

João Paulo Reus Rodrigues Leite

**Classificação Automática de Batidas Cardíacas Utilizando
Parâmetros de Hjorth**

Itajubá - MG

07 de junho de 2018

João Paulo Reus Rodrigues Leite

**Classificação Automática de Batidas Cardíacas Utilizando
Parâmetros de Hjorth**

Tese de doutorado submetida ao Programa
de Pós-Graduação em Engenharia Elétrica
como parte dos requisitos para obtenção do
título de Doutor em Engenharia Elétrica

Orientador:
Prof. Dr. Robson Luiz Moreno

UNIVERSIDADE FEDERAL DE ITAJUBÁ - UNIFEI
INSTITUTO DE ENGENHARIA DE SISTEMAS E TECNOLOGIA DA INFORMAÇÃO
DOUTORADO EM ENGENHARIA ELÉTRICA

Itajubá - MG
07 de junho de 2018

Agradecimentos

Agradeço a Deus, criador de todas as coisas, pela minha vida, minha saúde, pelas oportunidades que a mim foram concedidas e pelas pessoas com as quais Ele me cercou. A gratidão é necessária para uma vida de prazer e felicidade. Acredito que nossa felicidade depende da capacidade de perceber pequenos gestos de amor e a sutil presença de Deus no dia a dia. Se aproveitarmos as pequenas coisas, um dia olharemos para trás somente para descobrir que, na verdade, elas sempre foram as mais importantes.

À minha esposa, Karina, pelo amor e apoio em todos os momentos. Você escolheu percorrer um longo caminho comigo, e tem se saído muito bem. Amo você. Que Deus nos conceda muitos anos, para crescermos juntos a caminho da eternidade.

Aos meus pais, Carlos e Maria, por serem os maiores exemplos de vida para mim, e fontes de amor incondicional. Sua presença sempre traz conforto e tranquilidade, e sua confiança na minha capacidade é uma das maiores razões das minhas conquistas.

Ao Prof. Dr. Robson Moreno, cuja experiência foi muito importante para a condução deste trabalho. Seus conselhos e amizade foram fundamentais, especialmente durante os períodos mais difíceis, quando os bons resultados ainda estavam distantes. Agradeço também ao suporte de todos os colegas do Instituto de Engenharia de Sistemas e Tecnologia da Informação (IESTI), representados pelos professores Paulo Crepaldi e Luiz Lenarth, que me concederam a oportunidade de dedicar-me exclusivamente ao trabalho de pesquisa durante um bom tempo. Destaco, em especial, os amigos do Grupo de Microeletrônica e do Grupo de Pesquisa em Engenharia de Sistemas e de Computação (GPESC).

"Little by little, one travels far."

J. R. R. Tolkien

Resumo

Este trabalho apresenta métodos para processamento de sinais de eletrocardiograma (ECG), visando realizar a classificação automática de batidas cardíacas com bom desempenho e baixo custo computacional. Em especial, uma nova abordagem para a extração de características é apresentada, na qual o sinal de ECG é caracterizado por valores de intervalos entre batidas (intervalos R-R), dados de amplitude do sinal e, principalmente, parâmetros de Hjorth. Os parâmetros de Hjorth foram utilizados anteriormente em uma variedade de áreas de pesquisa, especialmente para caracterização de sinais cerebrais, mas sua aplicação no processamento de sinal de ECG é ainda pouco explorada.

Além disso, este trabalho introduz uma nova estratégia para a solução do problema de segmentação de batidas cardíacas, que evita que informações de batidas adjacentes à batida de interesse sejam levadas em consideração, aumentando o desempenho de classificação. Para o teste das técnicas propostas, utilizou-se o banco de dados norte-americano MIT-BIH de arritmias e classificadores do tipo máquina de vetor de suporte (SVM). Recomendações da Associação para o Avanço da Instrumentação Médica (AAMI) foram seguidas, de modo que o trabalho pudesse ser comparado a outros trabalhos importantes recentes.

O modelo proposto apresenta índices de desempenho compatíveis ou superiores a cinco outros trabalhos de metodologia semelhante utilizados para comparação, que compõem o estado da arte nesse campo. Os resultados obtidos nos testes indicam que as técnicas propostas neste trabalho podem ser aplicadas com sucesso ao problema da classificação automática do batimento cardíaco. Além disso, esta nova abordagem tem baixo custo computacional, o que permite sua posterior implementação em dispositivos de *hardware* com recursos limitados, como FPGA, sistemas embarcados e circuitos integrados.

Palavras-chave: Eletrocardiograma (ECG), Processamento de Sinais, Parâmetros de Hjorth, Segmentação de Batidas, SVM.

Abstract

This work presents methods for electrocardiogram (ECG) signal processing, aiming at an automatic classification of heartbeats with good performance and low computational cost. In particular, a new approach to feature extraction is presented, in which the ECG signal is characterized by values of heartbeat intervals (R-R intervals), amplitude data, and especially Hjorth parameters. Hjorth parameters were previously used in a variety of research areas, especially for characterization of brain signals, but their application in ECG signal processing is still little explored.

In addition, this work introduces a new strategy for the solution of the problem of heartbeat segmentation, which prevents information from beats adjacent to the beat of interest being taken into account, increasing classification performance. For the test of the proposed techniques, the MIT-BIH Arrhythmia database and support vector machine (SVM) classifiers were used. Recommendations from the Association for the Advancement of Medical Instrumentation (AAMI) were followed, so that this work could be compared to other recent important works.

The proposed model presents performance indexes compatible or slightly superior to those of five other works with similar methodology used for comparison, which compose the state of the art in this field. The results obtained in the tests indicate that the techniques proposed in this work can be successfully applied to the problem of automatic classification of heartbeats. In addition, this new approach has low computational cost, which allows its later implementation on hardware devices with limited resources, such as FPGA, embedded systems and integrated circuits.

Keywords: Electrocardiogram (ECG), Signal Processing, Hjorth Parameters, Heartbeat Segmentation, SVM.

Sumário

Lista de Figuras

Lista de Tabelas

Lista de Abreviaturas	p. 11
1 Introdução	p. 12
1.1 Considerações Gerais	p. 12
1.2 Proposta da Tese	p. 15
1.3 Contribuições	p. 16
1.4 Motivação	p. 17
1.5 Artigo Aceito em Periódico	p. 18
1.6 Organização do Trabalho	p. 18
2 O Sinal Cardíaco	p. 20
2.1 Funcionamento do Coração	p. 20
2.2 O Eletrocardiograma	p. 23
2.3 Arritmias e Tipos de Batidas	p. 27
2.3.1 Batidas Prematuras	p. 28
2.3.2 Batidas de Escape	p. 30
2.3.3 Bloqueios de Ramos de Feixes	p. 31
3 O Estado da Arte	p. 33
3.1 Padronização da Metodologia	p. 34

3.2	Técnicas para Classificação de Batidas Cardíacas	p. 36
3.3	Os Parâmetros de Hjorth	p. 39
3.4	Buscando Algumas Soluções	p. 41
3.5	Uma Nova Abordagem	p. 42
4	Materiais e Métodos	p. 45
4.1	Banco de Dados MIT-BIH <i>Arrhythmia</i>	p. 47
4.2	Estratégia de Divisão de Dados	p. 49
4.3	Pré-Processamento	p. 50
4.3.1	Filtros de Mediana	p. 52
4.3.2	Filtro <i>Butterworth</i> Passa-Baixa	p. 53
4.4	Detecção e Segmentação de Batidas	p. 54
4.4.1	Análise de Custo Computacional	p. 57
4.4.2	Comparação com Outras Técnicas	p. 58
4.5	Extração de Características	p. 59
4.5.1	Intervalos entre Batidas	p. 59
4.5.2	Características de Amplitude	p. 61
4.5.3	Parâmetros de Hjorth	p. 62
4.5.3.1	Análise de Custo Computacional	p. 67
4.5.3.2	Comparação com outras técnicas	p. 68
4.6	Modelo Classificador	p. 70
4.6.1	SVM - Máquina de Vetor de Suporte	p. 70
4.7	Medidas de Desempenho	p. 75
5	Testes e Resultados	p. 79
5.1	Testes Preliminares	p. 80
5.1.0.1	Segmentação com Comprimento Fixo	p. 80

5.1.0.2	Segmentação Dinâmica	p. 81
5.1.0.3	Características Normalizadas	p. 83
5.1.1	Comparação com Outros Trabalhos	p. 84
5.2	Teste com Duas Derivações	p. 86
5.2.1	Algumas Observações	p. 88
5.3	O Desbalanceamento do Banco de Dados	p. 90
5.4	Unindo as Duas Abordagens	p. 92
5.5	Observações sobre o Resultado Final	p. 94
6	Considerações Finais	p. 97
6.1	Trabalhos Futuros	p. 98
	Apêndice A - Análise de Custo Computacional	p. 100
A.1	Complexidade no Tempo	p. 100
	Referências	p. 104

Lista de Figuras

1	Fluxo do sangue e partes do coração.	p. 21
2	Fluxo do impulso elétrico no coração.	p. 22
3	Captação de atividade elétrica através de aparelho de ECG.	p. 24
4	Derivações bipolares de membros.	p. 24
5	Derivações unipolares de membros.	p. 25
6	I. Plano Frontal, II. Plano Transversal.	p. 25
7	Derivações unipolares precordiais (V1-V6).	p. 26
8	Principais ondas presentes em um exame de ECG.	p. 27
9	Batidas com ritmo normal sinusal, com taxa de 60 bpm.	p. 28
10	Batidas ectópicas prematuras supraventriculares.	p. 29
11	Batida ectópica prematura ventricular, em destaque.	p. 30
12	Batida de escape ventricular.	p. 31
13	Batida com bloqueio de ramo de feixes direito (V1).	p. 32
14	Batida com bloqueio de ramo de feixes esquerdo (V6).	p. 32
15	Condições cardíacas classificadas por Rizal e Hadiyoso (2015).	p. 40
16	Batidas normais vs. PACs (<i>Premature Atrial Contractions</i>).	p. 41
17	Processo desenvolvido para a classificação automática de batidas cardíacas.	p. 46
18	Divisão de dados para treinamento e teste.	p. 50
19	Passos de filtragem do sinal de ECG.	p. 51
20	Detecção e definição de limites para as batidas.	p. 55
21	Comparação entre técnicas de comprimento fixo e segmentação dinâmica.	p. 57
22	Diferença de amplitude entre batidas normais e prematuras ventriculares.	p. 62

23	Algoritmo para o cálculo dos Parâmetros de Hjorth.	p.67
24	Comparação entre técnicas: Hjorth, DWT e FFT.	p.69
25	Hiperplano gerado pela SVM para classificação de padrões.	p.71
26	Arquitetura da máquina de vetor de suporte.	p.72
27	Mapa não linear $\phi(\cdot)$ do espaço de entrada para o espaço de características.	p.72
28	Cálculo de parâmetros TP, FP, TN e FN segunda a AAMI.	p.77
29	Evolução dos índices de desempenho a cada teste realizado na fase preliminar.	p.86
30	Técnica de subamostragem para balanceamento do banco de dados.	p.91
31	Arquitetura para classificação em dois passos (<i>2-step</i>).	p.93
32	Crescimento de funções: (a) $T(n) = 2^n$ (b) $T(n) = \log n$	p.101
33	Comparação entre ordens de complexidade assintótica.	p.102

Lista de Tabelas

1	Classes de MIT-BIH <i>Arrhythmia</i> e classes da AAMI correspondentes.	p. 48
2	Quantidade de batidas de cada classe nos conjuntos de dados.	p. 49
3	Complexidade Computacional das Técnicas de Extração de Características.	p. 69
4	Exemplo de matriz de confusão.	p. 76
5	Matriz confusão - Segmentação de comprimento fixo.	p. 81
6	Índices de desempenho - Segmentação de comprimento fixo.	p. 81
7	Matriz de confusão - Segmentação dinâmica.	p. 82
8	Índices de desempenho - Segmentação dinâmica.	p. 82
9	Matriz confusão - Intervalos R-R normalizados.	p. 83
10	Índices de desempenho - Intervalos R-R normalizados.	p. 83
11	Resumo técnico dos trabalhos utilizados para comparação.	p. 84
12	Comparação dos testes preliminares com outros estudos.	p. 85
13	Matriz Confusão - Duas derivações e 39 características.	p. 87
14	Índices de Desempenho - Duas derivações e 39 características.	p. 87
15	Comparação de índices de desempenho com outros estudos.	p. 88
16	Índices de desempenho - Estratégias de Segmentação.	p. 90
17	Matriz Confusão - Sub-amostragem.	p. 91
18	Índices de desempenho - Sub-amostragem.	p. 92
19	Matriz Confusão - Classificação em dois passos.	p. 93
20	Índices de desempenho - Classificação em dois passos.	p. 94
21	Comparação final de índices de desempenho com outros estudos.	p. 95
22	Classes de algoritmos em ordem crescente de complexidade.	p. 102

Lista de Abreviaturas

AAMI	<i>Association for the Advancement of Medical Instrumentation</i>
ANSI	<i>American National Standards Institute</i>
BPM	Batidas por Minuto
ECG/EKG	Eletrocardiograma ou Eletrocardiografia
EEG	Eletroencefalograma ou Eletroencefalografia
EMG	Eletromiograma ou Eletromiografia
FFT	Transformada Rápida de Fourier (<i>Fast Fourier Transform</i>)
FN	Falso Negativo (<i>False Negative</i>)
FP	Falso Positivo (<i>False Positive</i>)
ICA	<i>Independent Component Analysis</i>
LBBB	Bloqueio de Ramo de Feixes Esquerdo (<i>Left Bundle Branch Block</i>)
MIT-BIH-AR	Banco de dados MIT-BIH de Arritmias
MLII	Derivação padrão de membros II modificada (<i>modified limb lead II</i>)
NSR	Ritmo Normal Sinusal (<i>Normal Sinus Rhythm</i>)
PAC	Batida Prematura Atrial (<i>Premature Atrial Contraction</i>)
PVC	Batida Prematura Ventricular (<i>Premature Ventricular Contraction</i>)
RBBB	Bloqueio de Ramo de Feixes Direito (<i>Right Bundle Branch Block</i>)
RBF	Função de Base Radial (<i>Radial Basis Function</i>)
SVEB	Batida Ectópica Supraventricular (<i>Supraventricular Ectopic Beat</i>)
SVM	Máquina de Vetor de Suporte (<i>Support Vector Machine</i>)
TN	Verdadeiro Negativo (<i>True Negative</i>)
TP	Verdadeiro Positivo (<i>True Positive</i>)
VCG	Vetorcardiograma
VEB	Batida Ectópica Ventricular (<i>Ventricular Ectopic Beat</i>)

1 Introdução

Neste trabalho, são propostas técnicas de processamento de sinais de eletrocardiograma (ECG) para classificação automática de batidas cardíacas, visando o diagnóstico de arritmias. O objetivo do trabalho é o desenvolvimento e utilização de algoritmos simples e de baixo custo computacional, implementados em MATLAB® e C++, para a solução de problemas clássicos da área, como a segmentação de batidas e a extração de características. Através da utilização de técnicas bem-sucedidas em outros campos de estudo, como os Parâmetros de Hjorth (HJORTH, 1970), o modelo proposto apresenta resultados comparáveis ao estado da arte em sua área de estudo, com a vantagem de apresentar baixo custo computacional e implementação simples, que viabilizam sua utilização em dispositivos com limitações de recursos (processamento, bateria, memória).

Este primeiro capítulo provê uma visão geral sobre o problema da classificação de arritmias cardíacas e constrói um contexto para o trabalho, destacando as motivações que o sustentaram, suas contribuições e o enunciado da tese escolhida.

1.1 Considerações Gerais

Segundo a Organização Mundial da Saúde, as principais causas de morte ao redor do mundo estão relacionadas a doenças cardiovasculares, especialmente em países cuja renda média anual é baixa ou mediana (WORLD HEALTH ORGANIZATION, 2017). No ano de 2015, somente no Brasil, cerca de 350 mil pessoas morreram devido a problemas relacionados ao sistema circulatório (BRASIL, 2017). A adoção de estilos de vida menos saudáveis, aumento de stress, obesidade, hipertensão e diabetes possuem um papel importante nesses números (ELHAJ et al., 2016), tornando o assunto mais relevante a cada ano que passa.

Arritmias cardíacas são fatores importantes a serem levados em consideração nesse cenário, uma vez que causam perturbações no ritmo natural do coração e podem ter consequências bastante sérias para a saúde do paciente (ELHAJ et al., 2016). A função

fundamental do coração é o bombeamento de sangue através do corpo, possibilitando o transporte de nutrientes, oxigênio e hormônios de uma parte para outra, além de resíduos metabólicos e gás carbônico (SHERWOOD, 2015). Esse processo é coordenado por um sistema elétrico que, quando apresenta problemas ou dificuldades, gera arritmias (KASTOR, 2008). Arritmias são definidas como qualquer alteração na taxa, regularidade, local de origem dos impulsos elétricos ou nos caminhos regulares de condução desses impulsos (THALER, 2010). Seus sintomas variam de palpitações e dores no peito, a desmaios e até morte súbita, dependendo do tipo e gravidade do problema (PARK et al., 2016).

De maneira simplificada, as diferentes formas de arritmia podem ser classificadas em dois tipos, de acordo com a gravidade. O primeiro deles representa risco iminente à vida do paciente, e cobre problemas como a fibrilação e taquicardia ventriculares, que demandam tratamento imediato com desfibrilador (CHAZAL; O'DWYER; REILLY, 2004). Muitas pesquisas já foram realizadas para a detecção desse tipo de arritmia, e detectores foram concebidos com bons resultados (AFONSO; TOMPKINS, 1995; MINAMI; NAKAJIMA; TOYOSHIMA, 1999). O foco deste trabalho, no entanto, é o segundo tipo, composto por arritmias que, ainda que não representem risco imediato à vida, demandam tratamento, visando a prevenção de problemas futuros ou agravamento das condições do paciente.

O exame de eletrocardiograma (ECG) é uma boa alternativa para a análise e diagnóstico de arritmias cardíacas, uma vez que não é invasivo, tem custo relativamente baixo e disponibiliza sinais fisiológicos essenciais para a análise de funções e patologias cardíacas (LLAMEDO; MARTÍNEZ, 2011). O aparelho de ECG provê informações sobre a ativação elétrica dos átrios e ventrículos do coração enquanto eles se contraem e expandem, captadas a partir de eletrodos posicionados sobre o corpo do paciente. A maneira como os eletrodos são posicionados pode prover pontos de vista diferentes da atividade elétrica do coração, auxiliando profissionais de saúde na análise da função cardíaca (KASTOR, 2008).

