



**UNIVERSIDADE DA INTEGRAÇÃO INTERNACIONAL DA LUSOFONIA AFRO-
BRASILEIRA
INSTITUTO DE ENGENHARIAS E DESENVOLVIMENTO SUSTENTÁVEL
CURSO DE ENGENHARIA DE ENERGIAS**

DÉLCIO AGUIAR JOSÉ BARRETO

**COMPARAÇÃO DE MODELOS MATEMÁTICOS PARA CLASSIFICAÇÃO
MORFOLÓGICA DO COMPLEXO QRS DO SINAL ELETROCARDIOGRAMA**

ACARAPE-CEARÁ

JANEIRO, 2018

DÉLCIO AGUIAR JOSÉ BARRETO

**COMPARAÇÃO DE MODELOS MATEMÁTICOS PARA CLASSIFICAÇÃO
MORFOLÓGICA DO COMPLEXO QRS DO SINAL ELETROCARDIOGRAMA**

Monografia apresentada ao curso de Engenharia de Energias do Instituto de Engenharia e Desenvolvimento Sustentável da Universidade da Integração Internacional da Lusofonia Afro-Brasileira, como requisito para obtenção do Título de Bacharel em Engenharia de Energias.

ACARAPE-CEARÁ

JANEIRO, 2018

DÉLCIO AGUIAR JOSÉ BARRETO

**COMPARAÇÃO DE MODELOS MATEMÁTICOS PARA CLASSIFICAÇÃO
MORFOLÓGICA DO COMPLEXO QRS DO SINAL
ELETROCARDIOGRAMA**

Monografia apresentada ao curso de Engenharia de Energias do Instituto de Engenharia e Desenvolvimento Sustentável da Universidade da Integração Internacional da Lusofonia Afro-Brasileira, como requisito para obtenção do Título de Bacharel em Engenharia de Energias.

Aprovado em 31 / 1 / 18.

BANCA EXAMINADORA



Prof. Dr. João Paulo do Vale Madeiro (Orientador)

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)



Prof. Dr. John Hebert da Silva Félix

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)



Prof. Dr. Antonio Alisson Pessoa Guimarães

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)

Universidade da Integração Internacional da Lusofonia Afro-Brasileira
Sistema de Bibliotecas da UNILAB
Catalogação de Publicação na Fonte.

Barreto, Delcio Aguiar Jose.

B261c

Comparação de modelos matemáticos para classificação morfológica do complexo QRS do sinal eletrocardiograma / Delcio Aguiar Jose Barreto. - Acarape, 2018.
0f: il.

Monografia - Curso de Engenharia de Energias, Instituto de Engenharias e Desenvolvimento Sustentável, Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Redenção, 2018.

Orientador: Prof. Dr. João Paulo do Vale Madeiro.

1. Eletrocardiografia. 2. Sinal ECG. 3. Complexo QRS. 4. Transformada Wavelet. I. Título

CE/UF/BSCL

CDD 616.1207547

*Dedico este trabalho aos meus pais
como um tributo pelo apoio
incondicional durante toda a minha
vida académica.*

Agradecimentos

Agradeço a todos que deram o seu contributo para a realização deste trabalho, em especialmente:

A Deus, por estar sempre presente durante a minha caminhada.

Aos meus pais pelo incentivo e apoio inexorável durante a minha trajetória estudantil.

Aos meus familiares e amigos por me incentivarem durante a minha jornada.

Ao meu orientador por desempenhar um papel determinante na elaboração deste trabalho.

Aos meus colegas e professores pelo auxílio e apoio em inúmeros momentos.

E à UNILAB por proporcionar experiências inovadoras e determinantes no meu quotidiano.

RESUMO

O uso do sinal eletrocardiograma (ECG) é mundialmente aceito como padrão ouro no diagnóstico não invasivo de arritmias e distúrbios de condução. Considerando-se que a extração automática de parâmetros do ECG é iniciada com a segmentação de suas ondas características, o presente trabalho tem como objetivo apresentar um estudo comparativo do desempenho de diferentes *kernels* para a modelagem matemática e a classificação morfológica do complexo QRS do sinal ECG, dado que as diversas morfologias identificadas podem estar ou não associadas a eventos adversos. Inicialmente, utilizou-se um simulador computacional de geração de sinais sintéticos a partir de modelos dinâmicos com análise de variação de um conjunto de parâmetros (batimento cardíaco, frequência de amostragem, duração do sinal, amplitude do ruído gaussiano, média e desvio-padrão de frequência cardíaca, relação entre os componentes de frequência LF (Low Frequency) e HF (High Frequency), duração, amplitude e morfologia do complexo QRS). A partir da geração de vinte diferentes tipos de morfologia do complexo QRS, realizaram-se testes computacionais de modelagem matemática da forma de onda do batimento (ondas Q, R e S). Para tanto, foram empregadas as seguintes funções matemáticas: função Gaussiana, função Chapéu Mexicano e função densidade de probabilidade de Rayleigh. Posteriormente, utilizaram-se 10 registros de sinais reais, com trinta minutos de duração, de referência da base de dados MIT-BIH (*Massachusetts Institute Technology - Beth Israel Hospital*) *Arrhythmia database*, e através de simulações computacionais, testou-se a conformação das funções propostas a um conjunto de morfologias disponíveis na base. A partir de resultados preliminares obtidos, constata-se que as funções matemáticas propostas com parâmetros ajustáveis podem ser aplicadas conjuntamente para modelagem e classificação automática de tipos de batimentos comumente presentes em sinais reais, com eficiência e precisão. O cálculo do erro RMS normalizado permite a diferenciação e a identificação do modelo mais apropriado a uma dada morfologia, a qual pode alternar-se ao longo de um mesmo registro de paciente.

Palavras-Chave: Sinal ECG; Complexo QRS; Transformada Wavelet; Transformada de Hilbert; Erro RMS Normalizado.

ABSTRACT

The use of the electrocardiogram (ECG) signal is globally accepted as a gold standard in the noninvasive diagnosis of arrhythmias and conduction disorders. Considering that the automatic extraction of ECG parameters is initiated with the segmentation of its characteristic waves, the present work aims to present a comparative study of the performance of different kernels for mathematical modeling and morphological classification of the QRS complex of the ECG signal. Some of identified morphologies may be associated with adverse events. Initially, we use a computer simulator to generate synthetic signals from dynamic models and to analyze variations of a set of parameters (heart rate, sampling frequency, signal duration, Gaussian noise amplitude, mean and standard deviation of heart rate, relationship between LF (Low Frequency) and HF (High Frequency) components, duration, amplitude and morphology of the QRS complex). From the generation of twenty different types of QRS morphology, computational tests for mathematical modeling of the beat waveform (Q, R and S waves) were performed. For that, the following mathematical functions were employed: Gaussian function, Mexican Hat function and Rayleigh probability density function. Subsequently, 10 real signal registers were used, with a reference time of 30 minutes, from the MIT-BIH (*Massachusetts Institute Technology - Beth Israel Hospital*) Arrhythmia database. Through computational simulations, the proposed functions were tested for a set of morphologies available in the referred database. The preliminary results demonstrate the proposed mathematical functions with adjustable parameters can be applied together for modeling and automatic classification of types of QRS morphologies commonly present in real signals, with efficiency and precision. The computing of normalized RMS error allows the identification of the model more appropriate to a given morphology, which can change over the same patient record.

Keywords: ECG signal; QRS complex; Mathematical Modeling; Wavelet Transform; Hilbert Transform; Noise.

LISTAS DE FIGURAS

| | |
|--|----|
| Figura 1- Principais Componentes de um ECG Normal | 18 |
| Figura 2- Anatomia do Coração | 21 |
| Figura 3- Segmentação do ECG | 23 |
| Figura 4- Representação do potencial elétrico de várias partes do coração | 24 |
| Figura 5- As três derivações de Einthoven..... | 26 |
| Figura 6- Derivações Precordiais | 27 |
| Figura 7- Estrutura comum de duplo-estágio dos detectores de QRS..... | 28 |
| Figura 8- Representação esquemática de várias configurações do complexo QRS | 36 |
| Figura 9- Função Gaussiana | 38 |
| Figura 10- Função Chapéu Mexicano | 39 |
| Figura 11. (a) Exemplos ilustrativos de Função de Densidade de Probabilidade de Rayleigh..... | 41 |
| Figura 11. (b) variante da função de densidade de probabilidade Rayleigh Ciclo Positivo- Negativo | 41 |
| Figura 11. (c) variante da função de densidade de probabilidade Rayleigh Ciclo Negativo- Positivo | 41 |
| Figura 11. (d) variante da função de densidade de probabilidade Rayleigh Ciclo Positivo- Positivo | 41 |
| Figura 12- Morfologias de QRS modeladas pelas funções Gaussianas, Chapéu Mexicano e Rayleigh..... | 44 |
| Figura 13- Morfologias de QRS dos sinais reais em que cada modelo foi vencedor: R, qRs e RS, respetivamente | 46 |
| Figura 14. (a) Exemplo de Morfologia predominante do sinal 234 (canal 1) que foi modelada pelo Modelo 1, exemplificada por 3 batimentos | 51 |
| Figura 14. (b) Exemplo de Morfologia predominante do sinal 220 (canal 1) que foi modelada pelo Modelo 3, exemplificada por 3 batimentos | 51 |

| | |
|---|----|
| Figura 14. (c) Exemplo de Morfologia predominante do sinal 219 (canal 1) que foi modelada pelo Modelo 3, exemplificada por 3 batimentos, e de morfologia que foi modelada pelo Modelo 2, também exemplificada por 3 batimentos..... | 51 |
| Figura 14. (d) Exemplo de Morfologia predominante do sinal 217 (canal 1) que foi modelada pelo Modelo 1, exemplificada por 3 batimentos, e de morfologia que foi modelada pelo Modelo 3, também exemplificada por 3 batimentos..... | 52 |
| Figura 14. (e) Exemplo de Morfologia predominante do sinal 215 (canal 1) que foi modelada pelo Modelo 3, exemplificada por 3 batimentos | 52 |
| Figura 14. (f) Exemplo de Morfologia predominante do sinal 212 (canal 1) que foi modelada pelo Modelo 1, exemplificada por 3 batimentos, e de morfologia que foi modelada pelo Modelo 2, também exemplificada por 3 batimentos..... | 53 |
| Figura 14. (g) Exemplo de Morfologia predominante do sinal 209 (canal 1) que foi modelada pelo Modelo 3, exemplificada por 3 batimentos | 53 |
| Figura 14. (h) Exemplo de Morfologia predominante do sinal 202 (canal 1) que foi modelada pelo Modelo 1 | 53 |
| Figura 14. (i) Exemplo de Morfologia predominante do sinal 201 (canal 1) que foi modelada pelo Modelo 1 | 54 |
| Figura 14. (j) Exemplo de Morfologia predominante do sinal 123 (canal 1) que foi modelada pelo Modelo 3, exemplificada por 3 batimentos, e de morfologia que foi modelada pelo Modelo 2, também exemplificada por 3 batimentos..... | 54 |

LISTAS DE TABELAS

| | |
|---|----|
| Tabela 1: Sequência da atividade atrioventricular..... | 25 |
| Tabela 2: Ranking de menor erro RMS (melhor desempenho) considerando-se os três modelos matemáticos propostos..... | 43 |
| Tabela 3: As 20 Morfologias de QRS modeladas pelas funções Gaussianas, Chapéu Mexicano e Rayleigh..... | 47 |
| Tabela 4: Ranking de menor erro RMS (melhor desempenho) por modelo matemático sobre sinais de base Arrhythmis database..... | 48 |
| Tabela 5: Resultados de aplicação do algoritmo de modelagem para um conjunto de sinais da base Arrhythmia Database..... | 49 |

LISTAS DE EQUAÇÕES

| | |
|--|----|
| Equação 1- Transformada de <i>Hilbert</i> | 31 |
| Equação 2- Transformada de <i>Fourier</i> | 31 |
| Equação 3- Transformada <i>Wavelet</i> Continua | 33 |
| Equação 4- Transformada <i>Wavelet</i> Discreta | 33 |
| Equação 5- Transformada <i>Wavelet</i> Discreta de forma compacta..... | 34 |
| Equação 6- Função Gaussiana..... | 38 |
| Equação 7- Função Chapéu Mexicano (segunda derivada gaussiana) | 38 |
| Equação 8- Função de derivada numérica de Chapéu Mexicano | 39 |
| Equação 9- Função densidade de probabilidade de Rayleigh de tempo discreto | 39 |
| Equação 10- Rayleigh Ciclo Positivo-Negativo..... | 40 |
| Equação 11- Rayleigh Ciclo Negativo-Positivo..... | 40 |
| Equação 12- Rayleigh Ciclo Positivo-Positivo | 40 |
| Equação 13- Erro RMS Normalizado (RMS- Root Mean Square) | 42 |

LISTAS DE ABREVIATURAS E SIGLAS

| | |
|-----------------|---|
| AV | <i>Atrioventricular</i> |
| BPM | <i>Batimentos Por Minuto</i> |
| ECG | <i>Eletrocardiograma</i> |
| FC | <i>Frequência Cardíaca</i> |
| <i>FT</i> | <i>Transformada de Fourier</i> |
| HF | <i>High Frequency</i> |
| HIS | Feixe de His Purkinje |
| TH | <i>Transformada de Hilbert</i> |
| MIT-BIH | <i>Massachusetts Institute Technology - Beth Israel</i> |
| <i>Hospital</i> | |
| LF | <i>Low Frequency</i> |
| SA | <i>Sinusal</i> |
| WT | <i>Transformada Wavelet</i> |
| WTF | Windowed Transform Fourier |

SUMÁRIO

| | |
|--|----|
| 1. INTRODUÇÃO | 15 |
| 1.1. CONTEXTUALIZAÇÃO HISTÓRICA..... | 15 |
| 1.2. JUSTIFICATIVA | 17 |
| 1.3. OBJETIVOS | 19 |
| 1.3.1. OBJETIVO GERAL..... | 19 |
| 1.3.2. OBJETIVOS ESPECÍFICOS | 19 |
| 1.4. ESTRUTURA DO TRABALHO | 20 |
| 2. FUNDAMENTAÇÃO TEÓRICA | 21 |
| 2.1. ATIVIDADE ELÉTRICA CARDÍACA | 21 |
| 2.2. DESPOLARIZAÇÃO E REPOLARIZAÇÃO | 22 |
| 2.3. BIOPOTENCIAIS CARDÍACOS | 23 |
| 2.4. FORMAÇÃO DA ATIVIDADE ELÉTRICA CARDÍACA | 24 |
| 2.5. CONDUÇÃO DA ATIVIDADE ELÉTRICA CARDÍACA | 24 |
| 2.6. DERIVAÇÕES ELETROCARDIOGRÁFICAS | 25 |
| 3. DETECÇÃO DO COMPLEXO QRS | 27 |
| 3.1. TRANSFORMADAS WAVELET E HILBERT | 29 |
| 3.1.1 TRANSFORMADA DE HILBERT | 30 |
| 3.1.2 TRANSFORMADA DE WAVELET | 31 |
| 3.1.2.1. TRANSFORMADA DE WAVELET CONTINUA | 32 |
| 3.1.2.2. TRANSFORMADA DE WAVELET DISCRETA | 33 |
| 4. METODOLOGIA | 35 |
| 4.1. MÉTODOS | 35 |
| 4.2. KERNELS PROPOSTOS | 36 |
| 4.2.1. FUNÇÃO GAUSSIANA | 38 |
| 4.2.2. FUNÇÃO CHAPÉU MEXICANO | 38 |
| 4.2.3. FUNÇÃO DENSIDADE DE PROBABILIDADE DE RAYLEITH | 39 |

| | |
|--|-----------|
| 4.2.4. ERRO RMS NORMALIZADO | 42 |
| 4.3. SOFTWARE | 42 |
| 5. RESULTADOS E DISCUSSÃO | 43 |
| 6. CONCLUSÃO E TRABALHOS FUTUROS | 56 |
| REFERÊNCIAS | 57 |
| APÊNDICE A- AMOSTRA DE RESULTADOS | 61 |

1. INTRODUÇÃO

1.1. CONTEXTUALIZAÇÃO HISTÓRICA

O uso do exame eletrocardiograma representa uma ferramenta primordial no diagnóstico primário, prognóstico e análise de doenças cardíacas. A invenção do eletrocardiograma por Willem Einthoven, em 1902, foi um marco histórico na Medicina, na qual contribuiu progressivamente para inúmeros diagnósticos. Com o desenvolvimento da eletrocardiografia foi possível o emprego de tecnologias que amplificaram o conhecimento sobre arritmias e distúrbios de condução (GIFFONI e TORRES, 2010).

Salienta-se o feito preconizado pelo Dr. Luigi Galvani, em 1786, médico e físico Italiano da Universidade de Bolonha, que forneceu uma contribuição significativa quando evidenciou a corrente elétrica registrada no músculo dos esqueletos em um sapo. Posteriormente, o Dr. Carlo Matteucci, em 1842, demonstrou que a corrente elétrica acompanha todos os batimentos cardíacos do sapo. Prontamente, três décadas depois, Augustus Waller, fisiologista Britânico na Universidade de Medicina de St. Mary publicou o primeiro eletrocardiograma humano usando um eletrômetro capilar e eletrodos colocados no tórax, bem como, nas costas de um indivíduo. Waller demonstrou que a atividade elétrica precedeu a contração ventricular. Em seguida, em 1891, William Bayliss e Edward Starling evidenciaram a atividade elétrica cardíaca trifásica utilizando um eletrômetro capilar melhorado (ALGHATRIF et al ,2012).

Conforme mencionado acima, o maior marco para a eletrocardiografia foi realizado por Willem Einthoven, pois inspirado pelos trabalhos de Waller e todos os outros trabalhos anteriores, aprimorou o eletrômetro capilar e pôde demonstrar cinco desvios, então denominados de ABCDE. Einthoven para realizar o ajustamento da inércia ao sistema capilar implementou uma correção matemática, que resultou nas deflexões observadas atualmente. Utilizando a tradição matemática utilizada por Descartes o fisiologista nomeou essas deflexões pela parte terminal da série do alfabeto (PQRST). Outras contribuições significativas realizadas pelo fisiologista foram o desenvolvimento de um galvanômetro de alta sensibilidade e a redução

do número necessário de eletrodos de cinco para três, excluindo os eletrodos de menor rendimento (STEIN, 2001).

É crível denotar que a interpretação do eletrocardiograma através dos algoritmos computacionais tem-se verificado com maior incidência nos últimos anos, pois o uso do eletrocardiograma é considerado um método de referência para inúmeros diagnósticos, constituindo-se um marcador de doenças cardíacas (OLIVEIRA, 2007).

A extração automática de parâmetros do ECG compreende um conjunto de etapas, que se iniciam com a detecção e a segmentação de suas ondas características. A correta detecção das depleções QRS e o seu respetivo delineamento são condições fundamentais para a detecção e segmentação eficiente das outras ondas características do ECG. Ademais, servem de alicerce para os algoritmos de reconhecimento de padrões de arritmias cardíacas (MADEIRO et al, 2015).

