

# Detecção Automática de Arritmias Cardíacas Utilizando Redes Neurais Artificiais Auto-Organizáveis

Sérgio Renato Rogal Jr.<sup>1</sup>, Emerson Cabrera Paraiso<sup>1</sup>, Celso Antônio Alves Kaestner<sup>2</sup>, Marcus Vinícius Mazega Figueredo<sup>1</sup> e Alfredo Beckert Neto<sup>1</sup>

<sup>1</sup>Pontifícia Universidade Católica do Paraná – PUCPR  
Programa de Pós-Graduação em Informática – PPGIA

<sup>2</sup>Universidade Tecnológica Federal do Paraná – UTFPR  
Departamento de Informática

[rogal@ppgia.pucpr.br](mailto:rogal@ppgia.pucpr.br), [paraiso@ppgia.pucpr.br](mailto:paraiso@ppgia.pucpr.br), [celsokaestner@utfpr.edu.br](mailto:celsokaestner@utfpr.edu.br),  
[marcus@ppgia.pucpr.br](mailto:marcus@ppgia.pucpr.br), [beckert@gmail.com.br](mailto:beckert@gmail.com.br)

**Abstract.** The arrhythmias or abnormal rhythms of the heart are common cardiac riots and may cause serious risks to the life of people, being one of the main causes of death. These deaths could be avoided if a previous monitoring of these arrhythmias was carried through, using the Electrocardiogram (ECG) exam. The continuous monitoring and the automatic detection of arrhythmias of the heart may help the specialist to perform a faster and precise diagnostic. This work raises the hypothesis that self-organized artificial neural networks (ANN) can be used in the processing of the cardiac arrhythmias. This ANN allows that, at any time, other groups of arrhythmias may be added, without the necessity of a new training phase. In this work, an ART2 neural network is used to detect the normal beatings, the atrial premature contractions (CPA) and the ventricular premature contractions (CPV).

**Keywords:** *arrhythmia detection, Wavelets, neural networks, ECG*

## 1 Introdução

As doenças cardiovasculares são hoje em dia uma das principais causas de óbitos em países desenvolvidos e em desenvolvimento [1]. Estes óbitos poderiam ser reduzidos se fossem realizados a detecção e o monitoramento prévio dessas arritmias a partir do Eletrocardiograma (ECG). O ECG é o registro de potenciais elétricos emitidos pelo coração que atingem a superfície do corpo [2].

As arritmias ou ritmos anormais do coração são distúrbios cardíacos comuns e podem causar sérios riscos à vida das pessoas. Estes distúrbios são caracterizados pela alteração da frequência ou ritmo dos batimentos cardíacos e podem ocorrer por várias razões [3].

A detecção automática de arritmias a partir do ECG pode ser obtida de várias maneiras, utilizando-se algoritmos específicos e métodos inteligentes [4], [5], [6], [7], [8], [9], [10], [11], [12]. Em geral, a detecção automática de arritmias é dividida em três etapas: pré-processamento, extração de características e processamento.

2 Sérgio Renato Rogal Jr. <sup>1</sup> Emerson Cabrera Paraiso <sup>1</sup> Celso Antônio Alves Kaestner <sup>2</sup>,  
Marcus Vinícius Mazega Figueredo <sup>1</sup> e Alfredo Beckert Neto <sup>1</sup>

Este trabalho levanta a hipótese de que uma RNA auto-organizável pode ser utilizada para o agrupamento de arritmias cardíacas. Esta RNA permite que, a qualquer momento, possam ser adicionados outros grupos de arritmias, sem a necessidade de realizar novamente o treinamento dos grupos antigos da RNA. Treinam-se apenas os novos grupos. A principal vantagem, portanto, é um ganho no momento em que deseja-se ampliar o número de arritmias detectadas por um sistema ajustado para trabalhar com uma RNA auto-organizável.

Em nossa abordagem, nas etapas de pré-processamento e de extração de características dos sinais de entrada, utilizamos as transformadas Wavelet. Através de uma transformação do sinal para o domínio tempo-frequência, as amostras dos batimentos são convertidas para coeficientes Wavelet. Em seguida, estes coeficientes são utilizados na entrada da RNA auto-organizável, que irá agrupá-los, ou seja, os dados similares serão colocados no mesmo grupo. Para os dados não similares, novos grupos são criados.