Alguns sintomas de arritmia aparecem com pouca frequência e podem ser de difícil detecção, tanto para o paciente quanto para o profissional que o examina. Existem muitos casos em que pacientes buscam ajuda médica, mas exibem comportamento cardíaco normal durante a consulta e o exame de curta duração (KO et al., 2012). Por este motivo, registros mais longos são necessários para o diagnóstico, resultando em uma demanda de dispositivos portáteis de eletrocardiograma que capturem os sinais por períodos mais longos de tempo, de horas ou até dias (PARK et al., 2016), como o *Holter* ECG (HOLTER, 1961), e possam até mesmo ser monitorados remotamente.

Arritmias cardíacas geralmente se manifestam no exame de ECG como uma sequên-

cia de batidas cardíacas cujos traçados apresentam formatos ou intervalos incomuns. Portanto, após a aquisição do sinal de ECG, um importante passo para a detecção de arritmias é a classificação das batidas cardíacas presentes nesse sinal. Uma análise de um exame de longa duração feita por um especialista humano pode ser custosa em tempo e sujeita a falhas causadas, por exemplo, pelo cansaço. Por essa razão, um processo de classificação automática de batidas e diagnóstico de arritmias torna-se um assistente valioso para profissionais de saúde (CHAZAL; O'DWYER; REILLY, 2004).

Segundo Luz et al. (2016), um sistema completo para classificação automática de arritmias possui quatro etapas principais: pré-processamento do sinal de ECG, detecção e segmentação das batidas cardíacas, extração de características e classificação. Sistemas desse tipo foram apresentados nas últimas três décadas por muitos pesquisadores, utilizando uma variedade de métodos para o cumprimento de cada um dos passos listados acima, variando especialmente os métodos utilizados para extração de características e classificação (LUZ et al., 2016). O Capítulo 3 apresenta um panorama dos métodos existentes, partindo de um contexto histórico até o estado atual da pesquisa na área.

Mazomenos et al. (2013) destacam, no entanto, que a grande maioria dos métodos propostos e utilizados para extração de características e análise de exames de ECG são computacionalmente intensos, ou seja, quando são executados em dispositivos com muitos recursos, sua eficácia é comprovada, mas quando há a necessidade de sua implementação em dispositivos com recursos limitados, alguns problemas podem ser levantados. A necessidade da utilização de dispositivos com limitações pode ter várias razões, entre as quais se destacam razões econômicas, financeiras, de portabilidade e de acessibilidade. Limitações de bateria, processamento ou memória podem tornar a implementação desses métodos inviável, devido ao excesso de consumo de energia ou tempo de execução, que são diretamente dependentes da complexidade computacional do processo algorítmico. A utilização de características adequadas, que demandem baixa complexidade computacional para serem calculadas, leva a um monitoramento de qualidade e permite a redução no consumo de energia e tempo de execução, viabilizando a implementação.

Visando o desenvolvimento de uma solução de baixo custo computacional para o problema da classificação de batidas, este trabalho apresenta uma técnica de extração de características cujo produto são os chamados Parâmetros de Hjorth (HJORTH, 1970). Desde sua concepção, esses parâmetros foram aplicados com sucesso em várias áreas de estudo de sinais biológicos, como no projeto de interfaces cérebro-computador (BCI, de *Brain Computer Interfaces*) (VIDAURRE et al., 2009), análise de eletromiografia (EMG)

(MOUZÉ-AMADY; HORWAT, 1996) e caracterização de sons pulmonares (RIZAL; HIDAYAT; NUGROHO, 2015). O algoritmo para o cálculo dos Parâmetros de Hjorth demanda passos de baixo custo computacional, especialmente quando comparado a outros métodos de análise de frequência, o que levou alguns autores (MOUZÉ-AMADY; HORWAT, 1996; CECCHIN et al., 2010) a escolhê-los em detrimento de técnicas mais conhecidas como a Transformada Rápida de Fourier (FFT, de *Fast Fourier Transform*) e *wavelets*. Dois outros trabalhos utilizaram os parâmetros de Hjorth para o processamento de sinais cardíacos (NOVIYANTO et al., 2011; RIZAL; HADIYOSO, 2015), mas esses estudos apresentam propostas diferentes do presente trabalho de tese, com relação a objetivos e metodologia. O Capítulo 3 apresenta mais informações e esclarece as diferenças entre os trabalhos.

A partir dessas características, extraídas de cada batida presente no sinal, são construídos vetores de dados, que servem como entrada para um modelo classificador. Como a finalidade deste trabalho não é explorar diferentes tipos de modelos classificadores, em seu decorrer são utilizadas máquinas de vetor de suporte (SVM, de *Support Vector Machines*) (CORTES; VAPNIK, 1995) como classificador padrão. Classificadores mais simples como discriminantes lineares já foram utilizados por outros pesquisadores (CHAZAL; O'DWYER; REILLY, 2004; LLAMEDO; MARTÍNEZ, 2011), mas fiam-se em algumas assunções sobre os dados de entrada, como distribuição normal e separabilidade linear (LLAMEDO; MARTÍNEZ, 2011). As máquinas de vetor de suporte são classificadores mais abrangentes e, de acordo com sua configuração, podem produzir regiões de decisão capazes de atingir um bom desempenho de classificação independentemente da separabilidade linear dos dados. Além disso, a SVM é um dos modelos mais utilizados para classificação de batidas cardíacas (LUZ et al., 2016).

1.2 Proposta da Tese

Algoritmos para classificação de batidas cardíacas já foram apresentados anteriormente com resultados relevantes (LUZ et al., 2016). No entanto, segundo Mazomenos et al. (2013), os métodos utilizados por cada um de seus autores possuem, em geral, um alto custo computacional – especialmente os que incluem informações sobre o sinal no domínio da frequência. Os parâmetros de Hjorth, utilizados neste trabalho, são obtidos com passos de computação de menor custo computacional quando comparados a outras técnicas com a mesma finalidade (MOUZÉ-AMADY; HORWAT, 1996), mas caracterizam o sinal cardíaco eficientemente, possibilitando resultados de classificação compatíveis com os de sistemas computacionalmente mais complexos.

O desenvolvimento e utilização de técnicas com baixa complexidade computacional para processamento de sinais de ECG e, especialmente, extração de características de batidas cardíacas, torna viável sua implementação em plataformas de baixo custo e dispositivos embarcados, que possuam limitações de recursos como processamento e tempo de bateria. Esse tipo de solução visa atender a uma demanda crescente de dispositivos portáteis para uso domiciliar e ambulatorial (GRADL et al., 2012), assim como facilitar o acesso de países em desenvolvimento a sistemas de diagnóstico de boa qualidade e baixo custo (SILVA; MOODY; CELI, 2011).

A tese defendida neste trabalho, portanto, é de que é possível realizar a classificação automática de batidas cardíacas com qualidade e desempenho comparáveis ao estado da arte e baixo custo computacional, a partir de uma técnica de extração características baseada, principalmente, nos parâmetros de Hjorth. O sucesso desse estudo viabilizará sua implementação futura em dispositivos de *hardware* que possuam limitações de recursos, como sistemas embarcados e circuitos integrados.

1.3 Contribuições

Llamedo e Martínez (2011) e Zhang et al. (2014) afirmam em seus trabalhos que ainda existe a necessidade de uma busca por métodos de extração de características que representem o sinal cardíaco com fidelidade e levem a uma melhoria de desempenho na classificação de batidas. Este trabalho apresenta um novo método para a realização dessa tarefa, os Parâmetros de Hjorth, que se beneficiam de uma descrição abrangente da morfologia do sinal, incluindo informações sobre os domínios do tempo e frequência, e se caracterizam pela simplicidade de cálculo e baixo custo computacional, atendendo à demanda levantada por Mazomenos et al. (2013) e Gradl et al. (2012).

Visando aproveitar o máximo das características extraídas, especialmente dos Parâmetros de Hjorth, é apresentada, também, uma nova técnica para delimitação e segmentação das batidas cardíacas, chamada de “segmentação dinâmica”. Sua função é delimitar com exatidão as batidas cardíacas presentes no sinal, evitando que informações de batidas adjacentes influenciem na extração de suas características e degradem o desempenho do sistema como um todo (Seção 4.4).

Além disso, a fim de diminuir a influência da taxa cardíaca atual do paciente no processo de extração de características, é introduzida uma técnica para a normalização dos valores de intervalos entre batidas subsequentes (intervalos R-R). Os valores de intervalos

R-R passam a ser calculados em relação a uma média de seu histórico recente, das últimas cinco batidas, o que torna o sistema mais eficiente e pronto para classificação em tempo real (Seção 4.5.1). A técnica proposta adapta o trabalho de Lin e Yang (2014), que realiza a normalização de maneira semelhante, mas inviabiliza a classificação em tempo real, devido à maneira como é executada.

1.4 Motivação

O processo de identificação e classificação de arritmias cardíacas realizado por um especialista humano, sem assistência de um computador, pode ser bastante desgastante e sujeito a erros, uma vez que torna necessária a inspeção visual de cada batida contida em um longo registro de ECG, cuja duração pode atingir horas ou até dias. Com uma taxa normal de batimentos cardíacos na faixa de 80 batidas por minuto, por exemplo, um exame de ECG geraria dados de 4800 batidas cardíacas por hora. A superação desse problema a partir de sistemas computacionais, aliada à possibilidade de se obter resultados em tempo real, até mesmo acessados remotamente através de dispositivos móveis, justifica o crescente interesse nessa área de pesquisa nas últimas décadas.

Além disso, segundo Li et al. (2014), o crescente envelhecimento da população mundial levará a um rápido crescimento de doenças relacionadas à idade, como doenças cardíacas e diabetes. Infelizmente, no entanto, a grande maioria dos pacientes não terá condições de realizar exames regulares em hospitais com infraestrutura adequada, seja por questões financeiras ou dificuldade de acesso (áreas remotas, países em desenvolvimento). Por isso, dispositivos portáteis de baixo custo que sejam capazes de realizar um monitoramento de qualidade com baixo consumo de energia podem se tornar uma alternativa de valor.

Gradl et al. (2012) destacam que existe uma necessidade definida por soluções de monitoramento fisiológico automáticas de baixo custo que sejam fáceis de usar, precisas, e possam ser utilizadas em casa ou em ambulatórios. Essa situação se agrava ainda mais em países em desenvolvimento, onde a disponibilidade de clínicas e especialistas médicos é mais baixa (SILVA; MOODY; CELI, 2011). Por este motivo, este trabalho visa o desenvolvimento de um modelo de classificação eficiente, que busque simplicidade computacional nos passos necessários para classificação automática de batidas cardíacas e viabilize sua migração para plataformas de baixo custo com recursos limitados, levando seus benefícios a regiões e pessoas que ainda não possuam acesso a este tipo de tecnologia.

1.5 Artigo Aceito em Periódico

Resultados parciais da pesquisa foram submetidos em formato de artigo para a revista *IET Signal Processing* sob o título “*Heartbeat Classification with Low Computational Cost Using Hjorth Parameters*”. O artigo foi aceito para publicação no dia 20 de novembro de 2017 e encontra-se disponível para consulta *online* (Anexo I). Sua versão impressa será publicada em breve, de acordo com cronograma específico da revista, definido por seus editores. A revista *IET Signal Processing* possui conceito A2 no sistema de avaliação de periódicos da CAPES, o *Qualis*, para a área de Engenharias IV.

O artigo aceito é composto pela maior parte dos conceitos explorados neste trabalho, com exceção da utilização da característica Diff-RR-Norm, incluída posteriormente (Seção 4.5.1), e dos testes utilizando a técnica de subamostragem (Seções 5.3 e 5.4). Os resultados obtidos pelo estudo são muito semelhantes ou ligeiramente superiores quando comparados aos demais trabalhos utilizados como referência.

1.6 Organização do Trabalho

No Capítulo 2, estão descritos os processos biológicos que regem o funcionamento do coração, necessários para a compreensão deste trabalho. O coração é caracterizado como um órgão fonte de atividade elétrica, que pode ser captada na superfície da pele através de eletrodos e processada para fins clínicos. O capítulo segue com informações sobre o exame de eletrocardiograma (ECG) e termina com a descrição de alguns tipos de batidas importantes, suas características elétricas e morfológicas.

O Capítulo 3 fornece uma revisão da literatura da área de classificação de batidas cardíacas e constrói um retrato do estado da arte no campo, dando ênfase aos trabalhos mais importantes e influentes. Também neste capítulo, são identificadas as oportunidades de pesquisa e lacunas deixadas por outros pesquisadores. Por fim, são listadas as contribuições deste trabalho de tese para a comunidade científica.

No Capítulo 4, estão descritos os passos para o desenvolvimento do trabalho, assim como os métodos utilizados em cada uma das etapas da classificação automática de batidas cardíacas. As seções partem do sinal puro, captado no aparelho de ECG, passando por seu processamento até a identificação de cada batida, individualmente, pelo modelo classificador. Também neste capítulo, há o embasamento teórico e informações aprofundadas sobre os parâmetros de Hjorth, as máquinas de vetor de suporte e outras técnicas

utilizadas no decorrer do trabalho.

O Capítulo 5 apresenta os resultados dos testes realizados no decorrer da pesquisa, seguindo uma ordem cronológica e destacando o ganho obtido pela inclusão de cada nova técnica. Há uma discussão dos resultados e sua comparação com cinco outros trabalhos importantes da área.

Finalmente, o Capítulo 6 apresenta as considerações finais sobre a pesquisa, compara os resultados obtidos aos objetivos propostos e conclui o documento. Além disso, são apontadas direções para o prosseguimento do estudo das técnicas propostas no decorrer do trabalho.

2 O Sinal Cardíaco

A existência do coração é conhecida desde os gregos antigos, que o nomearam *kardia*, origem de palavras como “cardíaco”. Romanos modificaram a palavra *kardia* para *cor*, origem da própria palavra “coração” (OPIE, 2004). A base dos conceitos modernos de circulação do sangue, no entanto, foram estabelecidas apenas em 1628, por William Harvey, que, pela primeira vez, consegue provar o fato de que o coração funciona como uma “bomba muscular” responsável pelo bombeamento do sangue para todo o corpo, em seu trabalho *Anatomical Treatise on the Motion of the Heart and Blood in Animals*, provavelmente o trabalho mais importante na história da cardiologia (KATZ, 2010).

O coração é um órgão muscular cuja função é o bombeamento de sangue através de vasos sanguíneos do sistema circulatório, levando oxigênio e nutrientes para todo o corpo, e assistindo na remoção de resíduos metabólicos. Seu funcionamento básico, propriedades elétricas e as características de cada tipo de batida cardíaca estão descritos nas seções seguintes.

2.1 Funcionamento do Coração

O coração humano, assim como o dos demais mamíferos, é um órgão muscular dividido em quatro câmaras: dois átrios e dois ventrículos, como ilustrado na Figura 1. Em um ciclo cardíaco, o sangue da maior parte das veias do corpo entra, especialmente através das veias cava, no átrio direito do coração, que ejeta o sangue para o ventrículo direito passando pela válvula tricúspide. Do ventrículo direito, o sangue é impulsionado através da válvula pulmonar pelas artérias pulmonares e para os pulmões. O sangue oxigenado é coletado dos pulmões pelas veias pulmonares e chega ao átrio esquerdo, passando pela válvula mitral até o ventrículo esquerdo, a principal câmara bombeadora do coração. O ventrículo esquerdo, então, bombeia o sangue pela válvula aórtica até as artérias, que distribuem o sangue para o restante do corpo. As válvulas mitral e tricúspide previnem que o sangue seja ejetado de volta para os átrios, enquanto as válvulas pulmonar e aórtica previnem seu retorno

para os ventrículos (KASTOR, 2008). Músculos que envolvem as câmaras (ou miocárdio) são responsáveis pelo bombeamento de sangue: durante sua contração (chamada sístole), o sangue é ejetado, e durante o relaxamento (diástole), o sangue preenche as câmaras.

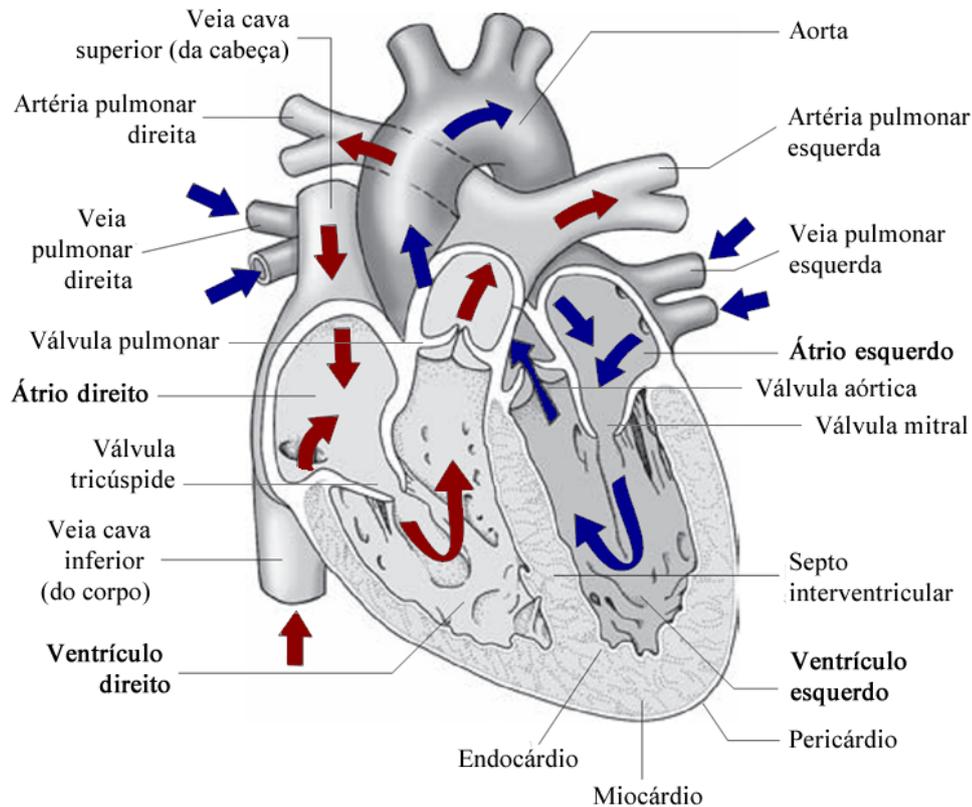


Figura 1: Fluxo do sangue e partes do coração (adaptada de Kastor (2008)).