É relevante citar que o traçado do sinal ECG apresenta uma infinidade de formatos possíveis, dependendo de situações e condições físico-emocionais em que o indivíduo se encontra, do ruído proveniente do ambiente, de cada indivíduo em si, da modulação da amplitude do sinal de acordo com a respiração e os ruídos dos dispositivos eletro-cirúrgicos (MADEIRO, 2013).

No que concerne a detecção do complexo QRS vários estudos comprovam o uso das transformadas matemáticas Wavelet e Hilbert na detecção e segmentação do complexo QRS, como por exemplo: (MADEIRO, 2013 e MADEIRO et al, 2012; OLIVEIRA, 2007; MANZAN, WILLIAM e BARBAR, JAMIL. 2004), entre outros.

De acordo com Oliveira (2007), existem ainda outros métodos utilizados na detecção e segmentação do complexo QRS como redes neurais artificiais, bancos de filtros, filtros adaptativos e derivativos.

Nesse sentido tem-se verificado inúmeros avanços relacionados à extração automática de parâmetros do sinal ECG e atualmente denota-se a existência de um grande número de doenças fisiopatológicas que podem ser diagnosticadas com o auxílio de ferramentas e técnicas de engenharia possibilitando o aumento do emprego do eletrocardiograma no cotidiano.

Partindo desse pressuposto, este trabalho objetiva a modelagem e classificação morfológica do complexo QRS do sinal ECG contribuindo para a disseminação do estudo do eletrocardiograma no espaço acadêmico e científico.

1.2. JUSTIFICATIVA

Milhões de pessoas são afetadas anualmente por doenças cardiovasculares, tornando-se imprescindível o advento de técnicas computacionais para auxílio ao diagnóstico médico. Atualmente, as doenças cardiovasculares representam a maior causa de morte de pessoas no Brasil. Com o desenvolvimento de tecnologias para o diagnóstico da doença, a tendência é de redução dos riscos de mortalidade por doenças cardiovasculares no Brasil e no Mundo. Entretanto projeções recentes indicam um aumento da sua importância relativa em países de baixo e médio desenvolvimento. A adoção dos modos de vida com maior exposição a fatores de risco tais como o tabagismo, sedentarismo, alimentos ricos em gorduras saturadas com consequente aumento dos níveis de colesterol e hipertensão, incrementa o aumento deste fenômeno (ISHITANI et al ,2006).

Numa perspectiva global, as doenças cardiovasculares têm aumentado significativamente, sendo a hipertensão a principal causa de mortalidade e morbidade a nível global. Denota-se que no continente africano este fenômeno tem-se verificado com maior incidência, pois estudos indicam que embora a pressão arterial alta fosse praticamente inexistente no continente africano na primeira parte do século XX, estimativas mostram que mais de 40% dos adultos têm hipertensão servindo de prova irrefutável do predomínio da doença no continente como uma séria ameaça para a saúde da população sendo o tratamento e a prevenção cruciais para salvaguarda continental (CAMH, 2013).

Com o desenvolvimento da tecnologia e a progressiva evolução da Engenharia aplicada à Medicina tornou-se possível o desenvolvimento de dispositivos e soluções para análises de diversos sinais vitais. Destaca-se o uso do Eletrocardiograma (ECG) como um marcador significativo na detecção de doenças cardiovasculares (ARDHAPURKAR et al., 2012).

O eletrocardiograma é um registro dos potenciais elétricos gerados pela atividade cardíaca através do uso de eletrodos dispostos na superfície corporal, considerado padrão ouro no diagnóstico não invasivo de arritmias e distúrbios de condução (MADEIRO, 2013).

O ECG, basicamente é constituído por um conjunto de ondas que compõem a sucessão de ciclos cardíacos. Segundo Neto (2010), a depleção denominada “onda P” é causada pela despolarização atrial, antes da contração do átrio. O complexo QRS é formado pelas deflexões negativas Q e S e pela deflexão positiva R, estando relacionado aos potenciais gerados pela despolarização ventricular, antes de sua contração. A deflexão denominada “onda T” é produzida pelo retorno do potencial de membrana das fibras musculares ventriculares a seu valor de repouso (repolarização ventricular) ao término da contração. As ondas característica do ciclo de um sinal ECG padrão são apresentadas na Figura 1.

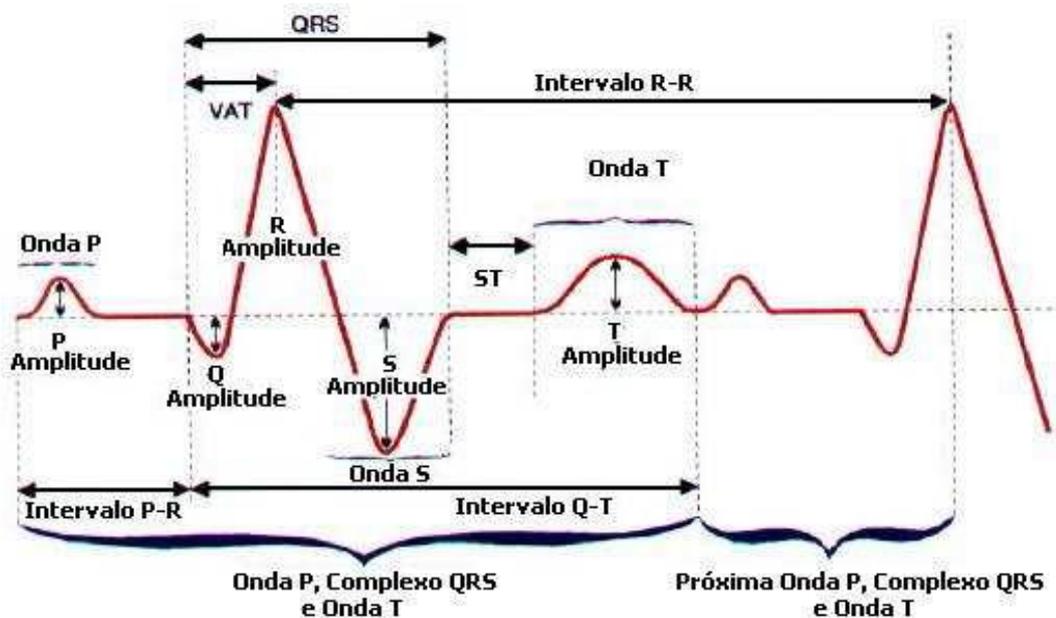


Figura 1- Principais componentes de um ECG padrão.

Fonte: Neto, 2010.

Atualmente, as disseminações de inúmeros estudos no aprimoramento de técnicas de processamento dos sinais ECG evidenciaram em uma melhoria significativa na detecção e segmentação das suas ondas características.

Entretanto, os inúmeros métodos existentes combinados não possibilitam uma referência padrão e universal para detecção de alguns eventos, como a detecção e a segmentação das ondas P e T que apresentam, em geral, amplitudes e energias inferiores ao complexo QRS, sofrendo facilmente os efeitos das interferências e ruídos incidentes no ECG (MADEIRO, 2013).

Não obstante, a detecção e a segmentação do complexo QRS do eletrocardiograma ainda continuam como importante objeto de estudo e de disseminação de pesquisas na área de Engenharia Biomédica. Diante do exposto, o presente trabalho apresenta um estudo do

desempenho de diferentes *kernels* ou funções matemáticas, sobre a modelagem do complexo QRS do sinal ECG, auxiliando e contribuindo para a disseminação da relevância do sinal ECG no espaço acadêmico.

1.3. OBJETIVOS

1.3.1. OBJETIVO GERAL

Comparar o desempenho de cinco diferentes *kernels* para modelagem matemática e classificação morfológica do complexo QRS do Eletrocardiograma.

1.3.2. OBJETIVOS ESPECÍFICOS

Visando prontamente o objetivo geral deste trabalho, alguns objetivos específicos são elencados:

- Estudar os fundamentos de fisiologia do coração, bem como de interpretação clínica do sinal ECG;
- Identificar os aspectos morfológicos das ondas características do sinal ECG segundo diretrizes da Sociedade Brasileira de Cardiologia;
- Recolher dados sobre a implementação de métodos de segmentação automática do Sinal ECG;
- Estudar os conceitos de métodos computacionais dinâmicos para síntese de sinais ECG artificiais;
- Implementar os métodos de detecção e segmentação do complexo QRS com base em modelagem matemática;
- Propor e adaptar *kernels* matemáticos que possam aproximar o traçado de morfologias do complexo QRS.

1.4 ESTRUTURA DE TRABALHO

Esta monografia é dividida em seis capítulos, sendo o primeiro dedicado a contextualizar o estudo de sinais ECG e propor os objetivos do trabalho.

O segundo capítulo destina-se à fundamentação teórica, provendo maior detalhamento e descrição dos assuntos abordados a partir de uma revisão teórica da literatura.

No terceiro capítulo, apresenta-se uma elucidação da detecção e segmentação do complexo QRS do eletrocardiograma e uma abordagem sobre as transformadas Wavelet e Hilbert aplicadas na detecção e segmentação do complexo QRS.

No capítulo subsequente, apresenta-se a metodologia utilizada no desenvolvimento de *kernels* para modelagem matemática do complexo QRS do sinal ECG: função Gaussiana, Chapéu Mexicano (2ª Derivada da função Gaussiana) e Densidade de Probabilidade de Rayleigh. Em seguida, detalha-se o algoritmo proposto para teste de modelagem e identificação dos *kernels* mais adaptados, ou seja, que melhor modelam um conjunto de morfologias de QRS sugeridos pela literatura.

No quinto capítulo, apresentam-se e discutem-se os resultados obtidos a partir de simulações computacionais sobre sinais sintéticos e sinais reais originados da base pública de sinais MIT-BIH ARRHYTHMIA DATABASE. Por fim, no sexto capítulo são apresentadas as conclusões e as sugestões de trabalhos futuros.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. ATIVIDADE ELÉTRICA CARDÍACA

O coração é um sistema formado por duas bombas separadas: o coração direito que impulsiona o sangue para os pulmões e o coração esquerdo que bombeia o sangue para os órgãos periféricos. Por conseguinte, cada uma dessas bombas é formada por um átrio, um ventrículo e válvulas. Os mecanismos especiais do coração são responsáveis por sucessões contínuas de contração cardíaca, transmitindo potenciais de ação pelo miocárdio (GUYTON, 2006). A Figura 2 ilustra a anatomia do coração humano.

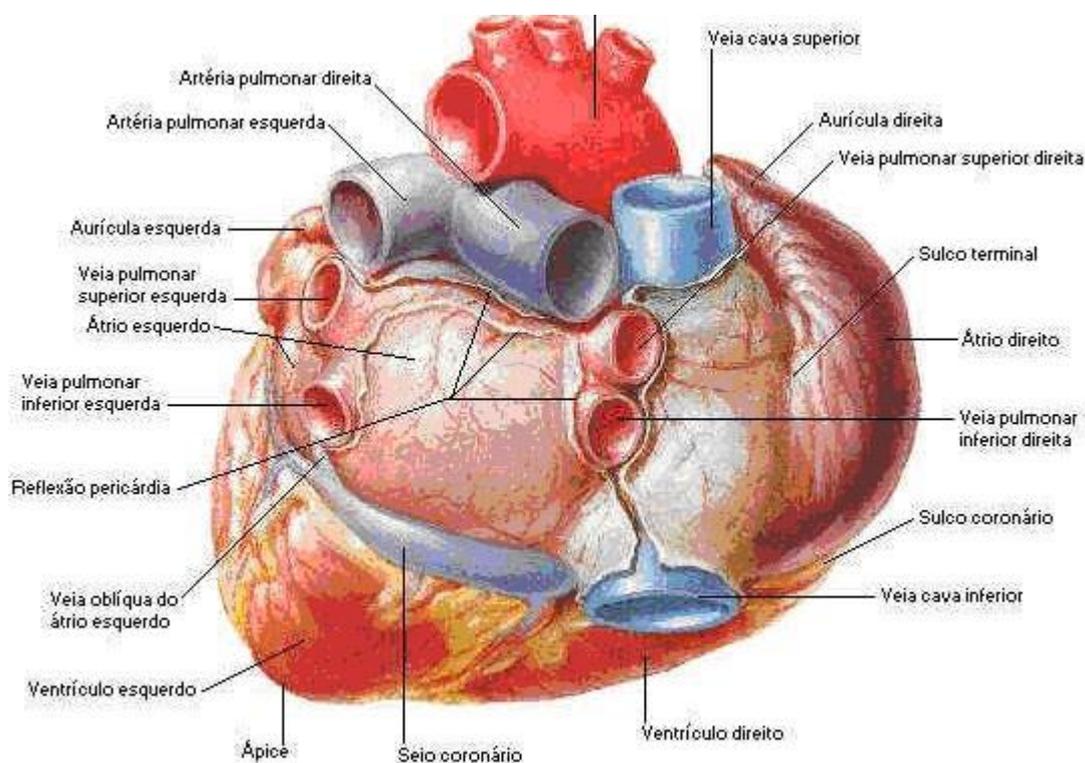


Figura 2- Anatomia do Coração.

Fonte: Vier, 2008.

Conforme Guyton (2006), as quatro válvulas distintas do coração permitem o sentido do fluxo do sangue em um único sentido, impedindo seu refluxo. São duas válvulas atrioventriculares, que regulam a passagem do sangue dos átrios para os ventrículos, e duas semilunares que permitem a saída do sangue dos ventrículos para a artéria pulmonar e a aorta, impedindo seu retorno. Ainda de acordo com o autor, o batimento cardíaco se inicia por um

pequeno pulso de corrente elétrica, que se propaga rapidamente pelo coração, fazendo sua musculatura contrair. Caso toda musculatura contraísse ao mesmo tempo não haveria efeito de bombeamento. Então o início da atividade elétrica se dá no topo do coração e se propaga para baixo e posteriormente inicia o novo ciclo no topo.

2.2. DESPOLARIZAÇÃO E REPOLARIZAÇÃO

Conforme citado anteriormente, o eletrocardiograma é o registro de eventos elétricos do coração, originado a partir do fluxo de corrente que apresenta carga positiva e negativa. Uma célula de fibra do coração que se encontra em repouso é uma célula polarizada, pois apresenta um equilíbrio iônico no seu interior (cargas negativas no interior e cargas positivas no exterior). Quando a célula retorna do seu ponto de repouso, o processo é denominado de repolarização (VIEIRA et al , 2008?).

O processo de despolarização inicia quando a célula recebe uma descarga elétrica, rompendo assim o equilíbrio de cargas positivas e negativas. No caso, acontece uma troca de cargas positivas e negativas, e o efeito é a contração da fibra miocárdica (NETO,2010). A distribuição do ciclo cardíaco em várias ondas representa a excitação e a recuperação de todo o miocárdio (VIEIRA et al, 2008?).

Na interpretação do eletrocardiograma, o coração é dividido em dois segmentos: os átrios representados pela onda P e os ventrículos representados pelas ondas QRS-T. Conforme é mostrado na Figura 3.

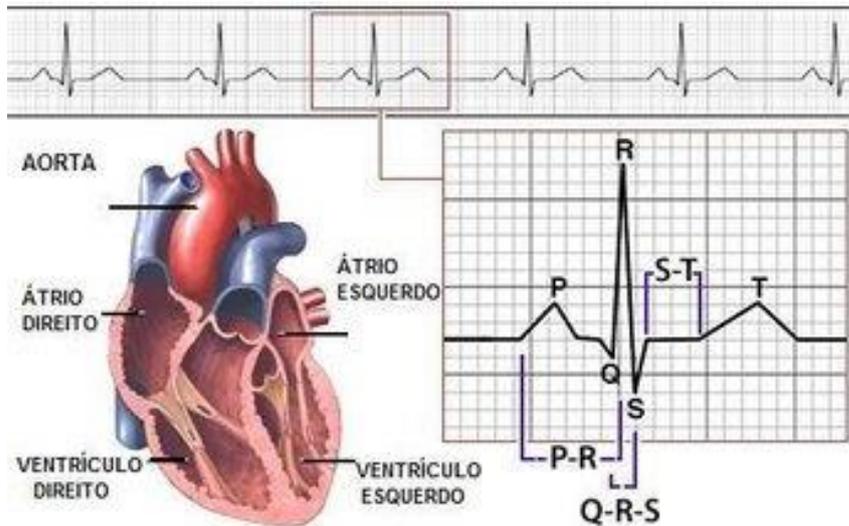


Figura 3- Segmentação do ECG.

Fonte: Vieira et al [2008?]

2.3. BIOPOTENCIAIS CARDÍACOS

De acordo com Guyton (2006), a ritmicidade ou automatismo é uma propriedade da fibra cardíaca que pode ser evidenciada em um coração exposto, que imerso em solução nutritiva continua a bater ritmicamente por muitas horas.

Conforme o autor, o sistema de condução cardíaca é formado pelos seguintes elementos:

- Nó sinusal (ou Modo S-A);
- Nó atrioventricular (ou Nodo A-V);
- Ramo de condução direito (RD);
- Ramo de condução esquerdo (RE);
- Fibras de His-Purkinje (His).

A ritmicidade se origina no nó sinusal ou marcapasso primário do coração. Na Figura 4, é apresentada a representação da atividade elétrica de várias partes do coração.

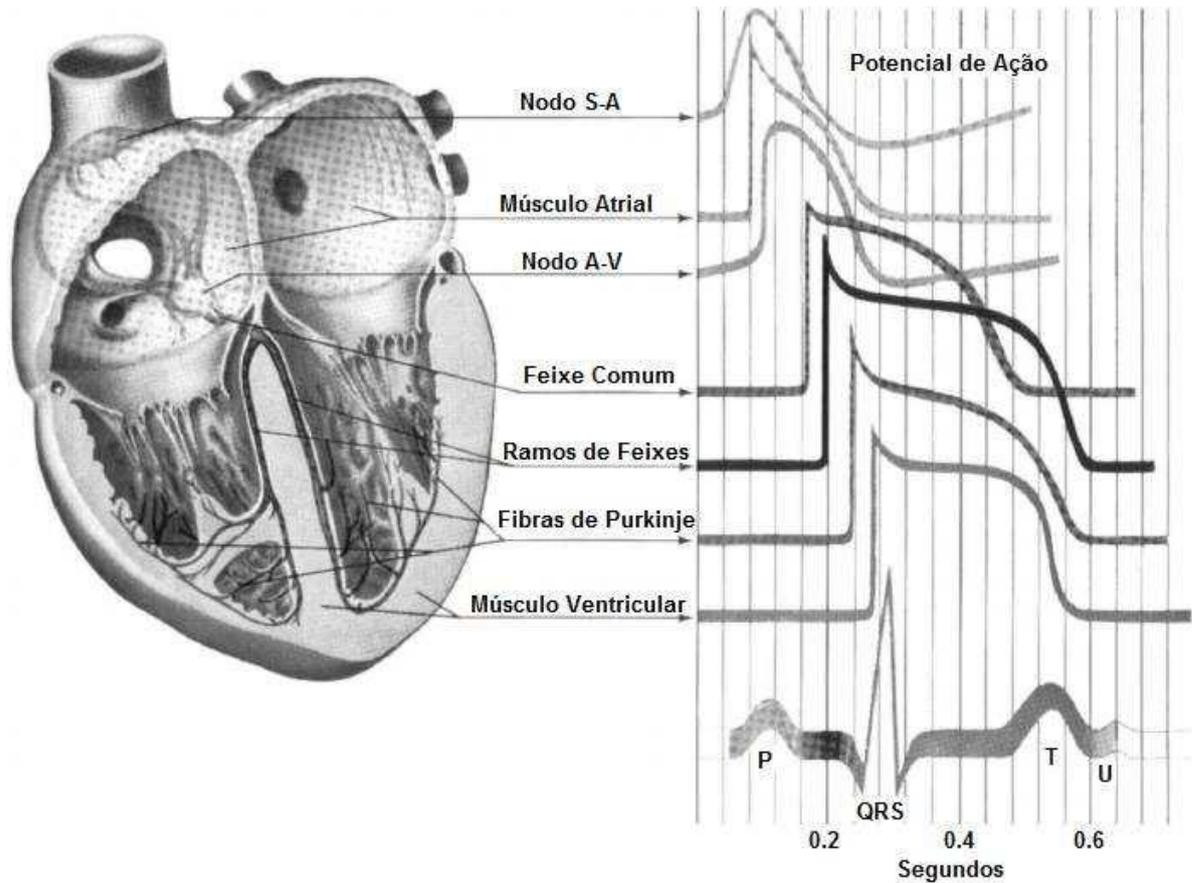


Figura 4- Representação do potencial elétrico de várias partes do coração.
 Fonte: Webster, 1998.

