

# ESTUDO COMPARATIVO DE ABORDAGENS DE CLASSIFICAÇÃO NÃO SUPERVISIONADA DE BATIMENTOS CARDÍACOS

ROGÉRIO O. AGUIAR\*, RODRIGO V. ANDREÃO\*, TEODIANO F. BASTOS FILHO\*

*\*Laboratório de Telecomunicações, Departamento de Engenharia Elétrica, UFES  
Av. Fernando Ferrari, s/n  
Vitória, Espírito Santo, Brasil*

E-MAILS: ROGERIOAG@YAHOO.COM, RODRIGO@ELE.UFES.BR, TBBASTOS@ELE.UFES.BR

**Abstract**— This paper presents two electrocardiogram (ECG) classification systems based on the Dynamic Time Warping (DTW) and K-means algorithms respectively. The DTW is employed to align beats of different lengths by a non linear time warping. On the other hand, K-means is a classical self-organizing algorithm very popular in ECG applications because it can cluster efficiently signals by making comparisons among them. Experiments were carried out using 42 two-channel recordings of the *MIT-BIH Arrhythmia Database* aiming at comparing the two systems in a premature contraction beat detection problem. Both systems have shown a very good performance in terms of sensitivity and positive predictivity measures. However, the system based on the DTW has presented some important advantages, since it carries out a full automatic classification; that is, without requiring the manual labeling from a specialist, and it operates in an online fashion, allowing to alarm in a context of patient monitoring.

**Keywords**— Non-supervised, Dynamic time warping, electrocardiogram, K-means.

**Resumo**— Este trabalho compara dois sistemas de classificação de eletrocardiograma (ECG), que são baseados nas seguintes abordagens: *Dynamic Time Warping* (DTW) e o K-médias. O DTW foi escolhido por sua capacidade de alinhar batimentos de diferentes tamanhos por meio de uma deformação temporal não linear. Já o K-médias é um algoritmo clássico de auto-organização, muito popular em aplicações de ECG, pois ele consegue dividir eficientemente sinais em grupos por meio de comparações entre eles. Os sistemas foram desenvolvidos baseados em abordagens não supervisionadas que classificam os batimentos cardíacos de um registro de ECG em duas classes distintas. Experimentos foram feitos utilizando 42 registros base de dados *MIT-BIH*. Ambos os sistemas tiveram ótimos desempenhos, de sensibilidade e de preditivos positivos, na classificação dos batimentos. Entretanto, o sistema baseado no algoritmo DTW se mostrou vantajoso, pois além de ser totalmente automático, ou seja, sem requerer a intervenção de um especialista, ele realiza uma classificação à medida que os batimentos são segmentados, o que possibilita a geração de alertas num contexto de monitoramento de pacientes.

**Palavras-chave**— Classificador não supervisionado, eletrocardiograma, K-médias, DTW.

## 1 Introdução

O eletrocardiograma (ECG) é um dos exames mais importantes e mais utilizados para a identificação de anomalias cardíacas. O ECG caracteriza-se por ser um procedimento simples, barato e indolor, pois ele é obtido pela medição da diferença de potencial entre eletrodos colocados na superfície do corpo do paciente. Desta forma, os campos elétricos resultantes dos batimentos cardíacos dos pacientes são detectados e sua variação é convertida em um sinal elétrico. O sinal de ECG de um coração normal é composto de alguns traços característicos (Figura 1), tais como o complexo QRS, a onda T e a onda P, isso em um ciclo cardíaco completo.




Figura 1. Sinal ECG com traços característicos.

Segundo o Atlas de Doenças Cardíacas e Derrames, publicado pela Organização Mundial da Saúde (OMS), no Brasil, em 2002, foram registradas 139.601 mortes por doenças cardíacas, sendo o 9º lugar na lista dos países cuja população morre mais, em números absolutos. Desta forma, o auxílio ao diagnóstico médico na identificação precoce de eventos de risco, por meio da análise automática de sinais de ECG, em particular dos registros ambulatoriais pelo método Holter, é uma forma de reduzir em muito esse índice de mortalidade.

