

Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Biológicas
Programa de Pós-Graduação em Ciência da Computação

PCC146
RECONHECIMENTO DE PADRÕES
Estado da Arte

Eduardo Luz
Rensso Mora Colque
Professor - David Menotti

Ouro Preto
27 de setembro de 2010

Sumário

1	Introdução	1
1.1	O Eletrocardiograma	1
1.2	Derivações	1
1.3	Aplicações	2
1.3.1	Monitores de sinais vitais	2
1.3.2	Desfibriladores	2
1.3.3	Holter	3
2	Aquisição do sinal	3
3	Pré-processamento	5
4	Extração de características	6
5	Segmentação	6
6	Classificação de arritmias	7
7	Performance	8
8	Conclusão	10

Lista de Figuras

1	Complexo QRS	2
2	Posicionamento dos eletrodos	3
3	Derivações	4
4	Morfologia de cada derivação	4
5	Aquisição de um sinal de ECG	5

1 Introdução

O presente trabalho visa levantar o estado-da-arte relativo à detecção automática de arritmias no sinal de eletrocardiograma (ECG). Ele apresenta a metodologia utilizada por alguns trabalhos publicados até o presente momento e seus resultados.

As informações aqui apresentadas foram extraídas de fontes consolidadas e de uma coleção de artigos na área do problema em questão. Este trabalho tem o propósito de ser um ponto de partida para todos aqueles interessados em iniciar pesquisa na área. Entretanto, não temos o intuito de contribuir diretamente com novos resultados ou novas metodologias.

Visando facilitar a compreensão do trabalho, o organizamos em seções. A seção 1 introduz o problema e as motivações para se desenvolver novos métodos ou aprimorar os já existentes assim como algumas aplicações reais. Alguns aspectos sobre a aquisição do sinal são vistos na seção 2. A seção 3 trata de técnicas para o pré-processamento e a seção 4 de extração de características. As áreas de maior interesse, que são a segmentação e classificação, serão discutidas nas seções 4 e 5, respectivamente. Finalmente, o trabalho é concluído com uma análise das performances de alguns trabalhos apresentados e algumas considerações para futuros trabalhos na área.

1.1 O Eletrocardiograma

O ECG é a técnica não-invasiva mais utilizada no diagnóstico de doenças do coração. Ele pode ser descrito como um registro dos fenômenos elétricos que se originam devido à atividade cardíaca. O ECG foi um dos primeiros sinais estudados pelas técnicas de processamento de sinais biomédicos[9] e é muito utilizado clinicamente para detectar arritmias assintomáticas e pouco frequentes ou para monitorar o estado do paciente submetido à procedimentos cirúrgicos e drogas que afetam o funcionamento do coração.

Temos três ondas importantes no sinal de ECG, a onda P, QRS e T (Figura 1).

Estas ondas correspondem ao campo induzido pelos fenômenos elétricos na superfície cardíaca, denominados despolarização atrial (onda P), despolarização ventricular (complexo QRS) e repolarização ventricular (onda T). O campo alcança os eletrodos posicionados na pele do paciente e então o sinal de ECG é construído.

1.2 Derivações

Podemos ter visões diferentes do sinal de ECG dependendo dos pares de eletrodos escolhidos para a construção do sinal. Normalmente três ou mais eletrodos são utilizados para obtenção do sinal. Uma configuração muito utilizada é a com cinco eletrodos, em que temos um eletrodo posicionado no braço esquerdo (LA - Do inglês *left arm*), braço direito (RA - *right arm*), perna esquerda (LL - *left leg*), perna direita (RL - *right Leg*) e um no peito, à direita do externo (V ou V1). Podemos encontrar também uma configuração com doze eletrodos, como visto na Figura 2.

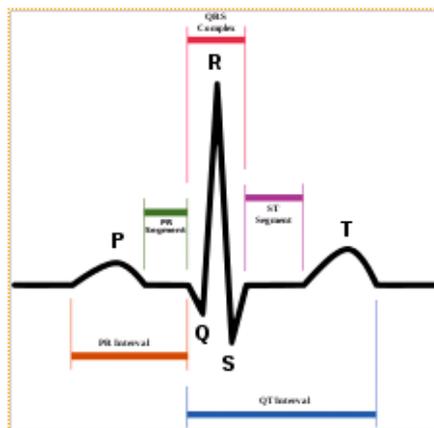


Figura 1: Complexo QRS

Chamamos de derivação as diversas combinações de pares de eletrodos, sendo que as mais usuais foram rotuladas. Assim, a derivação chamada de "derivação 1" ou "DI" é formada pela diferença de potencial entre os eletrodos LA e RA, a "derivação 2" ou "DII" é formada pela diferença de potencial entre os eletrodos LL e RA. Convencionou-se um eletrodo como referência (RL), sendo que o potencial de todos os demais seria relativo a ele. Podemos ver de forma sintética na Figura 3 alguns pares formando as derivações e na Figura 4 a morfologia característica de cada derivação.