2.4. FORMAÇÃO DA ATIVIDADE ELÉTRICA CARDÍACA

De acordo com Santos (2016), o estímulo que se origina normalmente no nó sinusal estabelece uma frequência cardíaca de 50 a 100 batimentos por minuto (bpm). Além deste, o estímulo pode se originar em outras regiões do coração:

- No nodo atrioventricular: pode formar impulsos de frequência em torno de 50 bpm.
- No sistema His-Purkinje: pode formar impulsos de frequência na ordem de 35 bpm.

2.5. CONDUÇÃO DA ATIVIDADE ELÉTRICA CARDÍACA

De acordo com Santos (2016), o nodo S-A (NSA), localizado na junção da veia cava superior do átrio direito, gera impulsos ativando primeiramente o átrio direito e posteriormente

o átrio esquerdo. Na sequência, atinge o nodo A-V (NAV) e depois alcança os ventrículos. A Tabela 1 evidencia a sequência da atividade atrioventricular.

Tabela 1- Sequência da atividade atrioventricular.

| | |
|--------------------------------|-----------------------|
| Átrio Direito | Início da Onda P |
| Átrio Esquerdo | Final da Onda P |
| NAV | Segmento PR |
| Ativação Septal (Q) | Porção Inicial do QRS |
| Ativação de paredes livres (R) | Porção Média do QRS |
| Ativação de paredes basais (S) | Porção Final do QRS |

Fonte: Modificado de Santos (2016).

2.6. DERIVAÇÕES ELETROCARDIOGRÁFICAS

Generalizando, as Derivações são descritas como a ligação de dois eletrodos com polos elétricos diferentes (positivo e negativo) que captam as diferenças de potencial geradas pelo miocárdio (VIEIRA et al, 2008?).

De acordo com diretrizes do Ministério da Saúde (MS, 2002), o ECG pode ser medido sobre qualquer ponto do corpo humano. No tórax, a amplitude típica é de 5mV. Além disso, o potencial medido sobre o tórax ou o pulso é praticamente o mesmo.

As três derivações bipolares foram criadas por Eithoven na eletrofisiologia (D1, D2, D3) e formam um triângulo equilátero possibilitando a idealização teórica para dedução do eixo elétrico do coração. A Figura 5 mostra o triângulo de Eithoven.

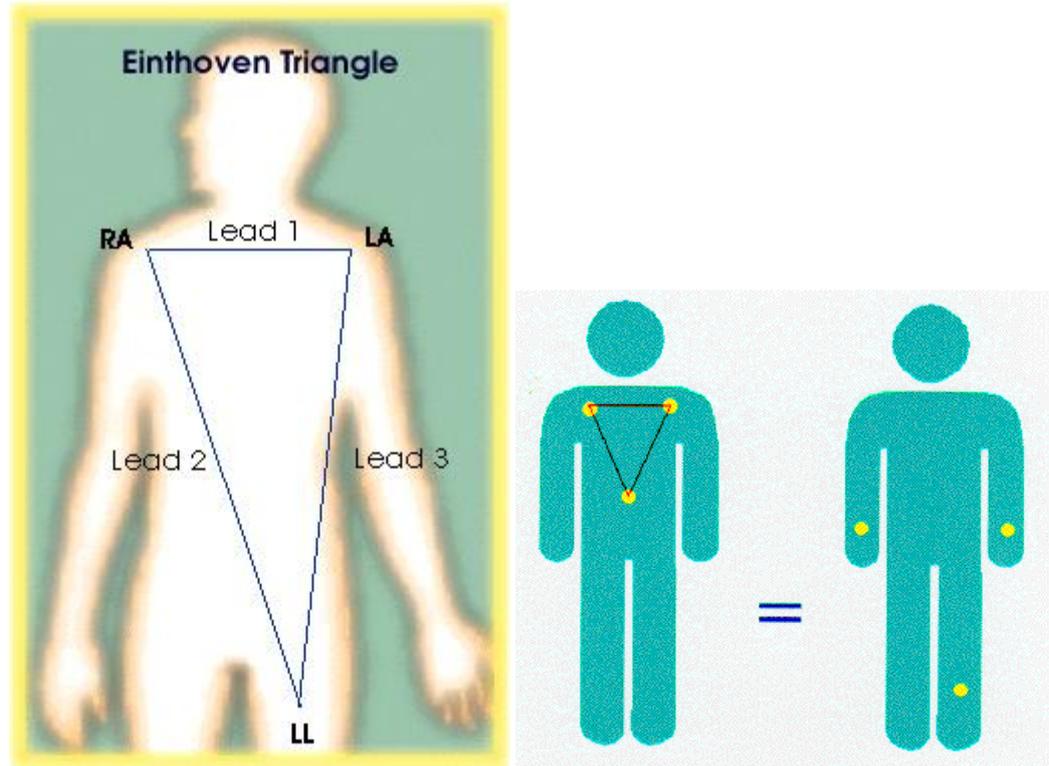


Figura 5- As três derivações de Eithoven.
 Fonte: Vieira et al [2008?]

O termo *RA* refere-se ao potencial absoluto do braço direito, *LA* refere-se ao potencial absoluto do braço esquerdo, e *LL* refere-se ao potencial absoluto da perna esquerda.

Saraiva (2012) salienta que a padronização eletrocardiográfica é formada pela linha que une dois eletrodos, correspondendo ao registro obtido por um eletrodo posicionado em qualquer ponto do corpo. As derivações podem ser classificadas em três tipos: bipolares, unipolares e precordiais. A derivação é dita bipolar quando os dois eletrodos se encontram á mesma distância do ponto de vista elétrico do coração. As Derivações unipolares são aquelas em que o traçado obtido se deve às variações de potencial aferidas por um dos eletrodos dito explorador. Já as derivações precordiais são utilizadas para analisar a atividade elétrica em vários ângulos distintos. Os três tipos de derivações são mostrados na Figura 6.

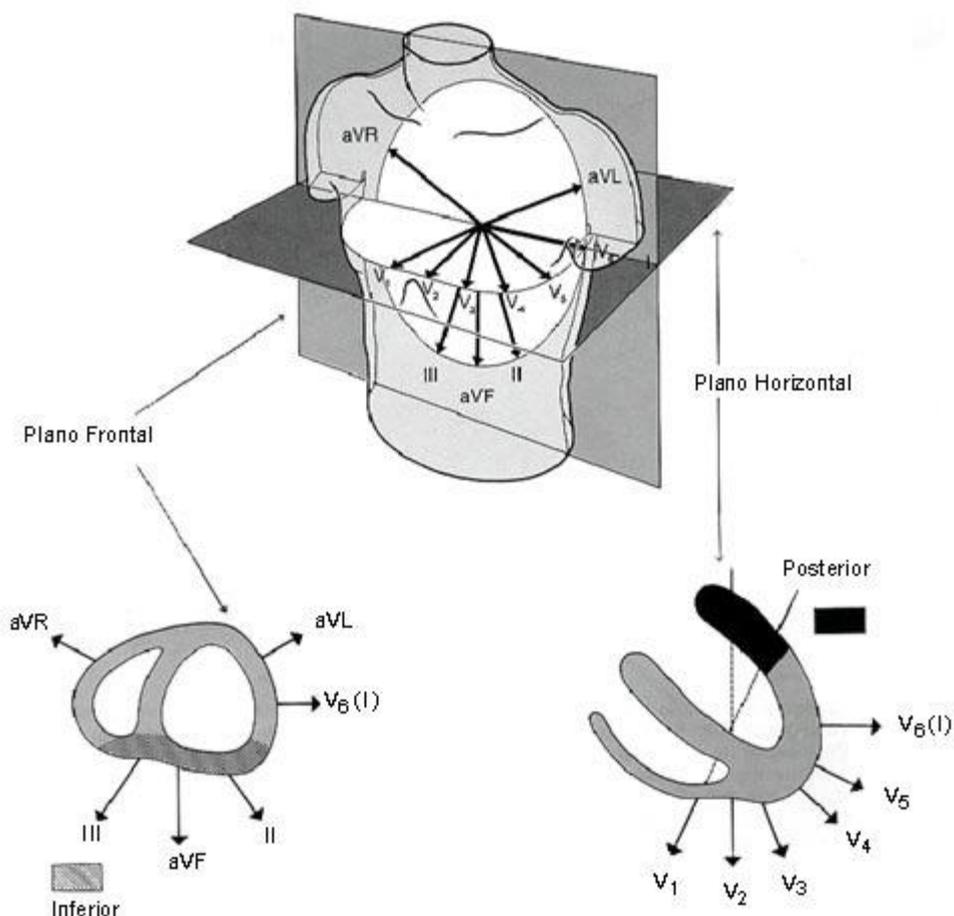


Figura 6- Derivações Precordiais.
 Fonte: (Malmivuo e Plonsey , 1995).

3. DETECÇÃO DO COMPLEXO QRS

A elevada amplitude de seu ponto fiducial, geralmente associada à onda R, torna o complexo QRS como a forma de onda mais distinta de todo o sinal ECG. De facto, esta notabilidade facilita a tarefa de detecção em comparação com as outras ondas características. Assim a correta detecção das depleções QRS e o seu respetivo delineamento são condições fulcrais para a detecção e segmentação eficiente das outras ondas características, bem como servem de alicerce para os algoritmos de reconhecimento de padrões de arritmias cardíacas (MADEIRO et al, 2015 e MADEIRO et al, 2009).

Segundo Oliveira (2007), os complexos QRS e os batimentos ventriculares em um eletrocardiograma representam o fenômeno de despolarização dos ventrículos e fornecem informação pertinente sobre o comportamento dessas câmaras. Adicionalmente, o tempo de

ocorrência de um conjunto de batimentos indica de uma forma generalizada informações sobre o estado atual do coração.

A evolução tecnológica trouxe aos longos dos anos, simplificação ao hardware utilizado para detecção e segmentação do complexo QRS e uma melhoria de software com diversas técnicas propiciando umas detecções mais confiáveis, tais como: os algoritmos baseados em redes neurais artificiais, transformada de *Wavelet*, banco de filtros, filtros adaptativos, filtros casados e cruzamento de zeros. Entretanto, estes métodos são em geral sensíveis às várias fontes de ruídos: interferência de rede elétrica, artefatos de movimento, flutuação da linha de base e os ruídos musculares (OLIVEIRA, 2007).

De acordo com (Oliveira, 2007 e Madeiro, 2013), usualmente dois ou mais canais de ECG são utilizados, a fim de melhorar a confiabilidade na detecção dos complexos QRS, ao invés de usar-se apenas um canal.

Oliveira (2007) e Madeiro et al (2015), salientam que existe uma estrutura algorítmica que é compartilhado pela maioria dos algoritmos. A estrutura é dividida em uma fase de pré-processamento que inclui filtragem linear e/ou não-linear e uma fase de decisão ou lógica de decisão, que inclui a detecção de picos. Frequentemente, um bloco de processo extra é usado para a determinação exata do local temporal do provável QRS. A Figura 7 evidencia o processo de duplo estágio utilizado pela maioria dos algoritmos (KÖHLER; HENNIG; ORGLMEISTER, 2002):

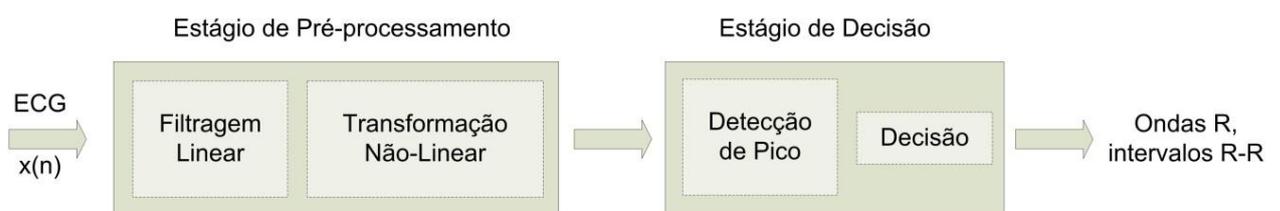


Figura 7- Estrutura comum de duplo-estágio dos detectores de QRS.

Fonte: Madeiro, (2013).

A filtragem linear, geralmente passa-banda, visa atenuar as ondas P e T, os ruídos de alta-frequência e as variações de linha de base. Posteriormente, a transformação não-linear, por exemplo, o filtro quadrático, visa realçar mais intensamente os complexos QRS. As regras de decisão são utilizadas para se determinar em que instantes os complexos QRS efetivamente estão presentes ao longo do sinal.

Para a detecção do complexo QRS foram propostos inúmeros algoritmos pela comunidade científica, destacando-se o algoritmo de Okada, multiplicação das diferenças regressivas (MOBD) e Pan-Tompkins.

De acordo com o artigo publicado por (ALVARADO. W; COSTA. C., 2015), o algoritmo de Pan-Tompkins realiza o reconhecimento do complexo QRS, utilizando limiares ajustados automaticamente de acordo com a morfologia e frequência cardíaca do QRS, o que possibilita uma adaptação periódica às mudanças no ECG e também a filtragem de ruídos significativos. O algoritmo faz uso de duas etapas de processamento: filtragem digital e regras de decisão. No processo de filtragem, o sinal de ECG passa por um filtro passa-faixa com frequências de corte de 5Hz e 15Hz, com o intuito de reduzir a influência das fontes de ruído e melhorar a relação sinal/ruído. Em seguida, a fim de realçar as deflexões de QRS, o sinal é derivado, elevado ao quadrado e então integrado com uma média móvel.

Após a fase de pré-processamento pode-se averiguar os picos do sinal, verificando se são os pontos de máxima amplitude relacionados a onda R. Salienta-se que entre um ponto máximo e outro é respeitado um intervalo que equivale a 20% da frequência de amostragem do sinal. Após o pré-processamento, são realizadas as decisões que atestam e reafirmam a existência do ponto de máxima amplitude do sinal pré-processado (pico R).

Ainda de acordo com os autores supracitados o algoritmo define dois limiares como base para o sinal filtrado. O limiar superior (LS) é tomado como sendo 50% do pico máximo encontrado no sinal filtrado e o limiar inferior (LI) será 50% do LS. A utilização desses limiares permite, ainda, que sejam realizadas análises para determinar os intervalos R-R (distância entre um pico R e o próximo). Por sua vez o algoritmo MOBD utiliza uma transformada não linear de ordem N que por meio de diferenças regressivas detecta zonas de elevados declives no sinal identificando assim o complexo QRS. Já o algoritmo de Okada também faz uso de uma transformada não linear de ordem N, na qual o QRS é identificado pela diferença entre a saída do filtro passa-baixas e a média geométrica de um conjunto de saídas (ALVARADO. W; COSTA. C., 2015).

3.1. AS TRANSFORMADAS DE WAVELET E HILBERT

Atualmente, é crível denotar que as transformadas *Wavelet* e de *Hilbert* destacam-se como ferramentas de pré-processamento e de transformação linear do sinal ECG. A

transformada *Wavelet*, aplicada desde a década de 90, continua sendo proposta junto a uma variedade de metodologias, apresentando-se como um dos métodos de segmentação mais precisos para segmentação das ondas características do sinal ECG (MARTÍNEZ; ALCARAZ; RIETA, 2010).

Li Zheng e Tai (1995) salientam um método baseado na busca por pontos críticos, isto é, valores de máximo em módulo ultrapassando um determinado limiar, obtido a partir do pré-processamento de batimentos iniciais pré-selecionados. O parâmetro de limiar é usualmente atualizado durante a análise, de forma a se obter um melhor desempenho frente a variações repentinas de amplitude do QRS e artefatos oriundos de atividades musculares ou de captação do sinal. Em fase posterior à detecção dos picos pelo limiar adaptativo, ondas R redundantes ou picos de ruído são removidos (LI; ZHENG; TAI, 1995; GHAFFARI; GOLBAYANI; GHASEMI, 2008).

Na metodologia desenvolvida por Martínez et al. (2004), que também utiliza o algoritmo desenvolvido por Li, Zheng e Tai (1995), o complexo QRS está associado, em diferentes versões da transformada *Wavelet* do sinal, a pares de picos de máximo e de mínimo. Aplicando a transformada *Wavelet* diádica (TWD), seu sistema de segmentação identifica os picos, bordas iniciais e finais dos complexos QRS.

A transformada de *Hilbert*, também utilizada desde a década de 90, é empregada no cálculo do envelope de sinal e geralmente vem precedida de um filtro derivativo (BENITEZ et al., 2001; ARZENO; DENG; POON, 2008). Neste caso, as ondas R são mapeadas similarmente como picos na saída do transformador de *Hilbert*. Sua propriedade de não alterar as amplitudes dos componentes de frequência do sinal de entrada, mas apenas a fase, assegura que os conteúdos de informação necessária do complexo QRS sejam preservados.

3.1.1. TRANSFORMADA DE HILBERT

De acordo com Madeiro et al (2012), o uso de transformada de *Hilbert* no processamento do sinal ECG está intrinsecamente relacionado às propriedades de ortogonalidade e de envelope da transformada.

A transformada de *Hilbert* $H[f(t)]$ de uma função $f(t)$ é definida para todo t por (OLIVEIRA, 2007):

$$H[f(t)] = \frac{1}{\pi} p \int_{-\infty}^{+\infty} \frac{f(\tau)}{t-\tau} d\tau \quad (1)$$

Devido ao polo em $\tau = t$, normalmente não é possível o cálculo da transformada de *Hilbert* como uma integral ordinária imprópria. Entretanto, o termo p na frente da integral representa a utilização da técnica do valor principal de *Cauchy*, que permite expandir o número de funções para as quais a integral da Equação (1) existe (HANS, 1996).

