

Processamento Digital de Sinais Biológicos Mediante Transformada Wavelet Packet para Aplicação em Redes Neurais Artificiais

Biological Signals Digital Processing by Wavelet Packet Transform for Application in Artificial Neural Networks

Fabio Augusto Guidotti dos Santos

fsantos.1995@alunos.utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

Victor Hideki Yoshizumi

yoshizumi@alunos.utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

Rafael Martinelli de Araujo

rafaelaraujo@alunos.utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

Aron Alexandre Martins Lima

aron@alunos.utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

Danilo Hernane Spatti

spatti@icmc.usp.br
Universidade de São Paulo, São Carlos, São Paulo, Brasil

Maria Eugenia Dajer

medajer@utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

Recebido: 31 ago. 2018.

Aprovado: 04 out. 2018.

Direito autoral:

Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.



RESUMO

As Redes Neurais Artificiais são ferramentas poderosas e extremamente versáteis, que podem ser utilizadas para solução de problemas nas mais diversas áreas, dentre elas destaca-se a classificação de padrões. Para que uma Rede Neural Artificial tenha seu desempenho otimizado existem alguns fatores que devem ser levados em consideração, como por exemplo, o volume e a qualidade dos dados de entrada da rede. Uma técnica que pode ser aplicada para reduzir e extrair características dos dados de entrada é a Transformada *Wavelet Packet*. Método notável por trabalhar tanto no domínio do tempo quanto no domínio da frequência e a presença de diversas famílias *wavelets* com características diferentes. Deste modo, este trabalho realizou a comparação das principais famílias *wavelets*, a partir de dados eletromiográficos aplicados a uma RNA do tipo *Perceptron* Multicamadas, onde o volume inicial de dados foi reduzido em 128 vezes e a família Haar obteve os melhores resultados.

PALAVRAS-CHAVE: Perceptron Multicamadas. Transformada Wavelet Packet. Sinais Eletromiográficos. Classificação de Padrões. Famílias Wavelet.

ABSTRACT

Artificial Neural Networks are powerful and extremely versatile tools, that can be used to solve problems in diverse areas, among which the standard classification stands out. For optimum performance of the Artificial Neural Network, there are several factors that must be considered, such as, the volume and quality of the input network data. A technique that can be applied to reduce and extract characteristics of the input data is de Wavelet Packet Transform. Method that is notable for working in both the time domain and frequency domain and the presence of several wavelet families with different characteristics. Thus, this work compared the main wavelet families, based on electromyographic data applied to Multilayer Perceptron type ANN, where the initial volume of data was reduced by 128 times and the Haar family obtained the best results.

KEYWORDS: Multilayer Perceptron. Wavelet Packet Transform. Electromyographic Signals. Standard Classification. Wavelet Families.



INTRODUÇÃO

As Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no sistema nervoso dos seres vivos (SILVA; SPATTI; FLAUZINO, 2010, p.24), que emergem como uma poderosa ferramenta para solucionar uma ampla gama de problemas. Podendo ser considerada até mesmo como essenciais em aplicações como o reconhecimento de padrões (IVANOV; GAVRILAÚ, 2014; RAMCHOUN et al., 2016). Uma das áreas onde as RNAs podem ser aplicadas é no estudo de sinais biológicos, como mostrado em Lima et al. (2017).

Por se tratar de uma ferramenta poderosa, utilizar grande volume de dados no treinamento da rede pode exigir um grande custo computacional, por exemplo, ao se trabalhar com dados no domínio do tempo com altas taxas de amostragem. Outro fator que pode prejudicar a rede é sua dependência em relação à qualidade dos dados de entrada do sistema, onde essas entradas devem apresentar características que identificam o padrão de saída desejado.

Sendo assim, em muitos casos faz-se necessário a utilização de técnicas de processamento digital de sinais para a extração de características contidas nos sinais de entrada. Essas análises podem ser realizadas por meio das Transformadas de Fourier, porém, uma das grandes deficiências da análise de Fourier surge do fato de que ela não apresenta um caráter local, mas sim um “comportamento global médio”, além de não fornecer uma análise temporal, apenas frequencial (OLIVEIRA, 2007).