1.3 Aplicações

1.3.1 Monitores de sinais vitais

A monitorização de sinais vitais é um dos recursos mais importantes durante o atendimento a pacientes críticos na Unidade de terapia intensiva (UTI). Monitores mais modernos são capazes de monitorar uma grande variedade de sinais fisiológicos invasivos e não-invasivos mas o sinal de ECG ocupa uma posição de destaque. A frequência cardíaca é o parâmetro acompanhado mais de perto em situações críticas e para que o seu valor seja confiável é desejável uma boa detecção dos eventos de arritmia.

1.3.2 Desfibriladores

O desfibrilador é um equipamento cuja função é reverter um quadro de parada cardiorespiratória. A reversão é feita aplicando-se uma descarga elétrica na parede torácica do paciente. Desfibriladores mais modernos capturam o sinal de ECG e automaticamente aplicam a descarga e para tal o equipamento precisa detectar as arritmias, que são a principal causa de paradas cardiorespiratórias.

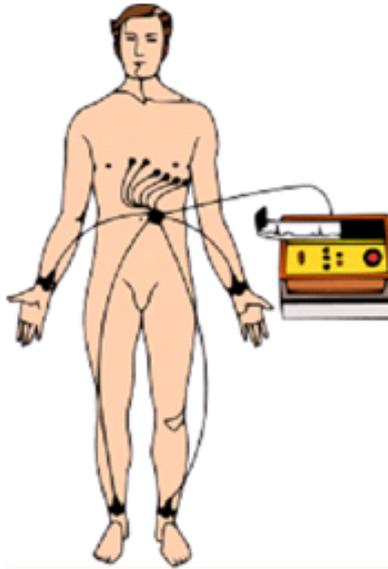


Figura 2: Posicionamento dos eletrodos

1.3.3 Holter

O holter de ECG é um equipamento portátil capaz de capturar e armazenar durante dias o sinal de ECG de uma pessoa. A finalidade do holter é permitir a detecção de arritmias ocasionais difíceis de serem detectadas durante a monitoração de um paciente por um curto período de tempo.

2 Aquisição do sinal

O sinal elétrico capturado pelos eletrodos em um ser humano é da ordem de aproximadamente 1mV pico-a-pico. Este sinal deve ser amplificado algumas centenas de vezes antes para podermos, por exemplo, injetá-lo a um conversor analógico/digital (ADC). Como o corpo humano age como uma antena, ele pode capturar vários ruídos, inclusive sofrer interferência da frequência da rede elétrica (50Hz ou 60Hz). Ruídos musculares também podem interferir significativamente no sinal. Alguns ruídos podem ser facilmente da mesma magnitude do sinal de ECG e tornar a tarefa de detecção do QRS muito complicada. Geralmente, o único filtro aplicado nesta etapa é o filtro de anti-aliasing, devido ao processo de amostragem. Nessa etapa, os filtros devem ser aplicados com muito cuidado, sob pena de inutilizar o sinal amostrado. Assim, uma filtragem mais controlada é feita na etapa de pré-processamento.

Uma vez filtrado o sinal já poderá ser amplificado. Para amplificação do sinal, utiliza-se normalmente de amplificadores diferenciais, também chamados amplifi-