3.1.2. TRANSFORMADA WAVELET

A análise do sinal ECG é classicamente baseada em métodos no domínio do tempo. Entretanto, métodos de natureza unicamente temporal são insuficientes para estudar todas as características dos sinais do ECG, sendo relevante a representação da informação do sinal ECG no domínio da frequência (MAYA, 2014).

Uma das técnicas mais importantes para o processamento de sinais é a transformada de Fourier, que tem como objetivo transformar um sinal do domínio do tempo para o domínio da frequência. De acordo com Maya (2014), a transformada de *Fourier* (*FFT- Fast Fourier Transform*) é representada pela seguinte equação:

$$F(w) = \int_{-\infty}^{+\infty} f(t)e^{iwt} dt \quad (2)$$

Esta equação corresponde à transformada de Fourier de um sinal contínuo $f(t)$.

O uso dessa transformada possui como limitações inevitáveis a elucidação de características não estacionárias ou transitórias das informações contidas no sinal.

Devido a necessidade de solucionar esse problema surgiram como alternativas: a Transformada de *Fourier* por Janelas (*WTF - Windowed Transform Fourier*) e a transformada *Wavelet* (*WT- Wavelet Transform*). A WTF é uma adaptação da transformada de *Fourier* que analisa segmentos do sinal no tempo através da transformada por janelas de Fourier. A técnica consiste em deslocar uma janela no domínio do tempo e calcular a transformada de Fourier da porção “visível” do sinal para cada posição da janela (JOHNSON, 2013).

Uma das limitações do uso das WTF está na definição de um valor fixo para o tamanho da janela. Como alguns sinais precisam de um enfoque mais flexível, torna-se adequado que o tamanho da janela possa variar com o objetivo de detectar o conteúdo local e frequência (DAUBECHIES, I, 1990).

Conforme Daubechies (1990), a transformada *Wavelet* é uma ferramenta que mapeia dados ou funções ou operadores em diferentes componentes de frequência e, em seguida, estuda cada componente com uma resolução correspondente à sua escala. Ainda de acordo com o autor supracitado, o uso de transformada *Wavelet* de um sinal envolvendo o tempo depende de duas variáveis: a escala (frequência) e o tempo.

Addison (2005) salienta que dentre os métodos de análise de tempo-frequência, a transformada de *Wavelet* tem sido uma ferramenta prioritária por muitos investigadores para a extração de parâmetros em sinais de grande complexidade em diversas áreas de estudo. Conforme o mesmo autor, o potencial do uso da transformada *Wavelet* reside na capacidade de análise simultânea de informações no domínio do tempo e da frequência com maior flexibilidade do que na transformada de Fourier de tempo curto (STFT-Short Time Fourier Transform). Também permite uma análise espectral local de características individuais do sinal sendo particularmente útil para a avaliação de transientes, aperiodicidade e outros parâmetros não estacionários, em que súbitas alterações na morfologia do sinal podem ser enfatizadas sobre as escalas de interesse.

Enfaticamente a transformada *Wavelet* possui uma variedade de funções *Wavelet* disponíveis, permitindo a sua adequação para um dado sinal ou uma dada morfologia. Citam-se as transformadas *Wavelet* discretas e contínuas.

3.1.2.1. TRANSFORMADA WAVELET CONTÍNUA

De acordo com Domingues et al (2016), a transformada *Wavelet* contínua (CWT) é uma transformada integral linear que pode ser utilizada na exploração de características de sinais não estacionários para extrair informações de variações em certas bandas de frequências e/ou detectar estruturas locais presentes.

Addison (2005) salienta que uma grande variedade de funções protótipos ou *Wavelet*-mães podem ser empregadas, desde que sejam satisfeitos critérios matemáticos pré-definidos.

Dado um sinal f , a transformada *Wavelet* contínua do sinal pode ser definida pela seguinte expressão (Addison, 2005):

$$W_f^{\psi^{(a,b)}} = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \psi^* \frac{t-b}{a} dt \quad (3)$$

O parâmetro a (> 0) se refere à escala e b a translação ou localização da função *Wavelet*-analisadora ψ , sendo a e $b \in \mathbb{R}$. O parâmetro a controla a dilatação/contração da função *Wavelet*-analisadora. À medida que o parâmetro b varia, o sinal f é analisado localmente em diversos instantes. Assim, podem-se analisar os aspectos multiescala do sinal não estacionário estudado. O traço superior em ψ denota o complexo conjugado da função ψ e $W_f^{\psi^{(a,b)}}$ é conhecido como coeficiente *Wavelet* (Domingues et al., 2016).

A função é denominada contínua, pois possui os parâmetros de escala (a) e de translação (τ) contínuos nessa representação.

3.1.2.2. TRANSFORMADA WAVELET DISCRETA

De acordo com Addison (2005), a transformada *Wavelet* discreta emprega uma matriz diádica, com parâmetros de fator de escala (a) e de localização, b , expressos como potências de 2, e funções *Wavelet* ortonormais, isto é, determina-se o valor da transformada apenas para um conjunto discreto finito de escalas e localizações. Ainda de acordo com o autor supracitado, uma forma natural de amostragem dos parâmetros a e b é o uso da discretização logarítmica, relacionando o fator de escala com o tamanho dos passos entre localizações. Este tipo de discretização pode ser representado da seguinte forma:

$$\Psi_{m,n}^t = \frac{1}{\sqrt{a_0^m}} \Psi\left(\frac{t-n b_0 a_0^m}{a_0^m}\right) \quad (4)$$

em que os inteiros m e n controlam, respectivamente, a dilatação (ou escala) e o deslocamento da *Wavelet*, a_0 é um passo ou incremento de escala fixo e b_0 é um passo ou incremento fixo de localização da *Wavelet*. Substituindo-se os valores $a_0 = 2$ e $b_0 = 1$ na equação 4, a função *Wavelet* diádica pode ser escrita na forma compacta:

$$\Psi_{m,n}^t = 2^{\frac{-m}{2}} \psi(2^{-m} t - n) \quad (5)$$

4. METODOLOGIA

4.1. ORGANIZAÇÃO DA PESQUISA

No desenvolvimento da pesquisa, foram seguidos os seguintes passos:

1. Levantamento de dados sobre os métodos e implementação computacional de algoritmos de geração artificial de sinais ECG com parâmetros variáveis, dentre os quais a média e o desvio padrão de intervalos entre batimentos, morfologia das ondas características (ciclo PQRS) e relação sinal/ruído, tomando-se como referência inicial a técnica desenvolvida por MCSHARRY et al., 2003. Também foram elaborados algoritmos de inserção simulada de ruído sobre os sinais ECG sintetizados, correspondente às oscilações da linha de base, interferência da rede elétrica (portadoras de 50 – 60 Hz), contração muscular e ruído branco gaussiano;

2. Levantamento de dados sobre métodos computacionais de filtros lineares e não-lineares clássicos e de aplicação da transformada *Wavelet* para eliminação do ruído do ECG, com a implementação de algoritmos no software *MATLAB* sobre os sinais sintetizados.

3. Implementação de algoritmos de detecção e segmentação do complexo QRS, disponíveis na literatura, sobre sinais ECG artificiais. Propôs-se para a presente monografia o uso da metodologia de detecção baseada na aplicação da função primeira-derivada e das transformadas *Wavelet* e de *Hilbert*, em combinação com técnica do limiar adaptativo (MADEIRO et al, 2012).

O processo de segmentação baseou-se no cálculo de um indicador relacionado à área abrangida pelo envelope do QRS. O envelope corresponde ao sinal analítico obtido a partir da aplicação em série da transformada *Wavelet* e da função primeira-derivada sobre o sinal ECG (parte real) e da aplicação da transformada de *Hilbert* sobre o sinal resultante (parte imaginária) (MADEIRO et al, 2012).

4. Modelagem do complexo QRS sobre os sinais ECG artificiais sintetizados, com base nos modelos matemáticos aplicados. Os modelos matemáticos utilizados para avaliação e teste experimental de modelagem do complexo QRS nesta monografia foram: função Gaussiana, função Chapéu Mexicano e combinação de funções Densidade de Probabilidade de Rayleigh. Para determinação do desempenho dos *kernels* em teste, utilizou-se o erro RMS normalizado (RMS- Root Mean Square).

5. Implementação dos algoritmos de detecção, segmentação e modelagem do complexo QRS sobre 48 registros de sinais reais, com trinta minutos de duração, de referência da base de dados MIT-BIH (*Massachusetts Institute Technology - Beth Israel Hospital*) *Arrhythmia*

database, e através de simulações computacionais, teste de conformação das funções em teste a um conjunto de morfologias disponíveis na base.

São apresentados nesta monografia os resultados de aplicação do algoritmo de modelagem do complexo QRS sobre os registros de dez sinais reais da base Arrhythmia Database, nos quais o modelo vencedor apresenta um percentual de ocorrência acima de 70% para todos os casos.

4.2. KERNELS UTILIZADOS

O complexo QRS possui uma variedade de morfologias e métricas de acordo com as derivações e alterações apresentada pelo paciente. É apresentada na Figura 8 uma representação esquemática de vinte morfologias do complexo QRS.

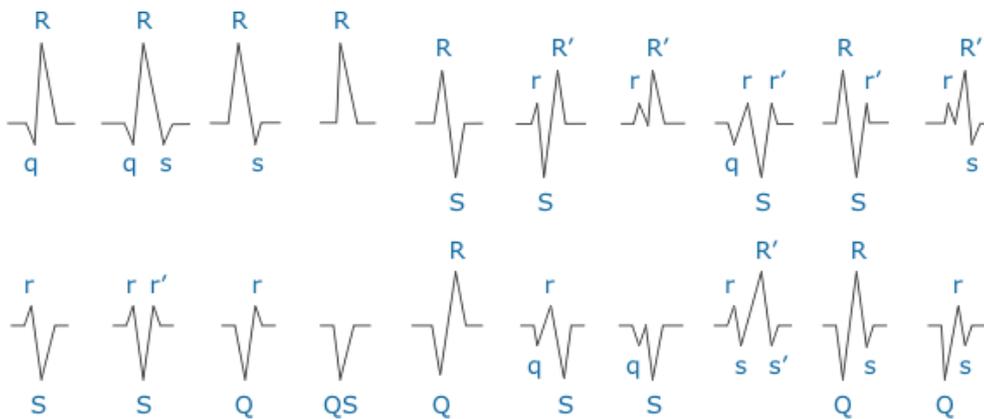


Figura 8- Representação esquemática de vinte morfologias do complexo QRS.

Fonte: Nemirko e Lugowaya, 2005.

Tipicamente, representa-se o complexo QRS de um eletrocardiograma com as deflexões “q” e “s” com menores amplitudes e a deflexão “R” com maior amplitude. Entretanto, cada derivação tem sua morfologia típica com tamanhos e formatos diferentes. Comumente, muitos autores fazem uso das letras minúsculas e maiúsculas para distinguir as diferentes morfologias. Assim, as ondas de maior amplitude recebem a letra maiúscula, e as de menor amplitude recebem a letra minúscula.

A determinação da polaridade das deflexões do QRS tem implicações extremamente relevantes para diversos critérios diagnósticos, sendo fundamentalmente importante para o cálculo de eixo elétrico do eletrocardiograma. No que concerne à polaridade, o complexo QRS

pode ser positivo, negativo ou isodifásico. O complexo QRS é positivo quando a altura da maior onda positiva (R ou R') é maior do que a profundidade da maior onda negativa (Q ou S). Por sua vez, o complexo QRS é negativo quando a altura da maior onda positiva (R ou R') é menor do que a profundidade da maior onda negativa (Q ou S). Por fim, o complexo QRS é isodifásico quando a altura da maior onda positiva e a profundidade da maior onda negativa são semelhantes (NUNES, 2016).

Conforme Madeiro et al (2017), atualmente é uma realidade a utilização de funções matemáticas para modelar o comportamento das ondas características do sinal ECG. Inicialmente, a utilização destas ferramentas visava fornecer subsídios para a análise espectral do sinal real, a partir de uma aproximação. Desta forma, foram propostos determinados modelos com um conjunto de parâmetros ajustáveis para a representação de cada ciclo cardíaco ou batimento, satisfazendo alguns pré-requisitos de precisão.

Na abordagem desenvolvida por Richardson et al (1971), usando-se funções Gaussiana e suas primeira e segunda derivadas, esses três modelos matemáticos são propostos para representar individualmente a onda P, o complexo QRS e a onda T. Em técnicas de extração de parâmetros mais recentes, a modelagem matemática faz parte de uma estrutura de duplo estágio. Num primeiro estágio, derivam-se os parâmetros de uma função matemática que aproxima um determinado segmento do ciclo cardíaco, e num estágio posterior efetua-se a caracterização morfológica das correspondentes formas de onda. A caracterização é desenvolvida através do uso de limiares.

As funções matemáticas ou *kernels* utilizados para modelar o comportamento das ondas características do complexo QRS do sinal ECG são descritas a seguir.

4.2.1 FUNÇÃO GAUSSIANA

Define-se uma função Gaussiana de tempo discreto $G_{\sigma_1}[k]$, com k em um dado intervalo $-x_1 \leq k \leq x_2$, e um desvio-padrão variável σ_1 . A equação que traduz essa função é apresentada como (MADEIRO et al, 2017):

$$G_{\sigma_1}[k] = \frac{1}{\sqrt{2\pi}\sigma_1} \exp\left(-\frac{k^2}{2\sigma_1^2}\right). \quad (6)$$

A Figura 9 mostra um exemplo ilustrativo para o *kernel* obtido com a função Gaussiana de tempo discreto.

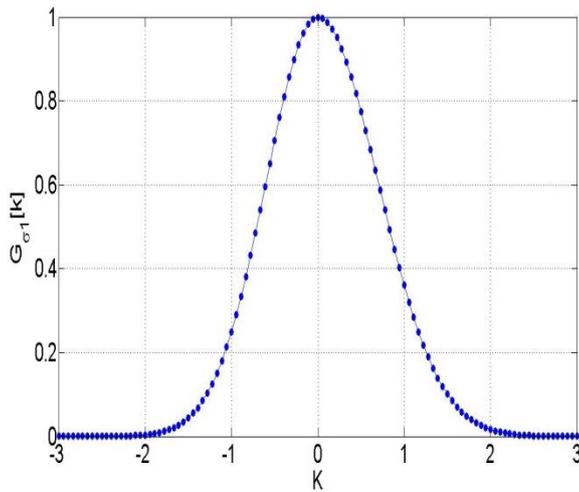


Figura 9- Função Gaussiana.

Fonte: Autor (2018)

4.2.2 FUNÇÃO CHAPÉU MEXICANO

Propõe-se uma modificação para a função Chapéu Mexicano, $G_{\sigma_1, \sigma_2}^d[k]$, correspondente à derivada numérica da composição $G_{\sigma_1, \sigma_2}[k]$ de duas funções Gaussianas de tempo discreto $G_{\sigma_1}[k]$ e $G_{\sigma_2}[k]$, respectivamente com desvios-padrões variáveis σ_1 e σ_2 , ambas definidas para $-x_1 \leq k \leq x_2$, tal que (MADEIRO et al, 2017):

$$G_{\sigma_1, \sigma_2}[k] = \begin{cases} G_{\sigma_1}[k], & -x_1 \leq k \leq 0 \\ G_{\sigma_2}[k], & 0 \leq k \leq x_2 \end{cases} \quad (7)$$

Apresenta-se a seguir a derivada numérica da composição de duas funções gaussianas, calculada na forma de uma diferença regressiva:

$$G_{\sigma_1, \sigma_2}^d[k] = G_{\sigma_1, \sigma_2}[k] - G_{\sigma_1, \sigma_2}[k - 1] \quad (8)$$

A Figura 10 apresenta um exemplo ilustrativo para o *kernel* obtido com a modificação proposta para a função Chapéu Mexicano.

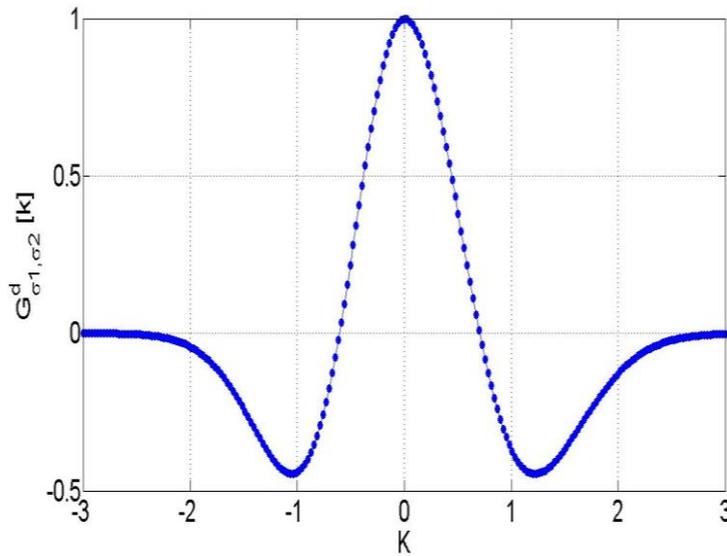


Figura 10- Função Chapéu Mexicano Modificada.

Fonte: Autor (2018)

4.2.3 FUNÇÃO DENSIDADE DE PROBABILIDADE DE RAYLEIGH

Define-se uma função densidade de probabilidade de Rayleigh de tempo-discreto $R_{\sigma_1}[k]$, no intervalo $0 \leq k \leq h$, com um parâmetro variável σ_1 (MADEIRO et al, 2017):

$$R_{\sigma_1}[k] = \frac{k}{\sigma_1^2} \exp\left(-\frac{k^2}{2\sigma_1^2}\right) \quad (9)$$

As três combinações matemáticas de funções Rayleigh utilizadas para modelagem do complexo QRS são: Rayleigh Ciclo Positivo-Negativo, Rayleigh Ciclo Negativo-Positivo e Rayleigh Ciclo Positivo-Positivo.

