

# Classificação de Arritmias Utilizando Sinais de Variabilidade da Frequência Cardíaca e o Algoritmo *Prediction by Partial Matching*

Thiago Fernandes Lins de Medeiros<sup>1</sup>, Amanda Barreto Cavalcanti<sup>2</sup>, Berg Élisson Sampaio Cavalcante<sup>2</sup>, Erick Vagner Cabral de Lima Borges<sup>2</sup>, Igor Lucena Peixoto Andrezza<sup>2</sup>, Leonardo Vidal Batista<sup>2,3</sup>

<sup>1</sup> Centro de Informática, Universidade Federal de Pernambuco (UFPE) – Recife – PE - Brasil

<sup>2</sup> Departamento de Informática, Universidade Federal da Paraíba (UFPB) – João Pessoa – PB – Brasil

<sup>3</sup> Programa de Pós-Graduação em Informática, Universidade Federal da Paraíba (UFPB), Brasil

{bergelisson01,erickvagnerr,igorlpa90,thiagofernandeslm}@gmail.com, {amanda, leonardo}@di.ufpb.br

**Abstract.** *This paper describes a method of heart arrhythmia classification based on the signal of the heart frequency variability (HFV) and the compression algorithm Prediction by Partial Matching. The extraction of the HFV signal is performed by analyzing the electrocardiogram to detect the R peak from the QRS complex of the heartbeats. Then it is possible to generate the signal. The classification of the heart arrhythmias is done in two steps. In the learning stage the PPM algorithm builds statistic models for the extracted tachogram. In the classification stage, the tachograms are compressed by the models obtained and attributed to the class whose models obtain the best ratio of compression.*

**Resumo.** *Este artigo descreve um método de classificação de arritmias baseado no Sinal de Variabilidade da Frequência Cardíaca (VFC) e no algoritmo de compressão Prediction by Partial Matching (PPM). A extração do sinal VFC é realizada através da análise do eletrocardiograma para detectar o pico R no complexo QRS dos batimentos cardíacos. Então é possível gerar o sinal. A classificação das arritmias cardíacas é feita em dois passos. Na etapa de treinamento o algoritmo PPM constrói modelos estatísticos para os tacogramas extraídos. Na etapa de classificação, os tacogramas são comprimidos pelos modelos obtidos e atribuídos às classes que obtêm a melhor razão de compreensão.*

## 1. Introdução

Os métodos de diagnóstico de doenças cardíacas podem ser invasivos ou não-invasivos. O eletrocardiograma (ECG), por ser um método eficiente, não-invasivo e de baixo risco, é um sinal extremamente útil na análise e diagnóstico das doenças cardíacas

[Goldberger 1977]. É também muito utilizado para monitorar pacientes em estado grave ou que necessitam de cuidados especiais. O ECG permite o diagnóstico de arritmias, que são distúrbios do batimento rítmico regular do coração. As arritmias podem ocorrer em corações saudáveis e ter consequências mínimas, mas também podem indicar anomalias e levar a graves doenças do coração como derrames e paradas cardíacas [Goldberger 1977]. A detecção automática de arritmias em registros de ECG tem sido considerada uma linha de investigação importante. A análise da variabilidade da frequência cardíaca (VFC), extraída dos ECGs, é atualmente uma das formas mais precisas para diagnosticar doenças do coração e avaliar a condição de saúde de um indivíduo [Eur. Heart J 1996]. A VFC refere-se às alterações, batimento a batimento, da frequência cardíaca, e representa o resultado de influências diversas dos centros simpáticos e parassimpáticos.

A análise da VFC é em geral efetuada com base em medidas estatísticas. Tsipouras et al [Tsipouras e Fotiadis 1997] propuseram um método baseado redes neurais, capaz de classificar um segmento apenas como normal ou arritmia, sem identificar o tipo da arritmia. Acharya et al. [Tsipouras, Fotiadis e Sideris 2005], com um classificador Fuzzy, e Tsipouras et al. [Asl, Setarehdan e Mohebbi 2008], com um método baseado em conhecimento, classificaram arritmias nas cinco seguintes categorias: Fibrilação Atrial(AF), Ritmo Sinusal Normal (NSR), Bloqueio de Segundo Grau do Coração (BII), Bradicardia Sinusal (SBR) e Fibrilação Ventricular (VF). Mohammadzadeh et al. [Honorio, Batista e Duarte 2009] apresentaram um método usando o algoritmo de classificação Support Vector Machine em conjunto com análise discriminante generalizada.