Na seqüência deste artigo, a seção 2 mostrará o ECG, as arritmias cardíacas e a detecção automática das mesmas. A seção 3 apresentará a metodologia desenvolvida durante este trabalho. Os resultados obtidos serão apresentados na seção 4. Ao final, oferecemos uma conclusão e as perspectivas de trabalhos futuros.

## 2 O Eletrocardiograma e a Detecção Automática de Arritmias

Nesta seção apresentamos os conceitos fundamentais sobre o ECG, as arritmias cardíacas e como, tradicionalmente, podem ser realizadas as detecções automáticas de arritmias.

### 2.1 O Eletrocardiograma (ECG)

À medida que o impulso cardíaco cursa pelo coração, correntes elétricas se propagam para os tecidos que cercam o coração e uma pequena fração dessas correntes atinge a superfície do corpo [3]. Se forem colocados eletrodos sobre a pele em pontos opostos do coração, os potenciais elétricos gerados por essas correntes podem ser registrados; esse registro corresponde ao ECG. Um ECG normal, para um batimento cardíaco, é apresentado na figura 1.



**Fig. 1.** Elementos do eletrocardiograma normal<sup>1</sup>

O ECG normal é composto por uma onda P, um complexo QRS e uma onda T [3].


<sup>1</sup> O ECG apresentado nesta figura não é real, é apenas uma ilustração com o objetivo de mostrar as ondas e os segmentos que o formam.

O complexo QRS nem sempre aparece sob a forma de três ondas (Q, R e S).

## 2.2 Arritmias Cardíacas

Arritmia cardíaca é o nome genérico de diversas perturbações que alteram a frequência e/ou o ritmo dos batimentos cardíacos. As arritmias podem levar à morte e constituir por isso, um caso de emergência médica.


Neste trabalho, nos concentramos nas arritmias conhecidas como contrações prematuras<sup>2</sup>, devido a sua grande incidência. A figura 2 apresenta uma contração prematura atrial (CPA) isolada, marcada pela letra “A”. A onda P desse batimento é encurtada.



**Fig. 2.** CPA - Contração prematura atrial (extraído do registro 100 de [14]). Intervalo da grade: 0.2 sec, 0.5mV.

A CPA ocorre com grande frequência em pessoas saudáveis. O seu aparecimento resulta de fatores tais como fumo, falta de sono, ingestão excessiva de café, alcoolismo e outros [2].

Também existe a Contração Prematura Ventricular (CPV). As CPV produzem efeitos específicos no eletrocardiograma, mostrado na figura 3, representada pela letra “V”.



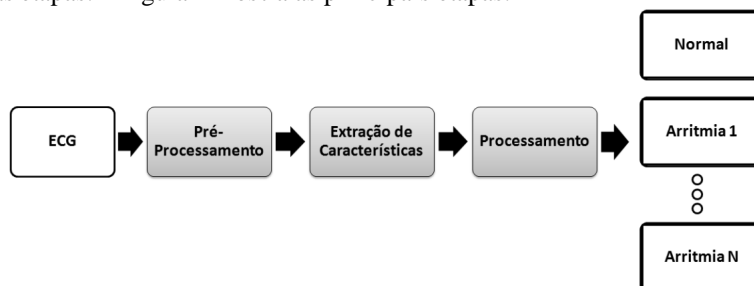
**Fig. 3.** CPV - Contração prematura ventricular (extraído do registro 100 de [14]). Intervalo da grade: 0.2 sec, 0.5mV.

Algumas CPV resultam dos mesmos fatores das CPA e, até mesmo, irritabilidade emocional. Essas são relativamente benignas em sua origem. Por outro lado, algumas CPV resultam de sinais reentrantes que se originam ao redor dos limites de áreas cardíacas enfartadas ou isquêmicas, podendo desenvolver fibrilação ventricular espontânea, o que é letal [2].

<sup>2</sup> Trata-se de uma contração que ocorre antes do momento em que deveria ocorrer uma contração normal.

### 2.3 Detecção Automática de Arritmias utilizando Redes Neurais Artificiais

A detecção automática de arritmias utilizando RNA é um processo que passa por diversas etapas. A figura 4 mostra as principais etapas.



**Fig. 4.** Principais etapas no processo de detecção de arritmias.

O pré-processamento é uma etapa muito importante, pois, é nela que ocorre a seleção das amostras do sinal de ECG.

