

Classificação de Doenças Cardíacas Através de Eletrocardiogramas e Fonocardiogramas

Mikaela Baldasso¹

Marcio Valk²

Airton Kist³

Resumo: Uma grande parcela da população sofre de problemas relacionados a doenças do coração que estão entre as principais causas de morte em todo o mundo. Em particular, 1-2% da população mundial sofre de algum tipo de arritmia cardíaca que pode afetar pessoas das mais variadas faixas etárias. Recentemente o “National Institute of General Medical Sciences” (NIGMS) lançou um desafio com o objetivo de estimular a proposição de técnicas para classificação dos diferentes tipos de arritmias baseados em eletrocardiogramas (ECG’s) e fonocardiogramas (PCG’s) que podem ser vistos como séries temporais em que a técnica de classificação e agrupamento baseada em U-estatísticas pode ser aplicada. A utilização dessas técnicas depende fundamentalmente de medidas de distâncias ou similaridade que sejam capazes de capturar diferenças entre dois ECG’s (ou PCG’s), quando elas existem. Abordagens muito comuns na análise de sinais, como a filtragem, que elimina os ruídos que possivelmente poderiam afetar a classificação, devem ser consideradas. A partir disso, pode-se utilizar ferramentas comuns na análise de séries temporais, como a autocorrelação que é característica definidora podendo ser usada na classificação dos diferentes tipos de arritmia. Por fim, neste estudo, os resultados são comparados aos disponibilizados pelo desafio sendo possível fazer uma comparação com outras técnicas propostas na literatura.

Palavras-chave: *Doenças Cardíacas, Classificação, Fonocardiograma.*

2 Introdução

As doenças cardiovasculares (DCV) continuam sendo a principal causa de morbidade e mortalidade no mundo todo Liu et al. (2016). Estima-se que 17,5 milhões de pessoas morreram de DCV em 2012, representando 31% de todas as mortes globais (OMS 2015). Um dos primeiros passos na avaliação do sistema cardiovascular é o exame físico. Auscultação dos sons do coração é parte essencial do exame físico e pode revelar muitas condições cardíacas patológicas,

¹UFRGS - Universidade Federal do Rio Grande do Sul. Email: mikaelabaldasso@gmail.com

²UFRGS - Universidade Federal do Rio Grande do Sul. Email: marcio.valk@ufrgs.br

³UEPG - Universidade Estadual do Paraná. Email: kist@uepg.br

como arritmias, doença valvar, insuficiência cardíaca e muito mais. Os sons cardíacos fornecem importantes pistas iniciais na avaliação da doença, servem de guia para um exame diagnóstico posterior e, assim, desempenham um papel importante na detecção precoce de DCVs, (Liu et al., 2016).

Durante o ciclo cardíaco, o coração primeiro sente um impulso elétrico que leva a atividade mecânica sob a forma de contrações atriais e ventriculares. Isso, por sua vez, força o sangue entre as câmaras do coração e ao redor do corpo, como resultado da abertura e fechamento das válvulas cardíacas. Essa atividade mecânica e o início ou parada repentina do fluxo de sangue dentro do coração, dá origem a vibrações de toda a estrutura cardíaca (Liu et al., 2016). Essas vibrações são audíveis na parede torácica e escutas de sons cardíacos específicos podem dar uma indicação da saúde do coração. As gravações de áudio desses sons são armazenadas em forma de uma série temporal e a representação gráfica dos sons resultantes, obtidos a partir da superfície do tórax, é conhecida como fonocardiograma (PCG).

Quatro locais são mais utilizados para ouvir e transduzir os sons do coração, que são nomeados de acordo com as posições em que as válvulas podem ser melhor ouvidas (Springer et al., 2016): *Área aórtica*- centrada no segundo espaço intercostal direito. *Área pulmonar* - no segundo espaço intercostal ao longo da borda esternal esquerda. *Área tricúspide* - no quarto espaço intercostal ao longo da borda esternal esquerda. *Área mitral* - no ápice cardíaco, no quinto espaço intercostal na linha do meio da clavícula.