Rayleigh Ciclo Positivo-Negativo

Para a composição de duas funções Rayleigh (terceiro *kernel* proposto), cuja função resultante denomina-se $R_{\sigma_1, \sigma_2}[k]$, $0 \leq k \leq 2h$, parte-se da utilização de duas funções Rayleigh

de tempo discreto $R_{\sigma_1}[k]$ e $R_{\sigma_2}[k]$, ambas definidas no intervalo $0 \leq k \leq h$, respectivamente com parâmetros variáveis σ_1 e σ_2 , tal que (MADEIRO et al, 2017):

$$R_{\sigma_1, \sigma_2}[k] = \begin{cases} R_{\sigma_1}[h - k], & 0 \leq k \leq h \\ -R_{\sigma_2}[k - h], & h \leq k \leq 2h \end{cases} \quad (10)$$

Rayleigh Ciclo Negativo-Positivo

O quarto *kernel* proposto, $R_{\sigma_1, \sigma_2}[k]$, $0 \leq k \leq 2h$, parte-se da utilização de duas funções Rayleigh de tempo discreto $R_{\sigma_1}[k]$ e $R_{\sigma_2}[k]$, ambas definidas no intervalo $0 \leq k \leq h$, respectivamente com parâmetros variáveis σ_1 e σ_2 , tal que (MADEIRO et al, 2017):

$$R_{\sigma_1, \sigma_2}[k] = \begin{cases} -R_{\sigma_1}[h - k], & 0 \leq k \leq h \\ R_{\sigma_2}[k - h], & h \leq k \leq 2h \end{cases} \quad (11)$$

Rayleigh Ciclo Positivo-Positivo

O quinto *kernel* proposto, $R_{\sigma_1, \sigma_2}[k]$, $0 \leq k \leq 2h$, parte-se da utilização de duas funções Rayleigh de tempo discreto $R_{\sigma_1}[k]$ e $R_{\sigma_2}[k]$, ambas definidas no intervalo $0 \leq k \leq h$, respectivamente com parâmetros variáveis σ_1 e σ_2 , tal que (MADEIRO et al, 2017):

$$R_{\sigma_1, \sigma_2}[k] = \begin{cases} R_{\sigma_1}[h - k], & 0 \leq k \leq h \\ R_{\sigma_2}[k - h], & h \leq k \leq 2h \end{cases} \quad (12)$$

As Figuras 11(a), 11(b), 11(c) e 11(d) mostram, respectivamente, exemplos ilustrativos de função densidade de probabilidade de Rayleigh, combinação de funções densidade de probabilidade de Rayleigh Ciclo Positivo-Negativo, combinação de funções densidade de probabilidade de Rayleigh Ciclo Negativo-Positivo e combinação de funções densidade de probabilidade de Rayleigh Ciclo Positivo-Positivo.

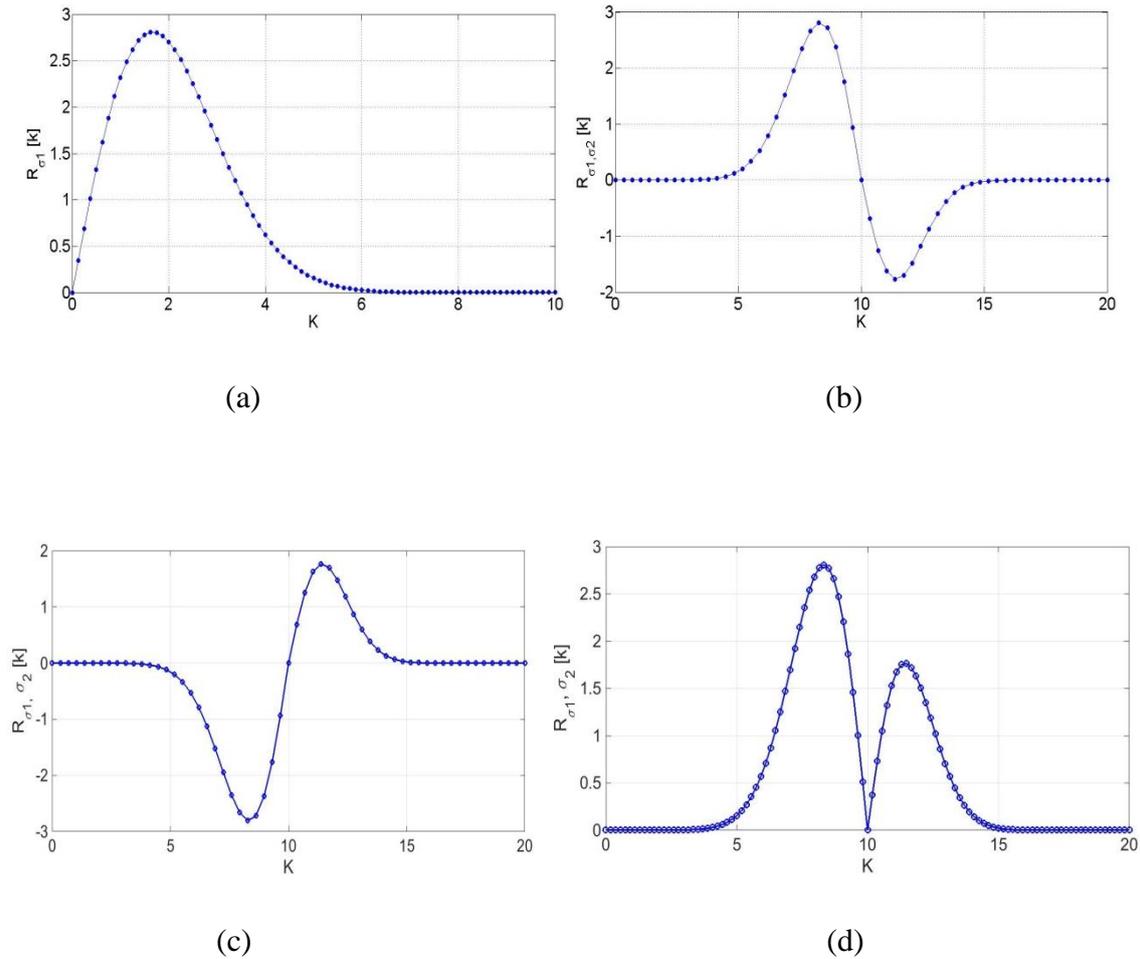


Figura 11: Exemplos ilustrativos de (a) função densidade de probabilidade de Rayleigh; (b) combinação de funções densidade de probabilidade de Rayleigh Ciclo Positivo-Negativo; (c) combinação de funções densidade de probabilidade de Rayleigh Ciclo Negativo-Positivo e (d) combinação de funções densidade de probabilidade de Rayleigh Ciclo Positivo-Positivo. Fonte: Autor (2018).

Cada um dos *kernels* utilizados possui um ou dois parâmetros específicos, correspondendo aos desvios-padrões σ_1 e σ_2 . Para cada *kernel*, estabelece-se um processo de adaptação ou conformação com cada forma de onda, variando-se os correspondentes parâmetros sobre uma faixa predefinida de [0,2; 1,5].

4.3 ERRO RMS NORMALIZADO (*RMS - ROOT MEAN SQUARE*)

O erro RMS normalizado é uma ferramenta estatística muito utilizada atualmente como métrica para medir o desempenho de modelos matemático-computacionais em diversas áreas.

A expressão que representa o erro RMS normalizado é (Martínez *et. al.*, 2015):

$$\varepsilon = \sqrt{\frac{\sum_{k=1}^L |W_X[k] - \tilde{W}_X[k]|^2}{\sum_{k=1}^L W_X[k]^2}}, \quad (11)$$

em que $W_X[k]$ refere-se à janela do sinal real que se deseja modelar, e $\tilde{W}_X[k]$ refere-se ao *kernel* avaliado.

4.4 SOFTWARE UTILIZADO

Para análise computacional dos resultados, utilizou-se o software MATLAB r2014b, pois é definido em muitas literaturas como um sistema interativo e uma linguagem de programação para computação técnica e científica em geral, integrando a capacidade de fazer cálculos, visualização gráfica e programação. O software é amplamente empregado por engenheiros e investigadores devido à capacidade de reunir a linguagem C++, a linguagem orientada a objetos e a linguagem programada a eventos, podendo realizar inúmeras simulações e modelagens.

5. RESULTADOS E DISCUSSÃO

Com base nos ajustes dos parâmetros dos modelos dinâmicos referidos no trabalho de (MCSHARRY et al., 2003), possibilitou-se a geração de sinais ECG com diferentes morfologias de suas ondas características e variação de amplitudes e intervalos entre as respectivas ondas. Constatou-se que o gerador proposto possibilita a simulação de diferentes condições fisiológicas, tais como ritmos cardíacos acelerados e desacelerados, inversão de polaridade de ondas, alargamento e distanciamento entre as ondas, além da incidência de ruídos e artefatos.

No que se refere à modelagem do complexo QRS, geraram-se, em sinais sintéticos, 60 amostras de cada uma das morfologias de QRS predominantemente encontradas na literatura, variando-se amplitude e fase das ondas Q,R e S: qR, qRs, Rs, R, RS, rSR, rR', qrSR', RSr', rR's, rS, rSr', Qr, QS, QR, qrS, qS, rsR's', QRs e Qrs (NEMIKO e LUGOVAYA, 2005). Nos testes computacionais, foi aplicado algoritmo de detecção de QRS, com base no trabalho de Madeiro et al., (2012), alcançando-se taxas de detecção acima de 99%.

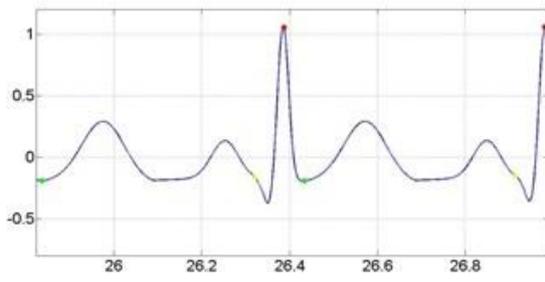
Em seguida, para cada um dos modelos matemáticos testados, identificou-se a morfologia, dentre as 20 consideradas, em que um dado modelo possui o menor erro RMS Normalizado (RMS-Root Mean Square) no Ranking, conforme é apresentado na Tabela 2. Na Figura 12, são ilustradas todas as vinte morfologias de QRS submetidas aos testes experimentais com a identificação do correspondente modelo vencedor, e a Figura 13 ilustra as três morfologias nas quais cada um dos modelos matemáticos testados obteve melhor desempenho.

Tabela 2: Ranking de menor erro RMS (melhor desempenho) considerando-se os três modelos matemáticos propostos para as morfologias de QRS geradas pelo simulador.

| Função Matemática | Morfologia de QRS | Erro RMS (média e desvio padrão) |
|--------------------------|--------------------------|---|
| Gaussiana | R | 4,67% ± 1,22 % |
| Chapéu Mexicano | rsR's' | 18,36% ± 0,94 % |
| Rayleigh | RS | 10,23% ± 3,1 % |

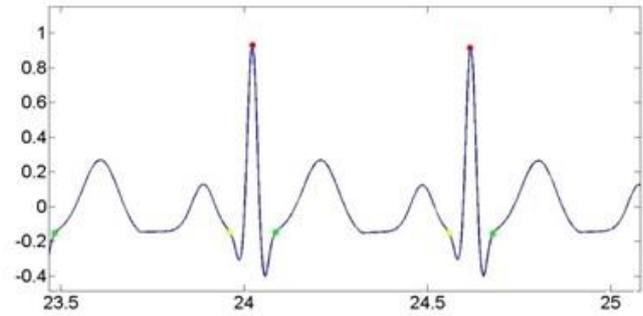
Fonte: Autor, 2018.

qR



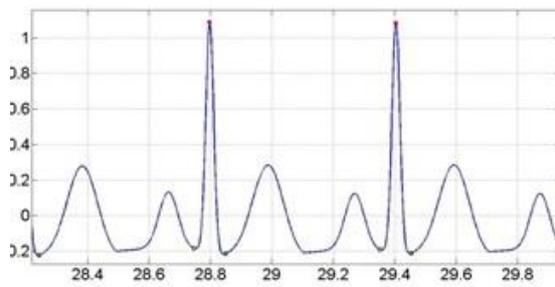
(1)

qRs



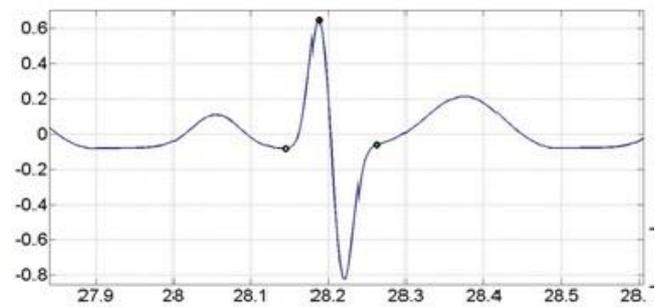
(2)

R



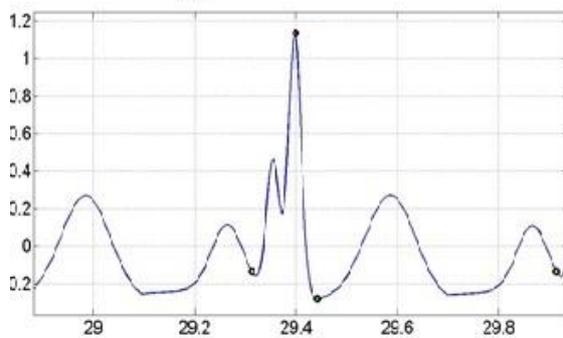
(1)

RS



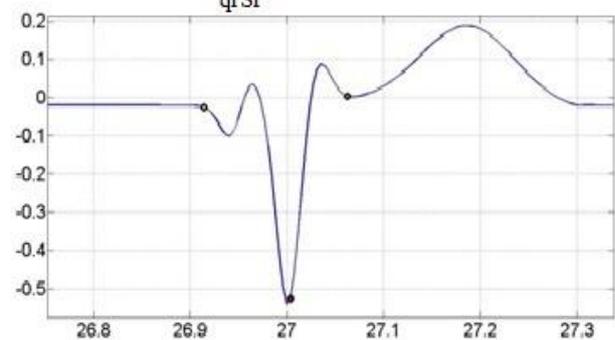
(3)

rR'



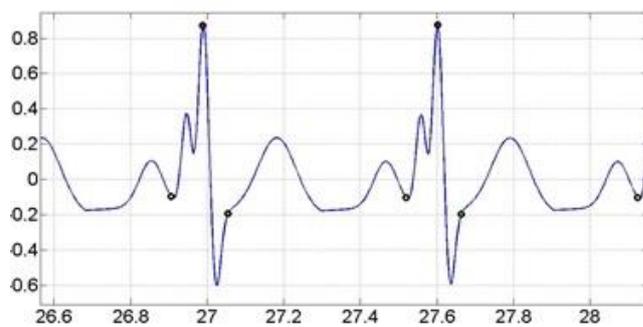
(5)

qrSr'



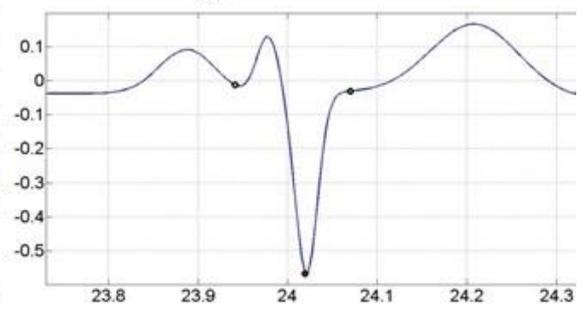
(3)

rR's

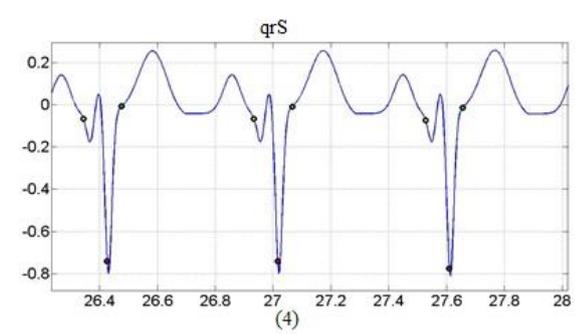
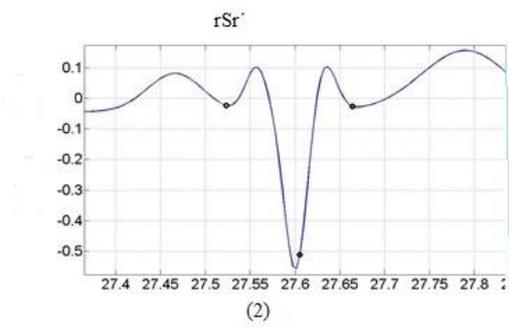
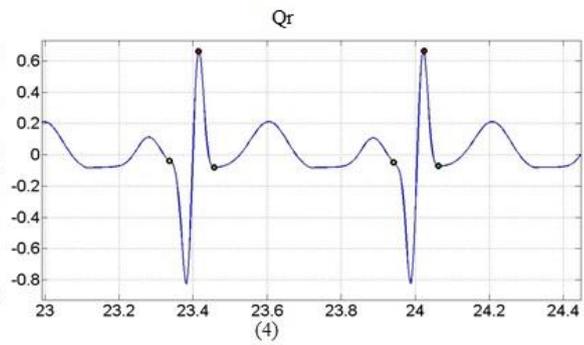
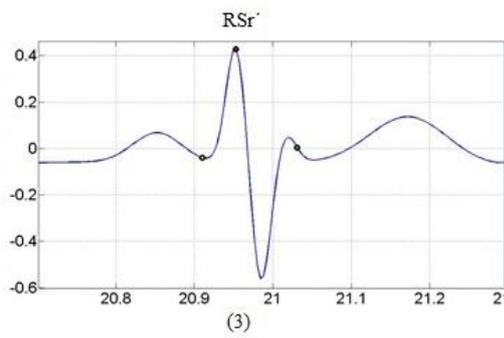
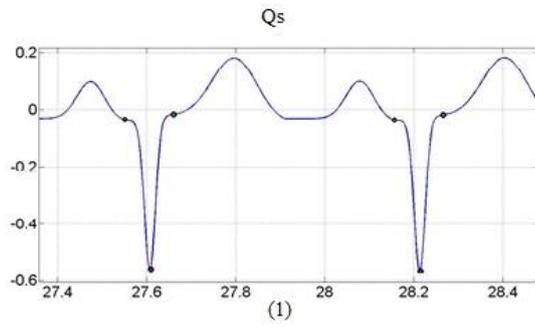
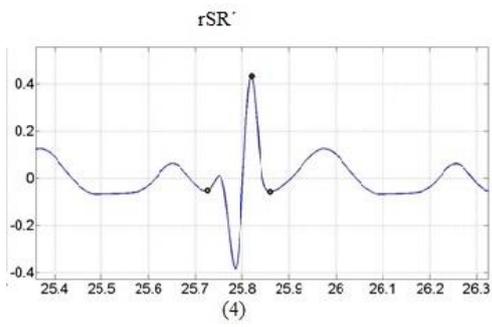
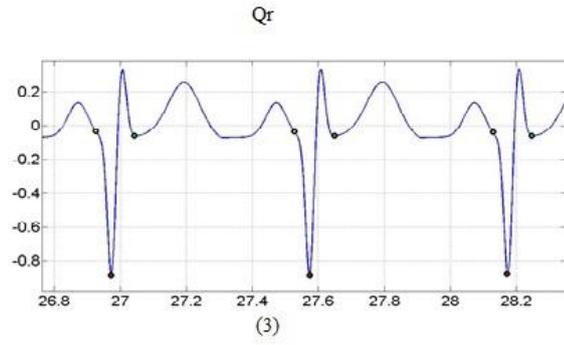
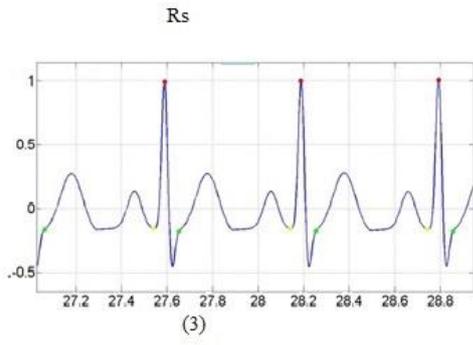