Diversos grupos de pesquisa vêm estudando as mais diversas técnicas de análise e classificação dos sinais ECG nas últimas décadas. (Chazal, Reilly O'Dwyer 2004), por meio de uma classificação supervisionada, divide os batimentos nas cinco diferentes classes recomendadas pela AAMI, um dos destaques na sua abordagem é a imposição de regras para diferenciar as classes. Por meio de um sistema híbrido, (Osowski e Linh 2001) utilizam uma sub-rede fuzzy auto-organizada conectada em cascata com uma rede neural que utiliza os algoritmos do K-means modificado e de Gustafson-Kessel. (Andreão *et al* 2006) desenvolveu um sistema on-line e não supervisionado que segmenta e localiza os batimentos ventriculares utilizando as cadeias ocultas de

Makov (HMM). Os grupos de (Wang *et al* 1999) e (Huang *et al* 2002) utilizam o DTW em seus respectivos trabalhos, o primeiro utiliza o algoritmo para sincronizar diversos vetores de dados, achando assim uma amostra que melhor os represente. Já o segundo desenvolveu um classificador e com base nele faz uma análise detalhada de alguns pontos do DTW.

Neste trabalho é realizada uma comparação entre duas abordagens de classificação de ECG ambulatoriais. A primeira, que é baseada no algoritmo DTW, é resultado de um trabalho de pesquisa que vem sendo desenvolvido (Aguiar e Andreão 2006) cujo objetivo principal é de classificar os batimentos no contexto de um sistema de telemonitoramento de pacientes. Neste caso, os batimentos são classificados de maneira on-line, ou seja, à medida que os mesmos são registrados pelo sistema. Isto permite que o sistema possa sinalizar um alarme imediatamente após o acontecimento de uma anomalia. Além disso, ele serve como pré-processamento no caso de detecção de anomalias do coração de maior gravidade como o caso da isquemia do miocárdio, pois os batimentos anormais não são levados em conta na análise.

Por outro lado, a método K-médias tem sua aplicabilidade quando se trata de banco de dados de registros de ECG de um dado paciente. Nessa situação, o especialista pode estar interessado em visualizar alguns padrões que caracterizam a maior parte dos batimentos do paciente. Isso possibilita uma maior agilidade a leitura do registro, pois pode-se determinar com uma certa precisão os representantes dominantes daquele registro. Se por um lado o método K-médias realiza satisfatoriamente a tarefa de agrupamento, por outro lado ele é incapaz de identificar o tipo de batimento. Essa limitação pode ser resolvida seja por um sistema a base de regras ou pela intervenção de um especialista.

Por fim, as duas abordagens serão testadas em um mesmo contexto: sinais ECG previamente registrados que foram retirados da base de dados *MIT-BIH Arrhythmia Database*, onde foram utilizados cerca de 90 mil batimentos cardíacos. Desta forma, buscaremos avaliar a aplicabilidade de nossa abordagem baseado no DTW também em um contexto off-line, onde todo o registro está disponível.

## 2 Materiais e Métodos

### 2.1 Eletrocardiograma

*Base de Dados:* Nos experimentos foi utilizada a base de dados *MIT-BIH Arrhythmia Database*, a qual contém diferentes sinais que foram retirados do PhysioBank. Essa base contém 48 registros, de dois canais, com taxa de amostragem de 360 Hz e com 30 minutos de duração cada e nesse trabalho foram selecionados 42 registros (excluindo os registros com baixa relação sinal/ruído e aqueles de pacientes com marca-passo). Os registros foram analisados por especialistas que indicaram a localização do complexo QRS e classificaram manualmente os batimentos, de

acordo com sua morfologia, em 13 tipos diferentes (Moody, Mark e Goldberger 2001).

A Association for the Advancement of Medical Instrumentation (ANSI/AAMI 1998) recomenda a combinação das 13 diferentes classes (Tabela 1) em cinco grupos de batimentos. Nesse trabalho foram analisados classificadores que dividem os batimentos em duas classes: batimentos normais (N) e anormais (A), que são compostos dos batimentos N+S e V+F+Q, respectivamente.

Tabela 1. Classes Recomendadas pela AAMI.

