

Detecção de Complexos QRS através de Time-Delay Neural Networks

Eduardo de Azevedo Botter¹, Cairo Lúcio Nascimento Júnior² e Takashi Yoneyama²

¹Faculdade de Tecnologia e Ciências Exatas

Universidade São Judas Tadeu - USJT

²Divisão de Engenharia Eletrônica - IEE

Instituto Tecnológico de Aeronáutica - ITA

E-mails: botter7@hotmail.com, cairo@ita.br, takashi@ita.br

Abstract

An important task in ECG analysis is the detection of the QRS complex. In this paper a QRS complex detector based on a time-delay neural network is proposed and its tolerance to noise and position of the QRS complex is investigated.

1. Introdução

Os tratamentos dados a sinais eletrocardiográficos utilizam, como ponto de partida, o intervalo entre dois complexos QRS [4] (onda R), ou ainda, em alguns casos, a média dos últimos batimentos

O que se verifica é que a maioria dos algoritmos utilizam, como ferramenta para detectar o complexo QRS, técnicas como filtragem [10], [5], redes neurais artificiais [6], derivadas [3], integrais combinadas com derivadas [11] métodos de transformação como Transformada Wavelet [7], [8].

Para confiarmos nas técnicas utilizadas, necessitamos de uma medida que nos indique a confiabilidade dos resultados encontrados. Normalmente se utilizam as figuras de mérito número de falsos positivos e número de falsos negativos.

- Falsos Positivos (FP) são aqueles complexos QRS que não existem naquela determinada localidade, mas que foram detectados pelo algoritmo.
- Falsos Negativos (FN) são aqueles complexos QRS que não foram detectados pelo algoritmo mas que existem.

Como o sinal eletrocardiográfico é um sinal que tem suas características variando ao longo do tempo, optamos por utilizar uma topologia de rede neural denominada TimeDelay Neural Network (TDNN), a qual foi proposta inicialmente por Alexander Waibel em 1988 [2], [13]. Esta topologia permite relacionar padrões que variam ao longo do tempo.

2. Materiais e métodos

Sabemos que o desempenho dos algoritmos varia de acordo com os sinais utilizados, ou seja, se o mesmo apresenta ou não algum tipo de ruído.

Os ruídos mais comumente encontrados são:

- interferência da linha elétrica;
- mau contato dos eletrodos;
- movimento do paciente no leito;
- mudança da linha de base devido a respiração do paciente.

Estes ruídos foram simulados aos sinais estudados no presente artigo via *software* [3].

Para aplicações onde as relações entre padrões são importantes, um sistema que apresente dinamicamente estes padrões na entrada permite que estas relações sejam melhor “aprendidas”.

A arquitetura TDNN (fig. 1) usada neste trabalho é bastante similar a arquitetura *perceptron de* múltiplas camadas (MLP), sendo constituída de:

- uma camada de entrada;
- uma ou mais camadas escondidas;
- uma camada de saída.

Para as unidades pertencentes a camada escondida (*hidden layer*), da mesma forma que para o MLP, utilizam-se funções de transferências não lineares, como por exemplo, sigmóides ou tangente hiperbólicas, e para a camada de saída a função pode ser linear ou não linear.

As camadas de entrada e/ou escondidas (intermediárias) são compostas com atrasos (*delays*) em cada neurônio, de modo a considerar apresentações anteriores das respectivas entradas, conforme ilustra a figura 1 a seguir.

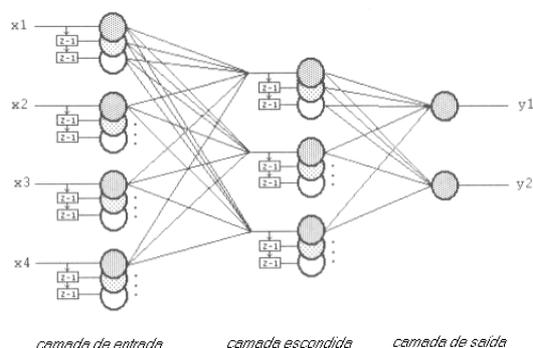


Figura 1 – Arquitetura TDNN clássica com uma camada escondida.

Utilizamos a arquitetura TDNN clássica unidimensional, onde cada neurônio da camada de entrada contém dois atrasos (*delays*) e a camada escondida é estática, ou seja, sem *delays*. O número de determinado experimentalmente via simulações, objetivando o menor erro após o treinamento.

No presente caso, compuseram como conjunto de dados de entrada, partes de sinais eletrocardiográficos tendo como base a posição do complexo QRS (extraído de [1]), contendo 100 amostras cada uma delas, gerando desta forma onze tipos de sinais devido à localização do complexo QRS, ilustrado a seguir, ou seja:

- um com o complexo QRS ocorrendo na amostra 1;
 - outro com o complexo QRS ocorrendo na amostra 10;
 - outro com o complexo QRS ocorrendo na amostra 20;
- e assim sucessivamente até a amostra 100;
- e outros não tendo complexo QRS dentro das 100 amostras que compõem os neurônios da camada de entrada.