A Figura 1 apresenta um esquema de como o sinal *Fundamental heart sound* (FHS) é naturalmente dividido em partes, que se repetem com um comportamento cíclico. Como podemos ver na Figura 1, em um paciente saudável, primeiramente observa-se o “primeiro som” (S1) em seguida o “segundo som” (S2). Outros sons também são audíveis devido ao movimento natural do coração denominados (S3) e (S4) além dos chamados murmúrios cardíacos causados por um fluxo de sangue turbulento e de alta velocidade, entre outros ruídos. Sons externos, como a respiração, também podem afetar o PCG.

A análise automatizada do som cardíaco nas aplicações clínicas geralmente consiste em três passos; Pré-processamento, segmentação e classificação. Nas últimas décadas, métodos para segmentação automatizada e classificação de sons cardíacos foram amplamente estudados. Muitos métodos demonstraram potencial para detectar com precisão patologias em aplicações clínicas. Infelizmente, as comparações entre técnicas foram dificultadas pela falta de bases de dados de alta qualidade, rigorosamente validadas e padronizadas, de sons cardíacos obtidos a partir de uma variedade de condições saudáveis e patológicas. Em muitos casos, ambos os dados experimentais e clínicos são coletados a custos consideráveis, mas apenas analisados uma vez por seus




Figura 1: Fonocardiograma de sons cardíacos normais e anormais. Vermelho indica pressão aórtica, verde indica pressão ventricular e azul a pressão atrial. Fonte: Liu et al. (2016).

coleccionadores e, em seguida, arquivados indefinidamente por variados motivos. Além disso, a energia necessária para documentar dados para uso externo, armazenar e compartilhar de forma semi-permanente raramente está disponível no final de um projeto de pesquisa Liu et al. (2016).

Outro aspecto importante na análise automatizada de sinais cardíacos é a segmentação que consiste basicamente na localização precisa de S1 e S2. Nesse trabalho, para classificar os sinais cardíacos, será empregada uma técnica que não faz a segmentação dos sinais. Uma revisão metodológica pode ser vista em Liu et al. (2016).

3 Metodologia

A metodologia adotada nesse trabalho segue basicamente aquela adotada em Deng e Han (2016). Inicialmente cada sinal x é convertido para uma frequência de 2kHz e então é filtrado através de um filtro Butterworth *band-pass, zero-phase* de ordem 6 (25Hz-900Hz) para eliminar ruídos que ultrapassem a banda. Depois disso o sinal resultante, \hat{x} , é normalizado por

$$\bar{x} = \frac{\hat{x}}{\max(|\hat{x}|)}. \quad (1)$$

Já convertido e normalizado, o sinal é decomposto em quatro níveis usando a transformada *wavelet* Daubechies de ordem 6 devido às suas semelhanças morfológicas com os componentes do som cardíaco. Os coeficientes wavelet de aproximação do quarto nível e os coeficientes wavelet de detalhes do segundo nível são selecionados para extrair os envelopes de *energia Shannon* de média normalizada (ASE), respectivamente. Usando uma *lag-window* de 30ms com uma mudança de quadro de 15ms, a ASE é calculada por

$$e(n) = -\frac{1}{N_w} \sum_{j=1}^{N_w} d^2(j) \log(d^2(j)), \quad (2)$$

onde N_w é o comprimento da janela e $d(j)_{j=1}^{N_w}$ são os coeficientes da sub-banda na n -ésima *lag-window*.

Os coeficientes de aproximação do quarto nível são correspondentes ao alcance de frequência de 0-125Hz que capta a maioria das informações sobre os sons fundamentais do coração. O conteúdo da frequência dos coeficientes wavelet de detalhes do segundo nível está principalmente entre 500-1000Hz, que representa principalmente a informação sobre ruídos. A partir da equação (2), pode-se calcular a Energia de Shannon $e_a(n)$ dos coeficientes de aproximação e $e_d(n)$ dos coeficientes de detalhes da transformada discreta de wavelet. Será considerada a informação desses dois vetores para caracterizar um sinal normal de um sinal de um paciente com arritmia.