Portanto, é válido dizer que o coração pode ser visto como duas bombas funcionando em série, uma delas formada pelo átrio e ventrículo direitos e outra pelo átrio e ventrículo esquerdos (KATZ, 2010). A primeira é responsável pelo recebimento do sangue do corpo e bombeamento para os pulmões, enquanto a outra recebe o sangue oxigenado dos pulmões e o bombeia para o restante do corpo.

Para que a sequência de bombeamento aconteça normalmente, é necessário que o sistema elétrico do coração a coordene. Na parede do átrio direito, há uma estrutura chamada de nó sinusal ou sinoatrial (SA), que funciona como o marca-passo fundamental do coração (Figura 2). Este nó sinoatrial gera pequenos impulsos elétricos em um ritmo regular, entre 60 e 100 por minuto, variando apenas com as necessidades do corpo e de acordo com comando do sistema nervoso autônomo. Durante períodos de descanso, a taxa diminui e o oposto acontece em períodos de nervosismo ou atividade física.

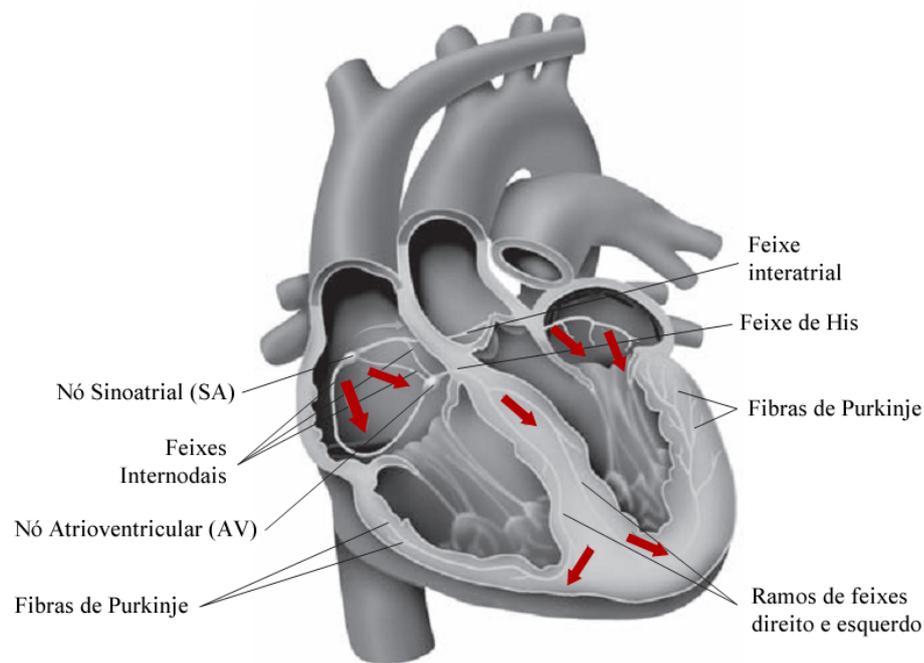


Figura 2: Fluxo do impulso elétrico no coração (adaptada de Kastor (2008)).

Os impulsos elétricos gerados no nó sinoatrial são conduzidos através dos feixes internodais até outro nó, o atrioventricular (AV), localizado no limite entre o átrio e ventrículo direitos, e pelos feixes interatriais, fazendo com que os dois átrios se contraíam simultaneamente. O nó atrioventricular consiste em uma coleção de células especializadas do sistema elétrico cardíaco, e é responsável pela inclusão de um pequeno atraso na transmissão do impulso para os ventrículos. Essa pequena interrupção fornece um tempo extra aos ventrículos, suficiente para que se encham do sangue expelido pelos átrios recém-contraídos antes de se contraírem e fecharem as válvulas mitral e tricúspide.

Após a passagem do sangue para os ventrículos, o impulso elétrico continua seu caminho, passando pelo feixe de His e ramos de feixes esquerdo e direito (chamados de “*bundle branches*” em inglês). Cada ramo emite uma grande quantidade de ramificações, as fibras de Purkinje, cuja finalidade é otimizar a chegada dos impulsos aos ventrículos. Essas fibras conduzem o sinal elétrico que leva à contração dos ventrículos, realizada em uma sequência especial que possibilita que o sangue seja ejetado de maneira eficiente, de baixo para cima, em um movimento similar a uma ordenha, bombeando sangue para as artérias aorta e pulmonares. Ao final, um novo impulso é gerado pelo nó SA e o ciclo se reinicia.

2.2 O Eletrocardiograma

Como resultado das batidas do coração, ocorrem variações no potencial elétrico da superfície de pele do paciente (LUZ et al., 2016), que podem ser capturadas e medidas com o auxílio de eletrodos e de um equipamento de eletrocardiograma (ECG). Esse tipo de equipamento é comumente utilizado por médicos para avaliação da atividade elétrica do coração e diagnóstico de problemas cardíacos. Eletrocardiogramas são amplamente utilizados como um meio barato e não invasivo de observação da fisiologia do coração (MOODY; MARK, 2001).

As ondas registradas pelo ECG foram nomeadas no início do século 20 por Einthoven (1860-1927), considerado pai da eletrocardiografia e inventor do primeiro galvanômetro que possibilitou registros de alta fidelidade da atividade elétrica de corações humanos (KATZ, 2010), em uma pesquisa que lhe rendeu o prêmio Nobel. Com o decorrer dos anos, o eletrocardiograma se desenvolveu e tornou-se um método fundamental na cardiologia, desempenhando papel importante no diagnóstico de transtornos do ritmo, síndromes coronarianas, crescimento das câmaras e outras condições do coração. Algumas décadas depois de Einthoven, Holter (1961) introduziu técnicas para gravação contínua de ECG em pacientes por períodos de muitas horas, que se tornaram um padrão para observação de aspectos transitórios da atividade elétrica cardíaca, indetectáveis em um exame rápido.

O exame de eletrocardiograma padrão registra até 12 diferentes aspectos da atividade elétrica do coração, que funcionam como “pontos de vista” diferentes, obtidos a partir da variação da localização dos eletrodos e de sua referência. Cada um desses aspectos, chamados de “derivações” do sinal de ECG, são obtidos a partir de 10 cabos conectados a eletrodos que são distribuídos em localizações específicas dos membros e peito do paciente, em uma configuração semelhante à mostrada na Figura 3.

São derivações bipolares aquelas que medem a diferença de potencial entre dois pontos da superfície corporal, ou a diferença entre a tensão medida em dois eletrodos. Este tipo contempla as derivações padrão de membros I, II e III, ilustradas na Figura 4. O triângulo formado pelos eixos das derivações bipolares, mostrado na Figura 4, é chamado de “Triângulo de Einthoven”, em homenagem ao seu criador (CONOVER, 2002). São elas:

- **I:** Um eletrodo no punho direito (−) e outro no punho esquerdo (+).
- **II:** Um eletrodo no punho direito (−) e outro no tornozelo esquerdo (+).
- **III:** Um eletrodo no punho esquerdo (−) e outro no tornozelo esquerdo (+).

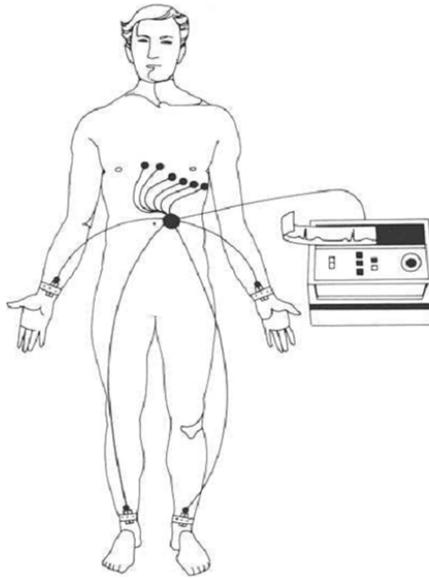


Figura 3: Captação de atividade elétrica através de aparelho de ECG (THALER, 2010).

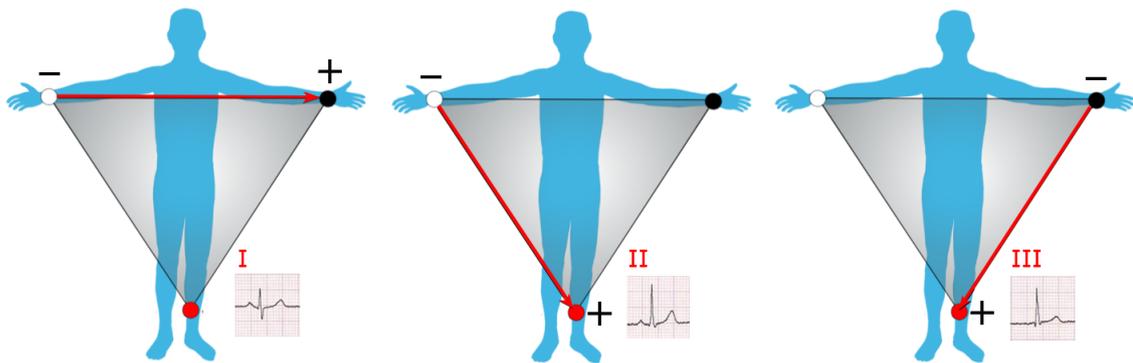


Figura 4: Derivações bipolares de membros (LIFE IN THE FAST LANE, 2017).

As derivações unipolares, por outro lado, são medidas utilizando-se apenas um eletrodo, que serve como terminal positivo enquanto o terminal negativo é obtido no aparelho, a partir de uma média dos valores dos outros eletrodos. São unipolares as derivações de membro aumentadas aVR, aVL e aVF, onde as letras R, L e F são provenientes das palavras *Right* (direito), *Left* (esquerdo) e *Foot* (pé), em inglês, e a letra minúscula a de *augmented* (aumentada), devido a uma amplificação de sinal realizada nesses casos. A letra V é referente à palavra inglesa *voltage*, ou tensão. As derivações aumentadas de membros estão ilustradas na Figura 5.

- **aVR**: Eletrodo no punho direito (+).
- **aVL**: Eletrodo no punho esquerdo (+).
- **aVF**: Eletrodo no tornozelo esquerdo (+).

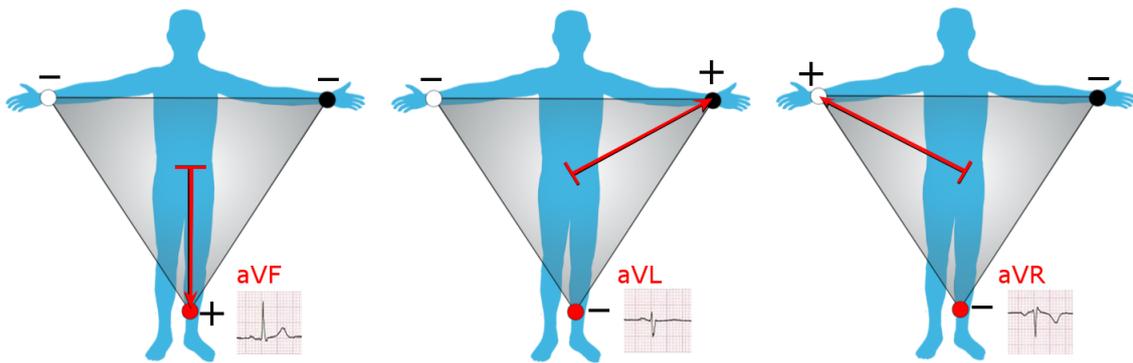


Figura 5: Derivações unipolares de membros (LIFE IN THE FAST LANE, 2017).

As seis derivações de membros estão relacionadas entre si, no sentido em que captam as variações elétricas do coração em um mesmo plano, que é frontal com relação ao paciente e perpendicular ao chão. Cada uma delas capta as ondas elétricas de polarização e despolarização geradas pelo coração de um ângulo diferente, como ilustrado pelas setas vermelhas presentes nas Figuras 4 e 5.

Com a finalidade de prover observações do coração em um outro plano, paralelo ao chão e chamado de transversal ou horizontal, foram introduzidas as derivações precordiais V1, V2, V3, V4, V5 e V6. Essas derivações também são unipolares e cada uma delas é captada a partir de um único eletrodo de polaridade positiva. Assim, além de informação sobre as porções inferior e superior do coração obtidas pelas derivações de membros, as derivações precordiais provêm informações sobre as partes posterior e anterior do coração. A Figura 6 ilustra a diferença entre os planos frontal e transversal.

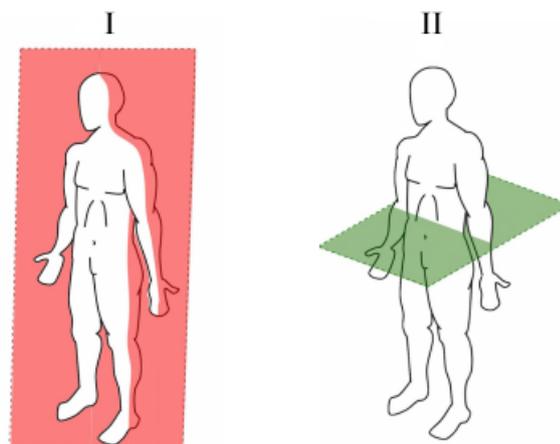


Figura 6: I. Plano Frontal, II. Plano Transversal (INFOGRAM, 2018).

A Figura 7 mostra o posicionamento dos eletrodos nas derivações precordiais. Segundo Thaler (2010), os locais onde são colocados os eletrodos para cada derivação precordial

são os seguintes:

- **V1:** No quarto espaço intercostal, na borda direita do osso esterno.
- **V2:** No quarto espaço intercostal, na borda esquerda do esterno.
- **V3:** A meia distância entre V2 e V4.
- **V4:** No quinto espaço intercostal esquerdo, em uma linha vertical que desce do meio da clavícula.
- **V5:** Na interseção da linha horizontal, que parte de V4, com a linha axilar anterior.
- **V6:** Na interseção da linha horizontal, que parte de V4, com a linha axilar média.

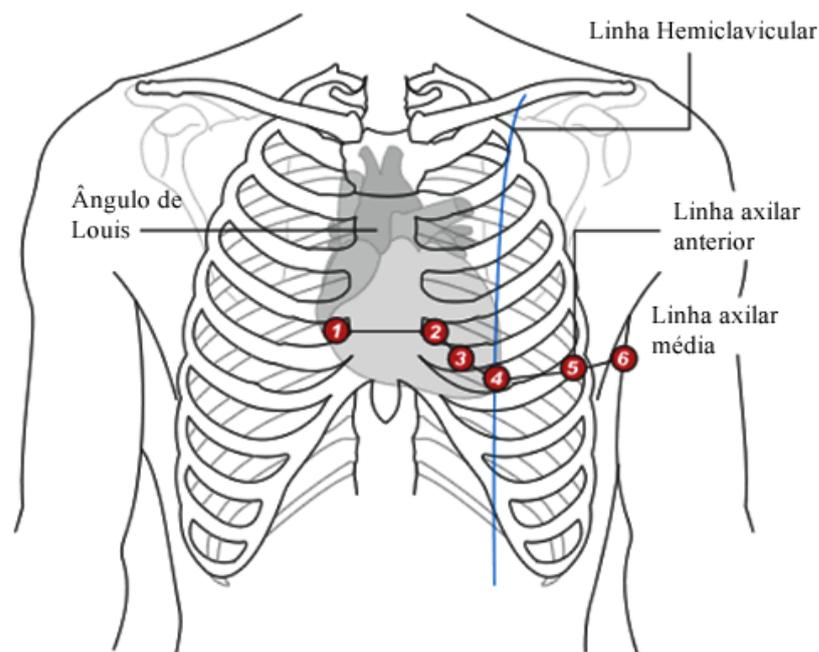


Figura 7: Derivações unipolares precordiais (V1-V6) (UNIVERSITY OF NOTTINGHAM, 2018).

Segundo Luz et al. (2016), uma das derivações mais utilizadas para diagnóstico de doenças cardíacas é a derivação padrão de membros II, cujas características destacam segmentos importantes da batida e mostram com clareza deflexões importantes, como as ondas P e T e o complexo QRS, mostrados na Figura 8. Para uso em sistemas de classificação automática de batidas e detecção de arritmias, a combinação dos dados da derivação II com os da derivação precordial V1 atualmente apresenta os melhores resultados (LLAMEDO; MARTÍNEZ, 2012).

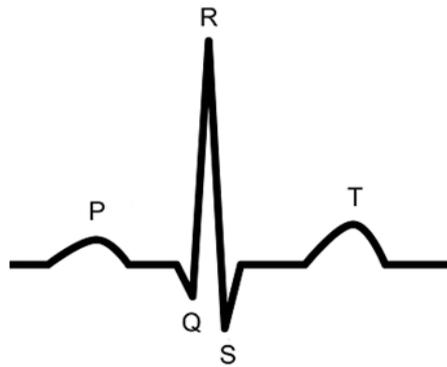


Figura 8: Principais ondas presentes em um exame de ECG.

As deflexões presentes no sinal do eletrocardiograma correspondem aos movimentos de contração (despolarização) e relaxamento (polarização) do coração. A despolarização atrial causa uma deflexão no sinal chamada de onda P. A seguir, a despolarização dos ventrículos causa o aparecimento de uma sequência de ondas chamada de complexo QRS. Por último, os ventrículos se repolarizam, gerando a onda T (KASTOR, 2008). A amplitude do complexo QRS é muito maior do que a da onda P, uma vez que os ventrículos possuem uma quantidade superior de massa muscular quando comparados aos átrios e, por isso, são capazes de gerar um potencial elétrico maior. A onda T indica a recuperação dos ventrículos, que voltam à sua condição de relaxamento, e também possui menor amplitude. A repolarização dos átrios acontece simultaneamente à despolarização dos ventrículos e não gera alteração visível no sinal de ECG: seu efeito elétrico é mascarado pelo complexo QRS, cuja amplitude é muito superior (THALER, 2010).