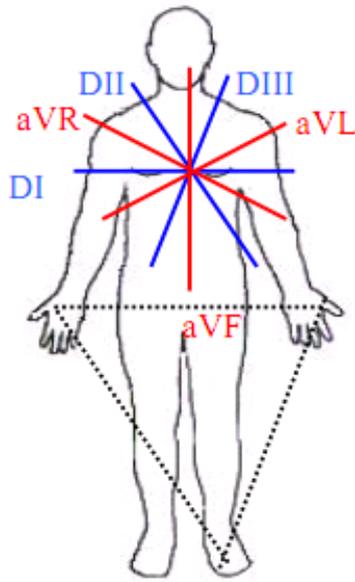


Figura 3: Derivações

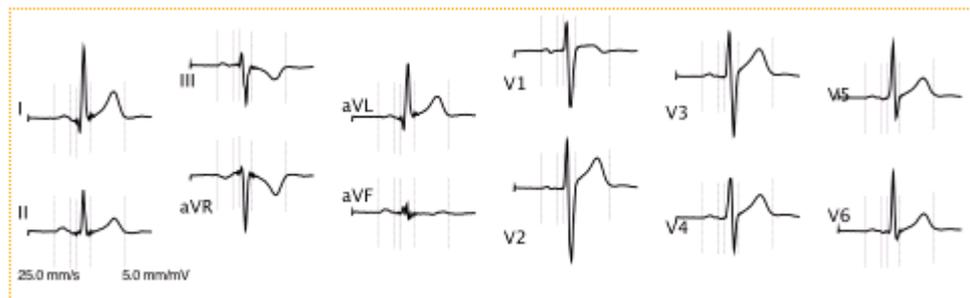


Figura 4: Morfologia de cada derivação

cadores de instrumentação para rejeição de ruído de modo comum. Um microcontrolador pode ser utilizado para efetuar a leitura do ADC a uma dada frequência e enviar as amostras para um computador ou algum equipamento capaz de fazer o processamento do sinal. A Figura 5 ilustra de forma simplificada uma aquisição de sinal de ECG utilizando-se apenas 3 eletrodos.

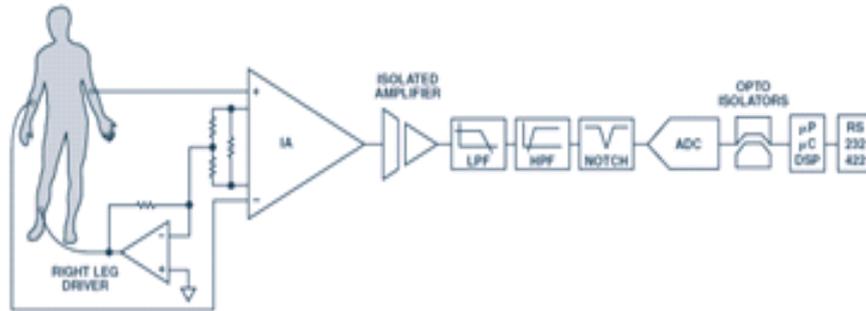


Figura 5: Aquisição de um sinal de ECG

3 Pré-processamento

Muitas técnicas já foram propostas para a redução de ruídos no sinal de ECG. A mais simples e amplamente utilizada é a implementação de filtros digitais recursivos de resposta ao impulso finita (FIR) [27], que foi viabilizada computacionalmente com o avanço dos microcontroladores e microprocessadores. Este método funciona bem para atenuação de faixas de frequências conhecidas, como o ruído proveniente da rede (50Hz ou 60Hz), pois ele permite uma rápida e fácil implementação de um filtro rejeita-banda. O problema com esta abordagem é que nem sempre a frequência do ruído é conhecida. O uso indiscriminado de filtros, como por exemplo, filtros passa-altas e passa-baixas, acabam distorcendo a morfologia do sinal e muitas vezes deixando ele inutilizado para o uso em diagnóstico de doenças cardíacas. Arquiteturas com filtros adaptativos [10] [29] também foram empregadas para remoção de ruídos no sinal de ECG mas de acordo com Thakor e Zhu [46] essa técnica possui limitações e não oferece grandes vantagens sobre os filtros digitais FIR. Xue et al[38] conseguiram contornar parte do problema utilizando filtros adaptativos baseados em redes neurais e aprimoraram significativamente a detecção do QRS comparado ao mesmo método utilizando-se filtros adaptativos lineares.

Técnicas estatísticas como *principal component analysis* [13] e *independent component analysis*[1][45] são poderosas ferramentas para atenuação do ruído no sinal de ECG pois permitem extração de ruídos de frequências próximas ao do sinal. Um estudo comparativo[6] entre o uso de *principal component analysis* e *independent component analysis* para redução de ruído e artefatos em sinais de ECG mostrou que *principal component analysis* é uma técnica melhor para redução de ruídos e *independent component analysis* é melhor para seleção de características. O uso das duas técnicas combinadas pode oferecer grandes vantagens se comparado à resultados obtidos com abordagens clássicas.

