

Detecção de Doenças Cardíacas Através de Lifting Wavelet e Redes Neurais Artificiais

Klaus Fabian Côco, Ailson Rosetti de Almeida, Evandro Ottoni Teatini Salles
Laboratório de Computadores e Sistemas Neurais, Engenharia Elétrica, Universidade Federal do
Espírito Santo, Vitória – ES, Brazil
E-mails: klaus@ele.ufes.br, ailson@ele.ufes.br, evandro@ele.ufes.br

Abstract

Previous works show that the energy spectrum, taken from the coefficients of each level of the wavelet decomposition of ECG signals, forms good feature vectors for the classification of a number of specific heart anomalies. The required processing is simple. On the other hand, it is highly desirable (and also required by some cardiologic analyses) the ECG recording during the normal daily patient's activities. We are also interested in real time patient monitoring for the detection and alarm of some critical situation. For such, we need a portable, inexpensive, and computationally efficient hardware/software system, leading to the use of readily available Palmtop computer augmented with the instrumentation hardware and embedded software. The present study exploits the use of lifting wavelets (also called second generation wavelets) as a feature extractor engine, followed by a neural network classifier. The purpose of this work is the development of such a classification system, with emphasis for efficiency and portability.

1. Introdução

A eletrocardiografia vem sendo utilizada amplamente na medicina como uma maneira rápida, barata e não invasiva no diagnóstico de uma ampla variedade de doenças do coração.

Boa parte dessas doenças somente é detectada pela investigação do sinal elétrico obtido através do eletrocardiograma (ECG). Contudo, a sutileza de detalhes, a análise rotineira e a ampla variedade das doenças acarretam em um aumento na possibilidade de erros no diagnóstico médico.

Com o intuito de melhorar a eficiência e a segurança das análises humanas sobre o sinal do ECG, várias pesquisas foram realizadas abordando diferentes técnicas de processamento de sinais e de reconhecimento de padrões [12]. Cada trabalho procura demonstrar maneiras de salientar características que sejam relevantes para determinadas inquirições patognomônicas, permitindo detectar doenças de forma mais robusta, rápida e eficiente [3], [4], [6], [12], [14].

Objetivando uma contribuição efetiva nas pesquisas em torno desse tema, o presente artigo traz o estudo de uma técnica que permite diagnosticar de forma satisfatória algumas doenças cardíacas e, ao mesmo tempo, ser rápido e compacto o suficiente para adaptação em um sistema portátil de processamento.

A necessidade de prover mobilidade ao sistema é um dos principais motivos do referido estudo. Mais especificamente, no que se refere ao sistema portátil, optou-se pelo uso de um *palmtop* devido às facilidades quanto à disponibilidade de sistemas de desenvolvimento e programação, facilidade de aquisição, concentração de recursos (boa relação custo-benefício), e facilidade de operação pelo médico e pelo paciente.

O uso da Transformada *Wavelet* (WT) de primeira geração na preparação (pré-processamento) das classes e das Redes Neurais Artificiais (RNA) para classificação dos padrões formados foi objeto de trabalho recentemente realizado e submetido para apresentação [5]. O presente trabalho procura aprimorar o anterior [5], utilizando as WT's de segunda geração (especificamente, as *lifting wavelets*), com boas vantagens.

Questões quanto à metodologia, resultados e implementação no *palmtop* serão discutidas nos tópicos subsequentes.

2. Suporte matemático

2.1. Transformada Wavelet

A WT, um tipo de distribuição espaço-freqüência ou tempo-freqüência (para sinais temporais), é amplamente usada em aplicações de reconhecimento de padrões para realçar características relativas à forma de um determinado sinal, permitindo obter informações de freqüência para distintos instantes bem como distintas escalas de tempo.

A WT é uma operação linear que decompõe um sinal em componentes que aparecem em diferentes escalas (ou resoluções) [1], [10], [11]. As WT de primeira geração são obtidas pelo uso da equação 2.1 abaixo, e com detalhamento descrito em [5]:

$$Wf(a, \tau) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \psi_{a, \tau}^*(t) dt \quad (2.1)$$

As WT de segunda geração objeto deste trabalho são conhecidas como Transformadas *Lifting Wavelets*

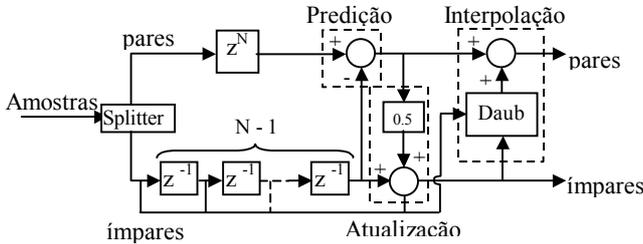


Figura 1: Decomposição *Lifting Wavelet*

(LWT) e foram introduzidas por Sweldens [8].