Modelos estatísticos de compressão de dados têm sido utilizados em diversos problemas de reconhecimento de padrões [Carvalho 2008]. Este trabalho apresenta um novo método de classificação de arritmias cardíacas baseado na VFC e no algoritmo de compressão de dados Prediction by Partial Matching.

## **2. Fundamentação Teórica**

O eletrocardiograma (ECG) é um sinal bioelétrico captado na superfície do corpo por meio de eletrodos, resultante da atividade elétrica que se espalha pelo coração durante o ciclo cardíaco [Madeiro 2007]. O ECG é um sinal extremamente útil na análise e diagnóstico das doenças cardíacas e é caracterizado por seis picos e vales identificados. Estas ondas proporcionam informações importantes sobre o funcionamento do coração cuja análise é amplamente utilizada para diagnóstico de muitas doenças cardíacas [Bell, Cleary e Witten 1984].

A variabilidade da frequência cardíaca (VFC) é caracterizada pelas oscilações dos intervalos entre batimentos cardíacos consecutivos (intervalos R-R em eletrocardiogramas). O sinal composto pela sucessão temporal das durações de intervalos R-R consecutivos é denominado tacograma. O tacograma é extraído a partir de um registro de eletrocardiograma onde todos os intervalos de tempo entre picos R adjacentes são determinados [Eur. Heart J 1996].

Uma fonte de informação discreta e estacionária que gera mensagens de um alfabeto finito escolhe símbolos sucessivos do alfabeto de acordo com uma distribuição de probabilidades que depende dos símbolos selecionados anteriormente. Uma mensagem genérica será modelada como um processo estatístico estacionário pertencente ao alfabeto.

O conceito de entropia como uma medida de informação é crucial para a Teoria da Informação e a compressão de dados provê uma perspectiva concreta a ele. Define-se a taxa de compressão de um sistema de codificação como a média do número de bits por símbolo que o sistema usa para codificar a saída de uma fonte.

O algoritmo PPM [Acharya, Bhat, Iyengar, Rao e Dua 2003] é considerado um dos mais eficazes algoritmos de compressão de dados sem perdas, de propósito genérico, embora seja bastante exigente computacionalmente.

O algoritmo PPM-C é baseado na modelagem e previsão de contexto. O modelo é atualizado à medida que os símbolos vão sendo codificados e, baseando-se em toda a seqüência de símbolos já codificados, as distribuições de probabilidade para o próximo símbolo são calculadas.

Uma abordagem seria primeiramente extrair o sinal da VFC do sinal de ECG, registrando seus sucessivos picos R (intervalos RR), para depois processá-lo. Este é um método mais robusto já que a detecção dos intervalos RR é menos afetada pelo ruído. Com esta abordagem, Tsipouras and Fotiadis [Tsipouras e Fotiadis 1997] propuseram um algoritmo baseado na análise do tempo e da freqüência do sinal da VFC utilizando um conjunto de redes neurais. Esse método é capaz de classificar um segmento como “normal” ou “arritmia”, sem identificar o tipo da arritmia.

Acharya et al. [Salomom 2004], utilizando um classificador Fuzzy, e Tsipouras et al. [Asl, Setarehdan e Mohebbi 2008], utilizando um método baseado em conhecimento, classificaram arritmias nas quatro seguintes categorias: Fibrilação Atrial (AF), Ritmo Sinusal Normal (NSR), Bloqueio de Segundo Grau do Coração (BII) e Bradicardia Sinusal (SBR).


### **3. Métodos**

Para fontes estacionárias, o algoritmo PPM aprende um modelo gradualmente melhor durante a codificação. Vários resultados experimentais mostram a superioridade do desempenho de compressão do PPM comparada a outros compressores, resultado da sua capacidade de construir um modelo preciso para a fonte logo no início do processo de compressão. Em outras palavras, o PPM gera um modelo eficiente da mensagem a ser comprimida mais rapidamente que a maioria dos outros algoritmos modernos de compressão de dados. Por este motivo o PPM será utilizado no método de classificação proposto.