2.3 Arritmias e Tipos de Batidas

A atividade cardíaca normal, sem desvio ou variação na morfologia do sinal de ECG é chamada de ritmo normal sinusal (NSR, de *Normal Sinus Rhythm*), e sua taxa cardíaca típica se encontra entre 60 e 100 batidas por minuto (DAS, 2015), sendo que a duração de intervalos R-R (intervalos entre os pontos mais altos dos complexos QRS de duas batidas adjacentes) varia levemente com o ciclo respiratório. A Figura 9 ilustra um trecho de ECG com ritmo sinusal normal com taxa de aproximadamente 60 batidas por minuto.

Arritmias são ritmos cardíacos anormais, resultantes de qualquer mudança na taxa cardíaca, regularidade, local de origem ou condução dos impulsos cardíacos. Seus sintomas variam desde pequenas palpitações, fraqueza, tontura e dor no peito até morte súbita, dependendo do tipo e gravidade do problema (PARK et al., 2016). Embora alguns sinais

físicos presentes durante a arritmia possam ajudar na realização do diagnóstico correto, o método padrão para reconhecimento de arritmias cardíacas é o eletrocardiograma.



Figura 9: Batidas com ritmo normal sinusal, com taxa de 60 bpm (HAMPTON, 2013).

Um dos principais tipos de arritmia ocorre quando o impulso para a despolarização do coração é originado fora do nó sinoatrial, em outra parte do miocárdio. Esse tipo de comportamento é chamado de polarização ectópica, e leva a “batidas ectópicas”. Causas comuns são o uso de drogas (cafeína, inclusive), infecção viral do miocárdio ou outra inflamação ou dano de parte do coração, causado, por exemplo, por uma isquemia (CLIFFORD; AZUAJE; MCSHARRY, 2006). Quando as batidas são geradas na junção atrioventricular (nó AV) ou nos átrios, são chamadas de “batidas ectópicas supraventriculares”. No caso de serem geradas abaixo do nó AV, nos ventrículos, são chamadas de “batidas ectópicas ventriculares”. Neste trabalho, são feitas referências a dois tipos de batidas ectópicas, as prematuras (Seção 2.3.1) e as batidas de escape (2.3.2).

Além de anomalias na geração do impulso cardíaco, alguns problemas podem ocorrer durante a condução desse impulso através do coração (THALER, 2010). Atrasos ou bloqueios podem surgir em algum ponto de seu caminho natural, que parte do nó sinoatrial, passando pelo nó atrioventricular, feixe de His e ramos de feixes. Neste trabalho, são feitas referências a dois tipos de batidas com bloqueios na condução, ambas com problemas na transmissão dos impulsos através dos ramos de feixes, direito e esquerdo (Seção 2.3.3).

2.3.1 Batidas Prematuras

Batidas prematuras são o tipo mais comum de arritmia. Qualquer parte do coração pode se despolarizar mais cedo do que o esperado, gerando uma batida chamada de “extra-sístole” ou “batida prematura”. O termo “ectópico” é utilizado normalmente para indicar que a despolarização se originou em local anormal (HAMPTON, 2013). Palpitações são o principal sintoma deste tipo de batida, independente do foco do impulso (KASTOR, 2012).

Quando a batida ectópica supraventricular se origina nos átrios, ela é chamada de batida prematura atrial (PAC, de *Premature Atrial Contraction*), e pode ser distinguida

de batidas normais pelo formato da onda P e pelo tempo da batida. Devido ao fato de uma batida deste tipo ser originada longe do nó sinoatrial, a despolarização atrial não ocorre da maneira usual, e a configuração da onda P resultante é diferente da de batidas normais. Além disso, uma batida prematura aparece antes do esperado, antecipando-se ao tempo da próxima batida sinusal. Este tipo de batida pode indicar a presença de alguma patologia atrial e a possibilidade de alguns tipos de arritmias mais graves, mas geralmente não representa risco imediato.

No caso do impulso cardíaco ser originado no nó ou junção atrioventricular (AV), a batida gerada é chamada de batida prematura juncional ou nodal. Nesse tipo de batida, além do aparecimento prematuro, normalmente não há onda P visível ou ela possui polaridade oposta à onda P de batidas normais, aparecendo invertida no traçado do ECG, uma vez que o impulso se desloca no sentido contrário dentro dos átrios. Tanto nas batidas prematuras atriais quanto nas juncionais, os complexos QRS e as ondas T possuem aparência idêntica a de ondas normais. A Figura 10 ilustra esses dois tipos de batidas entre outras de ritmo normal sinusal.

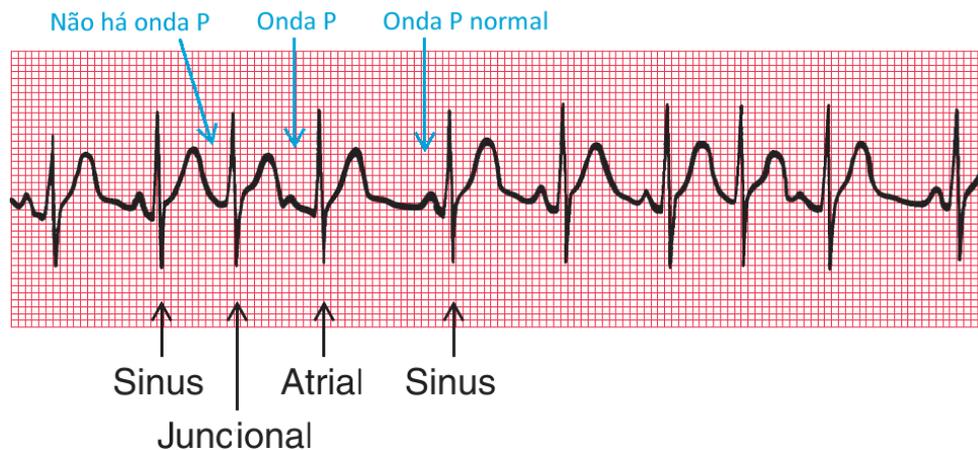


Figura 10: Batidas ectópicas prematuras supraventriculares (HAMPTON, 2013).

Batidas prematuras ventriculares (PVC, de *Premature Ventricular Contraction*) são reconhecidas pela presença de complexos QRS adiantados no tempo e de formato incomum. Neste tipo de batida, o complexo QRS é largo e anormal, devido ao fato da despolarização não seguir os caminhos normais de condução (THALER, 2010). O estímulo gerado normalmente não despolariza os átrios, de maneira que as ondas P mantêm seu ritmo subjacente (DAS, 2015), podendo aparecer no eletrocardiograma após o complexo QRS ou serem completamente mascaradas pela despolarização dos ventrículos. Uma batida prematura ventricular é geralmente seguida por uma pausa compensatória prolongada antes da próxima batida. A Figura 11 ilustra este tipo de batida, que pode ser causada

por cardiomiopatias, hipertensão, doenças pulmonares, álcool ou drogas (KASTOR, 2012).

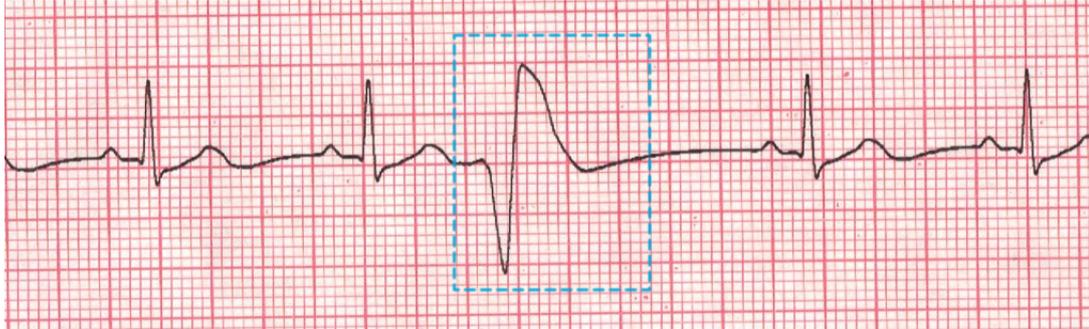


Figura 11: Batida ectópica prematura ventricular, em destaque (MEDLIBES, 2018).

Batidas isoladas do tipo PVC são comuns em corações normais e, geralmente, não requerem tratamento. No entanto, existem algumas situações em que elas representam um risco aumentado para o aparecimento de arritmias mais perigosas, como taquicardia ventricular e fibrilação ventricular, que podem causar a morte do paciente. Deve-se estar atento à frequência das batidas PVC, seu aparecimento consecutivo, variações em sua forma, aparecimento durante a onda T anterior (aumenta risco de taquicardia ventricular) e ocorrência durante uma configuração de infarto agudo do miocárdio.

2.3.2 Batidas de Escape

Diferentes partes do coração são capazes de iniciar a sequência de despolarização, como visto na seção anterior. Isso, no entanto, pode constituir uma vantagem, uma vez que provê ao coração mecanismos de segurança que garantem seu funcionamento mesmo que o nó sinoatrial falhe em gerar o impulso em algum dado momento (HAMPTON, 2013).

O coração é controlado pelo local que espontaneamente se despolariza com maior frequência. Em condições normais, o nó SA despolariza com taxa de 60 a 100 vezes por minuto. Caso o nó SA falhe em despolarizar, o controle será assumido por um foco localizado no átrio ou nó atrioventricular, cuja frequência média é de aproximadamente 50 vezes por minuto. Caso esses falhem, ou a condução pelo feixe de His esteja bloqueada por algum motivo, um foco ventricular assume o controle, com taxa de aproximadamente 30 vezes por minuto (HAMPTON, 2013).

Esses ritmos de segurança são mais lentos e são chamados de “ritmos de escape”. Eles não representam problemas em si mesmos, mas podem indicar a presença de problemas mais graves de condução. Por exemplo, eles são comumente vistos na fase aguda de ataques cardíacos.

Uma batida de escape é bastante similar à sua correspondente prematura, com a diferença de que as batidas de escape são uma resposta compensatória normal e apresentam intervalos R-R prolongados, enquanto batidas prematuras aparecem antes do esperado, antecipando o ritmo normal. Quando batidas não sinusais aparecem no ECG, é importante diferenciar as batidas prematuras, que geralmente indicam uma patologia de automicidade anômala, de batidas de escape, que geralmente indicam patologias na condução do impulso elétrico, uma vez que o tratamento é diferente para cada caso (CLIFFORD; AZUAJE; MCSHARRY, 2006). A Figura 12 mostra uma batida de escape ventricular, caracterizada pelo aparecimento tardio com relação ao ritmo normal, a ausência de onda P e o formato anômalo, mais largo, do complexo QRS.

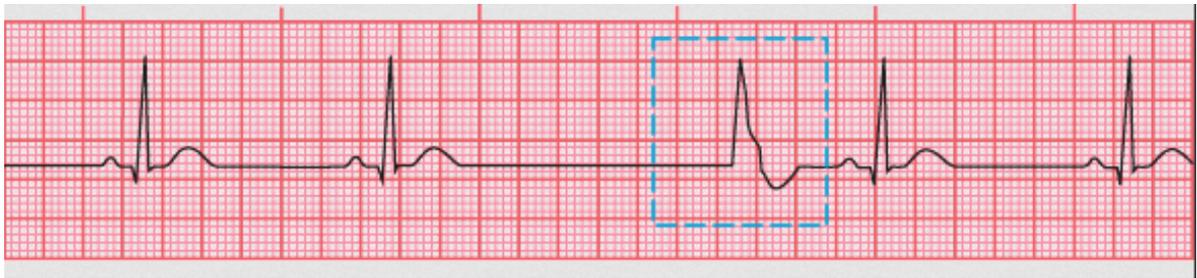


Figura 12: Batida de escape ventricular (BASIC ARRHYTHMIA, 2018). A batida de escape ventricular (destaque) aparece tardiamente, com complexo QRS largo e onda P ausente.

2.3.3 Bloqueios de Ramos de Feixes

A condução do impulso elétrico no coração pode sofrer atrasos e bloqueios em qualquer ponto de seu caminho. Quando a onda de despolarização chega ao septo intraventricular normalmente, o intervalo entre o início da onda P e a primeira deflexão do complexo QRS é normal no exame de eletrocardiograma. Entretanto, se há uma condução anormal através do ramo de feixes esquerdo ou direito, haverá um atraso na despolarização de parte do músculo ventricular, o que faz com que um dos ventrículos se despolarize primeiro do que o outro e causa um alargamento do complexo QRS (HAMPTON, 2013). Esses bloqueios geralmente representam um efeito mínimo na eficácia do bombeamento do sangue, mas podem indicar algumas importantes patologias subjacentes, como embolia pulmonar e isquemia aguda anterior (CLIFFORD; AZUAJE; MCSHARRY, 2006).

No bloqueio do ramo de feixes direito (RBBB, de *Right Bundle Branch Block*), a despolarização do ventrículo direito é atrasada e, em geral, não começa até que o ventrículo esquerdo esteja quase completamente despolarizado. Isso causa um alargamento do complexo QRS, que assume uma aparência como a de “orelhas de coelho” (THALER, 2010),

visível especialmente na derivação precordial V1 (Figura 13).

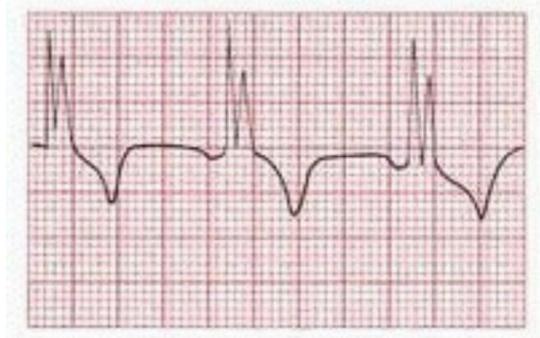


Figura 13: Batida com bloqueio de ramo de feixes direito (V1) (THALER, 2010).

No caso de bloqueio do ramo de feixes esquerdo (LBBB, de *Left Bundle Branch Block*), é o ventrículo esquerdo que despolariza com atraso em relação ao direito. Neste tipo de batida o complexo QRS é também mais largo que o normal, e seu formato característico pode ser melhor visualizado na derivação precordial V6, como ilustrado na Figura 14. Aspecto de “orelhas de coelho” pode aparecer também nesse caso, mas é menos frequente do que nas batidas RBBB.



Figura 14: Batida com bloqueio de ramo de feixes esquerdo (V6) (HAMPTON, 2013).

3 O Estado da Arte

Sistemas computadorizados para classificação automática de batidas cardíacas vêm sendo desenvolvidos por muitos pesquisadores há mais de três décadas, desde os anos 80. Drazen et al. (1988) estimam que aproximadamente 52 milhões de exames de eletrocardiograma foram processados por computador ainda no ano de 1987, provenientes dos mais de 15 mil sistemas de ECG digital já existentes nos Estados Unidos naquela época.

No início dos anos 90, Yeap, Johnson e Rachniowski (1990) foram capazes de distinguir batidas normais de ectópicas através de redes neurais artificiais do tipo perceptron de múltiplas camadas, em uma década que seguiu com trabalhos como o de Senhadji et al. (1995), que propõem a utilização de transformadas *wavelet* para extração de características do sinal. No ano de 1997, Wieben, Tompkins e Afonso (1997) propõem a lógica *fuzzy* para diferenciar batidas prematuras ventriculares das demais, enquanto Hu, Palreddy e Tompkins (1997) apresentam um modelo que se adapta ao paciente e utiliza uma mistura de especialistas (MOE, de *mixture of experts*) para a classificação a partir de características morfológicas do sinal. Este último trabalho consegue uma acurácia de mais de 90% na distinção entre batidas ectópicas ventriculares e não-ventriculares. Lagerholm et al. (2000) utilizam funções *Hermite* e mapas auto-organizáveis em uma técnica de *clusterização* de batidas cardíacas, que divide as batidas em 25 *clusters* de dados e garante com erro menor de 1.5% que as batidas em um mesmo *cluster* são de um mesmo tipo.

Sistemas de classificação automática de batidas cardíacas foram apresentados por muitos pesquisadores, utilizando uma variedade de métodos para cada um de seus passos, em especial na maneira como é realizada a extração de características e a classificação. Características extraídas variam de dados da morfologia e aspecto do sinal e intervalos entre batidas (normalmente chamadas de “características dinâmicas”) (CHAZAL; O'DWYER; REILLY, 2004; LLAMEDO; MARTÍNEZ, 2011; ZHANG et al., 2014) a coeficientes obtidos a partir de *wavelets* (CHRISTOV et al., 2006; ELHAJ et al., 2016), filtros de Kalman (OSTER et al., 2015), *Independent Component Analysis* (ICA) (JIANG et al., 2006) e dados de cardiograma vetorial (CHRISTOV et al., 2006; LLAMEDO; MARTÍNEZ, 2011). Além disso,

modelos classificadores de vários tipos foram utilizados: mapas auto-organizáveis (SOM) (LAGERHOLM et al., 2000), *learning vector quantization* (LVQ) (MELIN et al., 2014), máquinas de vetor de suporte (*SVM, de support vector machine*) (YE; KUMAR; COIMBRA, 2012; ZHANG et al., 2014; ELHAJ et al., 2016), redes neurais artificiais (YU; CHEN, 2007), discriminantes lineares (CHAZAL; O'DWYER; REILLY, 2004; LLAMEDO; MARTÍNEZ, 2011) e *extreme learning machines* (ELM) (KARPAGACHELVI; ARTHANARI; SIVAKUMAR, 2012).

Segundo Llamedo e Martínez (2011), muitos algoritmos para classificação de sinais de ECG foram desenvolvidos nas décadas de 90 e 2000, mas apenas alguns desses trabalhos possuem metodologias completamente comparáveis, de modo que os resultados possam ser confrontados de maneira justa (CHAZAL; O'DWYER; REILLY, 2004; LLAMEDO; MARTINEZ, 2007; PARK et al., 2008). A adoção das recomendações da Associação para o Avanço da Instrumentação Médica (AAMI, de *Association for the Advancement of Medical Instrumentation*) (ANSI/AAMI, 1998) para rotulação de classes e apresentação de resultados teve papel importante na diminuição do problema de falta de padronização. Por exemplo, Llamedo e Martínez (2011) destacam que muitos dos trabalhos tinham como interesse principal apenas a distinção entre batidas dos tipos normal (N) e ventricular (V), enquanto poucos se interessavam pelo problema multiclases. A partir do trabalho de Chazal, O'Dwyer e Reilly (2004), até hoje, muitos trabalhos vem utilizando metodologia semelhante, possibilitando uma comparação direta dos resultados (LLAMEDO; MARTÍNEZ, 2011; YE; KUMAR; COIMBRA, 2012; ZHANG et al., 2014; CHEN et al., 2017).

