

Análise comparativa de métodos de detecção de arritmias em Eletrocardiogramas

Guilherme de Lima¹, Fernando Varella^{1 2}, Valter Roesler¹, Cirano Iochpe¹

¹Instituto de Informática – Universidade Federal do Rio Grande do Sul (UFRGS)
Caixa Postal 15.064 – 91.501-970 – Porto Alegre – RS – Brazil

²i9Access Tecnologia Ltda

{gllima, favarella, roesler, ciochpe}@inf.ufrgs.br

Abstract. *This paper presents a comparative analysis Electrocardiogram Beat Classification Methods using pattern recognition in ECG images. This analysis aims to identify which method is the better option to be used on a mobile phone environment, considering the limitations of this environment. The three main existing methods were implemented and the results points to the better option on a mobile platform using JAVA. More than 11 thousand ECG beats records from this area reference database were used to validate this study.*

Resumo. *Este artigo apresenta uma análise comparativa de métodos de classificação de batidas de eletrocardiograma (ECG) através do reconhecimento de padrões nos seus sinais. Essa análise visa identificar qual dentre os métodos existentes é a melhor opção para a utilização no ambiente da telefonia celular, sabendo das limitações desse ambiente. Foram implementados os três principais métodos de classificação existentes, e os resultados direcionaram a melhor escolha, que foi validada em um dispositivo móvel na linguagem Java. Foram utilizadas mais de 11 mil gravações de ECG obtidas de um banco de dados de referência na área para validar o estudo.*

1. Introdução

Doenças cardíacas são as doenças que mais causam mortes no Brasil onde 30% das mortes causadas por doenças são relacionadas a cardiopatias [World Health Organization 2004]. No tratamento das cardiopatias é a necessário o constante monitoramento cardíaco do paciente. Esse monitoramento é tipicamente realizado por um eletrocardiógrafo.

A maioria dos sistemas utilizados no monitoramento destas situações depende de um sistema de comunicação para transmitir os dados adquiridos pelo eletrocardiógrafo para o servidor central. Entretanto, em países como o Brasil, onde a cobertura da rede móvel não é ideal, essa estratégia pode ser arriscada para os pacientes, dado que a comunicação pela rede não é confiável em muitas regiões. Para lidar com esse problema, sugere-se realizar a análise do ECG automaticamente através de uma aplicação executando em um telefone celular. Isso torna o sistema de monitoramento remoto como um todo à prova de falhas provenientes da falta de uma boa cobertura de rede.

Muitos métodos computacionais foram propostos para automatizar o processo de análise de ondas de ECG, ajudando médicos a diagnosticar anomalias em exames de ECG. Mesmo que tenham atingido desempenhos muito bons, vários deles dependem de

algoritmos computacionalmente pesados e podem ser muito custosos em termos de uso de CPU e memória.

O principal objetivo deste trabalho é identificar um ou mais métodos que possam classificar batidas de ECG com uma alta acurácia e que apresentem uma resposta rápida mesmo quando executando em um telefone celular, que possui recursos de CPU e memória limitados.

1.1. Trabalhos Relacionados

Dos métodos existentes na literatura [Engin 2004], [ul Amir Afsar Minhas and Arif 2008], [Yu and Chen 2007], [Yu and Chou 2007], [Chen and Yu 2007], [Osowski and Linh 2001], [Gülera and Übeyli 2005], [Khadtare and Sahambi 2004] capazes de alcançar altas taxas de acurácia na classificação de batidas de ECG. Foi realizada uma análise dos resultados de diversos desses métodos, visando à identificação de um método para ser implementado e testado em um sistema móvel. Os requisitos principais são que o método deve ser eficiente no consumo de tempo e memória, além de alcançar uma alta taxa de acurácia para garantir que o sistema seja capaz de salvar vidas humanas.

Três métodos foram escolhidos para a realização desta análise comparativa e desta implementação em dispositivos móveis: Método de Chen e Yu [Chen and Yu 2007] com 99,70% de acurácia, Método de Minhas e Arif [ul Amir Afsar Minhas and Arif 2008] com 99,49% de acurácia e Método de Yu e Chen [Yu and Chen 2007] com 99,65% de acurácia. Estes três métodos são os mais eficientes existentes que classificam os mesmos seis tipos de batidas: Batida Normal (N), Bloqueio de Ramo Esquerdo (LBBB), Bloqueio de Ramo Direito (RBBB), Extra-sístole Ventricular (PVC), Extra-sístole Atrial (APB) e Batida de Marca-passo (PB). Além disso, utilizam batidas provenientes do mesmo banco de dados para a validação de suas propostas, o banco de dados de arritmias do MIT-BIH.

