aparece na figura 1 processa o sinal gerado pela combinação linear das entradas e dos pesos sinápticos, e como resultado gera o sinal de saída [Silva (2010)]. Segundo Fiorin *et al.* (2011) as funções de ativação mais comumente utilizadas são: a função limiar (degrau), a função linear e as funções sigmóides logística e tangente hiperbólica. De acordo com Cardon e Müller (1994) um

neurônio apresenta um comportamento de “tudo ou nada”, tal comportamento se mostra no modelo matemático através de uma função limiar que indica quando o neurônio está ativo ou não.

Uma das propriedades mais interessantes de uma RNA é a sua capacidade de aprendizado, para isto se faz necessário um algoritmo de aprendizagem [Carvalho [20--]]. Este algoritmo corresponde a um conjunto de regras bem definidas que propiciam uma solução para um problema de aprendizagem [Carvalho [20--]]. Na seção 4 será descrito um algoritmo de aprendizado de amplo uso, o *backpropagation*.

Conforme Almeida e Faceroli (2016) o sinal EMG é um sinal estocástico, ou seja, não apresenta um padrão notável, portanto é necessário que haja uma extração de suas características para que se possa fazer uma posterior análise. Almeida e Faceroli (2016) ainda complementa que o processamento de sinais consiste no uso de técnicas matemáticas para extrair as informações sobre as ondas estudadas.

De acordo com Almeida e Faceroli (2016) o processamento de um sinal é composto pelas etapas mostradas na figura 2.




Figura 2. Etapas do processamento do sinal EMG

Fonte: Retirado de Almeida e Faceroli (2016).

Segundo Almeida e Faceroli (2016), o pré-processamento se faz necessário devido as variações sofrida pelo sinal por consequência do circuito de aquisição do sinal, limitações nos amplificadores utilizados e interferência da rede elétrica na captação do sinal. São aplicados filtros para que o sinal seja utilizado somente em sua faixa útil [Almeida e Faceroli 2016].

A segunda etapa apresentada na figura 2 consiste na transformação do sinal bruto em uma estrutura relevante nomeada de vetor característico, que contém as informações importantes do sinal em análise [Tello 2013]. A terceira etapa, classificação, é o agrupamento de sinais em classes predeterminadas, de acordo com a característica do sinal [Almeida e Faceroli 2016].

A próxima seção visa apresentar como ocorre a classificação de sinais, trazendo dois conceitos importantes (classificação supervisionada e não supervisionada), bem como um exemplo prático do trabalho de Mattioli *et al.* (2010).

3. Classificação dos sinais

Em seu trabalho Mattioli *et al.* (2010) afirma que devido a complexidade do sinal EMG, faz-se necessário reduzir o vetor de entrada da RNA. Esta redução proposta por

* O trabalho trata-se da utilização de uma rede neural para controle de uma prótese virtual de mão que realiza quatro movimentos [Mattioli *et al.* 2010].

Mattioli *et al.* (2010) foi feita em seu trabalho com a extração das características da onda e o resultado foi o mapeamento de um vetor de menor dimensão, ou seja, o vetor característico. O vetor foi obtido fazendo-se o janelamento do sinal, para que fosse possível selecionar os intervalos que apresentavam informações importantes para o processamento. Na figura 3 pode-se ver e entender um pouco mais sobre o trabalho de Mattioli *et al.* (2010).




Figura 3. Arquitetura de uma rede LVQ (*Learning Vector Quantization*)

Fonte: Retirado de Mattioli *et al.* (2010).

De acordo com Mattioli *et al.* (2010) o método desta arquitetura consiste em um conjunto inicial de padrões de treino com classificações conhecidas e junto uma distribuição inicial dos vetores de referência, no qual cada um representa um agrupamento predefinido. Mattioli *et al.* (2010) complementa o entendimento sobre a topologia LVQ afirmando que após treinada, uma rede LVQ classifica um vetor de entrada lhe atribuindo uma classe representada que contém o vetor de pesos mais próximo ao vetor de entrada. LVQ remete a uma técnica de aprendizado supervisionado, na qual os dados que se referem a um dado grupo são usados para mover os vetores de pesos das unidades de saída, assim obtendo um melhor desempenho nas regiões de decisão do classificador [Mattioli *et al.* 2010].