Como o som cardíaco é quase periódico e é composto por uma série de ciclos cardíacos, muitas estruturas semelhantes emergem em cada ciclo, tais como os sons fundamentais do coração e alguns ruídos. Também existe uma quase periodicidade nos sinais da sub-banda da batida do coração e em seus envelopes. A função de autocorrelação da ASE dos coeficientes wavelet da sub-banda podem capturar de forma automática e indireta a periodicidade dos múltiplos ciclos cardíacos e, conseqüentemente, pode ser uma ferramenta capaz de identificar as características do som cardíaco, (Deng e Han, 2016). Devido à simetria da função de autocorrelação, a ACF de sub-banda somente é calculada para *lags* positivos e é definida por

$$r(m) = \frac{1}{r(0)} \sum_{n=0}^{N-m-1} e(n)e(n+m), \quad m > 0, \quad (3)$$

onde $e(n+m)$ é a versão deslocada no tempo do sinal $e(n)$, com um intervalo de tempo m para $m = 0, 1, \dots, M$.




Figura 2: Autocorrelações dos coeficientes de aproximação e dos coeficientes de detalhes do som cardíaco com ruídos da sístole.

3.1 Função kernel gaussiano como medida de dissimilaridade

Em classificação e agrupamento de séries temporais é fundamental encontrar uma medida de dissimilaridade que seja capaz de detectar sinais com características distintas (ou processo gerador distinto). Em [Deng e Han \(2016\)](#) é utilizada a função kernel gaussiano como uma medida de dissimilaridade entre os FHS. O objetivo é que essa medida capture o padrão de comportamento de S1 e S2 e também os chamados murmúrios cardíacos. Devido à capacidade de capturar a estrutura temporal das informações, a ACF de sub-banda pode ser vista como a característica do sinal de sub-banda.

A característica ACF de sub-banda é construída colocando-se os M valores dos coeficientes ACF (ACFCs) como um vetor coluna $\mathbf{r} = [r(1), \dots, r(M)]^T \in \mathcal{R}^M$. Os ACFCs dos coeficientes de aproximação e detalhes da transformada wavelet discreta (TDW), denotados, respectivamente, por aACFC \mathbf{r}^a e dACFC \mathbf{r}^d , capturam a estrutura da informação temporal dos FHS e dos murmúrios, respectivamente ([Deng e Han, 2016](#)). Note que o valor de M deve ser maior que a sazonalidade do ciclo cardíaco para que os ACFCs contenham informação de todo o espaço de variação do som cardíaco. Em [Deng e Han \(2016\)](#) \mathbf{r}^a e \mathbf{r}^d são transformados em um só

vetor (adACFC) $\mathbf{r}^{ad} = [\mathbf{r}^a, \mathbf{r}^d] \in \mathcal{R}^{2M}$ para serem usados em classificadores (SVM, support vector machine).

Sendo n o número de sinais e \mathbf{r}_i o adACFC do sinal $i \in \{1, \dots, n\}$, define-se a medida de similaridade baseada na função kernel gaussiano entre os sinais i e j por

$$\omega(i, j) = \exp \left\{ -\frac{\|\mathbf{r}_i - \mathbf{r}_j\|^2}{\delta^2} \right\}, \quad (4)$$

em que δ^2 é a largura do kernel. A matriz de dissimilaridade W é composta pelas entradas $\omega(i, j)$.

4 Descrição dos dados

Em meados de 1999 foi criado o *PhysioNet Resouce* com o objetivo de estimular pesquisas atuais e novas investigações no estudo de sinais biomédicos e fisiológicos complexos. A partir disso, foi estabelecido pelo *Resource* o site *physionet.org* que é seu mecanismo de disseminação e intercâmbio livre e aberto de sinais biomédicos registrados e softwares de código aberto para analisá-los, fornecendo instalações para análise cooperativa de dados e avaliação de novos algoritmos propostos. O site é um serviço público do PhysioNet Research Resource for Complex Physiologic Signals, financiado pelo Instituto Nacional de Ciências Médicas Gerais (NIGMS) e pelo Instituto Nacional de Imagem Biomédica e Bioengenharia (NIBIB), que anualmente lança desafios para o público em geral que visa avanços na área da saúde.