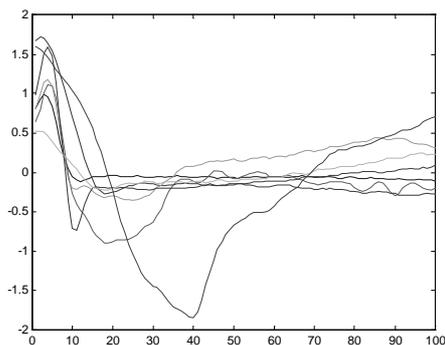


Figura 2 – Sinais eletrocardiográficos com o complexo QRS na amostra 1

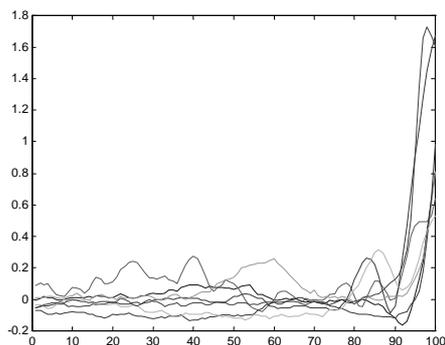


Figura 3 – Sinais eletrocardiográficos com o complexo QRS na amostra 100

O conjunto de dados de saída foi assim definido:

- quando o complexo QRS ocorrer na amostra 100 a saída desejada vale um (1);
- nos demais casos vale menos um (-1).

3. Resultados

Inicialmente a rede foi testada aplicando com sinais eletrocardiográficos deslocados com relação ao tempo, simulando um Detecção *on-line*.

Tabela 1 – Detecção dos complexos QRS

Sinal	Total de Batimentos	FP	FN	$\frac{FP+FN}{Total}$
100	198	0	1	0,0051
101	189	0	8	0,0423
102	196	0	6	0,0306
103	189	0	0	0
105	222	0	8	0,0360
107	188	1	2	0,0159
111	184	0	16	0,0869
112	229	0	5	0,0218
115	168	0	0	0
118	195	0	0	0
124	131	0	0	0
202	141	0	1	0,0071
209	252	0	0	0
212	144	0	0	0
220	191	0	0	0

O grande número de falsos negativos é notável na tabela acima, e isto se deve em parte a presença de ruídos nos sinais.

Uma das idéias para tentar reduzir este problema é a inclusão de ruídos, via *software*, nos padrões de treinamento da rede, alternativa esta utilizada no presente trabalho. As figuras 4 e 5 a seguir ilustram o resultado da inclusão dos ruídos nos padrões de treinamento da rede.

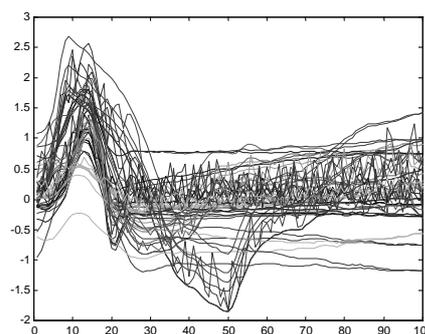


Figura 4 – Sinais eletrocardiográficos com ruído e com o complexo QRS na amostra 10

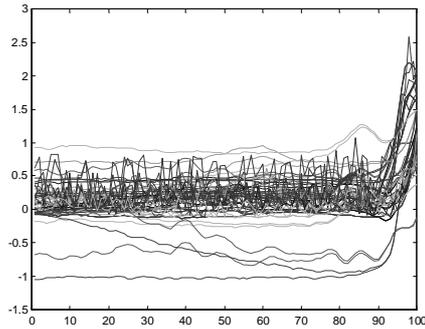


Figura 5 – Sinais eletrocardiográficos com ruído e com o complexo QRS na amostra 100

A tabela 2 mostra os resultados obtidos:

Tabela 2 – Detecção dos complexos QRS usando Injeção de ruído nos padrões de treinamento

Sinal	Total de Batimentos	FP	FN	$\frac{FP+FN}{\text{Total}}$
100	198	0	0	0
101	189	7	0	0,0370
102	196	0	0	0
103	189	0	0	0
105	222	1	0	0,0045
107	188	0	0	0
111	184	0	0	0
112	229	0	0	0
115	168	0	0	0
118	195	0	0	0
124	131	0	0	0
202	141	0	0	0
209	252	0	2	0,0079
212	144	0	0	0
220	191	0	0	0

O que notamos comparando agora as duas tabelas anteriores é que a rede apresentou melhor desempenho quando a mesma foi treinada utilizando sinais ruidosos.