Na entrada da rede da figura 3 tem-se as cinco características ($x_1 \dots x_5$) sendo analisadas. Essas características foram frutos do processo de extração de características mencionado na seção 2. Na saída da rede observa-se 80 unidades de classificação ($y_1 \dots y_{80}$) para quatro tipos de movimentos, ou seja, 20 unidades para cada movimento. Entre as camadas mais externas existem estruturas denominadas pesos sinápticos, que são

** Média dos valores absolutos (Mean Absolute Value – MAV), inclinação da média dos valores absolutos (Mean Absolute Value Slope – MAVS), cruzamentos em zero (Zero Crossings – ZC), alterações no sinal da inclinação (Slope Sign Changes – SSC) e comprimento da forma de onda (Waveform Length – WL) [Mattioli *et al.* 2010].

*** O janelamento de sinais é uma técnica simples que pode aumentar as características espectrais do sinal amostrado [Andrade e Soares [20--]].

responsáveis por fazer os devidos ajustes no sinal e o encaminhá-lo para sua classificação correta. Portanto, na rede estruturada por Mattioli *et al.* (2010), o sinal percorre o caminho de entrada, onde são analisadas cinco características pré-determinadas, de acordo com as características do sinal este é ajustado pelos pesos sinápticos e então encaminhado para sua classificação.

Na busca por um aumento na eficiência dos padrões analisados Mattioli *et al.* (2010) adotou uma abordagem alternativa, de forma que a medida que a rede detecta um novo sinal, este é dividido em segmentos de 40 amostras cada. Após isso cada segmento é classificado isoladamente e finalmente a RNA indica o sinal para classe na qual a maioria dos segmentos menores pertencem [Mattioli *et al.* 2010].

A ideia de Mattioli *et al.* (2010) pode ser visualizada na figura 4.




Figura 4. Segmentação e classificação do sinal

Fonte: Retirado de Mattioli *et al.* (2010).

De acordo com Almeida e Faceroli (2016) as classificações das RNAs podem ser divididas em dois tipos, supervisionada e não supervisionada. A classificação é supervisionada quando é conhecida a classe que gerou cada padrão do conjunto de treino, desta forma o classificador é treinado a replicar a correta decisão para os padrões de treino [Almeida e Faceroli 2016]. Na classificação não supervisionada os padrões de

treino não apresentam uma pré-classificação, logo o algoritmo de treino precisa encontrar uma estrutura nos dados que permita separá-los em classes [Almeida e Faceroli 2016].

A seção que segue apresenta a análise de alguns trabalhos que usaram RNA para tratar sinais EMG. As análises foram feitas com base nas configurações genéricas das redes e alguns dados estatísticos disponibilizados pelos autores.

4. Outras arquiteturas e parâmetros

Na seção três foi mostrado um caso em que a topologia utilizada foi a LVQ (*Learning Vector Quantization*). Em contrapartida, Almeida e Faceroli (2016) propõe o uso da topologia perceptrons de múltiplas camadas (MLP – figura 5) para uma aplicação similar. De acordo com Almeida e Faceroli (2016) a MLP “consiste em um conjunto de unidades sensoriais que constitui a camada de entrada, uma ou mais camadas ocultas de nós computacionais e uma camada de saída, onde o sinal de entrada se propaga para frente através da rede, camada por camada”. Conforme Almeida e Faceroli (2016) a estrutura de rede montada utilizou-se do algoritmo de aprendizado *backpropagation*, no qual aplica-se um vetor de entrada pré-determinado na RNA e se analisa a resposta para determinar o valor da função de erro. O sinal de erro é disseminado para trás através da rede, contra a direção das conexões sinápticas, assim os pesos sinápticos são regulados de modo que a resposta real da rede se mova para mais próximo da resposta que se deseja [Almeida e Faceroli 2016].




Figura 5. Representação gráfica de uma RNA-MLP com duas camadas intermediárias

Fonte: Retirado de Fiorin *et al.* (2011).