Atualmente tem-se utilizado muitos métodos baseados em transformadas wavelet, que além de mais precisos, preservam o sinal evitando perda de detalhes fisiológicos importantes[3].

Sayadi e Shamsollahi[35] apresentaram uma modificação da transformada wavelet, chamada *multiadaptive bionic wavelet transform* (MABWT), aplicada à redução de ruído e variação de linha base no sinal de ECG. O método apresentou uma performance alta comparado aos métodos que utilizaram transformada wavelet tradicional.

Outros métodos também apresentaram resultados interessantes, como Sameni e Jutten[41] que propuseram o uso de filtros Bayesian não-lineares para redução de ruídos no sinal de ECG. Sayadi apresentou e validou um novo algoritmo baseado na estrutura *extended kalman filter* (EKF) que incorpora os parâmetros do *ECG dynamical model* (EDM) para redução de ruído e compressão do sinal de ECG e trouxe uma contribuição significativa, visto que o método se mostrou melhor que os métodos mais eficientes até então, como MABWT ou EKF2 [36].

4 Extração de características

A escolha correta das características é de fundamental importância para a performance do algoritmo de classificação.

As características do sinal de ECG mais comuns são extraídas da morfologia e do intervalo RR. Métodos mais sofisticados vem sendo utilizados com o intuito de encontrar características mais imunes às variações da morfologia e ruídos como *autoregressive model coefficients, higher-order cumulant (higher order statistics)*[11] e variações da transformada wavelet. Estudos da literatura afirmam que transformada wavelet é o método mais promissor de se extrair características [11][21][7]. Minhas e Arif [12] utilizaram wavelet para extração de características e obtiveram um impressionante resultado(***** Descrever mais os métodos???). Contudo, Ozbay[54] salienta que métodos baseados em transformada wavelet podem ter limitações de modo a inviabilizar o seu uso para algumas aplicações.

5 Segmentação

A segmentação do ECG consiste em delimitar a parte de maior interesse, o complexo QRS, visto que ele reflete a atividade elétrica do coração. Uma vez feita a segmentação dos complexos QRS podemos obter diversas informações fisiológicas, como por exemplo, a frequência cardíaca.

Uma abordagem de detecção do QRS bastante utilizada é baseada em filtros digitais para atenuação de ruídos e remoção de flutuação de linha base, transformações não-lineares para realce da onda R e limiares de detecção adaptativos, como proposto por Pan e Tompkins[23].

Algoritmos para detecção de QRS são motivos de estudos a mais de três décadas e a evolução dos algoritmos e métodos refletem a evolução do poder de processamento dos computadores. Cada vez mais métodos estão sendo utilizados e os métodos mais

populares são baseados em redes neurais[53][22], algoritmos genéticos[39], transformada wavelet[42][50], banco de filtros[48] e SVM[32].

6 Classificação de arritmias

Para se detectar a frequência cardíaca com precisão é necessário levar em conta possíveis arritmias que possam ocorrer eventualmente. Uma classificação precisa do tipo de arritmia também é desejável para o correto diagnóstico de problemas cardíacos e em certos casos a detecção em tempo hábil pode até mesmo salvar vidas. Com esta motivação, pesquisadores continuam os esforços em obter algoritmos cada vez mais precisos e computacionalmente eficientes.

Artificial Neural Networks (ANNs) são amplamente utilizadas para classificação em sistemas de diagnóstico médico [51]. Sendo o *MultilayerPerceptron*(MLP) a rede mais popular para este tipo de diagnósticos automáticos [31].

O MLP convencional demonstrou precisão impressionante na classificação do batimento de ECG para as categorias (Normal e anormal). Embora as MLP tenham alta precisão na classificação de ECG, os algoritmos herdados de *back-propagation* tem alto custo computacional. A estrutura multi-ANN dos sistemas hierárquicos tornam a situação ainda pior [51]. MLP convencional sofre de convergência lenta local, mínimos globais e de valores iniciais aleatórias dos pesos. Isto pode torná-las impróprias para o uso clínico [5]. (**** rever essas frases!!!)Para contornar estas deficiências, sistemas hierárquicos que combinam e MLP com outro ANN são geralmente indispensáveis [51] [33]. Nestes tipos de sistemas o primeiro nível das redes neurais são responsáveis pela pre-classificação dos batimentos e também constroem modelos para as características de entrada. A MLP completa a segunda tarefa de multiclassificação[37][11]. Desta forma muitas fragilidades das MLP convencionais foram contornadas.