Dentro desse contexto, a Transformada Wavelet (TW) surgiu como uma alternativa à Transformada de Fourier, permitindo uma análise tempo-frequência, podendo ser utilizada em diversas áreas da ciência (OLIVEIRA, 2007). Uma forma bastante eficiente de aplicar a Transformada Wavelet Discreta é através de filtros, técnica desenvolvida por Mallat (1989), onde tem-se a decomposição da *wavelet* implementando uma análise multiresolução. A Transformada Wavelet Packet (TWP), proposta por Coifman e Wickerhauser (1992), é uma generalização do conceito da Transformada Wavelet Discreta, onde o sinal passa por filtros de passa-baixa (aproximação) e passa-alta (detalhe) (MALLAT, 2008).

Outro ponto importante que deve ser analisado ao se aplicar a TWP é em relação as diversas famílias de Wavelet-mãe que podem ser utilizadas, sendo que cada família apresenta diferentes características de aplicabilidades, como mostrado por Araujo (2011). A combinação da TWP para extração de características junto a RNA para a classificação de padrões, em muitos casos, torna-se um conjunto eficaz no processo de classificação. Uma das áreas onde tal combinação se mostrou aplicável e claramente eficiente é a dos sinais biológicos, seja com sinais de voz como desenvolvido por Fermino (2017) ou sinais eletromiográficos (EMG), em Barros (2017).

Deste modo, este trabalho se propõe a realizar o processamento de sinais eletromiográficos utilizando diversas famílias da Transformada Wavelet afim de comparar e analisar sua eficiência na classificação de padrão utilizando redes neurais artificiais.

METODOLOGIA

Os sinais utilizados neste trabalho são EMG do antebraço referentes aos movimentos da mão e punho. A coleta dos dados foi realizada por Khushaba et al. (2016), na *University of Technology* em Sydney, Austrália, a partir de 10 voluntários. Na aquisição de dados, os 6 eletrodos EMG foram dispostos na circunferência do antebraço, ainda no punho dos voluntários, foi disposto um acelerômetro 3D.

Os voluntários, já com eletrodos e acelerômetro predispostos, passaram por uma série de movimentos. Estes movimentos foram divididos em 6 classes, onde cada classe foi subdividida em 9 subclasses que definiam 3 orientações diferentes do pulso em 3 diferentes intensidades de contração muscular: fraca, média e forte. Para cada uma destas subclasses, foram realizados 3 testes, a uma taxa de amostragem de 4000 Hz. Por este trabalho ter como foco o processamento dos sinais EMG, foram utilizadas apenas três subclasses referentes a primeira classe de movimentos.

O tipo de classificador de padrões utilizado foi o supervisionado, visto que as saídas da rede eram conhecidas, mais especificamente, foi utilizado a rede Perceptron Multicamadas (PMC). Em relação à quantidade de camadas escondidas e número de neurônios, mediante os testes realizados de antemão com a RNA, decidiu-se utilizar 2 camadas escondidas com 9 e 7 neurônios, respectivamente. As demais configurações utilizadas na implementação da RNA do tipo PMC podem ser vistas no Quadro 1.

Quadro 1 – Configuração da RNA

Parâmetros	Configuração
Estrutura da rede	Única RNA
Algoritmo de treinamento	Levenberg-Marquardt (<i>Back propagation</i>)
Função de ativação camadas escondidas	Tangente Hiperbólica
Função de ativação saída	Rampa linear
Épocas	1000
Erro	1×10^{-20}
Gradiente	1×10^{-20}
Confiabilidade	90%
Porcentagem de treinamento	70%

Fonte: Autoria própria (2018).

Segundo Haykin (1998, p. 206), uma PMC pode, em geral, aprender mais rápido se a função de ativação for antissimétrica. Um exemplo popular de função antissimétrica é a tangente hiperbólica, escolhida neste estudo. Para as saídas foi utilizado o método *one of c-class*, que associa um neurônio, da camada de saída, para cada classe do problema.

Vale destacar que como a rede utilizou do parâmetro de confiabilidade, as saídas da mesma apresentam maior robustez, visto que elas só são consideradas pertencente a uma determinada classe se suas respostas estiverem acima de um grau de confiabilidade, caso contrário elas serão classificadas como incertas.

A Transformada *Wavelet Packet* foi utilizada com a finalidade de realizar a extração das características de energia dos sinais eletromiográficos, bem como diminuir a quantidade de dados que serão apresentados à RNA. Como na TWP existe uma variedade de famílias wavelet com características diferentes, foram utilizadas 14 famílias para fins comparativos, as mesmas podem ser vistas no Quadro 2.