3.1 Padronização da Metodologia

Para que haja uma comparação adequada entre os resultados obtidos em diferentes estudos, torna-se necessário que alguns itens da metodologia sigam uma padronização, proposta por ANSI/AAMI (1998) e popularizada por Chazal, O'Dwyer e Reilly (2004). Os itens principais dessa padronização são: 1) a escolha de um banco de dados comum; 2) a definição dos tipos de batida de interesse; 3) a abordagem na divisão de dados em subconjuntos de treinamento e teste; e 4) a escolha das métricas de desempenho.

Segundo Luz et al. (2016), entre as opções de bancos de dados recomendados pela AAMI, o mais representativo para o teste de sistemas de detecção de arritmias cardíacas é o MIT-BIH *Arrhythmia* (MARK; MOODY, 1997). Este banco de dados é o primeiro desenvolvido especificamente para essa finalidade e vem sendo refinado no decorrer dos anos, tornando-se um padrão no teste dos detectores de arritmias e sendo utilizado pela

maioria dos pesquisadores da área. Possui registros de pacientes com diversos tipos de arritmias e também de pacientes com condição cardíaca normal, divididos em 48 trechos de 30 minutos de eletrocardiograma ambulatorial. Uma descrição detalhada desse banco de dados está na Seção 4.1 deste trabalho.

Com relação aos tipos de batidas de interesse, a AAMI sugere a utilização de cinco classes: batidas normais (N), batidas ectópicas supraventriculares (S), batidas ectópicas ventriculares (V), fusão entre batidas normal e ventricular (F) e batidas desconhecidas (Q). Segundo Llamedo e Martínez (2011), ainda na primeira década dos anos 2000, uma considerável quantidade de trabalhos se interessavam apenas pela discriminação entre batidas normais (N) e ventriculares (V), enquanto poucos pesquisadores estudavam o problema multiclass, intrinsecamente mais complexo, como os próprios Chazal, O'Dwyer e Reilly (2004) e Lagerholm et al. (2000).

A partir dos dados disponibilizados pelo banco, normalmente se faz necessária uma divisão: parte dos dados será utilizada para o treinamento do modelo classificador, enquanto outra parte será utilizada para o teste. Alguns trabalhos realizam essa divisão com uma abordagem orientada a batidas (INAN; GIOVANGRANDI; KOVACS, 2006; JIANG; KONG, 2007), onde todas as batidas presentes no banco são embaralhadas e divididas em dois grupos, de treinamento e teste, sendo que esses subconjuntos podem conter batidas dos mesmos indivíduos simultaneamente. No entanto, Chazal, O'Dwyer e Reilly (2004) demonstram que este tipo de abordagem leva a resultados “otimistas”, devido ao fato de que o sistema absorve informações sobre os pacientes durante a fase treinamento e as utiliza nos mesmos pacientes na fase de testes, o que configura uma vantagem e afasta o resultado obtido da realidade. Por isso, é recomendada a divisão orientada a sujeitos, onde pacientes presentes no conjunto de treinamento não estão presentes nos dados de teste, simulando um cenário real de utilização. Vários trabalhos se utilizaram dessa nova abordagem (LLAMEDO; MARTÍNEZ, 2011; YE; KUMAR; COIMBRA, 2012; ZHANG et al., 2014; CHEN et al., 2017), criando uma tendência que dura até os dias atuais.

Finalmente, para que a comparação faça sentido, é necessário haver um padrão para as métricas de desempenho. As medidas recomendadas pela AAMI para a avaliação de métodos são: Sensibilidade (Se), Valor Preditivo Positivo ($P+$) e Acurácia Global (Acc). Além disso, em um problema multiclass, as matrizes de confusão mostram a saída obtida pelo classificador e detalham a distribuição de eventos de classificação de maneira clara, e, por este motivo, também são utilizadas pela maioria dos trabalhos já citados.

3.2 Técnicas para Classificação de Batidas Cardíacas

Em seu trabalho, Chazal, O'Dwyer e Reilly (2004) mostram a clara redução nos índices de desempenho do modelo classificador quando é utilizada a divisão de dados orientada a sujeitos, o que demonstra que resultados obtidos com a divisão orientada a batidas são tendenciosos, com um viés otimista e pouco realista. Seus resultados representam, no entanto, uma melhoria de desempenho quando comparados aos dois únicos trabalhos anteriores realizados com metodologia semelhante, de Hu, Palreddy e Tompkins (1997) e Lagerholm et al. (2000), apresentando índices de desempenho superiores para as classes de batidas ectópicas ventriculares e supraventriculares. Além disso, os autores destacam que, nesses outros trabalhos, há importantes intervenções de especialistas humanos durante o processo, seja para realizar anotações em trechos de ECG (HU; PALREDDY; TOMPKINS, 1997) ou identificar a classe dominante de um dado *cluster* (LAGERHOLM et al., 2000). A técnica de Chazal, O'Dwyer e Reilly (2004) extrai características morfológicas do sinal em conjunto com valores de intervalos R-R, gerando vetores de dados que são utilizados como entrada para discriminantes lineares, que realizam a classificação automaticamente.

Llamedo e Martínez (2011) utilizam metodologia semelhante em seu trabalho, visando um sistema de classificação de batidas totalmente automático de acordo com recomendações da AAMI. Enquanto Chazal, O'Dwyer e Reilly (2004) baseiam-se somente na morfologia do sinal e distâncias R-R, Llamedo e Martínez utilizam transformadas *wavelet* para extração de características. Além disso, seu trabalho realiza testes em outros bancos de dados, diferentes do MIT-BIH *Arrhythmia*, visando a validação do modelo e de sua capacidade de generalização. Segundo os resultados, testes realizados no próprio banco de dados MIT-BIH *Arrhythmia* utilizando a estratégia de divisão de dados orientada a sujeitos possuem desempenho muito semelhante aos testes realizados em um segundo banco de dados, o *St. Petersburg Institute of Cardiological Technics 12-lead Arrhythmia Database* (INCART) (GOLDBERGER et al., 2000), sem relação com o primeiro, o que depõe a favor desta técnica de divisão de dados. Apesar de obter resultados próximos aos de Chazal, O'Dwyer e Reilly (2004), os autores sugerem, durante suas considerações finais, que outras estratégias de extração de características e modelos classificadores podem ser desenvolvidos para uma melhoria no desempenho, especialmente para a classe de batidas supraventriculares.

Na busca da melhoria de desempenho através da descoberta de estratégias de extração de características, Ye, Kumar e Coimbra (2012) apresentam uma nova abordagem para classificação de batidas baseada em uma combinação de características morfológicas, ex-

traídas por *wavelets* e *Independent Component Analysis* (ICA), além de informações sobre intervalos entre batidas. Os autores utilizam, para a classificação, máquinas de vetor de suporte (SVM, do inglês *Support Vector Machine*), enquanto os dois trabalhos citados anteriormente utilizam discriminantes lineares. De acordo com Ye, Kumar e Coimbra (2012), características morfológicas e dinâmicas são as que melhor traduzem a maneira como especialistas médicos realizam a caracterização de arritmias cardíacas. Segundo eles, batidas ectópicas podem normalmente ser caracterizadas por vários padrões distorcidos ou anormais no formato da onda (como um complexo QRS distorcido), ou mesmo a falta de uma onda característica como a onda P. Além disso, arritmias cardíacas estão tipicamente associadas a irregularidades no ritmo cardíaco e podem ser identificadas pelo comprimento dos intervalos entre as batidas. Ainda segundo os autores, seu modelo se beneficia de uma representação mais completa da morfologia do sinal quando comparado às características derivadas apenas do formato das ondas, propostas nos outros artigos.

Sinais biomédicos normalmente exibem características estatísticas que mudam no tempo. Devido a natureza não estacionária desse tipo de sinal, a transformada de Fourier torna-se insatisfatória, por apresentar uma caracterização global do conteúdo de frequência das batidas e não incluir informações sobre sua evolução no tempo (YE; KUMAR; COIMBRA, 2012). Por outro lado, transformadas *wavelet* provêm uma caracterização do sinal tanto no domínio do tempo quanto de frequência. Segundo Ye, Kumar e Coimbra (2012), essa capacidade de análise em tempo-frequência faz com que *wavelets* sejam efetivas na análise de sinais não estacionários como o de ECG. Sua utilização em ECG varia de remoção de ruído (ZHANG, 2005), a detecção de batida (KADAMBE; MURRAY; BOUDREAUX-BARTELS, 1999) e extração de características (LIN; YANG, 2014).

A utilização da SVM também é um passo importante para a melhoria do desempenho dos sistemas de classificação de batidas. Propostas por Vapnik (CORTES; VAPNIK, 1995), essas máquinas consistem, basicamente, na construção de uma superfície de decisão na forma de um hiperplano que maximiza a margem de separação entre duas classes diferentes. Projetada como uma máquina linear, a técnica apresenta a possibilidade de tratamento de dados não lineares a partir de um mapeamento dos dados de entrada para um espaço de características onde os dados possam ser divididos pelo hiperplano. Esta abordagem provê modelos com excelente capacidade de generalização, tornando-se uma ferramenta poderosa em diversas aplicações (BYUN; LEE, 2002) e, em especial, em sistemas de classificação automática de batidas cardíacas (LUZ et al., 2016).

A nova abordagem proposta por Ye, Kumar e Coimbra (2012) apresenta resultados se-

melhantes aos obtidos por Llamedo e Martínez (2011) e Chazal, O'Dwyer e Reilly (2004). Enquanto a acurácia global dos modelos de Ye, Kumar e Coimbra (2012), Llamedo e Martínez (2011) e Chazal, O'Dwyer e Reilly (2004) são de 86,4%, 78% e 85,9%, respectivamente, ainda há muita variação nos índices de desempenho relacionados à classificação de padrões nas classes de batidas ectópicas ventriculares (VEB) e supraventriculares (SVEB). Os autores observam que seu desempenho inferior na classe SVEB (sensibilidade de 60,8% para SVEB e 81,5% para VEB) se deve ao fato de que existem menos amostras de dados de batidas ectópicas supraventriculares do que de batidas ventriculares, mas ressaltam seu desempenho comparável aos demais trabalhos nos outros índices e apontam na direção de investigações futuras relacionadas especialmente ao processo de segmentação de batida que, segundo eles, precisa se adaptar com maior naturalidade ao ritmo cardíaco.

Visando uma melhoria no desempenho de sistemas automáticos de classificação de batidas, Zhang et al. (2014) apresentam uma técnica inovadora de seleção de características, específica para cada doença (ou *disease-specific*). Quando comparados a outros trabalhos recentes, seus resultados estão entre os melhores, atingindo acurácia global de 88,3% e sensibilidades de 88,9%, 79,1% e 85,5% para as classes de batidas normais, SVEB e VEB, respectivamente. Mais recentemente, o trabalho de Chen et al. (2017) introduz um novo conjunto de características, de matrizes de projeção, que aplicadas a uma máquina de vetor de suporte apresentam um desempenho superior aos demais modelos que servem como comparação com relação à acurácia global e identificação de batidas normais, mas possui algumas deficiências, especialmente na identificação de batidas supraventriculares.

Segundo Zhang et al. (2014), a classificação de batidas cardíacas é, na verdade, um típico problema de balanceamento de sensibilidades, em que é necessário manter valores altos de sensibilidade para a classe de batidas normais ao mesmo tempo em que se busca valores mais altos de sensibilidade para classes de batidas ectópicas. A adaptação de algoritmos tradicionais de aprendizado de máquina a esta tarefa ainda é uma questão em aberto. Deve-se ter em mente, ainda, que as características existentes, de intervalos entre batidas e morfologia, são insuficientes para distinguir um tipo de batida de outra com desempenho adequado e a pesquisa de novos métodos de extração e seleção de características merece uma investigação aprofundada.

3.3 Os Parâmetros de Hjorth

Os parâmetros de Hjorth foram introduzidos no início dos anos 70 (HJORTH, 1970) devido à necessidade de métodos quantitativos para descrição de sinais de EEG. Os parâmetros propostos por Hjorth definem valores para caracterização de um sinal no domínio do tempo, através da aplicação de métodos matemáticos e estatísticos que também incluem informações importantes sobre seu comportamento no domínio da frequência.

Os parâmetros de Hjorth, chamados de atividade, mobilidade e complexidade, são obtidos a partir de cálculos simples de variância realizados sobre o sinal e suas derivadas de primeira e segunda ordem, e contêm informação do sinal nos dois domínios, de tempo e frequência. Segundo Hjorth (1973), seus parâmetros possuem um forte significado relacionado ao sistema físico que representam, indicando suas variações de amplitude e frequência, além de sua complexidade quando comparado a um sinal senoidal simples. Além disso, possuem como vantagem sobre outros métodos de análise em frequência o fato de serem calculados com maior simplicidade e passos de custo computacional mais baixo, possibilitando seu uso em tempo real e em plataformas com recursos reduzidos.

Apesar de terem sido criados para a caracterização de sinais cerebrais, e terem demonstrado bons resultados em trabalhos que variam desde o estudo de estágios do sono (CHARBONNIER et al., 2011; REDMOND; HENEGHAN, 2006) até lateralização de crises epilépticas de lobo temporal visando a localização de zonas epileptogênicas (CECCHIN et al., 2010) e desenvolvimento de interfaces cérebro-computador (VIDAURRE et al., 2009; OH; LEE; KIM, 2014), seu uso não se restringe a este segmento. Muitos trabalhos vêm explorando o potencial desta ferramenta com aplicações tanto em sinais biológicos como análise de eletromiografia (EMG) (MOUZÉ-AMADY; HORWAT, 1996) e caracterização de sons pulmonares (RIZAL; HIDAYAT; NUGROHO, 2015), como em outros campos de estudo como o controle de processos (AMORIM et al., 2015). Com relação à sua utilização em problemas envolvendo sinais de ECG, dois trabalhos se destacam (NOVIYANTO et al., 2011; RIZAL; HADIYOSO, 2015), mas apresentam aspectos diferentes deste trabalho de tese.

Noviyanto et al. (2011) investigam o problema de classificação de estágios de sono a partir de sinais de ECG e utilizam dois parâmetros de Hjorth (mobilidade e complexidade) como entrada para seu modelo, em conjunto com outras características matemáticas. Entretanto, seu trabalho não menciona segmentação e classificação de batidas cardíacas e não explora vantagens dos parâmetros de Hjorth sobre as outras características utilizadas.

Rizal e Hadiyoso (2015) incluíram os parâmetros de Hjorth na modelagem de um

sistema de classificação de sinais de ECG, em conjunto com classificadores do tipo *K-Nearest Neighbor* (KNN) e Percéptron de Múltiplas Camadas (MLP, do inglês *Multilayer Perceptron*). No entanto, algumas diferenças importantes podem ser destacadas com relação ao presente trabalho. Em primeiro lugar, os autores não seguem as recomendações da AAMI com relação a escolha do banco de dados e classes de dados, o que torna difícil sua comparação com outros trabalhos da área. Além disso, apenas 3 condições clínicas são levadas em consideração: ritmo normal sinusal (NSR, de *Normal Sinus Rhythm*), fibrilação atrial (FA) e falha cardíaca congestiva (CHF, de *Congestive Heart Failure*), ilustradas na Figura 15. Devido à própria estrutura do banco de dados escolhido pelos autores, seu objetivo principal não é a classificação individual de cada batida, como realizada neste trabalho, mas sim a detecção da condição cardíaca geral do paciente a partir de trechos de ECG com cerca de 2 a 3 segundos.

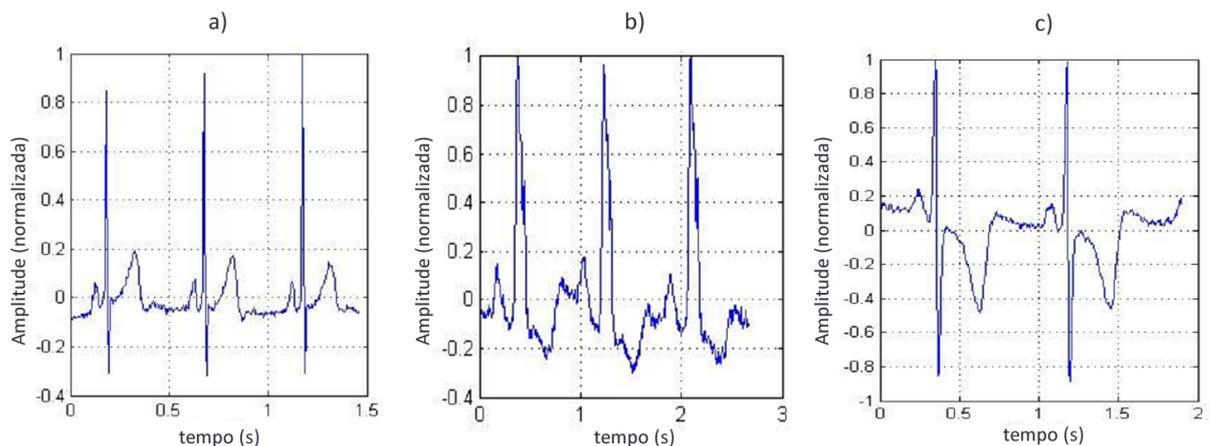


Figura 15: Condições cardíacas classificadas por Rizal e Hadiyoso (2015). a) Ritmo normal sinusal; b) fibrilação atrial; e c) falha cardíaca congestiva.

Rizal e Hadiyoso (2015) não incluem em seu trabalho nenhum tipo de segmentação ou delimitação de batidas, e o sinal utilizado para treinamento e teste de seus modelos classificadores é normalizado com relação ao sinal completo, o que inviabiliza a classificação em tempo real. Os autores concluem o estudo destacando que a utilização de um método de segmentação do sinal pode melhorar o desempenho de um sistema de classificação baseado nos parâmetros de Hjorth, e aconselham um cuidado especial com a qualidade do sinal, devido à susceptibilidade destes parâmetros a ruídos. Segundo eles, novas pesquisas seriam necessárias para comprovar a eficácia dos parâmetros de Hjorth em problemas mais complexos de classificação de sinais cardíacos, que envolvam um maior número de classes de dados. O presente trabalho contribui nesse aspecto.