Classes Segundo a AAMI	Batimentos agrupados
Normal (N)	N, E, j, R
Ventricular (V)	V
Supraventricular (S)	S, A, a, J
Fusão (F)	F
Desconhecido (Q)	/, f, Q

*Segmentação do ECG:* Esta é uma das etapas mais importantes do processo de classificação, pois, caso ela não seja bem feita, pode comprometer todo o processo. Geralmente a segmentação é feita por meio de detecção dos complexos QRS do ECG. Entretanto, esse problema não vai ser abordado neste trabalho, pois a base de dados que dispomos já contém as marcações do complexo QRS, eliminando, assim, a necessidade de detectá-los.

A distância RR é definida pelo intervalo de ocorrência entre as ondas R de dois batimentos consecutivos (Figura 1). O pico da onda R, na maioria dos casos, é fácil de ser detectado, já que sua amplitude é muito maior que as do restante do sinal. Por fim, a distância RR serve como referência para o cálculo da frequência cardíaca, já que por meio dela conseguimos saber o tempo que se passou entre dois batimentos.

Em um sinal ECG, as janelas geralmente são definidas de acordo com a localização dos picos da onda R e das distâncias entre os batimentos adjacentes. Uma janela ECG indica a localização do batimento cardíaco, ou seja, indica onde será seu início e seu final. Dependendo do tipo de aplicação, as janelas podem ser definidas de diferentes formas, podendo apresentar tamanhos fixos ou variáveis e podem abranger todo ou apenas parte do sinal.

Em todos os experimentos deste trabalho foram utilizadas janelas fixas de 160 ms abrangendo apenas o complexo QRS do batimento. A escolha da janela fixa foi feita para reduzir o custo computacional, além disso, as classes de batimentos agrupados têm o complexo QRS bem característico, bastando à análise de sua morfologia para diferenciá-los.

*Processamento do Sinal:* Todos os sistemas de aquisição de sinais bioelétricos estão sujeitos à interferência de ruídos e com o eletrocardiograma não é diferente. Eles são provenientes de diversas fontes, tais como: a interferência da rede elétrica, ruídos de movimento, ruídos de alta frequência, ruídos eletromiográficos e mudança das linhas de base e de amplitude moduladas pela respiração.

Um método muito eficiente de eliminar ruídos do sinal é por meio da filtragem fora da faixa de frequência onde o sinal tem maior conteúdo espectral. Foram testados diversos tipos de filtros, tais como o de Butterworth, Adaptativo, de Wiener dentre outros, mas o que apresentou melhores resultados foi o filtro derivativo combinado com um filtro passa-baixas sintetizado por (Coast *et al* 1990). A equação da diferença que representa o filtro IIR é dada por:

$$y[n] - 2y[n-1] + y[n-2] = x[n] - x[n-6] - 2x[n-9] - 2x[n-15] + x[n-18] - x[n-24] \quad (1)$$

onde  $x$  é o sinal de entrada e  $y$  é o sinal filtrado

## 2.2 Dynamic Time Warping

O DTW surgiu no final da década de 70 e foi a primeira técnica utilizada com sucesso no reconhecimento de palavras isoladas, tendo como ponto forte a capacidade em alinhar seqüências de sinais com durações diferentes.

O maior problema na classificação dos sinais ECG são suas características não-estacionárias, pois as variações dos batimentos cardíacos causam flutuações não-lineares no tempo. Isso significa que a distância Euclidiana não serve para comparar a semelhança entre dois batimentos, devido à inconsistência de seus tamanhos. O DTW é um algoritmo de alinhamento não-linear que faz a diferença temporal entre dois batimentos ser minimizada, dilatando de diferentes formas os eixos temporais dos sinais analisados até conseguir alinhá-los da melhor forma, até que a máxima verossimilhança entre eles seja alcançada. A Figura 2 mostra a idéia básica do alinhamento.

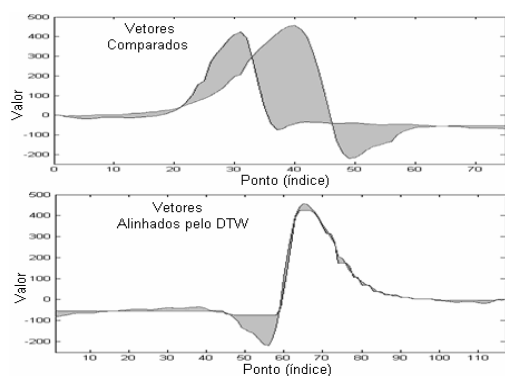


Figura 2. Alinhamento de vetores pelo DTW.