Outra etapa muito importante é a extração de características do sinal de ECG. Esta etapa deve ser muito bem estudada, pois, ela pode interferir diretamente na performance e na exatidão de todo o processo. Uma técnica de extração de características que vem obtendo bons resultados nos últimos anos é a transformada Wavelet [13]. A aplicação da transformada Wavelet sobre um sinal mostra informações adicionais deste sinal que não eram conhecidas no sinal original, mostrando efetivamente onde cada frequência está ocorrendo [15].

A última etapa é o processamento. É nesta etapa que as arritmias são de fato identificadas. As RNA são bastante utilizadas nesta etapa, fazendo a classificação ou o agrupamento dos sinais de entrada [16]. Na classificação, o sinal analisado será colocado em uma determinada classe já existente. Já no agrupamento, à medida que os sinais são processados, são criados grupos com base na similaridade dos dados analisados. Assim, um sinal analisado poderá ser adicionado a um grupo já existente, caso exista uma similaridade de informações e caso não exista esta similaridade, um novo grupo será criado.

Em [17] utilizou-se RNA para classificar as arritmias do ECG. A análise do sinal de ECG foi feita no domínio do tempo. Para classificar as arritmias, o intervalo entre dois picos (R-R) foi normalizado em 200 amostras, formando as 200 entradas da rede neural. O algoritmo de aprendizagem utilizado foi o *back-propagation*. Este método obteve um erro de 4,3%.

Em [11] foi proposto um novo algoritmo para análise do espaço de fase para sinais de ECG, visando facilitar a detecção de arritmias cardíacas. Um traçado da densidade do espaço de fase foi obtido com o mapeamento da distribuição dos pontos do sinal de ECG no espaço de fase e os valores da densidade do espaço de fase dentro de uma janela predefinida. A classificação foi executada usando uma RNA *back-propagation* e a taxa de acerto total obtida foi de 98,55%.

Em [18] foi proposto um método para classificar as arritmias cardíacas utilizando uma combinação de Wavelets e RNA. A habilidade da transformada Wavelet para decompor o sinal em resoluções variadas, permite a detecção e extração de

características de sinais não estacionários como o ECG. O valor dos coeficientes da transformada Wavelet discreta (TWD), que contém a informação suficiente sobre as arritmias, é selecionado da decomposição da Wavelet. Estes coeficientes junto com a informação do intervalo RR (a diferença entre os picos atuais e precedentes do complexo QRS) alimentam a rede neural *back-propagation* que classifica as arritmias. Utilizou-se um algoritmo robusto para eliminar os ruídos. Este método é capaz de distinguir além do ritmo normal, mais 12 arritmias diferentes com uma taxa de acerto de 96,77%.

Em [19] desenvolveu-se um algoritmo baseado na transformada Wavelet para detectar e classificar 4 tipos de arritmias ventriculares. O algoritmo implementado utilizou 4 Wavelets diferentes e comparou cada resultado. Para episódios extraídos das bases de dados MIT-BIH Arrhythmia [14] e Malignant Ventricular Arrhythmia, uma Wavelet de *Daubechies* de comprimento 4 obteve o melhor resultado das quatro Wavelets estudadas. O método teve uma taxa de acerto de 91,1%.

A seção seguinte mostrará a metodologia proposta neste trabalho.

### 3 Detecção de Arritmias Cardíacas Utilizando Redes Neurais Auto-Organizáveis

Apresentamos nesta seção a metodologia utilizada durante o desenvolvimento deste trabalho. Este trabalho levanta a hipótese de que uma RNA auto-organizável pode ser utilizada para agrupar as arritmias de um sinal de ECG, obtendo resultados semelhantes aos trabalhos que utilizaram outras abordagens (ver tabela 3). A figura 5 apresenta o diagrama para o processo de agrupamento utilizado neste trabalho.




Fig. 5. Diagrama de todo o processo para o agrupamento do sinal de ECG.

Para este trabalho foi escolhida a base de dados MIT-BIH Arrhythmia Database [14], que é uma base de dados utilizada para o desenvolvimento e avaliação de monitores de arritmias. Esta base é referência para o desenvolvimento de pesquisas na área de análise de arritmias. Ela foi criada pelo Boston's Beth Israel Hospital entre os anos de 1975 e 1979 [20], tendo sido publicada em 1980. Esta base possui 48 registros de ECG com arritmias, cada registro contendo duas derivações. O Boston's Beth Israel Hospital digitalizou os sinais com uma frequência de amostragem de 360 Hz e com 11 bits de resolução. Destes 48 registros, 25 foram coletados de um conjunto específico de exames e os outros 23 registros foram selecionados

aleatoriamente para representar outras arritmias [14]. Especialistas da área avaliaram cada batimento cardíaco dos registros, informando a ocorrência de uma arritmia ou não, totalizando 110000 anotações de batimentos cardíacos [21].