A figura 1 apresenta o diagrama de blocos das operações de *Lifting* aplicadas ao sinal submetido a LWT.

As operações *Lifting* são definidas conforme segue:

O bloco separador (*splitter*) recebe a seqüência original de amostras do sinal e fornece duas saídas: uma formada pelas amostras pares e outra pelas amostras ímpares do sinal de entrada.

Predição: $par = par - impar \quad (2.2)$

Atualização: $impar = impar + \frac{par}{2} \quad (2.2)$

A interpolação utiliza o filtro Daubechies [8] de ordem N.

As amostras ímpares são, por analogia a WT, os coeficientes de detalhe da decomposição e as amostras pares os coeficientes de aproximação.

Esse tipo de transformação satisfaz a conservação da energia, e o sinal original pode ser reconstruído da LWT.

As energias dos coeficientes de cada nível (E_i) resultantes da decomposição foram obtidas por:

$$E_i = \frac{\sqrt{\sum_{k=1}^{N_i} c_k^2}}{N_i} \quad (2.3)$$

onde “c” é um coeficiente da posição “k” do nível “i” que possui “ N_i ” coeficientes.

2.2. Redes neurais artificiais

As RNA são muito utilizadas para a classificação de padrões devido a uma série de características importantes como: generalização, paralelismo, adaptabilidade, estimação, não linearidade, resposta a

evidências, informação contextual, tolerância à falhas entre outras [7].

A equação 2.4 apresenta o modelo matemático de um neurônio (figura 2).

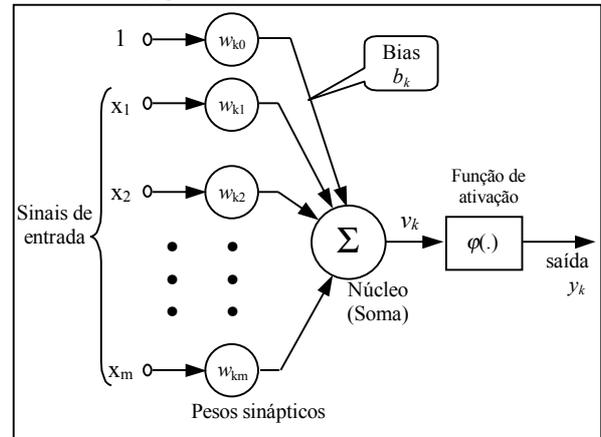


Figura 2: Neurônio Artificial

Onde:

$$y_k = \varphi \left(\sum_{j=1}^m w_{kj} x_j + b_k \right) \quad (2.4)$$

De acordo com [13], para processamento em tempo real, a detecção baseada em RNA é uma ótima escolha.

Uma RNA possui a propriedade de ser capaz de estimar sinais determinísticos e de remover os ruídos decorrelatados que acompanham esses sinais.

3. Metodologia

Os arquivos de sinais do ECG foram obtidos do banco de dados disponibilizado pelo MIT. As doenças

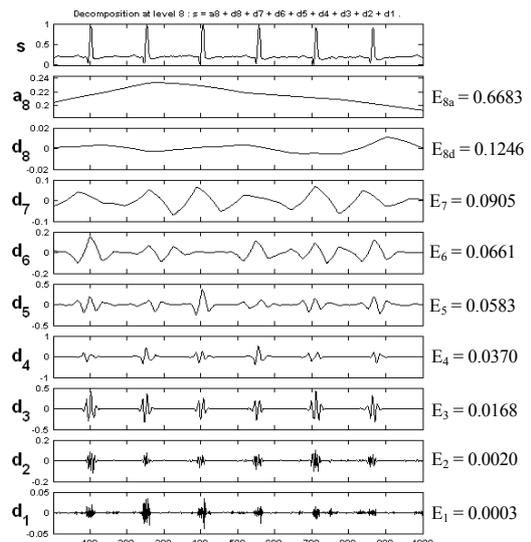


Figura 3: ECG normal e correspondente decomposição em oito níveis. A energia de cada nível é mostrada no lado direito. O sinal é oriundo da base de dados ECG do MIT e processado no Matlab.

selecionadas foram: Taquicardia Ventricular, Flutter Ventricular, Fibrilação Auricular e Flutter Auricular.

Os sinais de dois canais do ECG (derivações) foram amostrados a 250 Hz e conjuntos de pacotes contendo 1024 amostras por canal (≈ 4 segundos) de cada doença foram separados, normalizados e catalogados conforme as anotações médicas disponibilizadas pelo MIT. Foram utilizadas as mesmas derivações em todo o experimento.