Quadro 2 – Famílias *wavelet* utilizadas

Famílias	Variações
Haar	-
Daubechies (db)	2-5
Symlets (sym)	2-5
Coiflets (coif)	1-5

Fonte: Autoria própria (2018).

RESULTADOS E DISCUSSÕES

Foram executadas as etapas de pré-processamento da base de dados, onde foi obtido o total de 10 milhões e 800 mil dados, divididos em 6 eletrodos com 1 milhão e 800 mil amostras, no domínio do tempo.

Devido ao nível de decomposição escolhido (nível 3), após o processamento das TWP as 6 entradas (eletrodos) se tornaram 48. E devido ao janelamento de 2048 amostras com sobreposições de 50%, as 1 milhão 800 mil amostras foram reduzidas a 1755 amostras. Assim, os 10 milhões e 800 mil dados iniciais no domínio do tempo se tornaram 84 mil, redução maior que 128 vezes do volume inicial. O resultado, em porcentagem de acerto, das 14 famílias com 10 execuções, assim como a média de acerto de cada família pode ser vista no Quadro 3.

Quadro 3 – Porcentagem de acertos famílias *wavelet* e execuções

Treino	1	2	3	4	5	6	7	8	9	10	Média
Haar	98,11	97,16	97,35	97,15	97,53	97,53	97,15	97,53	89,54	97,72	96,68
db2	96,97	96,40	93,94	94,30	96,20	96,77	96,96	85,93	96,96	92,40	94,68
db3	94,70	95,83	93,37	93,56	94,89	94,30	94,70	95,45	93,75	95,53	94,61
db4	98,06	96,21	95,83	95,63	96,96	95,63	93,92	94,87	93,35	94,87	95,53
db5	93,75	96,21	94,89	94,70	95,64	92,23	93,94	94,51	95,45	94,30	94,56
coif1	97,16	95,45	93,75	93,94	94,45	92,50	96,97	97,16	95,52	96,02	95,29
coif2	93,56	96,78	90,72	89,54	93,75	94,70	91,88	95,45	95,64	92,35	93,44
coif3	94,89	94,89	95,64	95,62	93,94	94,30	95,06	96,08	92,90	93,75	94,71
coif4	95,06	96,39	92,59	91,44	94,49	94,49	93,35	91,25	94,68	95,06	93,88
coif5	87,26	96,02	96,01	96,77	89,73	97,92	96,77	91,83	95,06	90,30	93,77
sym2	96,97	93,94	95,64	93,75	96,97	95,08	94,51	94,20	95,64	96,97	95,37
sym3	92,23	97,35	96,02	94,51	94,70	96,89	97,16	93,35	93,75	96,21	95,22
sym4	95,08	95,45	93,56	94,89	94,45	95,06	93,75	95,64	94,70	95,53	94,81
sym5	92,83	94,51	91,10	94,45	93,92	93,56	94,30	94,71	93,92	94,89	93,93

Fonte: Autoria própria (2018).



O Quadro 3, além de conter os resultados em porcentagem de acertos, também apresenta uma análise em escala de cores, onde a cor verde-escura representa a maior porcentagem de acerto e o vermelho escuro a menor taxa, facilitando a análise visual dos resultados. Observando a escala de cores é possível ver que a família Haar apresentou os melhores resultados, visto que a mesma apresenta a linha com maior quantidade de células com tom verde. Além disso também podemos ver que a maior porcentagem obtida também se refere a família Haar com 98,11% de acertos. Ainda analisando o Quadro 3, foi validada a necessidade das repetitivas execuções da mesma família para evitar mínimos locais. Fato visível no resultado do treinamento 9 da família Haar (89,54%) ou do treinamento 8 da família db2 (85,93%), que apresentam valores discrepantes em relação as demais execuções.

Afim de obter um estudo mais a fundo, foi calculada a média dos valores das execuções, apresentada na última coluna do Quadro 3. Analisando o resultado das médias, assim como mencionado anteriormente, pode-se observar que a família Haar obteve o melhor resultado. Fato que está relacionado a uma característica da família Haar. Já que sua função é descontínua e sua utilização é adequada para as séries temporais que possuem variações bruscas de valores no tempo. Característica que condiz com sinais EMG na realização de movimentos.

Nota-se que os quatro melhores resultados pertencem a famílias diferentes, assim, podemos concluir que variações das mesmas famílias podem causar grandes diferenças no resultado do processamento.