Devido ao bom compromisso entre precisão do modelo e requisitos computacionais, a variante PPM-C foi implementada [Salomom 2004] e adaptado para realizar adequadamente as etapas exigidas para o treinamento e para a classificação dos sinais de ECG.

Os sinais da VFC utilizados foram gerados a partir dos sinais de ECG do MIT-BIH Arrhythmia Database [Mark e Moody 1997]. Foram extraídos segmentos relativos a cinco arritmias: Fibrilação Atrial (AF), Ritmo Sinusal Normal (NSR), Bloqueio de Segundo Grau do Coração (BII), Bradicardia Sinusal (SBR) e Fibrilação Ventricular (VF). Cada segmento extraído teve seu ritmo caracterizado de acordo com um arquivo de anotações de especialistas. Um total de 130 segmentos de ECG, com 32 intervalos RR cada, foi selecionado do banco.

A Figura 1 demonstra as etapas do método proposto.



**Figura 1: Etapas do processo de classificação do método proposto**

Os sinais da VFC dos sinais de eletrocardiograma dos bancos de dados precisam ser extraídos. Para tanto, utilizando o algoritmo de Hamilton e Tompkins [Pan e Tompkins 1985, Hamilton e Tompkins 1986 ] são detectados os complexos QRS e identificados os picos R de cada complexo e seus respectivos valores de tempo. O sinal da VFC então é construído a partir das diferenças de tempo entre os sucessivos picos R (intervalos RR). Cada tacograma gerado é dividido em segmentos contendo 32 intervalos RR e a classe de arritmia é identificada de acordo com os arquivos de anotações dos bancos de dados. Foram selecionadas 26 amostras (segmentos) de tacograma de cada classe.

Na fase de treinamento, o número de classes é definido ( $N = 5$ ) e cada conjunto de treinamento  $T_i$  é formado por 17 das 26 amostras de tacogramas de sua respectiva classe  $C_i$ ,  $i = 1, 2, \dots, N$ . O algoritmo PPM comprime seqüencialmente os tacogramas em  $T_i$ , e a tabela de probabilidades condicionais resultantes  $M_i$  é mantida como um modelo para os tacogramas da classe  $C_i$ ,  $i = 1, 2, \dots, N$ .

A razão de compressão (RC) é usada para aferir a qualidade dos modelos construídos durante o treinamento, e, portanto, para classificar amostras de classes desconhecidas. A RC é dada pela equação 1.

$$RC = n / m \quad (1)$$

em que  $n$  representa a quantidade de bits do tacograma comprimido, e  $m$  a quantidade de bits do tacograma original.

A classificação é realizada da seguinte forma. Um tacograma  $x$  de uma classe desconhecida é codificada pelo algoritmo PPM com modelo estático  $M_i$  e a razão de compressão correspondente  $RC_i$  é gravada,  $i = 1, 2, \dots, N$ . A amostra  $x$  é atribuída à classe  $C_i$  que obtiver a menor razão de compressão. A idéia é que, se  $x$  é uma amostra da classe  $C_i$ ,  $M_i$  contém o modelo que melhor descreve sua estrutura, produzindo assim, a menor razão de compressão.

A validação cruzada é uma importante técnica para estimar o desempenho de um modelo preditivo, que tenta prever qual a melhor probabilidade de um resultado a partir de um conjunto inicial de amostras. A técnica foi usada para o classificador proposto e consiste em avaliar como os resultados de uma análise estatística irão se comportar para um conjunto de dados independentes.

Uma rodada de validação cruzada consiste em separar amostras de dados em subconjuntos complementares, realizar a análise de um único subconjunto (chamado de conjunto de treinamento), nesse caso por intermédio do ppm, e finalmente obter o valor resultante dessa rodada.

A fim de reduzir a variância do resultado final, que é a média aritmética dos valores resultantes parciais, várias rodadas de validação cruzada são realizadas usando partições diferentes.

Para os testes de classificação apresentados nesse artigo foram aplicadas duas rodadas de validação cruzada. Previamente, testes foram realizados para determinar a quantidade de elementos por partição que gera melhores resultados e obteve-se um modelo com eficiência comparável a outros que utilizavam mais amostras.

