

Aplicação de redes neurais no tratamento de interferências. em sinais de ECG

John Oersted Wisbeck¹ e Renato Garcia²

¹ Prof. M.Sc., Dep. Eng. Elétrica (UFRGS) - Doutorado em Engenharia Elétrica, UFSC.

² Prof. Dr., Grupo de Pesquisas em Engenharia Biomédica (GPEB), UFSC.

Resumo - Um registro eletrocardiográfico (ECG) é comumente corrompido por uma série de sinais denominados interferências, entre esses: ruído de rede (60 Hz), emissões eletromagnéticas, atividade muscular (EMG), etc. A minimização dessas interferências através de filtros resulta em distorções no ECG que podem mascarar informações importantes. É proposto, neste artigo, o emprego de uma classe de redes neurais capaz de separar as interferências do sinal gerado no miocárdio, sem introduzir distorções. Para tanto, essas redes neurais processam registros de ECG tomados simultaneamente em posições espaciais diferentes.

Abstract - An electrocardiographic register (ECG) is commonly corrupted by interference signals as power noise (60 Hz), electromagnetic emissions, muscle activities (EMG), etc. The minimization of these interferences by filters results in ECG distortions which can hide important information. This article proposes the use of a neural network to separate interferences from the signal generated in the heart without introducing distortions. To do this, this neural network processes ECGs collected simultaneously at different spatial positions.

Introdução

A maioria dos diagnósticos fundamentados em sinais de ECG levam em consideração a forma temporal do sinal. No entanto, o sinal proveniente do miocárdio é contaminado por várias fontes externas (rede elétrica, emissões de rádio, etc.) e internas (movimentos musculares, sinapses, etc.). Nesse caso pouca informação útil estará visível.

Nas aplicações onde existe interesse em se analisar sinais de pequena amplitude gerados no miocárdio, tais como os potenciais tardios, o uso de filtros é crítico, pois ao tratar as interferências, acabam por deteriorar o próprio sinal em foco. Objetivando minimizar essa deteriorização, várias técnicas alternativas vêm sendo apresentadas. Dentre elas: AVECG (ECG médio) [4], análise biespectral [6] e filtros multidimensionais [2].

No intuito de evitar as distorções temporais, propõe-se que a minimização das interferências seja feita mediante o processamento espacial de sinais de ECG. Nesse sentido, empregam-se vários sensores (mapeando uma derivação) a fim de se obter, em posições diferentes, registros simultâneos de ECG's. Combinando-se essas leituras por meio de uma rede neural, consegue-se isolar sinais gerados por fontes independentes, que contribuem na composição dos ECG's. Como não são combinadas amostras de momentos diferentes, essa técnica não distorce temporalmente os sinais extraídos.

Metodologia

A técnica proposta tem por base o modelamento do ECG como uma combinação linear de várias fontes geradoras de sinal. Adicionalmente, é considerado que tais combinações diferem de uma posição espacial para outra (na mesma derivação). Dessa forma, sendo $s=[s_1(t), s_2(t), \dots, s_n(t)]$ o vetor das fontes que colaboram para os ECG's e $x=[x_1(t), x_2(t), \dots, x_n(t)]$ o vetor de leituras de ECG tomadas em n posições de uma mesma derivação, tem-se:

$$x=A \cdot s \quad (1)$$

onde A é a matriz de associação.

Esse modelo permite que a separação dos sinais seja procedida por uma série de técnicas [1][3][5], no entanto, devido à simplicidade e a título de ilustração, optou-se pela proposição de Amari [1]. Amari utiliza uma rede neural recorrente cujo vetor de saída $y=[y_1(t), y_2(t), \dots, y_n(t)]$, depois de um curto transiente, é dado por:

$$y=(I+W)^{-1} \cdot x \quad (2)$$

onde W é a matriz de pesos sinápticos.