2. O Método de Análise de ECG

A classificação automática de ECG utiliza técnicas de diversas áreas da computação, tais como estatísticas computacionais, reconhecimento de padrões, redes neurais, máquinas de vetor suporte, etc.

A análise de ECG inicia-se, normalmente, com a Detecção das Batidas, esse estágio deve ser feito por algum algoritmo de detecção de QRS. A Extração de Características é a fase que segue a detecção de batidas, e é responsável por transformar o sinal original do ECG para um vetor de características significativas e que auxiliem no processo da classificação. Por fim, é efetuada a Classificação das Batidas do ECG. Nessa fase diferentes tipos de classificadores e técnicas de reconhecimentos de padrões podem ser empregados, permitindo que seja identificado o tipo de cada batida recebida.

2.1. Método de Yu e Chen

2.1.1. Extração de Características

A Extração de Características é realizada primeiramente pela aplicação da Transformada Discreta de Ondaleta (Discrete Wavelet Transform - DWT). A DWT implementada utilizou o algoritmo piramidal proposto por Mallat [Mallat 1989] onde uma série de filtros passa-baixas e passa-altas, provenientes da ondaleta de Haar, são aplicados.

A partir das sub-bandas da DWT foram construídos dois conjuntos de características, nominalmente, FS1 e FS2. O FS1 inclui a variância do sinal e dos coeficientes, a variância da auto-correlação das sub-bandas e a amplitude relativa das sub-bandas. O FS2 contém as 10 características do FS1 e o intervalo RR instantâneo que informa a distância entre duas batidas consecutivas, dado que esta medida é muito importante para detecção de arritmias. Estas características foram normalizadas usando a função sigmóide tangente hiperbólica.

2.1.2. Classificação

Yu e Chen utilizam uma PNN para realizar a classificação das batidas. A PNN é uma rede neural utilizada basicamente como um classificador, sendo uma forma de implementação de um algoritmo de estatística chamado análise discriminante usando kernel. A rede é organizada em uma topologia composta por 4 camadas: Camada de Entrada, Camada de Padrão, Camada de Somatório e Camada de Saída.

Cada amostra do conjunto de treinamento corresponde a uma unidade da camada de padrão, e cada unidade de padrão estima a função de densidade de probabilidade da entrada ser parecida com a amostra do conjunto de treinamento na unidade e consequentemente ser classificada com a mesma classe da amostra do conjunto de treinamento.

2.2. Método de Minhas e Arif

O método desenvolvido por Minhas e Arif é similar ao de Yu e Chen. Eles usaram as mesmas medidas estatísticas para construir o conjunto de características, mas existem algumas diferenças na DWT e no classificador.

2.2.1. Extração de Características

Para realizar a extração de características, foi utilizado o algoritmo DWT à trous, que realiza a transformação sem sub-amostragem. Minhas e Arif propõe o uso da ondaleta Spline Quadrática como ondaleta mãe.

As mesmas características estatísticas como o FS2 do método de Yu e Chen são calculadas. Conforme proposto pelos autores, outro conjunto de características foi implementado empregando Análise de Componentes Principais para gerar um segundo conjunto de apenas as cinco maiores componentes principais. Entretanto, esse procedimento também reduziu a acurácia do método, com isso, o foco do trabalho foi apenas sobre o conjunto de características original, contendo 11 características de cada amostra.

2.2.2. Classificação

Minhas e Arif utilizaram o algoritmo de k vizinhança mais próxima para classificar p conjuntos de testes. O algoritmo de k-vizinhança mais próxima calcula a distância euclidiana de uma amostra de teste em relação a todas as amostras de treinamento. A batida de entrada é classificada utilizando a classe moda, ou seja, a classe mais frequente dentre as amostras mais próximas de acordo com a distância euclidiana.