Em 2016, foi proposto pelo PhysioNet o desafio do desenvolvimento de algum algoritmo capaz de classificar gravações do som do coração coletadas em uma variedade de ambientes, com o objetivo de identificar, a partir de uma única gravação curta (10-60s), quais sinais estão em bom estado e quais apresentam certo tipo de arritmia. Para isso, o site disponibilizou gravações de som do coração que foram obtidas de vários contribuidores em todo o mundo, coletados em um ambiente clínico ou não clínico, tanto de indivíduos saudáveis como de pacientes patológicos. O conjunto de treinamento disponível contém um total de 300 gravações de som de coração, que vão de 5 segundos a pouco mais de 120 segundos.

A Figura 3 mostra imagens de 4 sinais disponibilizados pelo *physionet.org*: dois de pacientes saudáveis e dois de pacientes com algum problema cardíaco. Essa representação gráfica dos ruídos cardíacos são chamados de *Fonocardiogramas* (PCG).

As gravações de som do coração foram coletadas de diferentes locais do corpo sendo quatro locais típicos: a área aórtica, a área pulmonônica, a área tricúspide e a área mitral. Elas foram divididas em dois tipos: gravações de som cardíacas normais e anormais. As gravações normais eram

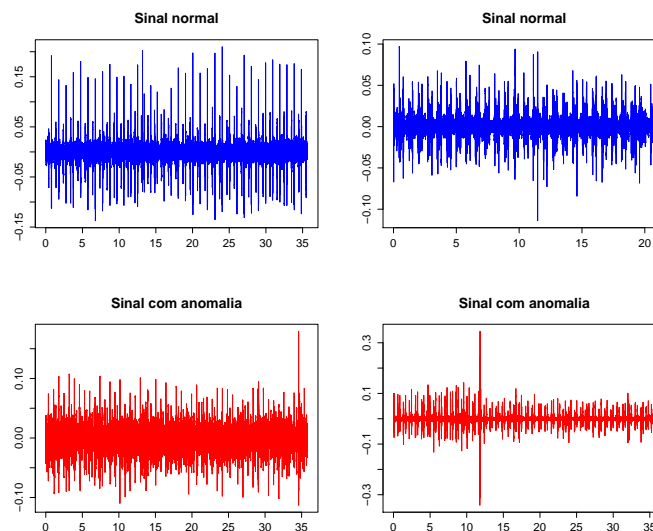


Figura 3: Exemplos de sinais cardíacos sem arritmia (parte superior) e sinais cardíacos com algum tipo de arritmia (parte inferior).

de indivíduos saudáveis e os anormais eram de indivíduos com diagnóstico cardíaco confirmado tais como pacientes que sofrem de uma variedade de doenças que geralmente são defeitos valvares cardíacos e pacientes com doença arterial coronariana. Os defeitos da valva cardíaca incluem o prolapso da valva mitral, regurgitação mitral, estenose aórtica e cirurgia valvular. Todas as gravações desses pacientes foram rotuladas como anormais.

Ambos os indivíduos saudáveis e pacientes patológicos incluem crianças e adultos. Cada um pode ter contribuído entre uma e seis gravações de som do coração que duram de vários segundos até mais de cem segundos. Todos os registros são baseados em 2000 observações por segundo e foram fornecidos em formato .wav.

5 Avaliação do Desempenho dos Métodos de Classificação

Muitas vezes as metodologias utilizadas para a classificação podem apresentar desempenhos diferentes quando comparadas em contextos distintos. Como um sujeito com a doença pode ser classificado como tendo a doença (verdadeiros positivos) ou pode ser classificado como não tendo a doença (falso positivo), também um indivíduo que não tem a doença pode ser classificados como sendo doente (falso negativo) ou não sendo doente (verdadeiro negativo). Assim, quantidade de verdadeiro positivos (VP), Negativos verdadeiros (VN), falso-positivo (FP) e falsos negativos (FN) cobrem todo o conjunto de possibilidades de classificação e os métodos podem apresentar diferenças, por exemplo, quando compara-se a proporção de FP e FN encontrados

por diferentes metodologias. Para uma comparação mais justa e precisa, utilizam-se algumas medidas que levam em consideração essas questões. As medidas mais usuais para avaliar a performance de um método de classificação são

$$\text{Sensitividade: } Se = \frac{VP}{VP + FN}$$

$$\text{Especificidade: } Es = \frac{VN}{FP + VN}$$

$$\text{Precisão/Acurácia: } Pr = \frac{VP + VN}{N}$$

6 Resultados

Podemos observar alguma separação na Figura 4, mais especificamente podemos observar 3 grupos. Como temos a possibilidade de não classificar sinais com muito ruído, podemos utilizar esse mapa para determinar os sinais “normais”, “arritmia” e “não classifica”.