(3)

rS



(4)



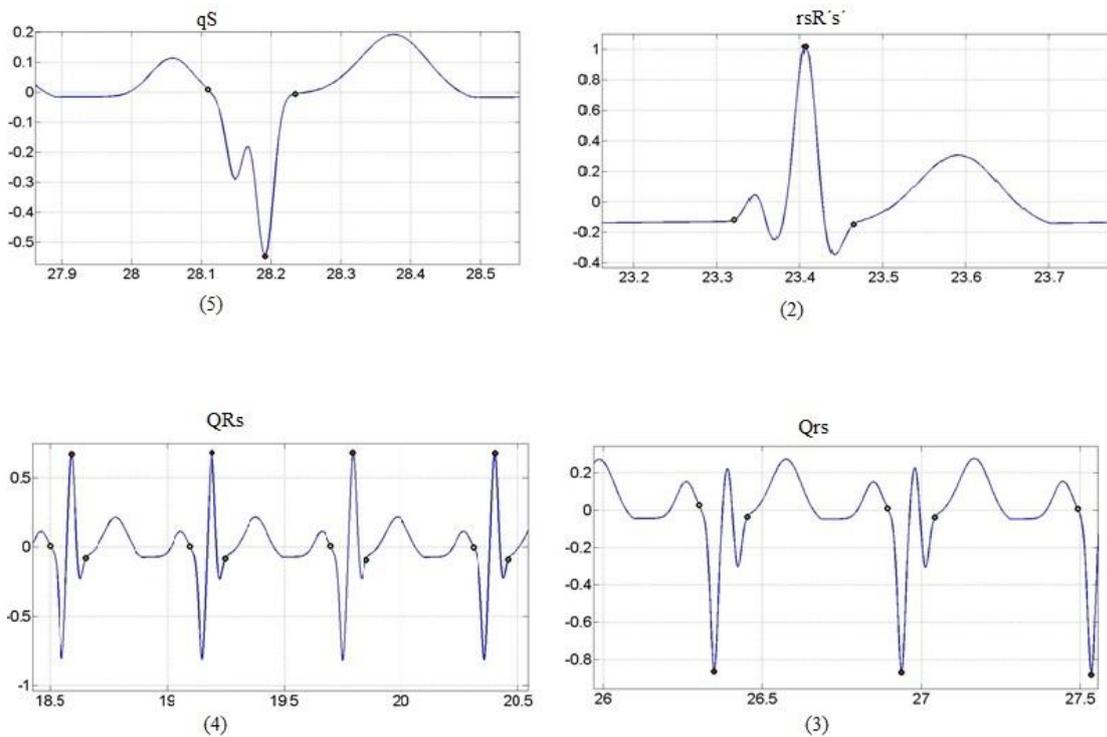


Figura 12- Morfologias de QRS modeladas pelas funções Gaussiana (1), Chapéu Mexicano (2), Rayleigh Ciclo Positivo-Negativo (3), Rayleigh Ciclo Negativo-Positivo (4) e Rayleigh Ciclo Positivo-Positivo (5).

Fonte: Autor, 2018.

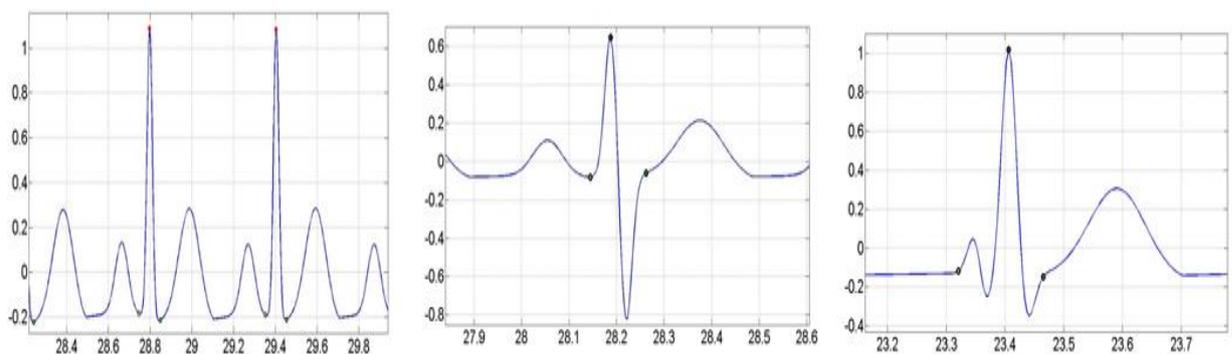


Figura 13- Morfologias de QRS modeladas com melhor desempenho pelas funções Gaussiana, Rayleigh e Chapéu Mexicano: R, RS e rsR's', respetivamente.

Fonte: Autor, 2018.

Pelos resultados aferidos sobre todas as amostras de morfologias, observou-se que a função Gaussiana apresenta, dentre o conjunto de funções testadas, o melhor desempenho para as morfologias qR, R e QS, com valores de erro RMS normalizado mínimo e máximo de:

4,67% \pm 1,22% e 17,94% \pm 0,72%, respectivamente. A função Chapéu Mexicano apresenta, dentre o conjunto de funções testadas, o melhor desempenho para as morfologias qRs, rSr' e rsR's', com valores de erro RMS normalizado mínimo e máximo de: 18,36% \pm 0,94% e 20,06% \pm 1,43%, respectivamente. As funções Densidade de Probabilidade de Rayleigh (três variantes) apresentam, dentre o conjunto de funções testadas, o melhor desempenho para as morfologias: Rs, RS, rSR, rR', qrSR', RSr', rR's, rS, Qr, QR, qrS, qS, QRs e Qrs, com erro RMS normalizado mínimo e máximo de 10,23% \pm 3,10% e 27,08% \pm 2,76%, respectivamente. A Tabela 3 apresenta os resultados detalhados de modelagem para cada uma das 20 morfologias de QRS consideradas sobre os sinais sintéticos, com o correspondente *kernel* vencedor.

Particularizando-se os tipos de combinações de funções densidade de probabilidade de Rayleigh, constatou-se que a Rayleigh Ciclo Positivo-Negativo apresentou, dentre as funções Rayleigh testadas, melhor desempenho para as morfologias Rs, RS, qrSr', RSr', rR'S, Qr e Qrs. A Rayleigh Ciclo Negativo-Positivo apresentou, dentre as funções Rayleigh testadas, melhor desempenho para as morfologias rSR`, rS, QR, qrS e QRs. Enquanto que a Rayleigh Ciclo Positivo-Positivo apresentou, dentre as funções Rayleigh testadas, melhor desempenho para as morfologias rR' e qS. É relevante salientar que, dentre as combinações de funções de densidade de probabilidade de Rayleigh, constatou-se que a Rayleigh Ciclo Positivo + Negativo foi o modelo vencedor com erro RMS normalizado, de 10,23% \pm 3,10%.

Tabela 3- Resultados de modelagem para cada uma das 20 Morfologias de QRS sobre os sinais sintéticos, considerando-se as funções Gaussiana, Chapéu Mexicano e Rayleigh.

| Ordem | Morfologia | Kernel Vencedor | Erro RMS Normalizado (média e desvio-padrão) |
|--------------|-------------------|----------------------------------|---|
| 1 | qR | Gaussiana | 17,94% \pm 0,72% |
| 2 | qRs | Chapéu-Mexicano | 20,06% \pm 1,43% |
| 3 | Rs | Rayleigh Ciclo Positivo+Negativo | 20,23% \pm 4,16% |
| 4 | R | Gaussiana | 4,67% \pm 1,22% |
| 5 | RS | Rayleigh Ciclo Positivo+Negativo | 10,23% \pm 3,10% |
| 6 | rSR` | Rayleigh Ciclo Negativo+Positivo | 17,02% \pm 3,91% |
| 7 | rR' | Rayleigh Ciclo Positivo+Positivo | 27,08% \pm 2,76% |
| 8 | qrSr' | Rayleigh Ciclo Positivo+Negativo | 19,56% \pm 1,61% |

| | | | |
|----|--------|----------------------------------|----------------|
| 9 | RSr' | Rayleigh Ciclo Positivo+Negativo | 15,01% ± 3,46% |
| 10 | rR'S | Rayleigh Ciclo Positivo+Negativo | 26,97% ± 2,27% |
| 11 | rS | Rayleigh Ciclo Negativo+Positivo | 18,37% ± 0,55% |
| 12 | rSr' | Chapéu-Mexicano | 19,93% ± 2,88% |
| 13 | Qr | Rayleigh Ciclo Positivo+Negativo | 11,95% ± 1,79% |
| 14 | QS | Gaussiana | 6,09% ± 1,69% |
| 15 | QR | Rayleigh Ciclo Negativo+Positivo | 11,96% ± 3,78% |
| 16 | qrS | Rayleigh Ciclo Negativo+Positivo | 14,71% ± 2,47% |
| 17 | qS | Rayleigh Ciclo Positivo+Positivo | 23,29% ± 1,77% |
| 18 | rsR's' | Chapéu-Mexicano | 18,36% ± 0,94% |
| 19 | QRs | Rayleigh Ciclo Negativo+Positivo | 18,80% ± 2,05% |
| 20 | Qrs | Rayleigh Ciclo Positivo+Negativo | 14,95% ± 1,08% |

Fonte: Autor, 2018.

Considerando-se a diversidade de morfologias existentes junto aos sinais reais da base *Arrhythmia Database* (GOLDBERGER et al., 2000), identificaram-se os registros de sinais em que cada um dos modelos testados possui, numa avaliação de ranking, o menor erro RMS (média e desvio-padrão) e o maior percentual de ocorrência, conforme a Tabela 4.

Na Tabela 5, são apresentados os resultados de aplicação do algoritmo de modelagem do complexo QRS sobre os registros de dez sinais reais da base *Arrhythmia Database*, considerando-se os modelos matemáticos de função Gaussiana (Modelo 1), função Chapéu Mexicano (Modelo 2), Rayleigh Ciclo Positivo + Negativo (Modelo 3), Rayleigh Ciclo Negativo + Positivo (Modelo 4) e Rayleigh Ciclo Positivo + Positivo (Modelo 5). É relevante salientar que em todos os resultados de aplicação de modelagem detalhados na Tabela 5, foi utilizado apenas o primeiro canal dos sinais ECG, e, dos cinco modelos matemáticos testados, o modelo vencedor apresenta um percentual de ocorrência acima de 70% para todos os casos.

Tabela 4: Ranking de menor erro RMS (melhor desempenho) por modelo matemático sobre sinais da base *Arrhythmia database*.

| Modelo | Registro | Morfologia | Erro RMS | Ocorrência |
|------------------------|-----------------|-------------------|-----------------|-------------------|
| Gaussiana | 234 | R | 7,56% ± 1,74 % | 94,25% |
| Chapéu Mexicano | 213 | qRs | 12,02% ± 4,15 % | 66,59% |
| Rayleigh | 219 | RS | 9,71% ± 3,34% | 79,75% |

Fonte: Autor, 2018.

Tabela 5- Resultados de aplicação do algoritmo de modelagem para um conjunto de sinais reais da base *Arrhythmia Database*.

| | Canal 1 | | | |
|---------------------|----------------|-----------------------|-----------------|----------------------|
| | Modelo | Ocorrência (%) | Erro RMS | Desvio-Padrão |
| Registro 234 | 1 | 94,25% | 7,56% | 1,74% |
| | 2 | 0,77% | 13,51% | 1,66% |
| | 3 | 4,98% | 11,28% | 1,60% |
| | 4 | 0,00% | 17,50% | 2,74% |
| | 5 | 0,00% | 16,94% | 2,83% |
| Registro 220 | 1 | 0,00% | 57,33% | 8,34% |
| | 2 | 0,39% | 38,74% | 6,67% |
| | 3 | 99,21% | 22,01% | 3,58% |
| | 4 | 0,00% | 59,40% | 8,20% |
| | 5 | 0,39% | 45,51% | 5,79% |
| Registro 219 | 1 | 2,76% | 13,07% | 3,34% |
| | 2 | 14,83% | 11,78% | 3,38% |
| | 3 | 79,55% | 9,71% | 3,34% |
| | 4 | 0,89% | 18,91% | 3,63% |
| | 5 | 1,97% | 20,65% | 4,10% |
| Registro 217 | 1 | 79,78% | 12,74% | 8,15% |
| | 2 | 5,20% | 14,89% | 8,90% |
| | 3 | 9,81% | 16,48% | 9,79% |
| | 4 | 1,51% | 19,47% | 8,54% |
| | 5 | 3,70% | 17,04% | 7,04% |

| | | | | |
|---------------------|---------------|-----------------------|-----------------|----------------------|
| Registro 215 | Modelo | Ocorrência (%) | Erro RMS | Desvio-Padrão |
| | 1 | 3,20% | 62,27% | 15,38% |
| | 2 | 1,71% | 44,17% | 11,08% |
| | 3 | 94,31% | 20,87% | 4,79% |
| | 4 | 0,30% | 62,11% | 14,56% |
| | 5 | 0,48% | 51,11% | 9,92% |
| Registro 212 | Modelo | Ocorrência (%) | Erro RMS | Desvio-Padrão |
| | 1 | 81,90% | 12,41% | 3,86% |
| | 2 | 9,30% | 16,27% | 2,84% |
| | 3 | 3,63% | 18,31% | 4,49% |
| | 4 | 0,04% | 23,78% | 3,78% |
| | 5 | 5,13% | 16,34% | 3,32% |
| Registro 209 | Modelo | Ocorrência (%) | Erro RMS | Desvio-Padrão |
| | 1 | 0,03% | 49,87% | 9,69% |
| | 2 | 4,32% | 31,45% | 7,73% |
| | 3 | 95,41% | 18,07% | 4,74% |
| | 4 | 0,13% | 51,09% | 9,23% |
| | 5 | 0,10% | 50,05% | 8,59% |
| Registro 202 | Modelo | Ocorrência (%) | Erro RMS | Desvio-Padrão |
| | 1 | 91,88% | 10,81% | 17,16% |
| | 2 | 0,66% | 18,06% | 20,16% |
| | 3 | 1,72% | 17,95% | 14,74% |
| | 4 | 2,78% | 24,89% | 12,20% |
| | 5 | 2,96% | 16,96% | 13,05% |
| Registro 201 | Modelo | Ocorrência (%) | Erro RMS | Desvio-Padrão |
| | 1 | 75,57% | 19,55% | 29,05% |
| | 2 | 4,26% | 24,95% | 31,79% |
| | 3 | 6,18% | 24,64% | 23,99% |
| | 4 | 5,01% | 30,45% | 21,30% |
| | 5 | 8,98% | 20,69% | 23,26% |
| Registro 123 | Modelo | Ocorrência (%) | Erro RMS | Desvio-Padrão |
| | 1 | 0,00% | 41,11% | 4,76% |
| | 2 | 19,41% | 24,10% | 3,56% |
| | 3 | 80,59% | 19,45% | 3,85% |
| | 4 | 0,00% | 44,50% | 4,49% |
| | 5 | 0,00% | 39,87% | 4,49% |

Fonte: Autor, 2018.

As Figuras 14(a), 14(b), 14(c), 14(d), 14(e), 14(f), 14(g), 14(h), 14(i) e 14(j) ilustram diferentes morfologias predominantes de QRS, encontradas nos registros de sinais da base *Arrhythmia Database* acima elencados, as quais são modeladas por algumas das funções matemáticas propostas.

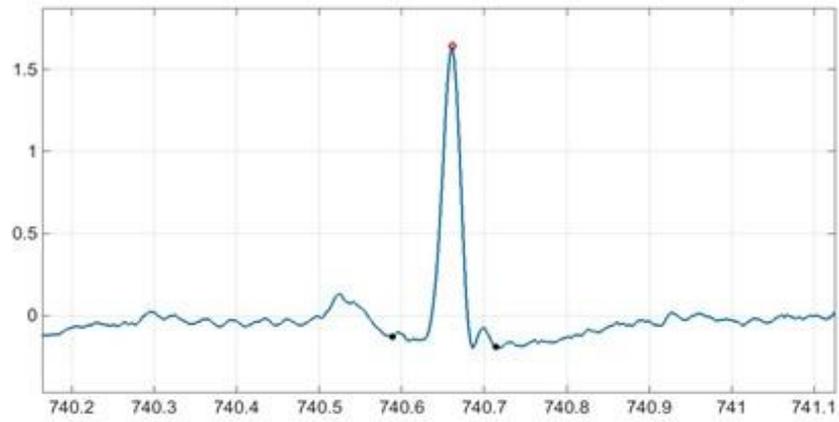


Figura 14(a) - Morfologia predominante do sinal 234, modelada pela função Gaussiana.

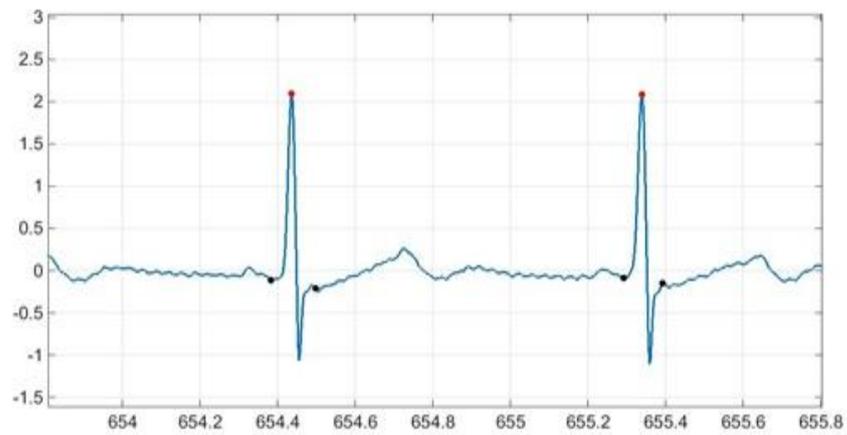


Figura 14(b) - Morfologia predominante do sinal 220, modelada pela Rayleigh Ciclo Positivo + Negativo.

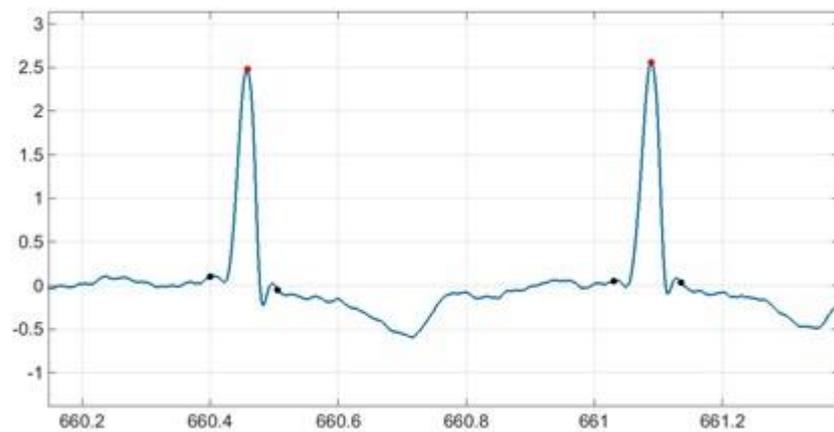


Figura 14(c) - Morfologia predominante do sinal 219, modelada pela Rayleigh Ciclo Positivo + Negativo.