2.3. Método de Chen e Yu

2.3.1. Extração de Características

Os autores empregaram cumulantes aliadas à sub-bandas obtidas pela DWT. Os autores utilizaram o algoritmo de DWT à trous, com a ondaleta mãe “sym6”, para calcular cinco níveis de coeficientes.

As cumulantes são medidas de estatística de ordem superior, o emprego de cumulantes na tarefa de classificação de batidas de ECG pode ajudar a remover a variabilidade entre as batidas de mesmo tipo, e melhorar a diferenciação entre batidas de tipos diferentes.

As três maiores cumulantes da HoS foram utilizadas para ajudar a construir o conjunto de características, nominalmente: cumulante de segunda ordem, cumulante de terceira ordem e cumulante de quarta ordem. As cumulantes de segunda, terceira e quarta ordem foram extraídas dos coeficientes de detalhe de 3º (D3), 4º (D4) e 5º (D5) nível. Como resultado, nove cumulantes foram calculadas para cada batida, e então algumas características são calculadas, incluindo: Variância das cumulantes, Somatório normalizado para cada cumulante, número de Zero - cruzamentos das cumulantes de 5º nível e a simetria das cumulantes de terceira e quarta ordem.

Adicionalmente, três características relacionadas ao intervalo RR foram definidas, incluindo: intervalo RR atual, intervalo RR anterior e a razão entre o intervalo RR atual e o anterior. Resumindo, o conjunto de características final é composto por 30 características.

2.3.2. Classificação

A fase de classificação desse método é realizada por uma rede neural Feed Forward Backpropagation (FFBNN), cujo nome demonstra que a entrada é propagada à frente na rede e os erros são retro propagados para corrigir os pesos dos neurônios.

O uso de redes neurais requer duas fases complementares: a fase de treinamento e a fase de teste. Durante a fase de treinamento, cada entrada do conjunto de treinamento é propagada através da camada de entrada da rede. A diferença entre o valor de ativação e o desejado é o erro para esta amostra que posteriormente é retro propagado para efetuar a correção dos pesos dos neurônios em todas as camadas. Esse processo é realizado durante um determinado número de épocas de treinamento.

A fase de testes apenas utiliza a rede previamente treinada, propagando as amostras do conjunto de teste e verificando se elas são classificadas corretamente.

3. Implementação e Resultados

3.1. Implementação

Os métodos selecionados foram implementados na Linguagem Java pela sua facilidade no porte para telefones móveis, que se faz necessário devido a intenção de utilizar o melhor método para monitoramento cardíaco. Com isso, foi possível a realização de uma comparação entre as implementações com diferentes linguagens, além é claro da comparação entre a implementação realizada com a documentada nos artigos originais.

O aparelho utilizado foi o Motorola Milestone A853 executando a versão 2.2 do Android. Esse aparelho possui 256MB de memória RAM e um processador Arm Cortex A8 com 600 MHz.

3.2. Análise de Resultados

Para avaliar o comportamento dos métodos implementados foram utilizados 23 gravações do banco de dados de arritmias do MIT/BIH, que contém diversos eletrocardiogramas anotados com diversos tipos de arritmias. Foram utilizadas as mesmas amostras para realizar os testes de todos os métodos implementados a fim de evitar qualquer superestimativa.

Table 1. Resultados dos testes com a implementação dos métodos

Medidas	Minhas e Arif	Yu e Chen	Chen e Yu
Acurácia (%)	99.0	98.79	94.7
Especificidade (%)	99.81	99.58	95.11
Sensitividade LBBB (%)	98.29	98.33	94.33
Sensitividade RBBB (%)	99.04	98.75	94.09
Sensitividade PVC (%)	97.91	97.91	94.25
Sensitividade APB (%)	98.00	97.06	94.58
Sensitividade PB (%)	99.67	99.50	95.83
Tempo por batida (ms)	573	623	32

Os resultados apresentados na tabela 1 não condizem com os propostos pelos autores. Os experimentos com as implementações dos três métodos efetuados neste trabalho foram bem sucedidos em um computador e em um celular, atingindo uma acurácia de 99% para o método de Minhas e Arif, contra 99,49% alegado pelos autores, 98,67% para o método de Yu e Chen, contra 99,65% alegado pelos autores e apenas 94,7% para o método de Chen e Yu, contra 99,7% alegado pelos autores.