Todo o sinal da base de dados foi segmentado na fase de pré-processamento por um algoritmo implementado em Java. Este algoritmo selecionou as amostras para a análise do ECG. Este processo é representado na figura 6.




Fig. 6. Diagrama do processo de segmentação do ECG.

O processo de segmentação inicia-se pela detecção de picos. No caso da base utilizada, a detecção de picos não foi necessária, visto que os mesmos já estão anotados. Para a seleção das amostras, foi definido um intervalo contendo 100 amostras, 50 amostras antes do pico e 50 amostras depois do pico. Este intervalo contém todas as ondas possíveis para a detecção de uma arritmia.

Este processo seleciona amostras de 7605 batimentos, 3000 batimentos para treinamento e 4605 batimentos para testes.

Após o processo de seleção das amostras, estas serão submetidas à transformada Wavelet para o processo de extração de características. Este processo é apresentado na seção seguinte.

### 3.1 Transformada Wavelet Discreta

Utilizou-se uma transformada Wavelet discreta (TWD) do tipo *Coiflet* com 4 níveis de resolução para processar as amostras de ECG da janela selecionada. As 100 amostras da janela selecionada são observadas na figura 7.




Fig. 7. Janela com amostras do sinal de ECG original.

Os coeficientes resultantes da transformada Wavelet apresentados na figura 8, são utilizados para formar o vetor de características do sinal de ECG analisado que será processado pela RNA.




Fig. 8. Coeficientes Wavelet da janela selecionada.

A TWD foi parametrizada até a quarta camada. Este número foi escolhido com base em trabalhos anteriores [18], [19] que obtiveram bons resultados.

Obtidos os coeficientes, estes são submetidos a RNA para o processamento.

### 3.2 Rede Neural Artificial Auto Organizável

Utilizou-se uma RNA auto-organizável do tipo ART2 (Adaptive Resonance Theory), com 100 unidades de entrada e com 15 unidades de saída (clusters). O vetor de características formado foi disponibilizado à entrada da RNA (uma característica por entrada). Os parâmetros da ART2 foram ajustados empiricamente, chegando a um nível de agrupamentos adequados. A tabela 1 mostra o valor dos parâmetros utilizados na ART2.

Tabela 1. Valor dos parâmetros utilizados na RNA ART2.

Parâmetro	Valor	Descrição
t	100	Ciclos de treinamento
n	100	Unidades de entrada
m	15	Unidades de saída
a	10	Peso fixo da primeira camada
b	10	Peso fixo da primeira camada
c	0.1	Peso fixo utilizado no teste de reset
d	0.9	Ativação da unidade vencedora de saída
$\rho$	0.99	Determina a taxa de formação dos clusters

O uso desta rede é muito importante neste trabalho, visto que a ART2 é uma rede “plástica”<sup>3</sup>, não sendo necessário treiná-la novamente desde o início para a adição de outros grupos [22]. Ela se ajusta automaticamente, formando novos grupos se necessário. A RNA foi treinada com um conjunto de 3000 batimentos divididos em: 1000 batimentos normais, 1000 batimentos com CPA e 1000 batimentos com CPV. Para os testes, foi utilizado um novo conjunto com 4605 batimentos divididos em: 1535 batimentos normais, 1535 batimentos com CPA e 1535 batimentos com CPV.

<sup>3</sup> Trata-se da propriedade da RNA que permite o desenvolvimento de alterações estruturais em resposta à experiência, e como adaptação a condições mutantes e a estímulos repetidos.

## 4 Resultados Obtidos

Os resultados obtidos são apresentados na tabela 2. Já na tabela 3 os resultados obtidos são confrontados com outros trabalhos.

**Tabela 2.** Resultados obtidos neste trabalho.

Sinal de ECG	Taxa de acerto
Batimento Normal	82%
Arritmia CPA	83%
Arritmia CPV	94%

A metodologia adotada obteve bons resultados, similares aos trabalhos que utilizaram a mesma base. A tabela 3 apresenta uma comparação entre os resultados de outros trabalhos e os resultados obtidos com a RNA auto-organizável.