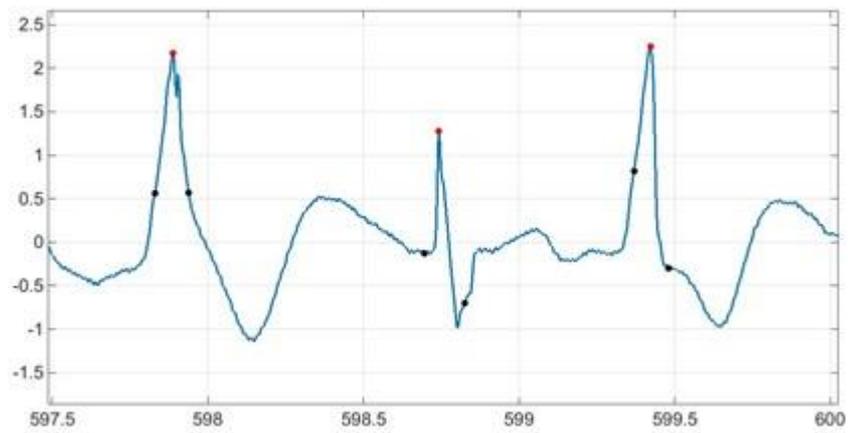


Figura 14(d)- Morfologias alternantes do QRS do sinal 217, modeladas pela função Gaussiana (primeiro e terceiro batimento) e pela Rayleigh Ciclo Positivo + Negativo (segundo batimento).

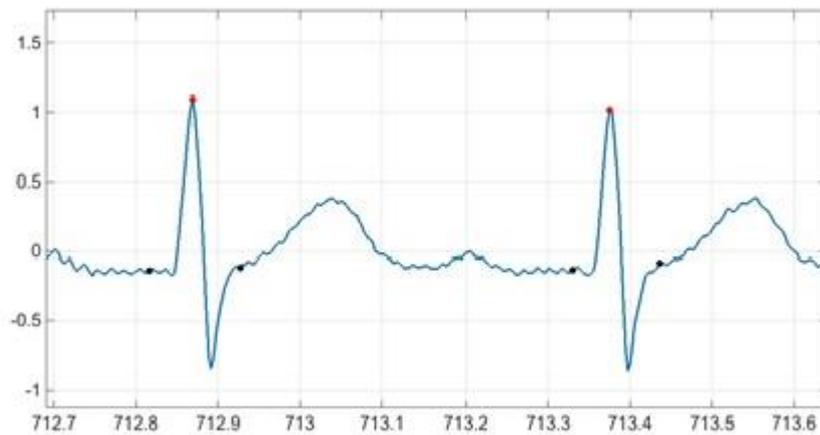


Figura 14(e)- Morfologia predominante do sinal 215, modelada pela Rayleigh Ciclo Positivo + Negativo.

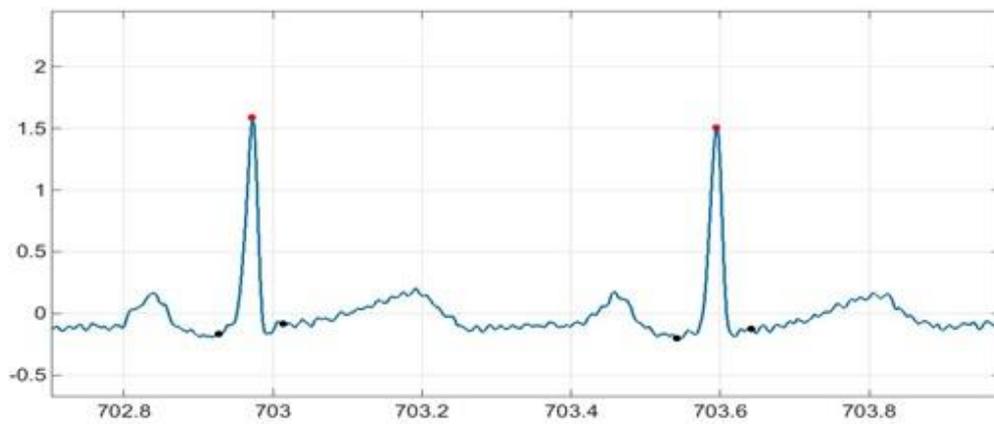


Figura 14(f) - Morfologia predominante do sinal 234, modelada pela função Gaussiana.

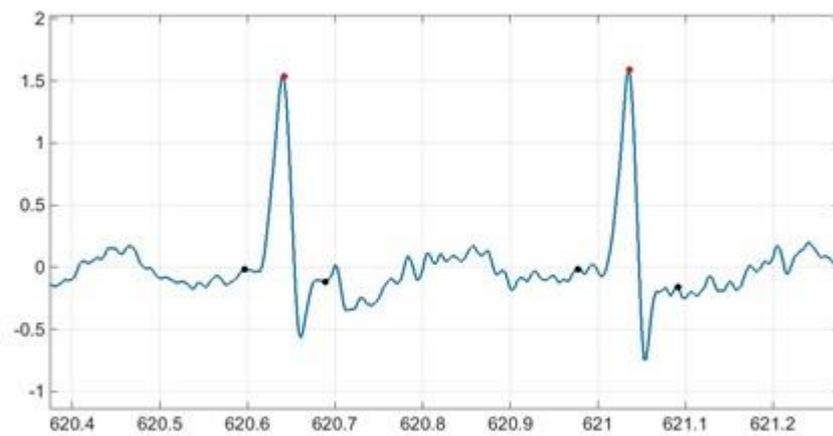


Figura 14(g) - Morfologia predominante do sinal 209, modelada pela Rayleigh Ciclo Positivo + Negativo.

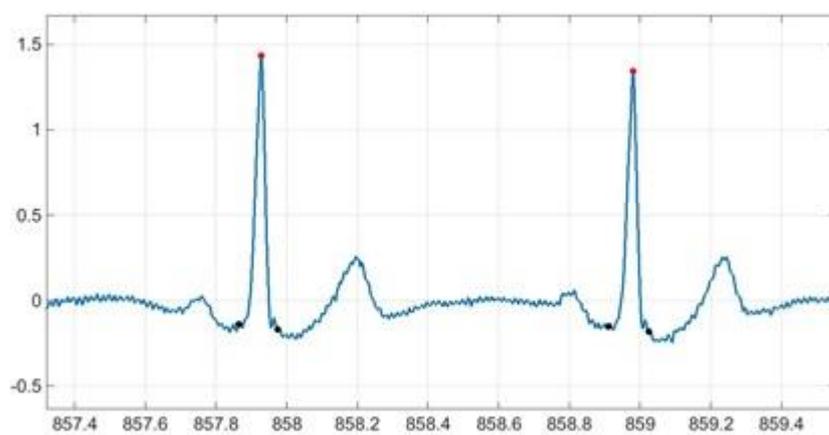


Figura 14(h)- Morfologia predominante do sinal 202, modelada pela função Gaussiana.

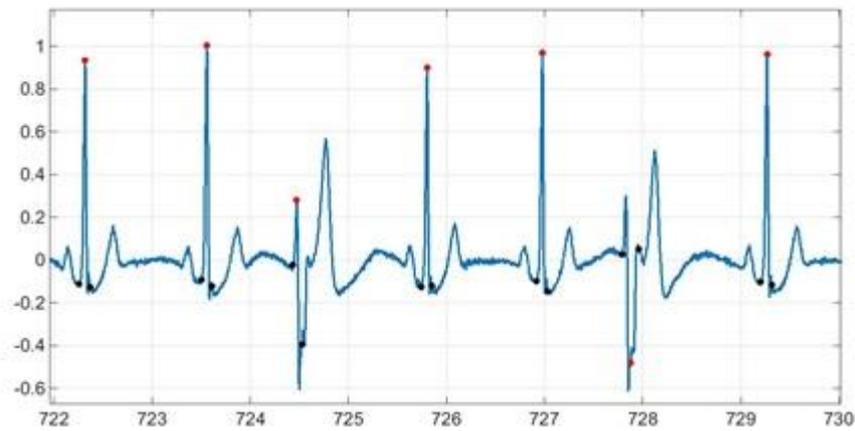


Figura 14(i)- Morfologias alternantes do QRS do sinal 201, modeladas pela função Gaussiana (cinco dos sete batimentos) e pela Rayleigh Ciclo Positivo + Negativo (terceiro e sexto batimentos).

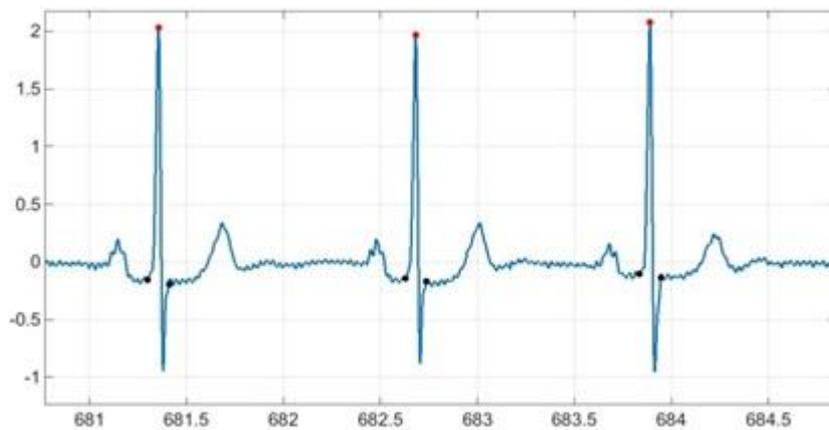


Figura 14(j)- Morfologia predominante do sinal 220, modelada pela Rayleigh Ciclo Positivo + Negativo.

Pelos resultados obtidos sobre as amostras do conjunto de sinais reais da base *Arrhythmia Database*, constatou-se que:

I – O complexo QRS possui elevada variabilidade morfológica, com oscilações significativamente presentes em amplitude, forma e duração, de paciente para paciente (registro para registro), bem como dentro de um registro de paciente (variabilidade intrapaciente);

II – A função Gaussiana é escolhida predominantemente como o melhor modelo matemático, tendo em vista o menor valor de erro RMS normalizado, valor médio mínimo de $7,56\% \pm 1,74\%$, para a morfologia R, tal como para os sinais sintéticos, considerando-se os resultados obtidos para os registros: 234, 201, 202, 212 e 217.

III – A função Chapéu-Mexicano é escolhida ora como melhor modelo matemático, ora como segundo melhor modelo matemático, valor médio mínimo de erro RMS normalizado $11,78\% \pm 3,38\%$, para a morfologia qRs, considerando-se os resultados obtidos para os registros: 219 e 212.

IV - A combinação de funções densidade de probabilidade de Rayleigh é escolhida predominantemente como o melhor modelo matemático, tendo em vista o menor valor de erro RMS normalizado, valor médio mínimo de $9,71\% \pm 3,34\%$, para as morfologias RS e Rs, considerando-se os resultados obtidos para os registros: 215, 219, 220, 209 e 123.

A ampla diversidade de morfologias de complexo QRS (em torno de 20, segundo a literatura), caracteriza a tarefa de classificação e reconhecimento como extremamente desafiante (NEMIRKO e LUGOWAYA ,2005). Dos resultados alcançados, observou-se que as funções matemáticas utilizadas com parâmetros ajustáveis podem ser aplicadas conjuntamente para modelagem e classificação automática de tipos de batimentos comumente presentes em sinais reais, com eficiência e precisão. O cálculo do erro RMS normalizado permite a diferenciação e a identificação do modelo mais apropriado a uma dada morfologia, a qual pode alternar-se ao longo de um mesmo registro de paciente. A próxima etapa da pesquisa consiste na utilização dos parâmetros fornecidos pelos modelos matemáticos e também dos valores de erro RMS normalizado calculados para cada modelo como dados de entrada de um classificador, a ser construído a partir de técnicas de aprendizado de máquina, para reconhecimento de padrão de morfologia.

6. CONCLUSÃO E TRABALHOS FUTUROS

A execução do presente projeto contribuiu para a avaliação e desenvolvimento de técnicas de processamento de sinais biológicos. A partir das diversas variações morfológicas, tão inerentes aos sinais ECG, foram determinadas métricas e parâmetros que possibilitam a caracterização das formas de onda e o monitoramento da qualidade de sinais ECG gravados.

Compreendeu-se mediante a realização deste trabalho a importância do estudo dos biopotenciais do ECG para a engenharia biomédica, e dos impactos da investigação do eletrocardiograma no nosso cotidiano.

Pelos resultados obtidos, evidenciou-se que as funções matemáticas utilizadas podem ser aplicadas para modelagem e classificação automática de tipos de batimentos comumente presentes em sinais reais. A taxa de erro RMS normalizado obtido para cada um dos modelos testados representa um parâmetro de tomada de decisão na identificação do modelo mais apropriado.

Ainda pelos resultados auferidos, conclui-se que os modelos matemáticos função Gaussiana, Chapéu Mexicano e distribuição de probabilidade de Rayleigh representam alternativas robustas no processo de modelagem de morfologias do complexo QRS de sinais reais comumente encontradas na literatura, com ênfase para R, qRs, RS, Rs e rsR's'. A taxa de erro RMS normalizado pode ser utilizada como parâmetro de entrada de classificadores automáticos.

Propõe-se, então, como trabalho futuro o desenvolvimento de classificadores baseados em técnicas de aprendizado de máquina, dentre os quais, Redes Neurais Artificiais e Florestas de Caminhos Aleatórios, para classificação automática de morfologias. Para os processos de treinamento e validação dos classificadores, serão comparados a classe morfológica de cada batimento sugerida pelo especialista com o ranking estabelecido pelo conjunto de modelos matemáticos aplicados.

REFERÊNCIAS

ADDISON, P. S. **The Illustrated Wavelet Transform Handbook: introductory theory and applications in science engineering, medicine and _nance**. Bristol: Institute of Physics Publishing, 2002. ISBN 0 7503 0692 0. Wavelet transforms and the ECG: a review. *Physiological Measurement*, v. 26, p. R155{R199, August 2005.

ALGHATRIF, MAJD .; LINDSAY , JOSEPH. **Uma breve revisão: história para entender os fundamentos da eletrocardiografia**. *J Community Hosp Intern Med Perspect* . 2012. Disponível em :<<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3714093/>> Acesso em 28 de Dezembro de 2017.

ALVARADO. W; COSTA. C. **Deteção do Complexo QRS Utilizando o Algoritmo de Pan & Tompkins Modificado**. Simpósio Brasileiro de Telecomunicações. 2015. Disponível em :<<http://falandoteleco.blogspot.com.br/2015/11/artigo-deteccao-do-complexo-qrs.html>> Acesso em : 02 de Janeiro de 2018.

ARDHAPURKAR, S.; MANTHALKAR, R.; GAJRE, S. **ECG Denoising by Modeling Wavelet Sub-Band Coefficients using Kernel Density Estimation**. *JInf Process Syst*, 8(4).669-684; 2012.

ARZENO, N. M.; DENG, Z.-D.; POON, C.-S. **Analysis of first-derivative based QRS detection algorithms**. *IEEE Transactions on Biomedical Engineering*, v. 55, n. 2, p. 478-484, February 2008.

BENITEZ, D; GAYDECKI, P. A.; ZAIDI, A.; FITZPATRICK, A. P. **The use of the Hilbert transform in ECG signal analysis**. *Computers in Biology and Medicine*, v. 31, n. 5, p. 399-406, 2001.

CAMH. **O Impacto das Doenças Não Transmissíveis (DNT) e Doenças Tropicais Negligenciadas (DTN) no Desenvolvimento de África**. Etiópia. 2013. Disponível em:<<http://www.carmma.org/sites/default/files/PDF-uploads/Background%20Report%20on%20Hypertension%20-%20Portuguese.pdf>> Acesso em 23 de Dezembro de 2017.

DAUBECHIES, I. **Ten Lectures of Wavelets**. 2006. Disponível em: <<https://jqichina.files.wordpress.com/2012/02/ten-lectures-of-waveletsefbc88e5b08fe6b3a2e58d81e8aeb2efbc891.pdf>> Acesso em 30 de Dezembro de 2017.

DOMINGUES, M. O.; MENDES, O.; KAIBARA, M. K.; MENCONI, V. E.; BERNARDES, E. **Explorando a Transformada Wavelet Continua**. *Revista Brasileira de Ensino de Física*, vol. 38, nº 3, e3314. 2016.

Generalidades do Eletrocardiograma. Disponível em < <http://pt.my-ekg.com/generalidades-ecg/generalidades-ecg.html>> Acesso em 2 de Janeiro de 2018.

GHAFFARI, A.; HOMAEINEZHAD, M. R.; AKRAMINIA, M.; ATAROD, M.; DAEVAEIIHA, M. **A robust wavelet-based multi-lead electrocardiogram delineation algorithm**. *Medical Engineering and Physics*, v. 31, n. 10, p. 1219-1227, December 2009.

GIFFONI, R.T.; TORRES, R.M. **Brief history of the electrocardiography**. *Rev. Med. Minas Gerais*, v.20, p.263-270, 2010.

GOLDBERGER AL, AMARAL LAN, GLASS L, HAUSDORFF JM, IVANOV PCH, MARK RG, MIETUS JE, MOODY GB, PENG CK, STANLEY HE. **PhysioBank, PhysioToolkit e PhysioNet: Componentes de um novo recurso de pesquisa para sinais físicos complexos. Circulação** 101 (23): e215-e220 [Páginas eletrônicas de circulação; <http://circ.ahajournals.org/content/101/23/e215.full>]; 2000.

GUYTON, A. C.; HALL, J. E. **Tratado de Fisiologia Médica**. Quarta Edição. Saunders Elsevier. Rj- Guanabara Koogan, 2006.

HANS, S. L. **Hilbert Transforms in Signal Processing**. Boston: Artech House Publishers, 1996.

ILLANES-MANRIQUEZ, A.; ZHANG, Q. **An algorithm for robust detection of QRS onset and offset in ECG signals**. In: **Computers in Cardiology**. Bologna: IEEE Xplore, v. 35, p. 857-860, 2008.

ISHITANI, L. H.; FRANCO, G. C.; PERPÉTUO, I. H. O.; FRANÇA, E.. **Desigualdade social e mortalidade precoce por doenças cardiovasculares no Brasil**. *Rev Saúde Pública*, São Paulo, 2006. Disponível em: <<http://www.scielo.br/pdf/rsp/v40n4/19.pdf>>. Acesso em: 14 de Dezembro de 2017.

JOHANSSON, MATHIAS. **The Hilbert Transform**. Disponível em: < <http://fuchs-braun.com/media/d9140c7b3d5004fbffff8007fffff0.pdf>> Acesso em 03 de Janeiro de 2017.

JOHNSON, R. W. **Some Notes on the Use of the Windowed Fourier Transform for Spectral Analysis of Discretely Sampled Data**. Jonesboro-USA. 2013. Disponível em: < <https://arxiv.org/pdf/1303.0306.pdf> >. Acesso em: 14 de Dezembro de 2017.