Em seguida realizou-se a comparação da nossa técnica com os resultados obtidos em [3]. Os resultados obtidos das simulações estão tabelados a seguir:

Tabela 3 – Presença de Ruído Aleatório

	% de Ruído	DF2	TDNN
% QRS Detectados	0	100	100
	25	100	100
	50	100	100
	75	100	100
	100	100	100
Número de Falsos Positivos	0	0	0
	25	0	0
	50	0	0
	75	0	0
	100	0	0
Número de Falsos Negativos	0	0	0
	25	0	0
	50	0	0
	75	0	0
	100	0	0

Tabela 4 – Presença de Ruído de Respiração

	% Ruído	DF2	TDNN
% QRS Detectados	0	100	100
	25	100	100
	50	100	100
	75	100	100
	100	100	100
Número de Falsos Positivos	0	0	0
	25	0	0
	50	0	0
	75	0	0
	100	0	0
Número de Falsos Negativos	0	0	0
	25	0	0
	50	0	0
	75	0	0
	100	0	0

Tabela 5 – Presença de Ruído de Deslocamento da linha de base

	% Ruído	DF2	TDNN
% QRS Detetados	0	100	100
	25	100	100
	50	100	100
	75	100	100
	100	100	100
Número de Falsos Positivos	0	0	0
	25	0	0
	50	0	0
	75	0	0
	100	0	0
Número de Falsos Negativos	0	0	0
	25	0	0
	50	0	0
	75	0	0
	100	0	0

Tabela 6 – Presença dos três tipos de ruído (aleatório, respiração, deslocamento da linha de base)

	% Ruído	DF2	TDNN
% QRS Detetados	0	100	100
	25	100	100
	50	100	100
	75	100	100
	100	100	100
Número de Falsos Positivos	0	0	0
	25	0	0
	50	0	0
	75	0	6
	100	0	7
Número de Falsos Negativos	0	0	0
	25	0	0
	50	0	0
	75	0	2
	100	0	9

4. Conclusões

Quando os sinais aplicados nos algoritmos não estão acompanhados de nenhum tipo de ruído, os dois algoritmos apresentaram ótimos resultados.

Ao se adicionar ruídos aos sinais, os resultados foram que quando consideramos a composição de todos os tipos de ruídos notou-se que o algoritmo baseado em TDNN teve o seu desempenho afetado para sinais com altos níveis de ruídos (75 e 100%), acarretando numa diminuição da porcentagem de complexos QRS detectados e a um pequeno número de falsos positivos e negativos. Isto pode ser devido a suas altas amplitudes, dificultando assim a sua detecção por parte da rede neural, pois a rede neural só foi treinada com o sinal “puro”, ou seja, não consideramos na fase

de treinamento da rede neural nenhum sinal acompanhado de ruído.

Referências

- [1] “MIT-BIH Database Distributor”, Beth Israel Hospital, Bimedical Engineering, Division KB-26, 330 Brookline Ave., Boston, MA 02215.
- [2] Cabral, Euvaldo F. *Redes Neurais Artificiais – Um Curso Técnico e Prático para Engenheiros e Cientistas*. Primeira Edição. Edição dos Autores, 1999.
- [3] Friesen, Gary M., Jannett, Thomas C., Jadalaah, Manal Afify, YATES, Standford L., Quint, Stephen R. & NAGLE, H. Troy. A Comparision of the Noise Sensitivity of Nine QRS Detection Algorithms. *IEEE Transactions on Biomedical Engineering*. 1990.
- [4] Guyton, A. C. *Tratado de Fisiologia Médica*. Oitava Edição. Rio de Janeiro. Editora Guanabara Koogan, p. 87-129. 1991.
- [5] Hamilton, Patrick S. & Tompkins, Willis J. Quantitative Investigation of QRS Detection Rules Using the MIT/BIH Arrhythmia Database. *IEEE Transactions on Biomedical Engineering*. Vol. BME-33, nº 12, December 1986.
- [6] Hu, Y. H., Tompkins, W. J. & Xue, Q. Artificial Neural Netwok for ECG Arrhythmia Monitoring. *IEEE Transactions on Biomedical Engineering*. 1992.
- [7] Kadambe, Shubha, Murray, Robin & Boudreaux-Bartels, Faye. The Dyadic Wavelet Transform Based QRS Detector. *IEEE Transactions on Biomedical Engineering*. 1992.
- [8] Li Cuiwei, Zheng, Chongxun & Tai Changfen. Detection of ECG Characteristic Points Using Wavelet Transforms. *IEEE Transactions on Biomedical Engineering*. Vol. 42, nº 1, January 1995.
- [9] Moreira, Dalmo Antonio Ribeiro. *Arritmias Cardíacas - Clínica, Diagnóstico e Terapêutica*. Primeira Edição. Editora Artes Médicas. 1995.
- [10] Okada, Masahiko. A Digital Filter for the QRS Complex Detection. *IEEE Transactions on Biomedical Engineering*. Vol. BME-26, nº 12, December 1979.
- [11] Pan, Jiapu & Tompkins, Willis J. A Real-Time QRS Detection Algorithm. *IEEE Transactions on Biomedical Engineering*. Vol. BME-32, nº 3, March 1985
- [12] Romero, Rodolfo Luis, *Electrocardiografía*. Primeira Edição. Editora Lopes Libreros.1964.
- [13] WaibelL, Alexander, Hanakawa, Toshiyuki , Hinton, Geoffrey, Shicano, Kiyohiro and LANG, Kevin J. Phoneme Recognition Using Time-Delay Neural Network. *IEEE Transactions on Acoustics, Speech, and Signal Processing* , Vol. 37, nº 3 March 1989.