Um terceiro trabalho analisado foi o de Cunha *et al.* (2007). Diferentemente dos trabalhos propostos por Mattioli *et al.* (2010) e Almeida e Faceroli (2016), este apresenta uma alteração no processo de classificação do sinal. Tal diferença está no fato de Cunha *et al.* (2007) descartar a parte de pré-processamento, visto que é uma fase que consome um tempo maior e a aplicação necessitava de respostas em tempo real. Vale salientar que a desconsideração desta etapa do processo só foi possível devido o

propósito da aplicação ter uma boa aceitação do sinal cru mesmo com ruídos.

Conforme Cunha *et al.* (2007) a rede foi arquitetada em três camadas e utilizou-se do algoritmo *backpropagation* como algoritmo de aprendizado. Na camada de entrada haviam 200 unidades, pois foram mapeados 200 pontos no sinal EMG, correspondente aos primeiros 200 milissegundos do início da execução do movimento muscular. A camada intermediária foi testada com 1, 2, 3 e 5 unidades, sendo que o melhor resultado apresentado foi o da arquitetura com três unidades nesta camada (Figura 6). Na camada de saída foram utilizadas duas unidades, na qual cada uma representava um movimento do punho.




Figura 6. Resultados dos testes da rede para as 4 arquiteturas

Fonte: Retirado de Cunha *et al.* (2007)

Outro trabalho analisado foi o de Ferreira e Gouvea Junior (2016) que contempla o desenvolvimento de um sistema neural para reconhecimento de padrões em sinais EMGs para controle de um braço robótico. Utilizou-se o método de treinamento supervisionado e o algoritmo *backpropagation* e a arquitetura de rede foi *Multilayer Perceptron* (MLP) [Ferreira e Gouvea Junior 2016].

Ferreira e Gouvea Junior (2016) fez o tratamento do sinal EMG perante duas abordagens distintas, contudo aqui será tratada apenas a segunda, que apresentou resultados mais satisfatórios. Para a abordagem aqui tratada Ferreira e Gouvea Junior (2016) afirma, “para cada canal, considera-se como entrada da RNA uma série temporal com 5 amostras consecutivas do sinal EMG”. A arquitetura da RNA contava com 10 neurônios na camada de entrada e 4 na de saída [Ferreira e Gouvea Junior 2016]. Os neurônios de saída representam 4 classes de movimentos do braço robótico e os 10 neurônios na camada de entrada se referem as 5 componentes da série temporal de cada canal (dois canais) [Ferreira e Gouvea Junior 2016]. A camada oculta foi testada com 15, 20, 25 e 30 neurônios, abaixo segue os resultados (Figura 7).

Topologia	Teste	
	Taxa de acerto	EQM
15	98.94 %	0.0204568
20	99.09 %	0.0187076
25	99.54 %	0.0186307
30	99.54 %	0.0180613

Figura 7. Resultados do teste da topologia para diferentes quantidades de neurônios na camada intermediária. (EQM - Erro Médio Quadrático)

Fonte: Retirado de Ferreira e Gouvea Junior (2016).

Em termos estatísticos a RNA proposta por Mattioli *et al.* (2010) apresentou eficiência média levemente superior a 80%. A estrutura proposta por Almeida e Faceroli (2016) apresentou 84,4% de acerto. A RNA montada por Cunha *et al.* (2007), em sua arquitetura com três unidades na camada intermediária, apresentou uma porcentagem de acerto próxima a 100%. E a rede montada por Ferreira e Gouvea Junior (2016) mostrou taxas semelhantes (99,54%) para as topologias com 25 e 30 neurônios nas camadas intermediárias.

Tratando-se em análise de sinal nota-se que os métodos de Cunha *et al.* (2007) e de Mattioli *et al.* (2010) apresentam uma boa acurácia. O primeiro mapeia 200 pontos correspondente aos 200 ms do sinal EMG referente ao início do movimento, já o segundo segmenta o sinal em cinco fatias menores, nas quais é possível fazer uma melhor análise das características da onda. Apesar da boa precisão, percebe-se que o método de Mattioli *et al.* (2010) é o que apresenta menor índice de acerto. Comparando-se as topologias, ver-se que a única diferente é a de Mattioli *et al.* (2010), o que pode ser um indício de que a MLP seja mais conveniente que a LVQ para tratar este tipo de sinal.