JUNIOR, S. R. R. **Detecção e Classificação de Arritmias Cardíacas Utilizando Redes Neurais Artificiais Auto-Organizáveis**. Dissertação de Mestrado de Computação- Pontifícia Universidade Católica do Paraná, Curitiba, 2008.

KÖHLER, B.; HENNIG, C.; ORGLMEISTER. **The principles of software QRS detection**. *IEEE Engineering in Medicine and Biology Magazine*. 21:42–57. 2002.

LI, C.; ZHENG, C.; TAI, C. **Detection of ecg characteristic points using wavelet transforms**. *IEEE Transactions On Biomedical Engineering*. 42 (1):21–8. 1995.

LUGOVAYA, T. S. **Biometric human identification based on electrocardiogram**. [Master's thesis] Faculty of Computing Technologies and Informatics, Electrotechnical University "LETI", Saint-Petersburg, Russian Federation; June 2005.

MADEIRO, J. P. do V.; CORTEZ, P. C.; MARQUES, J. A. L.; FELIX, J.H.S.; SCHLINDWEIN, F.S. **Evaluating Gaussian and Rayleigh-Based Mathematical Models for T and P-waves in ECG**. IEEE Latin American Transactions. v.15, n.5, Maio 2017.

MADEIRO, J. P. do V.; CORTEZ, P. C.; MARQUES, J.A.L.; SEISDEDOS, C.R.V.; SOBRINHO, C.R.M.R. **An innovative approach of QRS segmentation based on first-derivative, Hilbert and Wavelet Transforms**. Medical Engineering & Physics 34 1236–1246. 2012.

MADEIRO, J. P. do V.; CORTEZ, P. C.; NICOLOSI, D. E. C.; GUIMARÃES, A. **Algoritmo para detecção multicanal em tempo real de QRS em ECG com base nas transformadas Wavelet e de Hilbert**. Conference: VII SIIM / VI SPS-UNICAMP, At Campinas, 2015.

MADEIRO, J. P. do V.; CORTEZ, P. C.; SCHLINDWEIN, F.S.; NICOLSON, W. B.; **Testing Gaussian-Based Kernels For Modelling T-Waves and P-Waves in ECG Signals**. Oxford, Reino Unido, 2012.

MADEIRO, J. P. V. **Detecção e Segmentação Automática de batimentos cardíacos do Eletrocardiograma por modelagem matemática e combinação das transformadas Wavelet e de Hilbert**. Fortaleza: UFC, 2013. 148p. Tese de Doutorado, Programa de Pós-Graduação em Engenharia de Teleinformática, DETI/UFC, Fortaleza, 2013.

MALMIVUO, J., PLONSEY, R. **Bioeletrocardiogram- Principles and Applications of Bioelectric and Biomagnetic Fields**, Oxford University Press, New York, 1ª Edition, 1995.

MANZAN, WILLIAM.; E BARBAR, JAMIL. **O Uso de Wavelets no Reconhecimento de Padrão em ECG**. CONTECSI USP - International Conference on Information Systems and Technology Management - ISSN 2448-1041: n. pág. Web. 3 Jan. 2018.

MARTÍNEZ, A.; ALCARAZ, R.; RIETA, J. J. **Gaussian modeling of the P-wave morphology time course applied to anticipate paroxysmal atrial fibrillation**. Computer Methods in Biomechanics and Biomedical Engineering, v. 18, n. 16, p. 1775-1784, 2015.

MAYA, P; LEONARDI, F. **Controle Essencial**. 2ª Edição. Editora Pearson. 2014.

MCSHARRY, P. E., CLICOR, G.D., TARASSENKO, L., SMITH, L. A. **Adynamical model for generating synthetic electrocardiogram signals**. IEEE Trans. Biomed.Eng.50 (3). 289 – 294; 2003.

MS. **Equipamentos Médico-Hospitalares e o Gerenciamento da Manutenção: capacitação a distância**. Brasília, Ministério da Saúde, 2002. Disponível em: <http://bvsmms.saude.gov.br/bvs/publicacoes/equipamentos_gerenciamento1.pdf>. Acesso em 06 de Dezembro de 2017.

NEMIRKO AP, LUGOVAYA T. S. **Identificação humana biométrica baseada em eletrocardiograma**. Proc. XII-Conferência russa sobre métodos matemáticos de reconhecimento de padrões, Moscou, MAKS Press, pp. 387-390. ISBN 5-317-01445-X. 2005.

NETO, L. A. L. **Desenvolvimento de um Protótipo de Eletrocardiógrafo Portátil com uma Derivação e Comunicação Bluetooth**. Fortaleza: UFC, 2010. Tese de Doutorado, Programa de Pós-Graduação em Engenharia de Teleinformática, DETI/UFC, Fortaleza, Abril 2010.

NUNES, S. V. B. **Guia Básico de ECG 2016**. 2016. Disponível em: <https://issuu.com/limacs/docs/apostila_de_ecg_-_vers__o_inicial>. Acesso em 28 de Dezembro de 2017.

OLIVEIRA, F. I. **Transformada de Hilbert sobre bases de wavelets: detecção de complexos QRS**. 2007. 210f. Dissertação (Mestrado em Engenharia de Teleinformática) – Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza.

RICHARDSON, J.; HAYWOOD, L. J.; MURTHY, V. K.; HARVEY, G. “**A mathematical model for ECG wave forms and power spectra**” in *Mathematical Biosciences*, vol. 1, no. 12, pp. 321-328, 1971.

SANTOS, J. L. F. **Eletrocardiograma ao Alcance de Todos**. Editora PHorte. 3ª Edição. 2016. Disponível em: <https://issuu.com/phorteeditora/docs/eletrocardiograma_ao_alcance_de_tod> Acesso em: 28 de Dezembro de 2017.

SARAIVA, A. A. **Detecção do Complexo QRS Através da Matemática Multiescalar**. Dissertação de Mestrado de Engenharia Biomédica- Universidade Tecnológica Federal do Paraná, Curitiba, 2012.

SARITHA, C.; SUKANYA, V.; MURTHY, Y. NARASIMHA. **ECG Signal Analysis Using Wavelet Transforms**. Department of Physics and Electronics, S.S.B.N. COLLEGE (Autonomous) Anantapur – 515 001, Andhrapradesh, India, February 2008.

STEIN, EMANUEL. **Análise Rápida dos Eletrocardiogramas**, 2001. 3ª ed. USA. Editora Williams & Wilkins.

VIER, A. P. **Sistema de Eletrocardiograma (ECG) com Reconhecimento de Arritmias**. Monografia de Computação-Universidade Positivo, NCET, Curitiba, 2008.

VIEIRA, J.; CASTRO, M. C.; GUIMARÃES, M. F.; KOREA, B. **Manual Básico do Eletrocardiograma**. Universidade Federal da Uberlândia-FAMED. [2008?].

WEBSTER, J. G. **Medical Instrumentation Application and Design**. 3. ed. [S.l.]: John Wiley Sons, Inc, 1998.

APÊNDICE A- AMOSTRA DE RESULTADOS OBTIDOS

Neste apêndice são apresentadas as características das morfologias que obtiveram menor erro RMS normalizado para cada tipo de *kernel* matemático utilizado, conforme referido nos resultados. Em seguida é possível observar a modelagem da morfologia pelo Software *Matlab* e a evolução do erro RMS normalizado para cada morfologia. A evolução do erro RMS normalizado é apresentado em uma tabela de acordo com o ranking de melhor desempenho considerando o erro RMS normalizado (média e desvio-padrão) obtido.

Morfologia rsR's'

Características da morfologia de acordo com a literatura

```
sfecg = 256; %% Frequência de Amostragem
N = 100; Anoise = 0;
hrmean = 100;
hrstd = 1;
lfhfratio = 0.5;
```

```
%Order of extrema: [P Q R S T]
ti = [-30 -20 0 15 100];
ai = [7 -6 30 -6 0.75];
bi = [0.1 0.1 0.1 0.1 0.4];
```

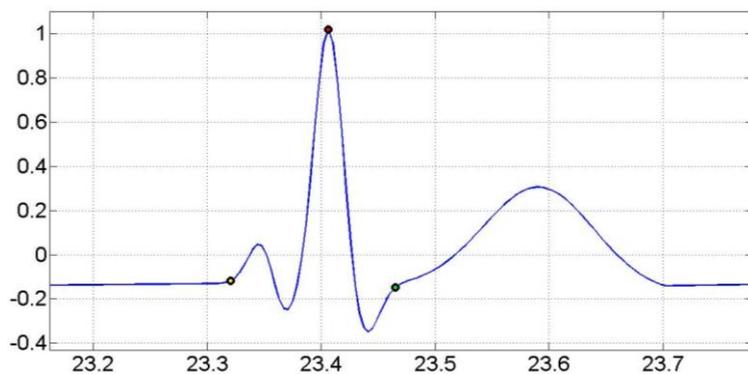


Figura 15-Modelagem pelo Matlab da morfologia rsR's
Fonte: Autor, 2018.

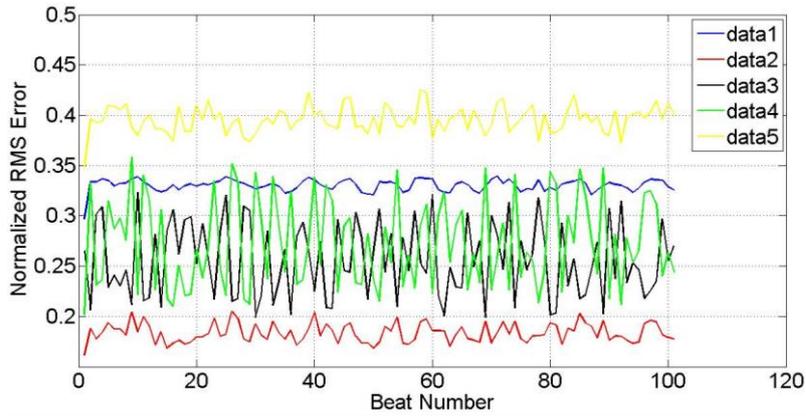


Figura 16-Erro RMS Normalizado da morfologia rsR's
Fonte: Autor, 2018.

Ranking dos *kernels* matemáticos Utilizados

| Desempenho | Erro Médio Quadrático (média e desvio-padrão) |
|------------|---|
| 1° | Erro RMS – Modelo 2: 18,36% ± 0,94% |
| 2° | Erro RMS – Modelo 3: 25,58% ± 3,64% |
| 3° | Erro RMS – Modelo 4: 27,29% ± 4,43% |
| 4° | Erro RMS – Modelo 1: 33,03% ± 0,58% |
| 5° | Erro RMS – Modelo 5: 39,55% ± 1,30% |

Fonte: Autor, 2018.

Morfologia R

Características da morfologia de acordo com a literatura

sfecg = 256; %% Frequência de Amostragem
N = 100;
Anoise = 0;
hrmean = 100;
hrstd = 1;
lfhfratio = 0.5;

%Order of extrema: [P Q R S T]

```

ti = [-70 -15 0 15 100];
ai = [1.2 0 30 0 0.75];
bi = [0.25 0.1 0.1 0.1 0.4];

```

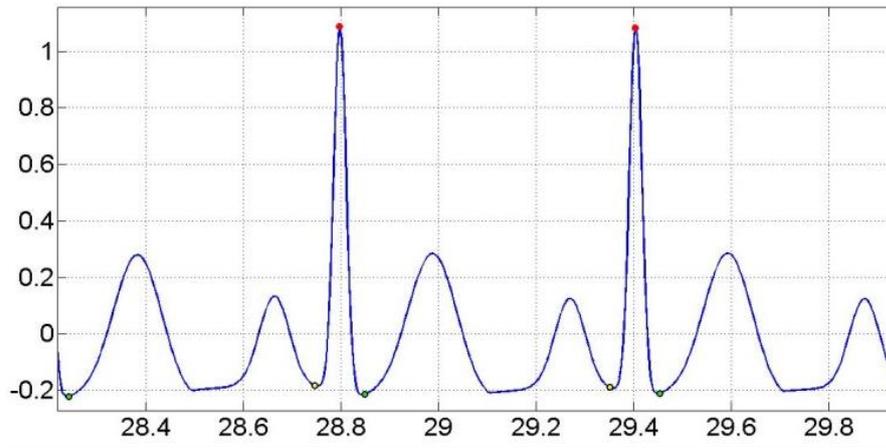


Figura 17- Modelagem pelo Matlab da morfologia R
 Fonte: Autor, 2018.

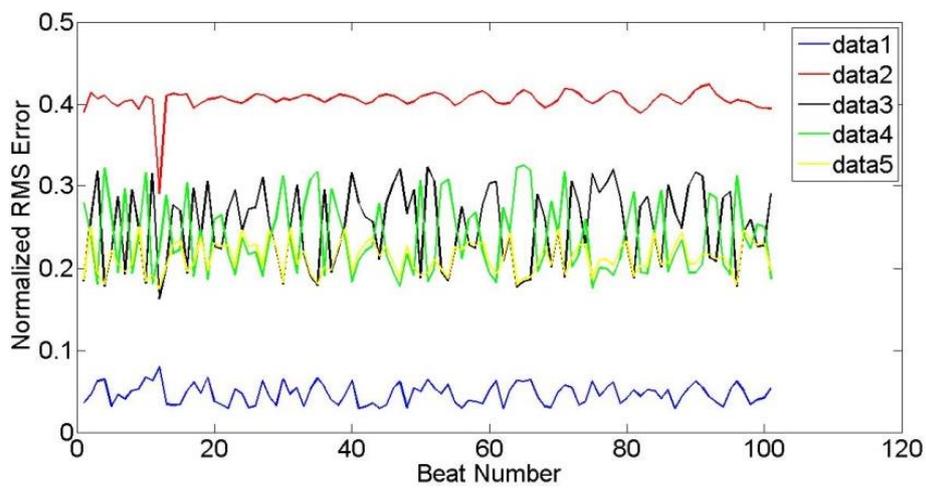


Figura 18- Erro RMS Normalizado da morfologia R
 Fonte: Autor, 2018.

Ranking dos *kernels* matemáticos Utilizados

| Desempenho | Erro Médio Quadrático (média e desvio-padrão) |
|------------|---|
| 1º | Erro RMS – Modelo 1: 4,67% ± 1,22% |

| | |
|----|-------------------------------------|
| 2° | Erro RMS – Modelo 5: 21,28% ± 1,97% |
| 3° | Erro RMS – Modelo 4: 23,83% ± 4,43% |
| 4° | Erro RMS – Modelo 3: 25,17% ± 4,58% |
| 5° | Erro RMS – Modelo 2: 40,51% ± 1,32% |

Fonte: Autor, 2018.

Morfologia RS

Características da morfologia de acordo com a literatura

sfecg = 256; %% Frequência de Amostragem
 N = 100;
 Anoise = 0;
 hrmean = 100;
 hrstd = 1;
 lfhratio = 0.5;

%Order of extrema: [P Q R S T]
 ti = [-70 -15 0 15 100];
 ai = [1.2 0 30 -30 0.75];
 bi = [0.25 0.1 0.1 0.1 0.4];

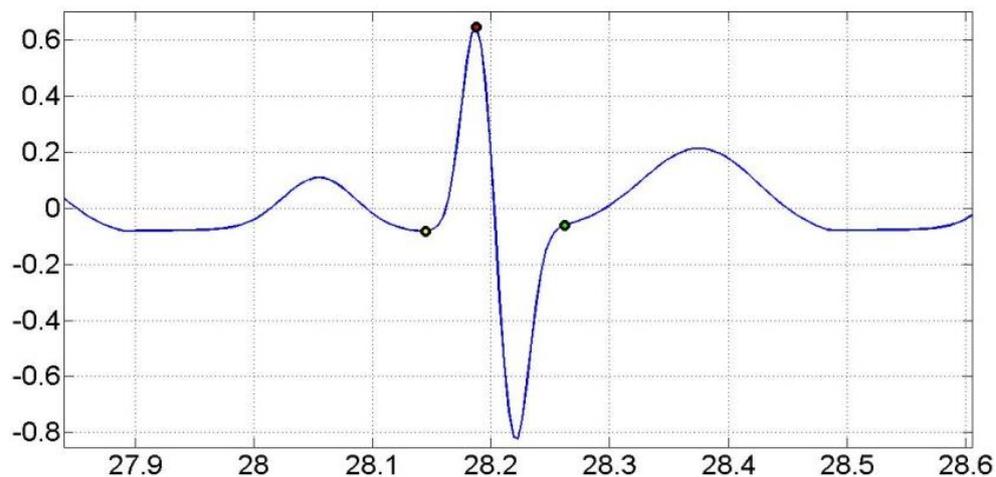


Figura 19- Modelagem pelo Matlab da morfologia RS

Fonte: Autor, 2018.

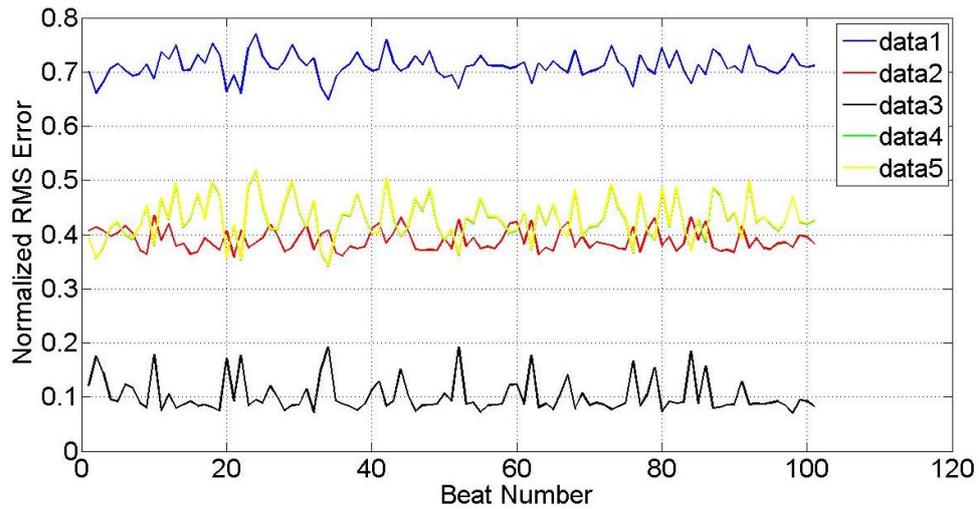


Figura 20- Erro RMS Normalizado da morfologia RS

Fonte: Autor, 2018.

| Desempenho | Erro Médio Quadrático (média e desvio-padrão) |
|-------------------|--|
| 1° | Erro RMS – Modelo 3: 10,23% ± 3,10% |
| 2° | Erro RMS – Modelo 2: 39,01% ± 1,99% |
| 3° | Erro RMS – Modelo 4: 42,77% ± 3,81% |
| 4° | Erro RMS – Modelo 5: 42,89% ± 3,83% |
| 5° | Erro RMS – Modelo 1: 71,09% ± 2,22% |

Fonte: Autor, 2018.