CONCLUSÃO

Considerando todas as etapas desenvolvidas neste trabalho, desde o processamento dos sinais EMG utilizando diversas famílias da Transformada Wavelet Packet até sua aplicação na RNA para classificação de padrões, foi possível comparar, analisar e verificar alguns fatores relativos as transformadas e suas famílias quando aplicadas em RNAs. O primeiro fato verificado através dos resultados deste trabalho foi a capacidade de redução do volume de dados ao se utilizar a TWP, reduzindo o volume inicial de dados em 128 vezes.

Outro ponto importante foram os resultados em porcentagem de acerto obtidos para cada família wavelet, que pode verificar a diferente capacidade de extração de características de cada família. Fato que demonstra a capacidade adaptativa da TW, visto que famílias distintas apresentam diferentes características possibilitando sua aplicação em diversas áreas.

Analisando a família Haar, que obteve os melhores resultados no processamento dos sinais EMG, foi possível relacionar seu alto desempenho a uma característica própria desta família. Vale destacar que apesar do ótimo resultado obtido pela família Haar, tal resultado não pode ser tomado como verdade absoluta para todo sinal EMG, mas pode servir como guia para outros trabalhos.

Como proposta para trabalhos futuros, estudos que podem ser realizados para aumentar a capacidade de extração de características da TWP estão relacionados a variação dos parâmetros de processamento (nível de decomposição, janelamento e sobreposição), que neste trabalho foram determinados como fixos.



REFERÊNCIAS

- ARAUJO, M.S. et al. **Influências de famílias wavelets e suas ordens no desempenho de um localizador de faltas em linhas aéreas de transmissão de energia elétrica.** 2011.
- BARROS F. K. H. et al. **Treinamento Otimizado de Redes Neurais Artificiais Para a Classificação de Movimentos Musculares.** Brazilian Conference on Intelligent Systems, Uberlandia, Brazil, 2017.
- COIFMAN, R. R.; WICKERHAUSER, M. V. **Entropy-based Algorithms for Best Basis Selection.** IEE Transaction on Information Theory, v. 38, n. 2, 1992.
- FERMINO, M. A. **Classificação de distúrbios vocais utilizando redes neurais artificiais.** Trabalho de Conclusão de Curso - Engenharia Elétrica - Universidade Tecnológica Federal do Paraná, p.99 2017.
- HAYKIN, S. **Neural Networks: A comprehensive Foundation.** Prentice Hall, 2 ed., 1998.
- IVANOV, O.; GAVRILAÚ, M. (2014). **Multilayer perceptron architecture optimization for peak load estimation.** 2014 12th Symposium on Neural Network Applications in Electrical Engineering (NEUREL).
- KHUSHABA, R. N. et al. **Combined influence of forearm orientation and muscular contraction on EMG pattern recognition.** Expert Systems with Applications, 2016.
- LIMA A. A. M. et al. **Reconhecimento de Padrões de Movimentos da Mão a Partir de Sinais Mioelétricos do Antebraço Utilizando Redes Neurais Artificiais e Algoritmos Genéticos.** V Congresso Brasileiro de Eletromiografia e Cinesiologia /X Simpósio de Engenharia Biomédica. Uberlândia, Brasil, 2017.
- S. G. **A theory of multiresolution signal decomposition: The wavelet representation.** IEEE Trans. Pat. Anal Mach. Intell., 11: 674-693, 1989.
- MALLAT, S. **A Wavelet Tour of Signal Processing.** Academic Press, 3 ed., 2008.
- OLIVEIRA, H. M. **Análise de Fourier e Wavelets: Sinais Estacionários e não Estacionários.** Recife: EDUFPE, 2007.



RAMCHOUN, H. et al. **Multilayer perceptron: Architecture optimization and training.** International Journal of Interactive Multimedia and Artificial Intelligence, 2016.

SILVA, I. N.; SPATTI, H. D.; FLAUZINO, R. A. **Redes Neurais Artificiais: para engenharia e ciências aplicadas.** São Paulo: Artliber, 2010.

AGRADECIMENTOS

Primeiramente gostaria de agradecer a Rami N. Khushaba, por disponibilizar a base de dados de sinais eletromiográficos utilizados, a UTFPR por conceder os equipamentos necessários para realização deste trabalho e ao grupo GE4Bio pelo suporte durante todo o desenvolvimento do trabalho.