**Tabela 3.** Comparação entre a RNA auto-organizável e outros trabalhos.

Trabalho	Arritmias		Nº total de arritmias analisadas	Taxa média de acerto (classificação/agrupamento) correto
	CPA	CPV		
RNA ART2	x	x	2	88,50%
[8]		x	2	80%
[9]		x	1	96,90%
[10]		x	1	98,60%
[7]	x	x	4	98,30%
[11]		x	4	93,70%
[23]	x	x	2	90%

A taxa de acerto apresentada foi calculada a partir da média das N classes (arritmias). Alguns aspectos podem ser relevantes para explicar os resultados obtidos e nos guiar para pesquisa futura.

Com relação a segmentação, pensamos em variar o número de amostras ou mesmo selecionar amostras específicas do sinal de ECG. Isso poderia melhorar os resultados.

A utilização da transformada Wavelet *Coiflet* provou-se ser muito eficiente para representar a onda de ECG e suas arritmias. A análise com Wavelet é mais aprofundada, já que mostra efetivamente onde cada frequência do ECG está ocorrendo. Porém, existem outras famílias de transformada Wavelet que poderiam ser utilizadas, como *Daubechies*, *Haar* e *Symmlet*. A utilização da transformada Wavelet *Daubechies* possui eficiência similar a *Coiflet*, como observado em [19].

Durante os testes foram utilizadas diversas configurações para a RNA ART2. Inicialmente, uma ART2 com 100 unidades de entrada e 3 clusters foi treinada, porém os resultados não foram bons. Isso aconteceu devido à grande similaridade entre o ECG normal e a arritmia CPA. Após os testes iniciais, variou-se o número de clusters



de saída, especificamente com 5, 10, 15, 20, 30 e 40 clusters. Após vários testes, a rede com 15 unidades de saída obteve os melhores resultados.

## 5 Conclusões e Trabalhos Futuros

A principal contribuição deste trabalho é mostrar que redes neurais artificiais auto-organizáveis do tipo ART2 em conjunto com a transformada Wavelet podem ser aplicadas nas tarefas de detecção automática e agrupamento de arritmias.

Os resultados obtidos são similares aos do estado da arte, o que indica que melhores resultados podem ser encontrados em estudos futuros envolvendo RNA e Wavelets no agrupamento de arritmias. Outras configurações da rede ART2 podem ser criadas e testadas, para obter melhores resultados. Além disso, existem outras famílias da transformada Wavelet que podem ser testadas além da *Coiflet*.

Por último, é relevante ressaltar que outros tipos de arritmias poderão ser adicionados, além das contrações prematuras atriais e ventriculares. Uma das próximas etapas deste trabalho é selecionar e testar outras arritmias.

## Agradecimentos

Sérgio Rogal gostaria de agradecer o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – Brasil, que apoiou o desenvolvimento deste projeto através de bolsa de estudos.

## Referências

1. Jornal da Unicamp - Edição 348 - dezembro de 2006. Disponível em: [http://www.unicamp.br/unicamp/unicamp\\_hoje/ju/dezembro2006/ju348pag9a.html](http://www.unicamp.br/unicamp/unicamp_hoje/ju/dezembro2006/ju348pag9a.html) Acessado em 2006.
2. Guyton, A.C., Hall, J.E. Tratado de Fisiologia Médica. Guanabara & Koogan, 1996.
3. Frownfelter, D., Dean, E. Fisioterapia Cardiopulmonar – Princípios e Prática. Terceira Edição, 2004. Editora Revinter.
4. Osowski, S., Hoai, L.T. Analysis of Features for Efficient ECG Signal Classification Using Neuro-fuzzy Network. Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on Volume 3, 25-29 July 2004 Page(s):2443 - 2448 vol.3.
5. Wang, F., Carrault, G., Quiniou, R., Cordier, M., Luo, L. Temporal reasoning based automatic arrhythmias recognition. Robotics, Intelligent Systems and Signal Processing, 2003. Proceedings. 2003 IEEE International Conference on Volume 2, 8-13 Oct. 2003 Page(s):1114 - 1119 vol.2.
6. Zhou, H., Hou, K.M., PONSONNAILLE, J., GINESTE, L., VALUX, C. De. A Real-Time Continuous Cardiac Arrhythmias Detection System RECAD. Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the 2005 Page(s):875 – 881.