Figura 4: Mapa de calor com matriz de dissimilaridade obtida utilizando a função kernel gaussiano das autocorrelações da energia de Shannon calculada com coeficientes wavelet de quarto e segundo nível.

Os resultados obtidos nesse trabalho podem ser comparados, ou são comparáveis, com os resultados de [Langley e Murray \(2016\)](#) o qual apresenta uma precisão (score) de 78% e seu método




Figura 5: Dendrograma da Figura 4, com os grupos separados por cores. Preto (não classifica), vermelho (anormal) e verde (normal).

é baseado em uma medida de entropia dos coeficientes wavelets. Os resultados preliminares apresentam uma Sensitividade de 57%, Especificidade de 76.92% e uma precisão de 65.73%.

7 Conclusão

Nesse trabalho propomos uma abordagem para classificar sinais cardíacos em dois grupos: Normal e Anormal. Buscamos na literatura alguns métodos que se destacam na realização dessa tarefa e utilizamos algumas de suas ferramentas, como a decomposição wavelet dos sinais e a autocorrelação da energia de Shannon. Para a obtenção de uma matriz de dissimilaridade, foi utilizado a função kernel gaussiano. Então utilizamos um método de agrupamento hierárquico para obter os grupos. Observamos que existem 3 grupos bem definidos no conjunto de dados, o que é razoável já que especificamente para esses dados criou-se uma classe de sinais que eram muito ruidosos para serem classificados. Determinamos quais eram os grupos Normal, Anormal e Não Classifica. A precisão dessa abordagem foi de 65.73%, um pouco distante dos 78% encontrado por um dos participantes do desafio. No entanto, nesse trabalho não foi utilizada nenhuma informação a priori para determinar os grupos. Sendo assim, para a continuidade desse trabalho, pretendemos incorporar essa informação, determinando pequenos grupos de sinais normais e anormais para então classificar um novo elemento. Além disso, pretendemos utilizar as técnicas baseadas em U-estatísticas propostas por [Cybis et al. \(2017\)](#) para colocar inferência em classificação de sinais cardíacos.

Referências

- Cybis, G. B., Valk, M., e Lopes, S. R. (2017). Clustering and classification problems in genetics through u-statistics. *Journal of Statistical Computation and Simulation*, pages 1–21.
- Deng, S.-W. e Han, J.-Q. (2016). Towards heart sound classification without segmentation via autocorrelation feature and diffusion maps. *Future Generation Computer Systems*, 60:13–21.
- Langley, P. e Murray, A. (2016). Abnormal heart sounds detected from short duration unsegmented phonocardiograms by wavelet entropy. In *Computing in Cardiology Conference (CinC), 2016*, pages 545–548. IEEE.
- Leatham, A. (1975). Auscultation of the heart and phonocardiography.
- Liu, C., Springer, D., Li, Q., Moody, B., Juan, R. A., Chorro, F. J., Castells, F., Roig, J. M., Silva, I., Johnson, A. E. W., Syed, Z., Schmidt, S. E., Papadaniil, C. D., Hadjileontiadis, L., Naseri, H., Moukadem, A., Dieterlen, A., Brandt, C., Tang, H., Samieinasab, M., Samieinasab, M. R., Sameni, R., Mark, R. G., e Clifford, G. D. (2016). An open access database for the evaluation of heart sound algorithms. *Physiological Measurement*, 37(12):2181.
- Springer, D. B., Tarassenko, L., e Clifford, G. D. (2016). Logistic regression-hsmm-based heart sound segmentation. *IEEE Transactions on Biomedical Engineering*, 63(4):822–832.