O algoritmo para adaptar os pesos é definido pela Equação 3.

$$dW/dt=-\mu \cdot (I+W) \cdot G(y) \quad (3)$$

onde μ determina a taxa de aprendizagem e a matriz G , dependendo de fatores como distribuição das fontes, velocidade de convergência e complexidade de implementação [1], pode assumir várias formas. Dentre essas optou-se por:

$$G(y)=I-f(y)\cdot g^T(y)(4)$$

onde $f(y)=y^3$ e $g(y)=y$.

Exemplo de aplicação

Para se obter o vetor x de leituras, posicionam-se n eletrodos em uma mesma derivação, onde $n=k+1$ e k é o número de fontes com amplitudes capazes de mascarar o diagnóstico. Para simular essa situação, os sinais do vetor x são criados artificialmente somando-se interferências a um sinal de ECG retirado da base de dados BIH-MIT. Todavia, apenas segmentos do ECG centrados no complexo QRS são utilizados para treinar a rede neural. Esse procedimento auxilia na convergência dos pesos sinápticos, pois nos segmentos TP o miocárdio comporta-se aproximadamente como uma fonte desativada. Na Figura 1 mostram-se os sinais na saída da rede durante o processo de treinamento. Na Figura 2 são apresentados dois ciclos cardíacos completos corrompidos por ruído, bem como o resultado da separação efetuada pela rede neural treinada.




Figura 1 - Sinais na saída da rede durante o treinamento com segmentos QRST + ruído.




Figura 2 - Separação efetuada em um sinal não utilizado no treinamento da rede.

Conclusão

Ao se trabalhar com sinais de ECG multidimensionais e multilocalizados tem-se mais informação disponível. Esse fato permite que outras técnicas, além do processamento temporal, possam ser empregadas, facilitando a preservação das informações contidas nos sinais. A separação dos sinais que compõem o registro de ECG através da rede neural proposta por Amari^[1] é viável, desde que a combinação desses sinais observe um modelo linear. Quando tal modelo não é suficiente, propõe-se o emprego de um pré-processamento temporal^[2] e/ou de uma rede neural não linear, objetivando compensar as diferenças entre os caminhos percorridos pelos sinais até os sensores.

Em se tratando de ECG's, a convergência dos pesos sinápticos é melhorada se apenas os segmentos QRST forem utilizados na fase de treinamento da rede neural. Depois de treinada, a rede representa a matriz inversa de combinação das fontes, isto é, o modelo inverso do sistema. Dessa forma, o desempenho da rede treinada é independente da forma temporal dos sinais gerados nas fontes.

Referências

- ¹AMARI, S., CICHOCKI, A., YANG, H. H. "Recurrent Neural Networks for Blind Separations of Sources" *Proceedings 1995 International Symposium on Nonlinear Theory and Applications*, v. 1, p. 37-42, December, 1995.
- ²BENSADOUN, Y., NOVAKOV, E. "Multi-dimensional Adaptive Method for Cancelling EMG Signal from the ECG Signal". *Proceedings IEEE/EMBC and CMBC*, p. 173-174, Montreal, 1995.
- ³CICHOCKI, A., UNBENHAUEN, R. *Neural Networks for Optimization and Signal Processing (second edition)*. John Wiley, New York, 1994.
- ⁴LANDER, P., BERBARI, E. J., LAZZARA, R. "Optimal Filtering and Quality Control of the Signal-Averaged ECG" *Circulation*. v. 91 n. 5, March, 1995.
- [5] MATSUOKA, K., OHYA, M., KAWAMOTO, M. "A Neural Net for Blind Separation of Nonstationary Signals". *Neural Networks*, 9(3). p.411-419, 1995.
- [6] SPEIRS, C. A., SOROGHAN, J. J., STEWART, R. W. "Ventricular Late Potential Detection from Bispectral Analysis of ST - Segments" *Proc. of EUSIPCO'94* - Edinburgh, Sept. 1994.