3.4 Buscando Algumas Soluções

Um dos principais problemas observados na maioria dos classificadores de batidas cardíacas está relacionado aos baixos índices de desempenho para batidas ectópicas supraventriculares. Um dos fatores que contribuem para este fato é a similaridade dos complexos QRS e ondas T deste tipo de batida com os de batidas normais, que leva a uma frequente confusão entre elas.

Como a presença de batidas ectópicas supraventriculares muda o comprimento dos intervalos entre batidas, devido à sua natureza prematura, a maioria dos trabalhos utiliza valores de intervalos R-R combinados a outras características como entrada para os modelos classificadores. A Figura 16 ilustra a semelhança entre batidas normais e prematuras atriais (supraventriculares), com complexos QRS e ondas T praticamente idênticas.

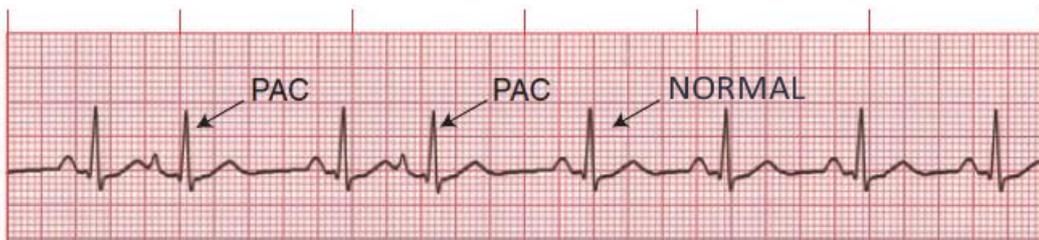


Figura 16: Batidas normais vs. PACs (*Premature Atrial Contractions*).

No entanto, intervalos R-R não são afetados apenas pela presença de batidas ectópicas prematuras ou de escape, mas também pela taxa cardíaca, que varia de acordo com as condições do paciente no momento e pode diminuir a eficiência deste tipo de característica na identificação do tipo de batida. Visando contornar este problema, Lin e Yang (2014) propõem a utilização de valores normalizados de intervalos R-R que, ao serem divididos pelo intervalo R-R médio do paciente durante o exame, reduz os efeitos da taxa cardíaca e melhoram a qualidade dos intervalos R-R na identificação de batidas ectópicas. Uma abordagem muito semelhante é utilizada neste trabalho (Seção 4.5.1), com uma adaptação importante no sentido de tornar os dados disponíveis para a classificação em tempo real. Outro trabalho que também utiliza a normalização de intervalos R-R através de divisão pela média total é o de Doquire et al. (2011).

Ainda com relação aos intervalos R-R, Krasteva, Jekova e Christov (2006) sugerem sua utilização na forma de uma diferença, que representa a variação entre dois intervalos R-R que circundam uma determinada batida (mais detalhes na Seção 4.5.1). Segundo os autores, esse tipo de característica auxilia o modelo classificador especialmente com relação a batidas ectópicas prematuras, uma vez que tende a permanecer próximo de

zero para batidas normais e de escape e crescer em mais de 15% em batidas prematuras. Krasteva, Jekova e Christov (2006) também sugerem que a diferença seja normalizada, para que o valor seja independente da taxa cardíaca no momento.

Além disso, esta tese visa contribuir também na maneira como é realizada a delimitação e segmentação das batidas cardíacas, executada após a detecção dos complexos QRS. Nesse sentido, há dois caminhos principais seguidos pelos pesquisadores.

Ye, Kumar e Coimbra (2012), Lin e Yang (2014) e Chen et al. (2017) são adeptos de uma primeira alternativa, assim como Christov et al. (2006). Nela, as batidas possuem comprimentos fixos que variam aproximadamente entre 700 e 800 milissegundos ao redor do ponto fiducial (ponto R do complexo QRS), independentemente da taxa cardíaca atual. Na segunda alternativa, segmentos e características do sinal são extraídos a partir da aplicação da ferramenta *ecgppwave* (LAGUNA et al., 2002) ou de transformadas *wavelet*, técnicas mais custosas computacionalmente mas com melhores resultados, utilizadas por Chazal, O’Dwyer e Reilly (2004), Llamedo e Martínez (2011) e Zhang et al. (2014).

Uma alternativa às duas abordagens tradicionais é proposta neste trabalho, com a “Segmentação Dinâmica” (Seção 4.4). Essa técnica se destaca pela baixa complexidade computacional, e contribui ao diminuir a influência da taxa cardíaca atual do paciente na qualidade das características extraídas, melhorando o desempenho da classificação.

3.5 Uma Nova Abordagem

Todos os algoritmos citados anteriormente apresentam resultados relevantes e foram publicados em revistas conceituadas, ainda que haja espaço para a pesquisa e desenvolvimento de novos métodos de extração de características e classificação de padrões. No entanto, há uma preocupação, destacada por Mazomenos et al. (2013), de que estes métodos sejam, em sua maioria, computacionalmente intensos. Contanto que estes métodos sejam executados em dispositivos com muitos recursos ou em um PC, sua efetividade é incontestável. No entanto, quando partimos para dispositivos mais limitados em recursos – especialmente tempo de bateria, mas também capacidade de processamento e memória, as abordagens tradicionais podem não ser aplicáveis, uma vez que o consumo de energia é altamente dependente da complexidade computacional do processo algorítmico, e a diminuição da complexidade tem grande impacto no tempo gasto para processamento.

Segundo Li et al. (2014), o crescente envelhecimento da população mundial levará a um rápido crescimento de doenças relacionadas à idade, como hipertensão, diabetes e do-

enças cardíacas. No entanto, a grande maioria dos pacientes não terá condições de realizar exames regulares em hospitais com infraestrutura adequada, seja por questões financeiras ou dificuldade de acesso (áreas remotas, países em desenvolvimento). Por este motivo, dispositivos portáteis de baixo custo que sejam capazes de realizar um monitoramento de qualidade com baixo consumo de energia podem se tornar uma alternativa de valor. Segundo os autores, a extração de características adequadas do sinal leva a um monitoramento de qualidade, e a redução da complexidade computacional é um bom método para um consumo reduzido de energia.

Mazomenos et al. (2013) destaca que uma grande parte da energia gasta por um sistema de sensoriamento sem fio dedicado à captação de sinais cardíacos está relacionada à transmissão dos dados para um computador principal, que realiza o processamento. Em seu artigo, através de alguns cálculos de consumo de energia, os autores concluem que um sistema transmitindo dados constantemente através de *bluetooth* teria um tempo de autonomia insatisfatório para um dispositivo de monitoramento remoto, de apenas 8 a 12 horas. Esse cálculo é feito a partir de uma análise prévia realizada por Balani (2007), considerando uma configuração típica para aplicações em redes de sensores sem fio, com transceptor *bluetooth* V2 com consumo de corrente de 40-55mA em modo de transmissão, e bateria de 1200mAh. Uma boa maneira de se economizar energia seria através do processamento do sinal nos próprios nós de captação, de maneira a diminuir a quantidade de informação transmitida para um computador central. Este processamento precisa ser de baixo custo computacional, para que sua execução não ultrapasse, por exemplo, o consumo de energia necessário para a própria transmissão do sinal.

Segundo Mouzé-Amady e Horwat (1996), os parâmetros de Hjorth oferecem passos de computação de baixo custo quando comparados a outras análises de frequência. Os mesmos motivos levaram à escolha dos parâmetros de Hjorth sobre técnicas mais usuais como Transformadas de Fourier e *wavelets* em Cecchin et al. (2010). Rizal, Hidayat e Nugroho (2015) destacam que o baixo custo computacional e reduzido número de características extraídas do sinal tornam os parâmetros de Hjorth candidatos ideais para o reconhecimento em tempo real de sons pulmonares, e as mesmas características são utilizadas como justificativa para sua utilização no processamento de ECG realizado em Rizal e Hadiyoso (2015). Oh, Lee e Kim (2014) destacam que os parâmetros de Hjorth são uma boa alternativa à *Short-Time Fourier Transform* (STFT), uma técnica popular para análise de frequência de sinais não estacionários de complexidade computacional mais alta, por extrair informações relevantes tanto do domínio do tempo quanto de frequência a partir de cálculos simples.

Aproveitando-se da lacuna apresentada por Zhang et al. (2014) e Llamedo e Martínez (2011), que expõem a necessidade pela busca de novas técnicas de extração de características, este trabalho apresenta um novo método para a realização dessa tarefa, baseado nos parâmetros de Hjorth, um conceito pouco utilizado na área de processamento de ECG que, assim como a técnica de Ye, Kumar e Coimbra (2012), se beneficia de uma descrição mais completa da morfologia do sinal quando comparadas a outros trabalhos. Este novo método visa, além de um bom desempenho de classificação, o suprimento das necessidades de baixo custo computacional levantadas especialmente por Mazomenos et al. (2013) e Li et al. (2014) para implementação de um sistema de classificação de batidas e detecção de arritmia em um dispositivo de recursos mais limitados, com objetivo de ampliar o público atendido por este tipo de tecnologia, oferecendo uma classificação de qualidade que impacte na qualidade de vida dos pacientes que a utilizarem. Visando aumentar a efetividade das características dinâmicas, este trabalho adota uma abordagem de normalização de intervalos R-R semelhante à descrita por Lin e Yang (2014), com uma adaptação importante que disponibiliza as características em tempo real. Finalmente, é desenvolvida uma nova técnica para delimitação e segmentação do sinal da batida cardíaca individual, chamada “segmentação dinâmica”, visando aproveitar o máximo das características extraídas do sinal, especialmente os parâmetros de Hjorth.

4 Materiais e Métodos

A Figura 17 apresenta, em linhas gerais, os passos para o desenvolvimento deste trabalho, realizado para a classificação automática de batidas cardíacas. Cada um desses passos será detalhado nas próximas seções, partindo dos dados puros, extraídos de uma base de dados *online* especializada neste tipo de problema, até seu último estágio, que é a classificação das batidas e análise de desempenho do modelo.

Há quatro estágios principais: pré-processamento, segmentação de batidas, extração de características e modelo classificador. Todas as etapas foram implementadas a partir da ferramenta MATLAB® e da linguagem de programação C++. Para a classificação, foi utilizada a biblioteca LIBSVM (CHANG; LIN, 2011), também desenvolvida em C/C++. Este trabalho visa contribuir, especialmente, nos estágios de segmentação de batidas, com a “segmentação dinâmica” (Seção 4.4), e extração de características, com a utilização dos parâmetros de Hjorth (Seção 4.5.3) e a normalização de intervalos R-R (Seção 4.5.1).

Dados obtidos diretamente do equipamento de ECG sofrem com alguns tipos de interferências e normalmente apresentam ruído, o que degrada a qualidade do sinal e dificulta a distinção entre os tipos de batidas. O estágio de pré-processamento tem como objetivo a filtragem do sinal original, resultando em um sinal mais limpo e mais rico em informação significativa. A partir dos sinais filtrados, o modelo passa a um segundo estágio, onde cada batida cardíaca é individualizada, normalmente a partir das posições de seus complexos QRS, e segmentada. É de cada um dos segmentos obtidos que são extraídas uma série de características, que a partir de algum processamento no sinal visam reforçar e tornar mais claras as diferenças entre as classes de batidas, viabilizando o trabalho do modelo classificador. Um vetor de características é formado neste estágio, e este vetor serve como entrada para o modelo classificador, que é treinado e realiza a classificação.

A comparação dos resultados obtidos com os resultados esperados a partir de métricas definidas finalmente nos fornece índices de desempenho, importantes para auto-avaliação e comparação com modelos disponíveis na literatura.

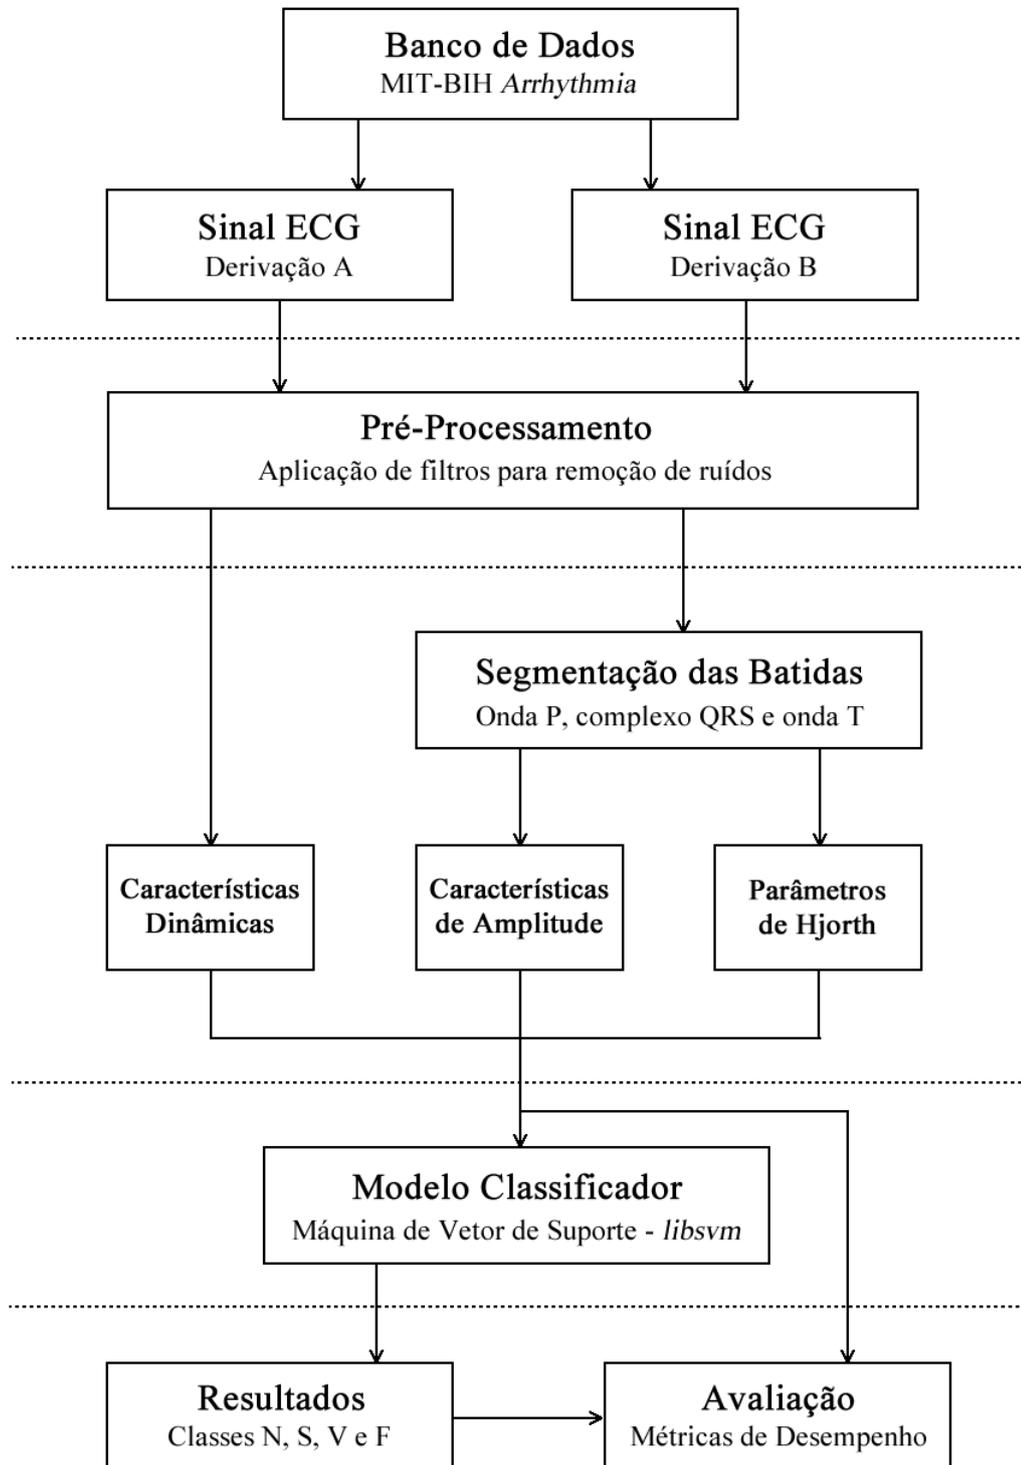


Figura 17: Processo desenvolvido para a classificação automática de batidas cardíacas.

As etapas de segmentação de batidas (Seção 4.4) e extração de características (Seção 4.5), nas quais este trabalho visa contribuir, serão analisadas com relação à sua complexidade computacional, em suas respectivas seções. Maiores informações sobre o processo de análise de complexidade no tempo e seu jargão específico, como a notação *Big-O* (CORMEN et al., 2001), estão disponíveis no Apêndice A, ao final deste documento.

4.1 Banco de Dados MIT-BIH Arrhythmia

Os dados utilizados nos testes são provenientes de uma única fonte, o banco de dados MIT-BIH *Arrhythmia* (MARK; MOODY, 1997), ou MIT-BIH-AR¹, criado para servir como material padrão em testes de detectores de arritmias, e que tem sido utilizado desde a sua criação pela maioria dos pesquisadores da área (LUZ et al., 2016). As siglas MIT e BIH referem-se às duas instituições envolvidas em sua concepção: o *Massachusetts Institute of Technology* e o *Beth Israel Hospital* (hoje em dia, *Beth Israel Deaconess Medical Center*), ambas sediadas nos Estados Unidos, no estado de Massachusetts.

O banco de dados contém 48 trechos de 30 minutos de sinal, retirados de exames de eletrocardiograma ambulatorial de 47 indivíduos, estudados pelo *Beth Israel Hospital Arrhythmia Laboratory* entre os anos de 1975 e 1979. Os registros são referenciados por números entre 100 e 234, sendo que os primeiros 23 (a série dos “100”) são de pacientes com condição cardíaca normal, e os 25 seguintes (a série dos “200”) de pacientes com diferentes tipos de arritmias. Todos os registros estão digitalizados com taxa de amostragem de 360 Hz e filtrados com um filtro passa-faixa entre 0,1 e 100 Hz.