Para o método de Yu e Chen, a classificação de uma única batida teve duração média de 623 ms. Para Minhas e Arif o tempo médio para a classificação de uma batida foi de 573 ms. Em contraponto a esses métodos, o método de Chen e Yu é capaz de classificar uma batida em um tempo curto, apenas 32 ms.

4. Conclusões e Trabalhos Futuros

4.1. Conclusões

Em relação à literatura especializada existente, foram selecionados três métodos que reportaram altas acurácias juntamente com altas sensibilidades, nominalmente: Método de Chen e Yu, de Minhas e Arif e de Yu e Chen. A implementação do método de Chen e Yu não atingiu a acurácia proposta pelos autores do método (99,7%), sendo inferior inclusive à acurácia dos métodos de Minhas e Arif e de Yu e Chen. Entretanto, os métodos de Yu e Chen e Minhas e Arif obtiveram acurácias de 98,67% e 99,00%, respectivamente, mesmo assim não estão aptos para utilização em plataformas móveis devido ao grande custo de processamento, 623 ms e 573 ms, respectivamente.

Em uma implementação que visa o monitoramento de pacientes em tempo real, a CPU também ficará ocupada com a tarefa de adquirir o sinal cardíaco proveniente

do eletrocardiógrafo. O resultado de toda essa série de operações juntamente com a classificação utilizando um classificador do tipo PNN ou KNN levaria mais do que 800 ms para cada batida. Normalmente a frequência cardíaca de um paciente é de 75 batimentos por minuto, valor que corresponde a uma batida a cada 800 ms. Em outras palavras, no aparelho selecionado para testes estes dois classificadores não são capazes de monitorar pacientes com frequências cardíacas superiores a 75 BPM, tornando o uso dos métodos de Minhas e Arif e de Yu e Chen inutilizáveis em um sistema real com o aparelho utilizado.

O método de Chen e Yu seria a melhor opção para utilização em plataformas móveis, pois necessita de pouco tempo, 32 ms, para efetuar a classificação de batidas. Entretanto, a acurácia obtida pela implementação foi de 94,7%, sendo a pior entre os três métodos, e também não correspondendo aos resultados declarados pelo autor 99,70%.

4.2. Trabalhos Futuros

Para superar as limitações no desempenho encontradas neste estudo, propõem-se um estudo de um novo método de classificação de batidas de ECG, baseando-se em um classificador semelhante à MLP que exija pouco tempo de processamento e provendo uma melhor acurácia do que o proposto pelos métodos estudados.

References

- Chen, Y.-H. and Yu, S.-N. (2007). Subband features based on higher order statistics for ecg beat classification. In *Proceedings of the 29th Annual International Conference of the IEEE EMBS*.
- Engin, M. (2004). Ecg beat classification using neuro-fuzzy network. *Pattern Recognition Letters*, 25:1715–1722.
- Gülera, I. and Übeyli, E. D. (2005). Ecgbeat classifier designed by combined neural network model. *Pattern Recognition*, 38:199–208.
- Khadtare, M. S. and Sahambi, J. (2004). Ecg arrhythmia analysis by multicategory support vector machine. In *Applied Computing*. Springer Berlin / Heidelberg.
- Mallat, S. G. (1989). A theory for multiresolution signal decomposition: The wavelet representation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 11(7):674–693.
- Osowski, S. and Linh, T. H. (2001). Ecg beat recognition using fuzzy hybrid neural network. *IEEE Transactions on Biomedical Engineering*, 48.
- ul Amir Afsar Minhas, F. and Arif, M. (2008). Robust electrocardiogram (ecg) beat classification using discrete wavelet transform. *Physiological Measurement*, 29:555–570.
- World Health Organization (2004). Estimated deaths per 100,000 population by cause, and Member State. Technical report, World Health Organization.
- Yu, S.-N. and Chen, Y.-H. (2007). Electrocardiogram beat classification based on wavelet transformation and probabilistic neural network. *Pattern Recognition Letters*, 28:1142–1150.
- Yu, S.-N. and Chou, K.-T. (2007). A switchable scheme for ecg beat classification based on independent component analysis. *Expert Systems with Applications*, 33:824–829.