O DTW alinha dois vetores da seguinte forma: supõe-se duas seqüências ( $X$  e  $Y$ ) de vetores de parâmetros com tamanhos  $T_x$  e  $T_y$  respectivamente. Os vetores são posicionados seguindo a direção dos eixos  $x$  e  $y$  do plano cartesiano e em seguida é traçado o caminho de alinhamento.

Para se achar o caminho de alinhamento, inicialmente é calculada uma matriz com as distâncias Euclidianas  $d(X,Y)$  ponto a ponto entre todos os elementos das seqüências a serem comparadas, formando, assim, uma *matriz das distâncias*. De posse desta,

utilizando o princípio da *programação dinâmica*, é calculada uma nova matriz, chamada de *matriz custos* que armazena as distâncias acumuladas dos caminhos possíveis até o último elemento. Por fim, é feita uma varredura, de trás para frente, nessa matriz, seguindo os pontos de menor distância, formando, assim, o caminho ótimo e a distância ótima.

**Determinação do Batimento de Referência:** Com a intenção de implementar um sistema de classificação não-supervisionado, esbarramos no problema de ter que determinar a referência manualmente, o que tornaria o sistema semi-supervisionado.

O método, denominado de comparações sucessivas, utiliza o DTW como algoritmo de comparação e consiste em determinar um intervalo do sinal ECG onde existe um grupo de batimentos muito semelhantes (Figura 3). A partir disso, é bem provável, que a seqüência encontrada seja formada apenas de batimentos normais.




Figura 3. Funcionamento das Comparações Sucessivas.

Depois de achada a seqüência, será selecionado como referência o batimento central da mesma. Desta forma, pode-se supor que, terá sido escolhido o batimento mais estável e com menos interferência de batimentos anormais que possam estar nas proximidades.

**Comparação entre Dois Canais:** Inicialmente nosso sistema foi concebido para analisar apenas um canal de ECG para fazer a classificação dos batimentos cardíacos. Entretanto, durante os experimentos, foi percebido que essa abordagem tem certas limitações, pois certos tipos de batimentos, que são facilmente detectados em um determinado canal, não se diferenciam muito dos batimentos normais em outros canais. Assim, a classificação final é dada por meio da combinação das distâncias ótimas dos canais analisados.

**Medidor de Frequência Cardíaca:** O medidor de frequência cardíaca grava a duração dos últimos três batimentos normais consecutivos. Em seguida, é tirada a média desses períodos e assim calcula-se a frequência cardíaca  $F_c$  atual. Essa informação é utilizada como referência tanto para determinar a ocorrência de um batimento prematuro quanto para indicar a variação da frequência cardíaca ao longo do tempo.

**Classificador:** O classificador funciona da seguinte forma: dado um batimento  $b$ , calcula-se a dis-

tância ótima  $d$  de cada canal em relação ao batimento de referência utilizando o DTW. Em seguida, compare-se o valor da soma das distâncias com um limiar de classificação, dado por:

$$\tau_c = (T_x \times T_y / w) \times c_1, \quad (2)$$

onde  $T_x$  e  $T_y$  são os tamanhos dos vetores analisados,  $w$  é o tamanho do caminho ótimo e  $c_1$  é uma constante de proporcionalidade.

Desta forma os batimentos são divididos em duas classes: normais (para valores abaixo do limiar) ou anormais (para valores acima do limiar).

*Atualizador de Referência:* A atualização da referência é necessária devido a flutuações que podem ocorrer no sinal e até devido a possíveis problemas em sua aquisição. Isso poderia levar a classificação ser mal feita caso comparássemos um batimento com frequência de 120 bpm, por exemplo, com uma referência de 70 bpm.

Assim, a referência é atualizada sempre quando a distância ótima calculada pelo DTW for menor que um limiar de atualização:

$$\tau_a = c_2 \times \tau_c, \quad (3)$$

onde  $\tau_c$  é o limiar de (2) e  $c_2$  é uma constante de proporcionalidade.