Oowski[44] e Engin [11] conseguiram uma boa precisão e suas metodologias se mostraram menos sensíveis à variações na morfologia pelo fato de basearem a extração de características em *higher order statistics*. Ceylan et al[40] também utilizaram um método combinando fuzzy e redes neurais sendo que uma rede *type-2 fuzzy c-means clustering* foi utilizada para aprimorar a performance da rede neuronal.

Segundo Kim et al[25] algoritmos baseados em redes neurais tem problemas em aplicações práticas, como taxas de aprendizado lentas e performance instável causada pelo mínimo local. O trabalho propõe um novo método para detecção de arritmia com taxa de aprendizado mais rápida e alta precisão, utilizando *Morphology Filtering*, *Principal Component Analysis* e *Extreme Learning Machine (ELM)*. O algoritmo é proposto para classificação de seis tipos de batimentos e os resultados demonstraram que o algoritmo baseado em ELM é significativamente mais rápido que métodos como *back propagation neural network*, *radial basis function network* e *support vector machine*.

Sung et al [52] propuseram uma rede probabilística utilizando componentes independentes. Redes como *Adaptive Resonance Theory Mapping*(ARTMAP) são utilizadas também para reconhecimento de arritmias cardíacas, Han et all [14] apresentaram um modelo difuso de ARTMAP(**** está muito vago ???).

support vector machine (SVM) também é bastante empregado para classificação de arritmias. Moavenian e Khorrami[28] fizeram uma comparação entre diversos métodos utilizando ANN e SVM e chegaram a conclusão que algoritmos baseados em SVM devem ser escolhidos quando o tempo de treinamento for levado em consideração. Son et al[32] utilizaram *linear discriminant analysis* (LDA) para a redução de características e obtiveram performance superior se comparado à classificação por MLP convencional ou *fuzzy inference system* (FIS).

Um método recentemente utilizado para compressão e classificação do sinal de ECG é o *quad level vector* (QLV)[19]. A performance foi levantada utilizando-se a base de dados de arritmia do MIT-BIH e a precisão foi de 100% de acerto para sinais sem ruídos e 97.5% no pior caso - ruído de 10dB *signal-to-noise ratio* (SNR). O método foi proposto para uso em holter por que possui baixo custo computacional.

7 Performance

Normalmente os métodos e algoritmos são testados e validados com uma base de dados de referência, em que os eventos de arritmias já foram previamente classificados por seres humanos, como o banco de dados de arritmia do MIT-BIH[34], do *Common Standards for Electrocardiography*(CSE)[49] , da *American Heart Association* (AHA)[2] e o da sociedade européia de cardiologia (ESC)ST-T[8].

A base do MIT-BIH é formada por dez bancos de dados de propósitos variados, sendo que grande parte dos trabalhos analisados nesta pesquisa utilizaram o banco de dados específico para análises de arritmia, que contém 48 registros de ECG de 30 minutos no qual todos os complexos QRS e eventos de arritmias foram previamente classificados. Os sinais foram amostrados a uma frequência de 360Hz e com uma resolução de 11 bits para uma faixa de 10mV. Ao todo, o banco tem 116137 complexos QRS.

A tabela 1 mostra os resultados obtidos por alguns métodos e os parâmetros de interesse são a precisão (percentual do número de batimentos corretamente classificados para o total de batimentos considerados), especificidade (percentual de batimentos normais classificados corretamente) e sensibilidade (percentual de batimentos anormais classificados corretamente).