Cada registro contém dados de duas diferentes derivações do exame de ECG, gravados em dois canais: A e B. As derivações variam de acordo com o paciente, especialmente devido a presença de curativos cirúrgicos e variações de anatomia que inviabilizavam a colocação dos eletrodos sempre no mesmo local (MOODY; MARK, 2001). No entanto, na grande maioria dos casos, o canal A contém um sinal gravado a partir da derivação MLII (*modified limb lead II*, ou derivação de membros II modificada), obtida de maneira semelhante à derivação de membros II padrão, mas com eletrodos colocados sobre o peito do paciente, como é padrão para gravação de ECG ambulatorial, e o canal B contém um sinal da derivação precordial V1 (podendo ser, em alguns poucos casos, V2, V4 ou V5).

O banco de dados possui um total de aproximadamente 109 mil batidas, cada uma delas classificada por especialistas e rotulada com uma de 15 diferentes classes, listadas

¹Disponível em <http://physionet.org/physiobank/database/mitdb/>

na Tabela 1. Há uma grande diferença no número de exemplos de cada tipo de classe: enquanto batidas do tipo “Normal” são representadas por cerca de 75 mil exemplos, outros tipos como o de “batidas prematuras supraventriculares” possuem apenas 2 exemplos. O desbalanceamento entre a quantidade de exemplos de cada tipo é um dos desafios a serem superados nesta pesquisa. A técnica de subamostragem dos dados de treinamento, descrita na Seção 5.3, contribui nesse sentido.

Tabela 1: Classes de MIT-BIH *Arrhythmia* e classes da AAMI correspondentes. (CHAZAL; O'DWYER; REILLY, 2004)

Classes AAMI	Classes MIT-BIH
N Normal	Batida Normal Bloqueio de Ramo de Feixes Esquerdo Bloqueio de Ramo de Feixes Direito Batida de Escape Atrial Batida de Escape Nodal (ou Juncional)
S Ectópica Supraventricular	Batida Prematura Atrial Batida Prematura Atrial Anômala Batida Prematura Nodal (ou Juncional) Batida Prematura Supraventricular
V Ectópica Ventricular	Batida Prematura Ventricular Batida de Escape Ventricular
F Batida de Fusão	Fusão de batida normal e ventricular
Q Batida Desconhecida	Batida “ritmada” (<i>paced beat</i>) Fusão de batida normal e ritmada Batida não-classificada

A Associação pelo Avanço da Instrumentação Médica (AAMI, do inglês *Association for the Advancement of Medical Instrumentation*) é uma organização sem fins lucrativos fundada em 1967, cuja missão é o desenvolvimento, gerenciamento e utilização de tecnologia segura e efetiva para cuidados médicos. É a fonte primária internacional de padrões consensuais para a indústria de equipamentos médicos (AAMI, 2017). No que diz respeito a algoritmos de detecção de arritmias cardíacas, a AAMI recomenda, através do documento de padronização ANSI/AAMI EC57:1998 (ANSI/AAMI, 1998), a classificação de batidas em apenas cinco tipos: batidas normais, ectópicas supraventriculares, ectópicas ventriculares, batidas de fusão e desconhecidas. A Tabela 1 descreve como é realizada a correspondência entre as 15 classes de batidas oferecidas pelo banco de dados MIT-BIH-AR e as 5 classes recomendadas pela AAMI, utilizadas na grande maioria das pesquisas da área.

Ainda de acordo com o mesmo documento de recomendações da AAMI, é necessário excluir dos testes todos os registros que contenham sinais de ECG de pacientes cujo ritmo cardíaco seja controlado artificialmente, por exemplo por um marca-passo. Essas batidas são chamadas de “batidas ritmadas” ou “*paced beats*”, e estão presentes nos registros 102, 104, 107 e 217 do banco de dados MIT-BIH-AR. Após a remoção dos quatro registros, restam 44 registros liberados para o uso, dos quais 22 serão utilizados para o treinamento do modelo e 22 para teste, de acordo com divisão detalhada na seção seguinte.

4.2 Estratégia de Divisão de Dados

Após a remoção dos quatro registros contendo batidas ritmadas, os 44 registros restantes são divididos em dois conjuntos (CD1 e CD2) com 22 cada, com aproximadamente a mesma proporção de batidas de cada tipo, de acordo com divisão sugerida por Chazal, O’Dwyer e Reilly (2004). Cada um dos conjuntos criados contém aproximadamente 50 mil batidas, entre as quais se misturam gravações de pacientes com condição cardíaca normal e pacientes com arritmias. As quantidades de batidas de cada tipo estão na Tabela 2.

Tabela 2: Quantidade de batidas de cada classe nos conjuntos de dados.

Conjunto	N	S	V	F	Q	Total
CD1	45639	943	3776	413	8	50779
CD2	44039	1829	3207	388	7	49470

A Figura 18 mostra como foi realizada a divisão dos dados, incluindo os números dos registros pertencentes a cada conjunto. O Conjunto de Dados 1 (CD1) foi escolhido para o treinamento do modelo, enquanto o Conjunto de Dados 2 (CD2), para teste e avaliação de seu desempenho.

Chazal, O’Dwyer e Reilly (2004) demonstram em seu artigo que a utilização de batidas cardíacas dos mesmos pacientes nos dois conjuntos de dados, de treinamento e teste, gera resultados tendenciosos e torna o processo de avaliação menos significativo para aplicações do mundo real. Essa constatação vem do fato de que os modelos classificadores tendem a aprender particularidades das batidas dos pacientes utilizados durante a fase de treinamento, obtendo um desempenho expressivo de classificação durante a fase de testes (geralmente muito próximos de 100%). Ao encontrar pacientes com características diferentes durante seu teste em ambiente clínico, o modelo apresenta índices bem mais modestos de acerto. Este tipo de abordagem é chamada na literatura de “orientada a

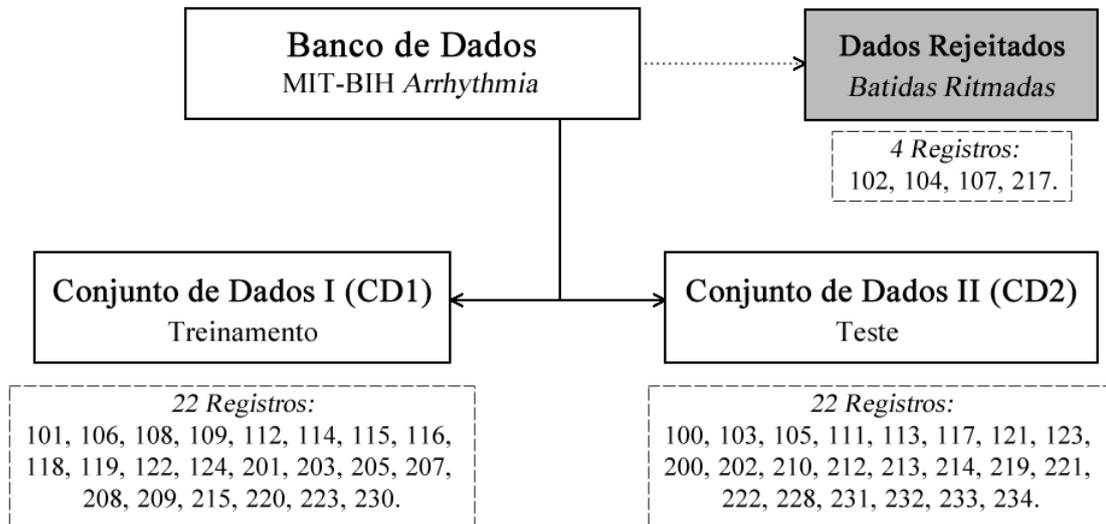


Figura 18: Divisão de dados para treinamento e teste.

classes”, “orientada a batidas” ou “intra-pacientes” e se caracteriza pela divisão aleatória dos dados em conjuntos de treinamento e teste, de maneira que eles possam conter dados dos mesmos pacientes.

Visando resolver este problema e obter resultados mais realistas, Chazal, O’Dwyer e Reilly (2004) propõem um processo de divisão de dados mais coerente com a realidade, onde as batidas que compõem cada conjunto (CD1 e CD2) provêm de indivíduos diferentes. Esse processo, utilizado também no decorrer do presente trabalho, define uma divisão de dados chamada de “orientada a sujeitos” ou “inter-pacientes”. Segundo Luz et al. (2016), este tipo de divisão torna a classificação das batidas cardíacas uma tarefa mais difícil, e reduz os índices de desempenho do modelo classificador (especialmente para classes que são menos representadas no conjunto de dados), mas tende a caracterizar o desempenho do modelo desenvolvido com maior fidelidade em relação ao ambiente clínico e deve ser preferido com relação à abordagem intra-pacientes.

4.3 Pré-Processamento

Os dados presentes no banco de dados escolhido não estão livres de interferências ocorridas durante os exames. O sinal captado pelo equipamento de eletrocardiograma pode ser afetado por diferentes fontes de ruído, provenientes dos próprios contatos dos eletrodos, flutuações de linha de base, artefatos musculares, interferência da rede elétrica, artefatos de movimentação e ruído de quantização (ELHAJ et al., 2016). A classificação

das batidas presentes no sinal depende fortemente da qualidade do mesmo. Portanto, a realização de um esforço no sentido de filtrar o máximo de interferência, para obtenção de um sinal limpo, é de grande valor.

Neste trabalho, dois tipos de filtros são aplicados ao sinal original. Para a remoção das flutuações de baixa frequência na linha de base, foram utilizados os filtros de mediana. Para a filtragem de ruídos de maior frequência, utilizou-se um filtro *butterworth* passa-baixa (35 Hz). A Figura 19 ilustra o processo de filtragem do sinal, cuja saída é um sinal com menor nível de interferência, a ser utilizado nas fases seguintes de processamento.

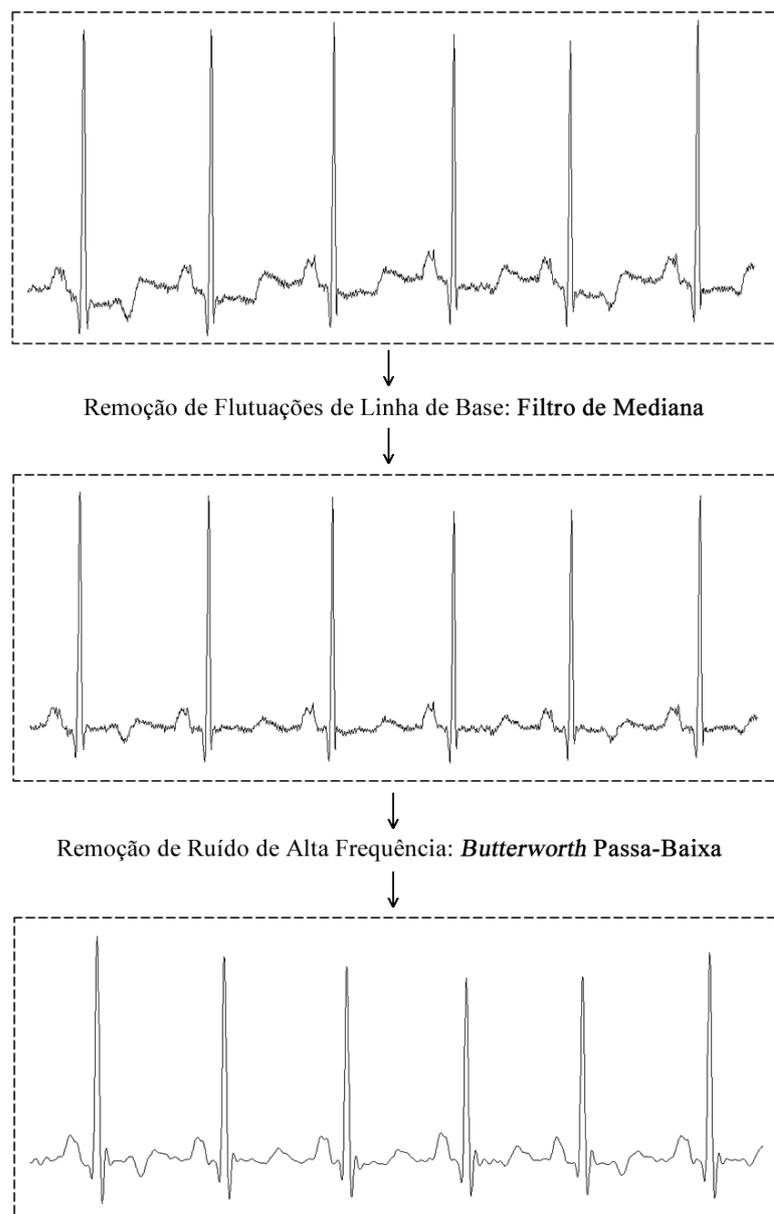


Figura 19: Passos de filtragem do sinal de ECG.

4.3.1 Filtros de Mediana

Para remoção das componentes de ruído de baixa frequência, conhecidas como flutuações de linha de base (em inglês, *baseline wander* ou *baseline drift*), os sinais de ECG foram submetidos à aplicação de dois filtros de suavização conhecidos como filtros de mediana. Este tipo de interferência é causado especialmente pela transpiração do paciente (influenciando na impedância dos eletrodos), sua respiração e movimentos corporais.

Os filtros de mediana são filtros de suavização muito utilizados na área de processamento de imagens, especialmente para o desfoque (*blurring*) e redução de ruídos. Neste tipo de filtro, o algoritmo seleciona uma região da imagem em torno de um determinado *pixel*, calcula o valor da mediana dos tons de cinza nesta região e troca o valor do ponto central pelo valor calculado. O filtro de mediana é um dos melhores filtros de suavização para eliminar ruídos preservando o contorno da imagem (GONZALEZ; WOODS, 2004).

No caso deste estudo, os filtros de mediana funcionam de maneira semelhante. Para cada ponto da série temporal define-se um vetor de valores retirados de seu entorno na série temporal, centralizado nele. Esse vetor possui um comprimento específico para cada aplicação. A seguir, o valor de cada ponto presente no sinal é substituído pela mediana dos elementos presentes no seu respectivo vetor. O vetor funciona como uma “janela”, que desliza de ponto em ponto através do sinal, substituindo seus valores originais pela mediana dos elementos que a compõem naquele momento.

O Código 4.1 mostra uma função desenvolvida em MATLAB®, que implementa o filtro de mediana. A função *medianfilter* recebe o sinal original (*sig*) e o tamanho desejado de janela (*window**sz*) e retorna o sinal filtrado (*sf*).

Código 4.1: Implementação do filtro de mediana.

```
function [sf] = medianfilter(sig , window)
    halfwindow = (window - 1)/2; % metade da janela
    counter = halfwindow + 1; % contador de amostras
    sf = zeros(size(sig , 1) , 1); % alocando memória para sinal filtrado

    while counter <= (size(sig,1)-halfwindow)
        window = sig(counter-halfwindow:counter+halfwindow);
        window = sort(window); % ordenando valores
        sf(counter) = window(halfwindow+1); % valor central
        counter = counter + 1; % desliza janela
    end
end
```

De acordo com técnica descrita por Chazal, O'Dwyer e Reilly (2004), e utilizada nesta tese, cada um dos registros de ECG deve ser processado utilizando-se um filtro de mediana com uma janela de $200ms$ para eliminação de complexos QRS e ondas P. O sinal resultante desta primeira etapa deve ser, então, submetido a um segundo filtro de mediana, com janela de comprimento de $600ms$, para remoção das ondas T. O sinal obtido após as duas etapas contém uma linha de base com flutuações de baixa frequência do sinal no tempo. Finalmente, esse sinal suavizado é subtraído do sinal original, resultando em um sinal livre deste tipo de interferência.

4.3.2 Filtro Butterworth Passa-Baixa

A segunda fase de filtragem está relacionada à remoção de ruídos de frequência mais alta, incluindo interferência da rede elétrica (50 ou 60 Hz, dependendo da localidade). A faixa mais sensível de frequência no sinal cardíaco está entre 1 e 30 Hz, uma vez que frequências fundamentais do complexo QRS são geralmente menores que 30 Hz e frequências fundamentais da onda T são maiores que 1 Hz (BAILEY et al., 1990). Trabalhos importantes da área (CHAZAL; O'DWYER; REILLY, 2004; ZHANG et al., 2014) utilizam filtros passa-baixa com frequência de corte de 35 Hz.

A partir destas informações, um filtro digital IIR (*Infinite Impulse Response*) *Butterworth* passa-baixa de quinta ordem e frequência de corte de 35 Hz foi criado e aplicado ao sinal. Filtros digitais IIR, também chamados de recursivos, possuem como vantagem uma execução mais rápida quando comparados aos filtros FIR (*Finite Impulse Response*), calculados através de convolução. A implementação do filtro escolhida e utilizada neste trabalho foi provida pelo software MATLAB[®], de acordo com o Código 4.2.

Código 4.2: Implementação de filtro *Butterworth*.

```
% calcula ordem mínima do filtro , dados os valores de ripple , roll-off
% e frequência.
[N, Wn] = buttord(35/180, 40/180, 5, 10);

% Projeta filtro de ordem N, retornando coeficientes.
[b, a] = butter(N, Wn);

% Filtro digital
sinalf = filter(b, a, sinal);
```

O filtro *Butterworth* foi proposto inicialmente pelo engenheiro britânico Stephen Butterworth (BUTTERWORTH, 1930), e se caracteriza por uma resposta em frequência o mais

plana quanto for matematicamente possível na banda passante, e atenuação (*roll-off*) suave e monotônica na banda rejeitada. Além disso, esse tipo de filtro praticamente não apresenta ondulação (*ripple*) na banda passante ou na banda de interrupção. Muitos pesquisadores consideram a função de transferência do filtro *Butterworth* como o melhor compromisso entre atenuação e resposta de fase para aplicações de uso geral, tornando-se a mais utilizada no projeto de filtros de sinais biológicos (PRUTCHI; NORRIS, 2005).

4.4 Detecção e Segmentação de Batidas

O resultado da etapa de pré-processamento é um conjunto de 88 séries temporais filtradas de cerca de 30 minutos, uma para cada uma das 2 derivações presentes nos 44 registros do banco de dados utilizados. O passo seguinte na construção de um classificador automático de batidas cardíacas é a localização de todas as batidas presentes nos sinais, individualizando-as para posterior processamento.