### 2.3 K-médias

O K-médias é um algoritmo iterativo de classificação não-supervisionada muito utilizado na área de telecomunicações, processamento de sinais e data mining. Ele realiza a divisão de um conjunto de elementos em classes ou *cluster* de maneira a minimizar o erro quadrático médio de sua função custo  $J_e$ .

$$J_e = \sum_{i=1}^c \sum_{x \in D_i} \|x - m_i\|^2, \quad (4)$$

onde  $D_i$  é um determinado *cluster* (agrupamento),  $m_i$  é o melhor representante das amostras em  $D_i$ ,  $c$  é a quantidade de *clusters* e  $x$  é o vetor analisado.

O K-médias, também conhecido como aprendizado auto-organizado, tem como entradas: vetores de dados, medidas de distâncias e números de grupos, e fornece como saída: o grupo, o centróide e o desvio padrão.

Ele funciona da seguinte maneira: depois de definido o número de grupos, é feita uma atribuição arbitrária dos centróides de cada grupo de acordo com as amostras de dados (Figura 4-a). Depois são executadas as interações: inicialmente para cada amostra procura-se o centróide mais próximo; atribui-se a amostra ao cluster correspondente; e finalmente recalcula-se o centróide para esse cluster (Figura 4-b). Isso é feito até seja cumpridos os seguintes critérios de convergência:

1. Nenhuma amostra mudar de agrupamento
2. Os centróides não sejam modificados

3. Os valores da função custo se mantêm constantes ou abaixo de um limiar
4. Alcançar um limite para o número de interações




Figura 4. Funcionamento do K-médias.

Um dos pontos mais importantes na abordagem que utiliza o K-médias é a definição do número de classes que serão utilizadas. A princípio queremos agrupar os batimentos em apenas duas classes, mas não há garantias que o desempenho do método seja satisfatório, pois o próprio batimento normal do paciente pode apresentar variações ao longo do registro. Deste modo, foi avaliado o desempenho do sistema com divisões maiores do que as duas classes testadas inicialmente. Vale destacar que no caso da abordagem baseada no DTW, esse problema de variabilidade do batimento normal é tratado por meio do atualizador de referência.

### 2.4 Principais Características dos Sistemas

*DTW versus K - médias:* Depois de implementados os sistemas foi feita uma análise das principais características de cada um.

O DTW é um algoritmo on-line, ou seja, ele faz a classificação em tempo real, diferentemente do K-médias que necessita de toda a base para fazer a divisão dos batimentos em classes, o que impediria uma possível geração de alertas quando um problema mais grave estiver acontecendo. Além disso, a abordagem baseada no método DTW funciona como um classificador automático, já que ele não necessita de um especialista para dizer a que classe pertence os grupos divididos, ao contrário do K-médias que agrupa o batimento em classes sem indicar quais delas correspondem aos batimentos normais e anormais. Porém a do DTW tem um custo computacional muito maior que K-médias, mas nada que impeça sua execução on-line.

## 3 Resultados

Os experimentos foram divididos em duas fases: *aprendizagem* e *testes*. Na fase de aprendizagem, foram selecionados oito registros da base MIT-BIH que tinham uma grande variedade de tipos de batimentos (10084 batimentos N e 1916 batimentos A). Em seguida, foram feitas simulações visando melhorias e ajustes no sistema, em especial na estimação

dos limiares. A fase de testes contou com uma base de trinta e quatro registros, totalizando 69809 batimentos N e 4511 batimentos A, os quais serviram para avaliar o desempenho do sistema.

*Medida de Desempenho:* Como recomenda a AAMI (ANSI/AAMI 1998), as medidas de sensibilidade (Se), que calcula a taxa de acerto na classificação de batimentos, e de valor preditivo positivo (PP), o qual mede a probabilidade da classificação feita pelo sistema estar correta, são os critérios de análise do desempenho do classificador.

*Resultados:* As duas abordagens foram testadas no contexto off-line, ou seja, quando todos os dados do registro estão disponíveis. Enquanto o DTW faz a identificação automática e indica o resultado da classificação, a abordagem baseado no método K-médias agrupa os batimentos em clusters e o especialista indica a qual classe corresponde cada cluster.