Referência	Pré-processamento	Extração de características	Classificação	Precisão
Pan and Tompkins[23]	Filtros digitais lineares	Transformações não-lineares	Adaptive threshold method	99.3%
Moody e Mark[16]	Filtros digitais	Transformada discreta KLT	Clusterização (<i>Mahalanobis dist. metric</i>)	94.76%
Hu et Al[53]	-	-	ANN (MLP)	84.5%
Xue et all[38]	ANN matched filtering	-	<i>Simple threshold method</i>	99.5%
Li, Zheng e Tai[4]	-	Transformada Wavelet	Alg. baseado conjunto de regras	99.8%
Ham e Han[15]	Filtros digitais	Coefficientes LPC e <i>Mean-Square Value</i>	Fuzzy ARTMAP	
Valtino et al[48]	<i>Filter banks</i>	-	<i>Threshold method</i>	99.56%
Osowski e Linh[44]	-	Higher order statistics	Fuzzy hybrid NN	96.06%
Prasad e Sahambi[17]	-	WT	ANN	96.77%
Jung e Tompkins[50]	-	DWT(Daubechies)	Alg. baseado conjunto de regras	91.1%
Zhou e Li [24]	-	PCA	B-spline NN	98.43%
Osowski e LT Hoai[43]	-	PCA	Takagi-Sugeno-Kang neuro-fuzzy	96.21%
Engin[11]	-	<i>Autoregressive model coefficients, higher-order cumulant e WT</i>	Fuzzy-Hybrid NN	93.5%
Christov e Bortolan[20]	Filtros digitais recursivos	Conjunto de 26 parâm.	Redes Neurais	-
Zhang et al[55]	-	<i>AR modeling</i>	<i>Quadratic discriminant function</i>	98.3%
Güler e Übeyli[22]	-	WT(db2)	<i>Combined NN models</i>	96.94%
Song et al[32]	WT	<i>Linear discriminant analysis</i>	SVM	99.350%
Exarchos et al[47]	Filtros digitais	<i>Decision Trees</i>	<i>Fuzzy Expert System</i>	96%
Ceylan e Özbay[5]	-	FCM e PCA	Redes neuronais supervisionadas	99.09%
Sung-Nien e Ying-Hsiang[51]	-	DWT(Haar)	<i>Probabilistic neural net-</i>	99.65%

8 Conclusão

Os desafios para a detecção de arritmias no sinal de ECG são muitos e os resultados das pesquisas recentes mostram que ainda há muito o que se fazer, especialmente com relação ao desempenho computacional dos algoritmos, visto que grande parte das aplicações demandam respostas em tempo real. Entretanto, percebemos que a maioria dos trabalhos mantém o foco no aprimoramento da precisão e poucos testes criteriosos tem sido feitos com intuito de analisar o custo computacional dos métodos.

Pudemos notar que técnicas baseadas em transformada wavelet estão sendo muito utilizadas tanto no pré-processamento quanto para extração de características devido à suas vantagens previamente citadas. Observamos vários métodos para segmentação e classificação de arritmias, com destaque para métodos combinando lógica fuzzy e redes neurais.

Detectamos a falta de um padrão para testes e validação dos algoritmos na literatura.

Referências

- [1] Noboru Ohnishi Allan Kardec Barros*, Ali Mansour. Removing artifacts from electrocardiographic signals using independent components analysis. *Neurocomputing*, 22:173 – 186, 1998.
- [2] American Heart Association. Aha database.
- [3] Arvind K. Tiwari Brij N. Singh. Optimal selection of wavelet basis function applied to ecg signal denoising. *Digital Signal Processing*, 2006.
- [4] C Tai C Li, C Zheng. Detection of ecg characteristic points using wavelet transforms. *Biomedical Engineering, IEEE Transactions on*, 1995.
- [5] Rahime Ceylan and Yüksel Özbay. Comparison of fcm, pca and wt techniques for classification ecg arrhythmias using artificial neural network. *Expert Syst. Appl.*, 33(2):286–295, 2007.
- [6] M. P. S. Chawla. A comparative analysis of principal component and independent component techniques for electrocardiograms. *Neural Comput e Applic*, 18:539 – 556, 2008.
- [7] Tainsong Chen Chia-Hung Lin, Yi-Chun Du. Adaptive wavelet network for multiple cardiac arrhythmias recognition. *Expert Systems With Applications*, 2008.
- [8] National Research Council (CNR). European st-t database. institute of clinical physiology,dept. of bioengineering and medical informatics. *Methods Inform. Med.* Available: <http://www.ifc.pi.cnr.it/>.
- [9] A. Cohen. *Biomedical Signal Processing*. CRC Press., Boca raton,FL, 1988.