Efetua-se a decomposição wavelet de cada pacote até o oitavo nível, uma vez que o sinal do ECG apresenta informação em frequência na faixa de 0.5 Hz a 40 Hz [4]. A *Lifting Wavelet* foi escolhida com filtro interpolador Daubechies de ordem 4. A energia de cada nível foi calculada para compor o vetor de energia do pacote. Cada vetor de energia foi composto por 18 valores formados pela concatenação das energias dos 8 níveis de decomposição de cada canal do ECG tomados ao mesmo tempo no paciente (Figura 3). Incluindo as amostras ímpares do oitavo nível (num total de 9 valores de energia).

Os vetores de energia formados compunham o conjunto de entrada da RNA.

O estudo em questão fez uso de uma RNA multicamadas conforme mostrada na figura 4, com aprendizado supervisionado e algoritmo *Feed-forward Backpropagation*.

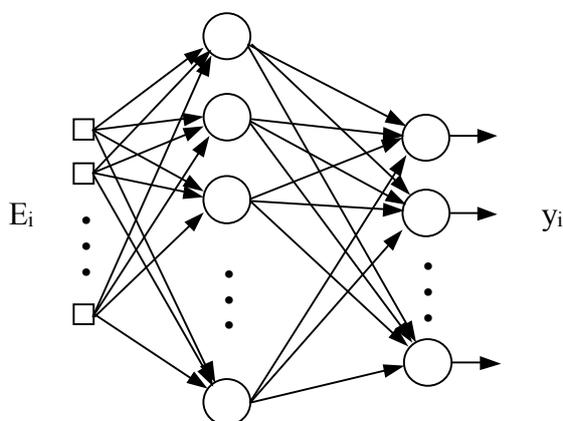


Figura 4: Rede Neural

4. Implementação em palmtop

O sistema foi desenvolvido na plataforma SDK para Pocket PC.

Optou-se pelo uso do “MS Embedded Visual Basic” para “MS Windows CE”, com a vantagem de ser um ambiente de desenvolvimento fornecido gratuitamente pela Microsoft.

O algoritmo do *palmtop* efetua os seguintes procedimentos:

1. Na inicialização do programa, é carregado o arquivo contendo os pesos sinápticos e os

valores de “bias” da RNA treinada no MATLAB.

2. Durante a captura do sinal ocorre a exibição dos dois sinais do ECG no display em suas respectivas derivações (Figura 5).



Figura 5: ECG de dois canais vistos simultaneamente no display do *palmtop*.

3. Simultaneamente, a decomposição *Lifting wavelet* em 8 níveis, para cada canal, é computada para cada nova amostra adquirida do referido canal.
4. Após a formação dos 8 níveis, calcula-se a energia dos coeficientes em cada nível.
5. Concatena-se os vetores de energia dos dois canais.
6. Submete-se o vetor de energias à entrada da RNA treinada.
7. Efetua-se a exibição dos valores percentuais aproximados da saída neural, obtidos do vetor de energia levado à incursão na rede.

5. Resultados

As amostras foram obtidas do banco de dados do MIT e correspondem aos mesmos conjuntos de amostras usados em [5], contudo a análise em questão faz uso de wavelets de segunda geração.

O treinamento da RNA foi efetuado no MATLAB com 150 vetores de energia (30 para cada doença e ECG normal), 6 neurônios na camada intermediária e 5 na camada de saída.

Para teste foram submetidas 20 amostras para cada doença e ECG normal perfazendo um total de 100. Essas amostras não foram incluídas no treinamento neural.

Do total de 100 amostras testadas, apenas 14 foram classificadas de forma errada, sendo 13 erros de classificação entre Taquicardia Ventricular e Flutter Ventricular. O treinamento durou 65 épocas com meta 0.00001.

Outra RNA foi preparada contendo 4 neurônios na camada intermediária, 4 na camada de saída, e um total de 120 amostras para treino, com eliminação das 30 amostras do Flutter Ventricular. A classificação efetuada pela nova rede sobre 80 amostras de teste, com

20 épocas de treinamento e meta de 0.00001 teve uma taxa de acerto de 98.5% com apenas uma classificação errada.

Acrescentando-se 4 neurônios na camada intermediária e retirando-se os coeficientes do primeiro nível da decomposição *Lifting* e as amostras do Flutter Ventricular, a taxa de acerto foi de 97.5% com 2 erros em 22 épocas de treinamento e meta de convergência de 0.00001.