Os resultados mostram (Tabela 2) que, mesmo com o auxílio do especialista, a estratégia de agrupamento de batimentos baseado no método K-médias possui limitações. Quando o número de clusters é pequeno (dois ou três), o método é incapaz de separar corretamente um grupo de batimentos normais dos anormais. Por outro lado, o método baseado no DTW, mesmo sem a intervenção do especialista, apresenta melhores resultados. Isto pode ser explicado pela variabilidade dos batimentos normais ao longo do registro, o que é levado em conta no método baseado no DTW através do atualizador de referências ao longo do registro. Desta forma, podemos concluir que os batimentos normais seriam mais bem agrupados se criássemos outros clusters para eles. Por esse motivo, quando o número de clusters foi aumentado para quatro o método k-médias superou a abordagem baseado no algoritmo DTW.

Tabela 2. Resultados dos Sistemas de Classificação.

Sistema Classificador	Normais (%)		Anormais (%)		Taxa de Acerto Global
	Se	PP	Se	PP	
K-média(2clusters)	99,9	98,2	72,3	97,9	98,1 %
K-média(3clusters)	99,9	98,4	76,3	98,8	98,4 %
K-média(4clusters)	99,9	99,1	86,7	99,1	99,1 %
DTW	99,4	98,9	82,9	90,5	98,5 %

#### 4 Conclusão

Foram apresentados, neste trabalho, dois sistemas de classificação não-supervisionada de batimentos cardíacos, um baseado no DTW e outro no algoritmo K-médias. O primeiro se mostrou mais eficiente com a vantagem de ser on-line e automático. Já o segundo, off-line e semi-automático, além de ter um ótimo desempenho tem a vantagem de o custo computacional ser menor e ter sua rotina já muito otimizada e implementada em Matlab.

Já existem grupos de estudos que fazem modificações no algoritmo do DTW, com propósito de dei-

xá-lo mais rápido e aumentar sua eficiência em aplicações específicas (Wang *et al* 1999). Essa é uma das estratégias que estão sendo adotadas para melhorar o desempenho do sistema.

Além disso, pretende-se estudar outras alternativas aos limiares binários utilizados neste trabalho, como, por exemplo, a lógica fuzzy, a qual possibilita uma melhor modelagem da abordagem médica na identificação das arritmias. Desta forma, poder-se-ia criar outras classes de batimentos conforme recomendação da AAMI.

#### Agradecimentos

Este trabalho contou com o apoio da FAPES (Fundação de Apoio à Pesquisa do Espírito Santo) com uma bolsa de mestrado oferecida.

#### Referências Bibliográficas

- Chazal, P.; Reilly, R.; O'Dwyer, M. (2004). Automatic Classification of the Heartbeats Using ECG Morphology and Heartbeat Interval Features, *IEEE Transactions on Biomedical Engineering*, v. 18, i. 3, p. 1996-1206.
- Osowski, S.; Linh, T. H. (2001). ECG Beat Recognition Using Fuzzy Hybrid Neural Network, *IEEE Transactions on Biomedical Engineering*, v. 48, n. 11, p. 1265-1271.
- Andreão, R.; Dorizzi B.; Boudy, J. (2006). ECG Signal Analysis Through Hidden Markov Models, *IEEE Transactions on Biomedical Engineering*, v. 53, no. 8, p. 1541-1549.
- Wang, K.; Gasser, T. (1999). Synchronizing Sample Curves Non-Parametrically, *The Annals of Statistics*, 27, pp. 439-460.
- Huang, B.; Kinser, W. (2002). ECG Frame Classification Using Dynamic Time Warping, *Canadian Conference on Electrical & Computer Engineering of the IEEE*, Canada, p. 1105-1110.
- Aguiar, R.; Andreão, R.; Bastos, T. (2006). Classificação Automática e Não Supervisionada de Sinais de Eletrocardiograma, *XX Congresso Brasileiro de Engenharia Biomédica*, São Pedro, SP, pp. 375-378.
- Moody, G., Mark, R., Goldberger, A. (2001). PhysioNet: A Web-Based Resource for the Study of Physiologic Signal, *IEEE Engineering in Medicine and Biology*, Istanbul, p. 70-75.
- ANSI/AAMI (1998). Testing and Reporting Performance Results of Cardiac Rhythm and ST Segment Measurement Algorithms, ANSI/AAMI EC 57-293, Arlington, p. 37.
- Coast, D., Stern, R. (1990). An Approach to Cardiac Arrhythmia Analysis Using Hidden Markov Models, *IEEE Transactions on Biomedical Engineering*, v. 37, i. 9, p. 826-836.