- [10] Inc. ESL Earl R. Ferrara, Bernard Widrow. Fetal electrocardiogram enhancement by time-sequenced adaptive filtering. *Biomedical Engineering, IEEE Transactions on*, 29:458 – 460, 1982.
- [11] Mehmet Engin. Ecg beat classification using neuro-fuzzy network. *Pattern Recognition Letters*, 2004.
- [12] Muhammad Arif Fayyaz-ul Amir Afsar Minhas. Robust electrocardiogram (ecg) beat classification using discrete wavelet transform. *PHYSIOLOGICAL MEASUREMENT*, 2008.
- [13] Leif Sornmo Andreas Bollmann and José Millet Roig Francisco Castells, Pablo Laguna. Principal component analysis in ecg signal processing. *EURASIP Journal on Advances in Signal Processing*, 2006.
- [14] M. Ham Fredric and Han Soowhan. Classification of cardiac arrhythmias using fuzzy artmap. *Biomedical Engineering, IEEE Transactions on*, 43(4):425 – 429, 2002.
- [15] Soowhan Han Fredric M. Ham. Classification of cardiac arrhythmias using fuzzy artmap. *Biomedical Engineering, IEEE Transactions on*, 1996.
- [16] RG Mark GB Moody. Qrs morphology representation and noise estimation using the karhunen-loeve transform. *Computers in Cardiology*, 1989.
- [17] J. S. Sahambi G.Krishna Prasad. Classification of ecg arrhythmias using multi-resolution analysis and neural networks. *Conference on Convergent Technologies for Asia-Pacific Region*, 2003.
- [18] Joseph K. Paul Hassan Hamsa Haseena, Abraham T. Mathew. Fuzzy clustered probabilistic and multi layered feed forward neural networks for electrocardiogram arrhythmia classification. *Journal of Medical Systems*, 2009.
- [19] Patrick Merken Chris Van Hoof Hoi-Jun Yoo Hyejung Kim, Refet Firat Yazicioglu. Ecg signal compression and classification algorithm with quad level vector for ecg holter system. *Biomedical Engineering, IEEE Transactions on*, 2010.
- [20] G Bortolan I Christov. Ranking of pattern recognition parameters for premature ventricular contractions classification by neural networks. *Physiological Measurement*, 2004.
- [21] Elif Derya Übeyli Inan Güler. Ecgbeat classifier designed by combined neural network model. *Pattern Recognition Letters*, 2005.
- [22] Elif Derya Übeyli Inan Güler. Ecgbeat classifier designed by combined neural network model. *Pattern Recognition*, 2005.
- [23] WILLIS J. TOMPKINS JIAPU PAN. A real-time qrs detection algorithm. *Biomedical Engineering, IEEE Transactions on*, 1985.
- [24] Liqun Li Jie Zhou. Regularized b-spline network and its application to heart arrhythmia classification. *Symposium on Applied Computing*, 2004.

- [25] Kwangsoo Shin Myoungho Lee Jinkwon Kim, Hang Sik Shin. Robust algorithm for arrhythmia classification in ecg using extreme learning machine. *BioMedical Engineering OnLine*, 2009.
- [26] Joon S. Lim. Finding features for real-time premature ventricular contraction detection using a fuzzy neural network system. *IEEE TRANSACTIONS ON NEURAL NETWORKS*, 2009.
- [27] P. A. Lynn. Recursive digital filters for biological signals. *Med. Biol. Eng.*, 9:37 – 43, 1979.
- [28] Hamid Khorrami Majid Moavenian. A qualitative comparison of artificial neural networks and support vector machines in ecg arrhythmias classification. *Expert Systems with Applications*, 2009.
- [29] John M. Cioffi Edward Hesler Jeffrey A. Leddy Inc. Nellcor Mark Yelderman, Bernard Widrow. Ecg enhancement by adaptive cancellation of electrosurgical interference. *Biomedical Engineering, IEEE Transactions on*, 30:392 – 398, 1983.
- [30] Dimitrios I. Fotiadis Markos G. Tsipouras, Costas Voglis. A framework for fuzzy expert system creation application to cardiovascular diseases. *Biomedical Engineering, IEEE Transactions on*, 2007.
- [31] Engin Mehmet. Ecg beat classification using neuro-fuzzy network. *Pattern Recogn. Lett.*, 25(15):1715–1722, 2004.
- [32] Sung Pil Cho Kyoung Joung Lee Sun Kook Yoo Mi Hye Song, Jeon Lee. Support vector machine based arrhythmia classification using reduced features. *International Journal of Control, Automation, and Systems*, 2005.
- [33] K. Minami, H. Nakajima, and T. Toyoshima. Real-time discrimination of ventricular tachyarrhythmia with fourier-transform neural network. *Biomedical Engineering, IEEE Transactions on*, 46(2):179 – 185, 1999.
- [34] Massachusetts Institute of Technology. Mit-bih ecg database. Available: <http://ecg.mit.edu/>.
- [35] Mohammad B. Shamsollahi Omid Sayadi. Multiadaptive bionicwavelet transform: Application to ecg denoising and baselinewandering reduction. *Journal on Advances in Signal Processing*, 2007.
- [36] Mohammad B. Shamsollahi Omid Sayadi. Ecg denoising and compression using a modified extended kalman filter structure. *Biomedical Engineering, IEEE Transactions on*, 2008.
- [37] S. Osowski and T.H. Linh. Ecg beat recognition using fuzzy hybrid neural network. *IEEE Trans. Biomed. Eng.*, 48(11):1265 – 1271, 2001.
- [38] Willis J. Tompkins Qiuzhen Xue, Yu Hen Hu. Neural-network-based adaptive matched filtering for qrs detection. *Biomedical Engineering, IEEE Transactions on*, 39(4):317 – 329, 1992.