Retirando-se as amostras ímpares do último nível da decomposição *Lifting* e as amostras do Flutter Ventricular, a taxa de acerto foi de 98.5% com apenas um erro em 22 épocas de treinamento e meta 0.00001.

Retirando-se os coeficientes do primeiro nível da decomposição *Lifting*, os coeficientes ímpares do último nível e as amostras do Flutter Ventricular, a taxa de acerto foi de 98.5% com apenas um erro em 38 épocas de treinamento e meta de 0.00001.

6. Conclusões

As implicações quanto ao uso da energia dos níveis da decomposição wavelet permanece, como exposto em [5].

O uso de redes neural artificiais e da transformada *Lifting wavelet* apresentou-se eficiente no sistema implementado no *palmtop*.

Doenças como a Taquicardia Ventricular e o Flutter Ventricular apresentam espectro de energia que impossibilitam a separabilidade entre essas classes de doenças. Contudo, com a supressão do Flutter Ventricular a classificação teve uma eficiência superior a 97.5%.

O primeiro nível da decomposição *Lifting* e o último nível com amostras ímpares não possuem informação significativa para as doenças consideradas, como era de se esperar, uma vez que as informações no sinal do ECG estão entre 0.5 Hz e 40 Hz [4].

Isso demonstra que a energia dos níveis da decomposição wavelet pode ser uma excelente maneira de elaborar a pré-seleção de doenças cardíacas de forma rápida e eficiente.

Em comparação com a transformada wavelet de primeira geração [5] pode-se destacar:

- A transformação *Lifting* é efetuada em tempo real, ou seja, continuamente amostra por amostra.
- A transformação *Lifting* é linear.
- O algoritmo da *Lifting* é de simples computação, e
- Pode facilmente ser capacitado com a característica de transformação sem perdas, ou seja, de reconstrução perfeita, ideal para a compressão de sinais biomédicos [9]. Conseguir-se isto pela utilização de coeficientes inteiros [2] para efeito de melhoria do desempenho de processamento e do aproveitamento da memória de armazenamento, caso se queira armazenar os sinais avaliados.

Referências

- [1] Burrus, C. Sidney; Gopinath, Ramesh A.; Guo, Haitao., Introduction to wavelets and wavelet transform - a primer. New Jersey: Prentice Hall, 1998.
- [2] Calderbank, A. R.; Daubechies, Ingrid; Sweldens, Win., Wavelet transform that map integers to integers. Technical report, Department of Mathematics, Princeton University, 1996.
- [3] Chazal, P de et al., Classification of the electrocardiogram using selected wavelet coefficients and linear discriminants. IEEE, p. 3590-3593, 2000.
- [4] Chazal, P. de; Celler, Branko., Selection of parameters from power spectral density, wavelet transform and other methods for the automated interpretation of the ecg. IEEE Digital Signal Processing, p. 71-74, 1997.
- [5] Coco, Klaus F.; Almeida, Ailson R.; Salles, Evandro O. T., Neural ECG Classification based on the Energy of the Wavelet Coefficients. Aceito para apresentação no ISIE - IEEE International Symposium on Industrial Electronics, Rio de Janeiro, 2003.
- [6] Dokur, Z.; Ölmez, Tamer; Yazgan, E., Ecg waveform classification using the neural network and wavelet transform. IEEE, p. 273, 1999.
- [7] Haykin, Simon, Redes neurais: princípio e prática. Porto Alegre: Bookmam, 2001.
- [8] Jensen, A.; la Cour-Harbo, A., Ripples in Mathematics: The Discrete Wavelet Transform. Germany: Springer, 2001.
- [9] Krzysztof, Duda; Pawel, Turcza; Tomasz, P. Zielinsk, Lossless ECG compression with lifting wavelet transform. IEEE Instrumentation and Measurement Technology Conference, Hungary, may 21-23, 2001.
- [10] Mallat, S., Multiresolution frequency channel decomposition of images and wavelet models. IEEE Trans. on Acoust, Speech Signal Processing, v. 12, p. 2091-2110, 1989.
- [11] Rioul, O.; Vetterli, M., Wavelet and signal processing. IEEE Signal Processing Magazine, p. 14-38, 10.1991.
- [12] Silipo, Rosaria; Bortolan, Giovanni, Neural and traditional techniques in diagnostic eeg classification. IEEE, p. 123-126, 1997.
- [13] Szilagyi, S. M.; Szilagyi, L.; David, L., Comparison between neural-network-based adaptive filtering and wavelet transform for eeg characteristic point detection. IEEE, p. 272-274, 1997.
- [14] Watson, Jamie et al., Evaluating arrhythmias in eeg signal using wavelet transform. IEEE Engineering in Medicine and Biology, p. 104-109, 10.2000.