Na primeira rodada foram selecionadas 17 amostras de tacogramas de cada classe para o conjunto de treinamento. Nove amostras de tacogramas não presentes no treinamento foram utilizadas para a etapa de classificação. Na segunda rodada, outras 17 amostras de cada classe foram selecionadas para o treinamento e nove para a classificação. Conforme recomendado na literatura, não há interseção entre os conjuntos de treinamento e classificação. Após a obtenção dos resultados de cada etapa, o resultado final é calculado.

#### 4. Resultados e Discussões

A avaliação do desempenho do classificador proposto foi feita utilizando três medidas típicas para esse propósito: a sensibilidade, a especificidade, a acurácia, a preditividade positiva e a preditividade negativa apresentadas nas equações (2), (3), (4), (5) e (6).

$$\text{Sensibilidade (\%)} = \frac{VP}{(VP + FN)} \quad (2)$$

$$\text{Especificidade (\%)} = \frac{VN}{(VN + FP)} \quad (3)$$

$$\text{Acurácia (\%)} = \frac{(VP + VN)}{(VP + VN + FP + FN)} \quad (4)$$

$$\text{Preditividade Positiva (\%)} = \frac{VP}{(VP + FP)} \quad (5)$$

$$\text{Preditividade Negativa (\%)} = \frac{VN}{(VN + FN)} \quad (6)$$

em que VP, VN, FP e FN representam o número de verdadeiro-positivos, verdadeiro-negativos, falso-positivos e falso-negativos, respectivamente. Se, por exemplo, um segmento da VFC com a arritmia AF é classificado como um AF tem-se um VP; se um segmento não-AF é classificado como não-AF tem-se um VN; um segmento não-AF classificado como AF irá resultar em um FP; e um segmento AF classificado como não-AF produzirá um resultado FN. Pode-se definir a sensibilidade como a frequência com a qual o classificador indica a presença de determinada classe quando ela está presente de fato, e a especificidade como a frequência com a qual o classificador indica a ausência de determinada classe quando ela está ausente. A acurácia é a proporção de predições corretas em relação a todas as predições. Preditividade positiva é a proporção de amostras classificadas como verdadeiro-positivos em relação a todas as predições positivas. Preditividade negativa é a proporção de amostras classificadas como verdadeiro-negativos em relação a todas as predições negativas.

Foram realizados testes com valores variados para o tamanho do contexto,  $k$ , utilizado no PPM-C, mas os melhores resultados foram obtidos com o contexto igual a dois ( $k = 2$ ). O melhor caso ( $k = 2$ ) produziu os valores mostrados na Tabela 1.

**Tabela 1. Sensibilidade (S), Especificidade (E), Acurácia (A), Preditividade Positiva(PP) e Preditividade Negativa(PN) para cada classe com  $k = 2$ .**

Classes	S %	E %	A %	PP%	PN%
NSR	94,45%	100,00%	98,81%	50,00%	100,00%
BII	94,45%	100%	98,81%	100,00%	50,0%
AF	100%	97,06%	97,68%	50,00%	100,00%
VF	88,89%	97,22%	95,56%	100,00%	50,00%
SBR	100,00%	100,00%	100,00%	100,00%	100,00%
Média	95,56%	98,86%	98,17%	80,00%	80,00%

A Tabela 2 apresenta um comparativo dos resultados de diferentes métodos de classificação de arritmias cardíacas e o método proposto.

As classes usadas pelos autores na tabela 2 foram em [Tsipouras e Fotiadis 1997] – Normal ou Arritmia; em [Tsipouras, Fotiadis e Sideris 2005] - NSR, PVC, VF e BII; em [Asl, Setarehdan e Mohebbi 2008] – NSR, PVC, AF, VF, SBR e BII; no Método Proposto – NSR, BII, AF, SBR e VF.