- [39] G Valli R Poli, S Cagnoni. Genetic design of optimum linear and nonlinear qrs detectors. *IEEE Transactions on Biomedical Engineering*, 1995.
- [40] Bekir Karlik Rahime Ceylan, Yüksel Özbay. A novel approach for classification of ecg arrhythmias: Type-2 fuzzy clustering neural network. *Expert Systems with Applications*, 2009.
- [41] Christian Jutten Reza Sameni. A nonlinear bayesian filtering framework for ecg denoising. *Biomedical Engineering, IEEE Transactions on*, 2007.
- [42] GF Boudreaux-Bartels S Kadambe, R Murray. Wavelet transform-based qrs complex detector. *Biomedical Engineering, IEEE Transactions on*, 1999.
- [43] LT Hoai S Osowski. Analysis of features for efficient ecg signal classification using neuro-fuzzy network. *Neural Networks*, 2004.
- [44] Tran Hoai Linh Stanislaw Osowski. Ecg beat recognition using fuzzy hybrid neural network. *Biomedical Engineering, IEEE Transactions on*, 2001.
- [45] Lionel Tarassenko Taigang He, Gari Clifford. Application of independent component analysis in removing artefacts from the electrocardiogram. *Neural Comput e Applic*, 15:105 – 116, 2006.
- [46] N. V. Thakor and Yi-S. Zhu. Applications of adaptive filtering to ecg analysis: Noise cancellation and arrhythmia detection. *IEEE Transaction on Biomedical Engineering*, 1991.
- [47] Costas P. Exarchos Costas Papaloukas Dimitrios I. Fotiadis Lampros K. Michalise Themis P. Exarchos, Markos G. Tsipouras. A methodology for the automated creation of fuzzy expert systems for ischaemic and arrhythmic beat classification based on a set of rules obtained by a decision tree. *Artificial Intelligence in Medicine*, 2007.
- [48] TQ Nguyen S Luo Valtino X. Afonso, WJ Tompkins. Ecg beat detection using filter banks. *Biomedical Engineering, IEEE Transactions on*, 1999.
- [49] J.H. van Bommel and J.L. Williams. Standardisation and validation of medical decision support systems: The cse project. *Methods Inform. Med*, 1990.
- [50] Willis J. Tompkins WJ Youngkyoo Jung. Detecting and classifying life-threatening ecg ventricular arrhythmias using wavelet decomposition. *Engineering in Medicine and Biology Society*, 2003.
- [51] Sung-Nien Yu and Ying-Hsiang Chen. Electrocardiogram beat classification based on wavelet transformation and probabilistic neural network. *Pattern Recogn. Lett.*, 28(10):1142–1150, 2007.
- [52] Sung-Nien Yu and Kuan-To Chou. Integration of independent component analysis and neural networks for ecg beat classification. *Expert Syst. Appl.*, 34(4):2841–2846, 2008.
- [53] José L. Urrusti Valtino X. Afonso Yu Hen Hu, Willis J. Tompkins. Application of artificial neural networks for ecg signal detection and classification. *Journal of Eletrocardiology*, 1990.

- [54] Yüksel Özbay. A new approach to detection of ecg arrhythmias: Complex discrete wavelet transform based complex valued artificial neural network. *Journal of Medical Systems*, 2008.
- [55] Ding fei Ge Xin jian Xiang Zhe gen Zhang, Hui zhong Jiang. Patten recognition of cardiac arrhythmias using scalar autoregressive modeling. *Congress on Intelligent Control and Automation*, 2004.