10 Sérgio Renato Rogal Jr. <sup>1</sup> Emerson Cabrera Paraiso <sup>1</sup> Celso Antônio Alves Kaestner <sup>2</sup>,  
Marcus Vinícius Mazega Figueredo <sup>1</sup> e Alfredo Beckert Neto <sup>1</sup>

7. Zhang, Z.G., Jiang, H.Z., Ge, D.F., Xiang, X.J. Pattern Recognition of Cardiac Arrhythmias Using Scalar Autoregressive Modeling. Intelligent Control and Automation, 2004. WCICA 2004. Fifth World Congress on Volume 6, 15-19 June 2004 Page(s):5545 - 5548 Vol.6.
8. Lettnin, D.V., Vargas, F., Macarthy, M. Estudo de um Sistema para Classificação de Batimentos Cardíacos Utilizando Redes Neurais. Universidade Federal de Pelotas (UFPel), Pontifca Universidade Católica do Rio Grande do Sul (PUCRS). 2002.
9. Ham, F.M, Han, S. Classification of Cardiac Arrhythmias Using Fuzzy ARTMAP. Biomedical Engineering, IEEE Transactions on Volume 43, Issue 4, April 1996 Page(s):425 – 429.
10. Lee, J., Park, K.L., Song, M.H., Lee, K.J. Arrhythmia Classification with Reduced Features by Linear Discriminant Analysis. Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the , vol., no.pp. 1142- 1144, 01-04 Sept. 2005.
11. Srinivasan, N., Wong, M.T., Krishnan, S.M. A new phase space analysis algorithm for cardiac arrhythmia detection. Engineering in Medicine and Biology Society, 2003. Proceedings of the 25th Annual International Conference of the IEEE , vol.1, no.pp. 82- 85 Vol.1, 17-21 Sept. 2003.
12. Capua, C.D., Falco, S.D., Morello, R. A Soft Computing-Based Measurement System for Medical Applications in Diagnosis of Cardiac Arrhythmias by ECG Signals Analysis. Computational Intelligence for Measurement Systems and Applications, Proceedings of 2006 IEEE International Conference on July 2006 Page(s):2 – 7.
13. Vidakovic, B., Mueller, P. Wavelets for Kids. A Tutorial Introduction. Duke University.
14. Physionet. PhysioBank. MIT-BIH Arrhythmia Database. Disponível em: <http://www.physionet.org/physiobank/database/mitdb>. Acesso em: 15 de dezembro de 2006.
15. Polikar, R. The Wavelet Tutorial. Rowan University, College of Engineering Web Servers, 1996. Disponível em: <http://users.rowan.edu/~polikar/WAVELETS/WTpart1.html>. Acesso em: 20 de junho de 2007.
16. Krose, B., Smagt, P. An Introduction Neural Networks. November 1996. 8ª ed.
17. Ozbay, Y, Karlik, B. A RECOGNITION OF ECG ARRHYTHMIAS USING ARTIFICIAL NEURAL NETWORKS. Engineering in Medicine and Biology Society, 2001. Proceedings of the 23rd Annual International Conference of the IEEE. Volume 2, 25-28 Oct. 2001 Page(s):1680 - 1683 vol.2.
18. Prasad, G.K., Sahambi, J.S.. Classification of ECG arrhythmias using multi-resolution analysis and neural networks. TENCON 2003. Conference on Convergent Technologies for Asia-Pacific Region , vol.1, no.pp. 227- 231 Vol.1, 15-17 Oct. 2003.
19. Jung, Y.K., Tompkins, W.J.. Detecting and classifying life-threatening ECG ventricular arrhythmias using wavelet decomposition. Engineering in Medicine and Biology Society, 2003. Proceedings of the 25th Annual International Conference of the IEEE , vol.3, no.pp. 2390- 2393 Vol.3, 17-21 Sept. 2003.
20. BIH. Beth Israel Hospital Inc. Disponível em: <http://www.bih.harvard.edu>. Acesso em: 15 de dezembro de 2006.
21. MIT. Massachusetts Institute of Technology. Disponível em <http://www.mit.edu>. Acesso em: 15 de dezembro de 2006.
22. Carpenter, G.A., Grossberg, S. Adaptive Resonance Theory. Department of Cognitive and Neural Systems. September 1998.
23. Lin, Z., Ge, Y., Tao, G. Algorithm for Clustering Analysis of ECG Data. Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the 01-04 Sept. 2005 Page(s):3857 – 3860.