5. Conclusão

Diante do que foi exposto e discutido, percebe-se que as RNAs tem se mostrado uma boa alternativa quanto ao uso para classificação de padrões de sinais EMG. Entre os trabalhos que foram principalmente descritos na seção quatro, nota-se que todos apresentaram bons índices de acertos, com destaque para a RNA proposta por Cunha *et al.* (2007) que apontou uma taxa de acerto próxima aos 100% e para a RNA elaborada por Ferreira e Gouvea Junior (2016). No entanto, vale ressaltar que essas taxas são influenciadas por diversos parâmetros, como por exemplo o número de amostras testadas e o propósito da aplicação. Inclusive, entre os trabalhos, os que mencionaram menor número de testes foram os de Cunha *et al.* (2007) e Ferreira e Gouvea Junior (2016), sendo este possivelmente um fato que tenha ajudado na obtenção de altas taxas de acerto.

Portanto, vê-se que é necessário fazer diversos testes na RNA que se deseja estruturar a fim de encontrar a melhor configuração possível, para que haja o menor nível de erro. Além disso, é essencial ter um bom número de amostras disponíveis para o treino da rede, pois só assim consegue-se uma alta confiabilidade.

Referências

- Almeida, Roberto Coelho de (2016); Faceroli, Silvana Terezinha. reconhecimento de padrões mioelétricos do movimento dos dedos da mão utilizando redes neurais artificiais. Disponível em: <periodicos.jf.ifsudestemg.edu.br/multiverso/article/download/15/14>. Acesso em: 13 fev. 2017.
- Andrade, A. O.; Soares, A. B.. Técnicas de Janelamento de Sinais. [20--]. Disponível em: <<http://www.aoandrade.eletrica.ufu.br/Documents/T%E9cnicas%20de%20Janelame>

- nto%20de%20Sinais.pdf>. Acesso em: 18 fev. 2017.
- Cardon, André; Müller, Daniel Nehme (1994). Introdução Às Redes Neurais Artificiais. Disponível em: <http://www.inf.ufrgs.br/~danielnm/docs/intro_rna.pdf>. Acesso em: 15 fev. 2017.
- Carvalho, André Ponce de Leon F. de. Redes Neurais Artificiais. [20--]. Disponível em: <<http://conteudo.icmc.usp.br/pessoas/andre/research/neural/#links>>. Acesso em: 12 fev. 2017.
- Cunha, Fransérgio L. *et al* (2007). O Uso de Redes Neurais Artificiais Para o Reconhecimento de Padrões em uma Prótese Mioelétrica de Mão. Disponível em: <http://www1.sel.eesc.usp.br/labciber/alunos_pos/ortolan/arquivos/p339.PDF>. Acesso em: 15 fev. 2017.
- Ferreira, Evelyne L.; Gouvea junior, Maury M. (2016). Sistema Neural para Reconhecimento de Padrões em Sinais EMGs para Controle de Braço Robótico. Disponível em: <<http://www.lbd.dcc.ufmg.br/colecoes/eniac/2016/043.pdf>>. Acesso em: 16 fev. 2017.
- Fiorin, Daniel V. *et al.* (2011). Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares. Revista Brasileira de Ensino de Física, São Paulo, v. 33, n. 1. Disponível em: <<http://dx.doi.org/10.1590/S1806-11172011000100009>>. Acesso em: 15 fev. 2017
- Gouvêa, M. M. (2012). A neural-based gradient optimization in large power systems. WSEAS Transaction on Systems, 11(8).
- Mattioli, Fernando E. R. *et al* (2010). Utilização de redes neurais para a classificação de sinais EMG aplicados no controle de próteses virtuais de mão. Disponível em: <<http://www.lbd.dcc.ufmg.br/colecoes/wrva/2010/0040.pdf>>. Acesso em: 15 fev. 2017.
- Silva, Marília Paula e (2010). Aplicação de Redes Neurais Artificiais no Diagnóstico de Falhas de Turbinas a Gás. 107 f. Dissertação (Mestrado) - Curso de Engenharia Mecânica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2010. Disponível em: <https://www.maxwell.vrac.puc-rio.br/16580/16580_1.PDF>. Acesso em: 10 fev. 2017.
- Tello RJMG (2013). Extração de características e classificação de sinais sEMG aplicados auma prótese de mão virtual. [dissertação]. Vitória: Universidade Federal do Espírito Santo.