**Tabela 2. Comparação dos resultados obtidos com o método proposto neste trabalho com outros métodos extraídos da literatura.**

Autor	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
Tsipouras et al. [3]	89,95	92,91	-
Tsipouras et al. [4]	-	-	94,26
Asl Mohammadzadeh et al. [5]	95,77	99,40	99,16
Método Proposto	95,56	98,86	98,17

## 5. Conclusão

Este trabalho apresentou um novo classificador de arritmias cardíacas baseado no sinal da VFC, com resultados comparáveis aos melhores classificadores modernos. O método proposto apresentou uma média de 95,56% de sensibilidade, 98,86% de especificidade e 98,17% de acurácia, valores superiores aos apresentados em [Tsipouras e Fotiadis 1997] e [Tsipouras, Fotiadis e Sideris 2005], mas não superiores aos observados em [Asl, Setarehdan e Mohebbi 2008]. Como se trata de uma abordagem inovadora, os resultados podem ser melhorados em trabalhos futuros. Testes preliminares indicam que o aumento dos conjuntos de treinamento tem impacto positivo, levando a acurácia para 99,71%, a sensibilidade para 97,09% e a especificidade para 99,85%. Contudo, testes mais sistemáticos devem ser efetuados para consolidação destes últimos avanços.

## Agradecimentos

Agradecemos à nossa instituição de fomento Ministério da Educação (MEC) e à Secretaria de Educação Superior (SESU), além do Departamento de Informática da Universidade Federal da Paraíba.

## Referências

- Acharya R.U., Bhat BS, Iyengar SS, Rao A, Dua S. (2003) “Classification of heart rate data using artificial neural network and fuzzy equivalence relation”. *Pattern Recogn* 2003;36(1): p. 61-68.
- Asl B.M., Setarehdan SK, and Mohebbi M. (2008). “Support vector machine-based arrhythmia classification using reduced features of heart rate variability signal”, *Artif. Intell. Med.* 44, 1 (Sep. 2008), p. 51-64.
- Bell T. , Cleary J. , Witten I. (1984), “Data compression using adaptive coding and partial string matching”, *IEEE Transactions on Communications*, v. 32, n. 4, p. 396-402.
- Shannon C. E. (1948) “A mathematical theory of communication”, *Bell System Technical Journal*, vol. 27, p. 379-423 and 623-656, July and October.
- Carvalho L.C. (2008) “Instrumentação Médico-Hospitalar”, 1ª ed. Barueri - São Paulo: Manole. v. 1.
- Hamilton P.S., Tompkins W.J. (1986) “Quantitative investigation of QRS detection rules using the MIT/BIH arrhythmia database”. *IEEE Trans Biomed Eng* 1986;33(12), p.1157-1165.
- Honorio, T. C. S. ; Batista, L. V. ; Duarte, R. C. M. (2009) —Texture Classification Using Prediction by Partial Matching Models. *Workshop de Visão Computacional*, São Paulo, p. 21-26.
- Goldberger, L. and E. (1977), *Clinical Electrocardiography*, Saint Louis: The Mosby Company, 1<sup>st</sup> edition.
- Madeiro J.P.V. et al (2007), “A new approach to QRS segmentation based on wavelet bases and adaptive threshold technique”, *Medical Engineering and Physics*, v. 29, p. 26-37.

- Mark R.G., Moody G.B. (1997). “MIT-BIH Arrhythmia Database” [Online]. Disponível em: <http://ecg.mit.edu/dbinfo.html> [acessado: 23.02.2009].
- Pan J., Tompkins W.J. (1985) “A real time QRS detection algorithm” IEEE Trans Biomed Eng 1985;32(3): p. 230-236.
- Salomom D. (2004) “Data Compression – The Complete Reference”. 3ª ed. Springer.
- Task force of The European Society of Cardiology and The North American Society of Pacing and Electrophysiology (1996), “Heart Rate Variability: Standards of measurement, physiological interpretation and clinical use”, Eur. Heart J, vol. 17, p. 354-381.
- Tsipouras M.G., Fotiadis D.I. (2004) “Automatic arrhythmia detection based on time and time—frequency analysis of heart rate variability” Comp Meth Prog Biomed 2004;74(2): p. 95-108. Comput 1997;35(6): p. 626-632.
- Tsipouras M.G., Fotiadis D.I., Sideris D. (2005) “An arrhythmia classification system based on the RR-interval signal” Artif Intell Med 2005;33(3): p. 237-250.