Esse processo é, em geral, baseado na localização do complexo QRS, ou ponto fiducial (ponto R do complexo QRS), normalmente proeminente no traçado do ECG. Existem algoritmos projetados para essa finalidade, que realizam a detecção do complexo QRS com erro menor do que 1%, como o algoritmo de Pan-Tompkins (PAN; TOMPKINS, 1985). O banco de dados MIT-BIH-AR possui uma série de anotações, realizadas por especialistas, indicando a posição de cada ponto fiducial presente nos registros (MARK; MOODY, 1997). Como este trabalho não tem como objetivo investigar o problema da detecção de batida, essas anotações foram utilizadas para identificação dos pontos fiduciais. Todos os trabalhos que serão utilizados para comparação de resultados (Capítulo 5) também fazem uso das anotações do banco de dados, o que torna justa a comparação.

Uma vez conhecida a localização do ponto fiducial de cada uma das batidas do sinal, é necessário escolher uma técnica para que, dado esse ponto, sejam definidos limites dentro dos quais está contida a batida, como ilustrado na Figura 20.

Devido à regularidade característica das batidas cardíacas e sua morfologia conhecida, alguns autores realizam uma delimitação com valores fixos, onde uma batida é contida em um intervalo de X amostras anteriores ao ponto fiducial e Y amostras após o ponto fiducial (CHRISTOV et al., 2006; YE; KUMAR; COIMBRA, 2012; CHEN et al., 2017), onde X e Y são valores constantes como, por exemplo, 100 e 200, respectivamente (CHEN et al., 2017). A vantagem dessa abordagem reside em sua simplicidade, mas há também algumas limitações. Por exemplo, dado um caso onde o coração passe a bater mais rápido que o

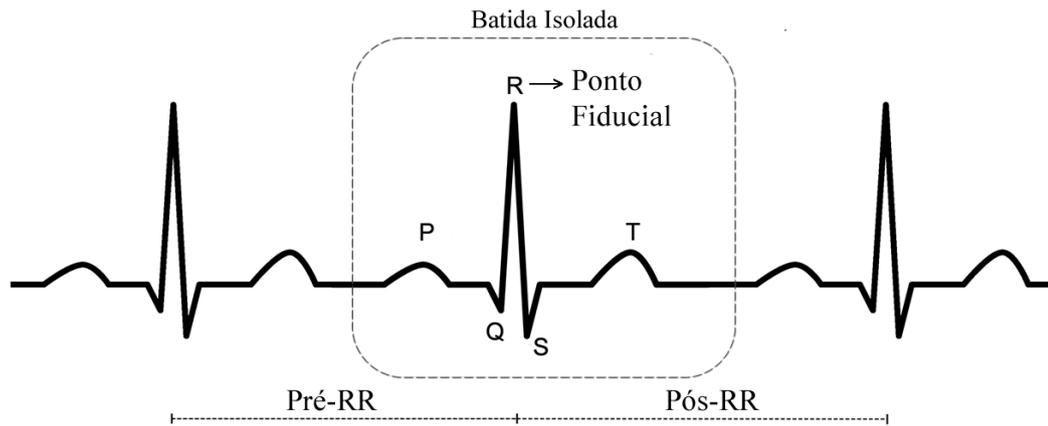


Figura 20: Detecção e definição de limites para as batidas.

normal, como durante atividades físicas ou situações de ansiedade, a utilização de valores fixos pode fazer com que um segmento de batida contenha informações sobre batidas adjacentes, resultando em um aumento de falsos alarmes e degradação do desempenho de classificação. O caso contrário também é delicado: em situações com taxa cardíaca reduzida, como durante períodos de repouso, a delimitação com valores fixos pode vir a “podar” o sinal das batidas, descartando informações importantes.

Como alternativa a essa abordagem, alguns trabalhos (CHAZAL; O'DWYER; REILLY, 2004; ZHANG et al., 2014) utilizam a ferramenta *ecgpuwave* (LAGUNA et al., 2002), que realiza uma análise baseada em filtros e seguidas varreduras do sinal e de sua derivada, a fim de localizar o início e o fim das ondas P e T, e do complexo QRS. Outra abordagem é proposta por Martínez et al. (2004), na qual o mesmo resultado é atingido a partir da aplicação de transformadas *wavelet*. Essas duas alternativas melhoram a exatidão do processo de delimitação e segmentação de batidas, mas pagam o preço de um custo computacional mais elevado, ou seja, de um maior número de operações e passos computacionais a serem executados a cada batida.

Neste trabalho, é apresentada uma nova solução, baseada no comprimento médio dos intervalos entre batidas adjacentes e no fato de que existe uma proporção típica entre os comprimentos das ondas que compõem cada batida. Esta abordagem, chamada de “segmentação dinâmica”, possui um custo computacional baixo, especialmente quando comparada às técnicas de Martínez et al. (2004) e Laguna et al. (2002), e minimiza o problema da abordagem de comprimento fixo, diminuindo o número de ocorrências de “invasão” de batidas adjacentes durante a delimitação, como visto na Figura 21. Isso se deve, especialmente, ao fato de que a técnica proposta leva em consideração a taxa cardíaca atual do paciente e não pressupõe uma taxa fixa.

Os passos são os seguintes:

1. **Cálculo do intervalo R-R Médio:** Os comprimentos dos intervalos entre pontos fiduciais de batidas subsequentes, ou intervalos R-R, são calculados pela subtração de suas posições no traçado de ECG. Ao intervalo entre o pico R de uma determinada batida e o da batida imediatamente anterior, chama-se *Pre-RR*. Ao intervalo entre o pico R de uma batida e o da batida imediatamente posterior, chama-se *Pos-RR*. A média dos dois valores gera um valor de intervalo R-R médio (*avg-RR*) que provê informação sobre o ritmo cardíaco instantâneo e é calculado pela equação 4.1. A Figura 20 ilustra graficamente o significado de cada um desses valores.

$$avg-RR = \frac{Pre-RR + Pos-RR}{2} \quad (4.1)$$

2. **Cálculo de comprimento dos segmentos:** As proporções utilizadas para calcular os comprimentos dos segmentos contendo as ondas P, complexo QRS e T são, respectivamente 25%, 25% e 50% do comprimento *avg-RR* calculado para a batida. Os segmentos são chamados de I (onda P), II (complexo QRS) e III (onda T). Esses valores de proporção são típicos, uma vez que as durações características para segmentos PR, complexos QRS e ondas T são, respectivamente, 12-22ms, 12-20ms e 35-40ms (HAMPTON, 2013). Os valores foram calculados, testados no banco de dados MIT-BIH-AR e validados por inspeção visual nos gráficos gerados.
3. **Segmentação da batida:** Baseado no comprimento *avg-RR* calculado e na posição dos pontos fiduciais, calcula-se posições de início e fim de cada um dos segmentos (I, II e III), de maneira que 35% das amostras referentes à batida estejam antes do ponto fiducial e 65% depois (CHRISTOV et al., 2006).

Exemplos de aplicação da técnica estão presentes nos gráficos da direita na Figura 21, onde é, também, possível constatar uma de suas vantagens com relação à técnica de comprimento fixo. Para batidas normais, na parte superior da figura (a e b), há pouca diferença. No entanto, para batidas ectópicas supraventriculares (tipo S), na parte inferior (c e d), a segmentação dinâmica previne a invasão da próxima batida. Nas duas técnicas, segmentos I, II e III foram obtidos com proporção 25-25-50%.

O trecho de código 4.3 mostra uma versão simplificada (para fins de clareza) da implementação da delimitação e segmentação dinâmica na ferramenta MATLAB[®], a partir da posição de cada ponto fiducial.

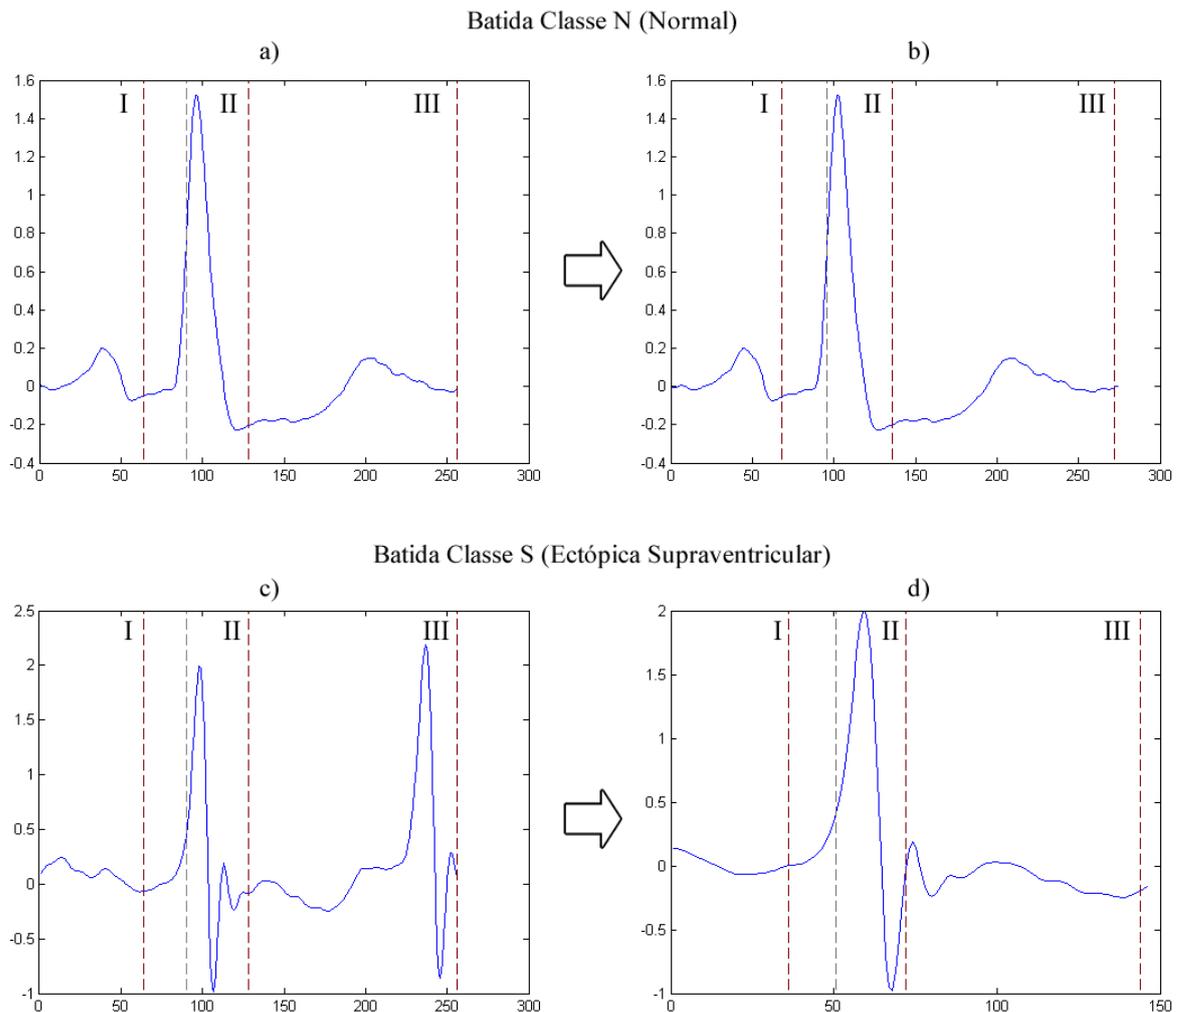


Figura 21: **Comparação entre técnicas de comprimento fixo e segmentação dinâmica:** os gráficos da esquerda (a e c) representam uma implementação baseada em comprimento fixo (90 amostras antes e 165 depois do ponto fiducial). As imagens à direita (b e d) representam o resultado da segmentação dinâmica.

4.4.1 Análise de Custo Computacional

A técnica de segmentação dinâmica é aplicada a cada batida individualmente, partindo de seu ponto fiducial previamente localizado. Para isso, são, inicialmente, calculados os intervalos da batida atual com as duas batidas vizinhas, através de duas operações de subtração. A seguir, o comprimento aproximado da batida é obtido, como a média dos dois intervalos calculados anteriormente. A partir desse comprimento e da posição do ponto fiducial, são calculados os limites da batida. Finalmente, são calculados as posições de início e fim de cada segmento, com proporção 25-25-50%.

Portanto, a quantidade de passos executados independe do comprimento da batida,

Código 4.3: Implementação da Segmentação Dinâmica.

```

% Para cada ponto fiducial i detectado:
rr_pre = ponto_fid(i) - ponto_fid(i-1); % interv. batida anterior
rr_pos = ponto_fid(i+1) - ponto_fid(i); % interv. batida posterior

% obtendo a batida a partir dos intervalor RR
rr_medio = round((rr_pre + rr_pos)/2); % valor médio
tempo_pre = rr_medio*0.35; % após ponto fiducial
tempo_pos = rr_medio - tempo_pre; % antes do ponto fiducial
seg_batida = floor(rr_medio/4); % segmento de batida

% delimitando batida (inicio:fim)
batida = sinal_completo((ponto_fid(i) - tempo_pre):(ponto_fid(i) +
    tempo_pos));

% segmentando em ondas
ondaP = batida(1:seg_batida); % 25%
compQRS = batida(seg_batida+1:seg_batida*2); % 25%
ondaT = batida(seg_batida*2+1:seg_batida*4); % 50%

```

e o algoritmo consiste apenas em cálculos com as operações básicas a partir de valores definidos previamente. Com isso, um número baixo e constante de operações é realizado durante a execução do algoritmo, e sua complexidade é $O(1)$.

4.4.2 Comparação com Outras Técnicas

A segmentação com valores fixos, utilizada por Ye, Kumar e Coimbra (2012) e Chen et al. (2017), é ainda mais simples, uma vez que, ao invés de calcular o comprimento aproximado da batida, assume um comprimento fixo, de 256 ou 300 amostras, por exemplo. A partir desse valor e da posição do ponto fiducial, poucas operações são realizadas, também de maneira independente do tamanho da batida, e sua complexidade é $O(1)$.

O método proposto por Laguna et al. (2002), implementado na ferramenta *ecgpuwave*, realiza cálculos de derivada e submete o sinal a filtros de frequência e varreduras em busca de valores limites (*thresholds*), o que resulta em uma complexidade mais alta. Cada um desses passos - derivação, filtragem, busca - implica na execução de uma quantidade fixa de operações para cada uma das n amostras que compõem a entrada (a própria batida). Portanto, esse método, utilizado por Chazal, O'Dwyer e Reilly (2004) e Zhang et al. (2014), possui complexidade $O(n)$, e o tempo consumido em seu processamento aumenta de acordo com o tamanho da entrada, em uma proporção linear.

Um maior custo computacional também pode ser observado no método de Martínez et al. (2004), baseado em *wavelets*. Transformadas *wavelet* discretas (DWT, do inglês

Discrete Wavelet Transform) possuem complexidade linear $O(n)$ (MALLAT, 2008), e são realizadas a partir da aplicação de seguidos filtros de frequência no sinal (com operações de convolução), gerando séries de coeficientes de onde são extraídas informações de interesse.

4.5 Extração de Características

Cada batida detectada no sinal deverá servir como entrada para um modelo classificador, que a associará a uma determinada classe. No entanto, após a fase de detecção e segmentação, cada batida é representada por um número relativamente grande de valores, na forma de uma série temporal de comprimento variável entre 250 a 400 amostras, aproximadamente. O processo de extração de características do sinal serve para diminuir sua dimensionalidade (DAS, 2015), que passa de uma sequência grande de amostras para uma lista normalmente mais curta de características associadas a ela, de modo a destacar sua informação mais importante e reduzir informação irrelevante.

Um dos objetivos desse processo, além da diminuição de dimensionalidade, é gerar dados sobre a batida através dos quais o modelo classificador seja capaz de inferir com maior precisão a classe à qual ela pertence. Portanto, as características devem ser escolhidas cuidadosamente para auxiliar na diferenciação entre as diferentes classes.

Para este trabalho, três tipos de características são extraídos de cada batida, formando padrões de baixa dimensionalidade para a entrada do modelo classificador. Os três tipos são obtidos com simplicidade e baixa complexidade computacional: intervalos entre batidas, características de amplitude e Parâmetros de Hjorth.

4.5.1 Intervalos entre Batidas

Características relacionadas ao intervalo de tempo entre batidas vizinhas, também conhecidas como “características dinâmicas”, são importantes na definição do tipo de batida e detecção de arritmias, pois caracterizam o estado atual da taxa cardíaca. Se o coração está acelerado ou batendo mais devagar, temos intervalos diferentes, menores ou maiores. Quanto a alguns tipos de batidas que se pretende detectar, temos que as prematuras normalmente chegam antes do esperado, enquanto batidas de escape aparecem depois do esperado para uma batida normal. Portanto, há um comportamento esperado, baseado na taxa cardíaca recente, e há manifestações detectáveis no exame de ECG que caracterizam mudanças de ritmo e outras anomalias.

A maneira usual de se definir o intervalo entre batidas é medindo a distância entre dois picos R (do complexo QRS) no sinal de ECG. Três valores básicos são utilizados para calcular as características dinâmicas utilizadas neste trabalho:

- **Pre-RR:** Comprimento do intervalo R-R entre uma batida e a batida anterior.
- **Pos-RR:** Comprimento do intervalo R-R entre uma batida e a batida posterior.
- **Recent-RR:** Média dos últimos 5 intervalos R-R que antecedem a batida.

Esses valores podem ser utilizados para a composição dos padrões de entrada do classificador da maneira como foram calculados. No entanto, visando destacar alguns aspectos, como a relação entre o comportamento da batida atual com seu histórico recente de batidas, e torná-las independentes da taxa cardíaca atual, são calculados intervalos R-R normalizados, como os descritos nas equações 4.2 e 4.3.

$$Pre-RR-Norm = \frac{Pre-RR}{Recent-RR} \quad (4.2)$$

$$Pos-RR-Norm = \frac{Pos-RR}{Recent-RR} \quad (4.3)$$

Neste tipo de medida, o valor calculado se aproxima da unidade quando mantém o comportamento recente ou se distancia de 1 quando se tornam mais curtos (<1) ou mais longos (>1). Além de melhorar a capacidade do sistema para detecção de mudanças de ritmo (batidas prematuras e escape), a normalização torna os valores independentes do comportamento cardíaco médio do paciente, que naturalmente pode ser muito diferente a cada indivíduo (DOQUIRE et al., 2011).

Doquire et al. (2011) e Lin e Yang (2014) adotam estratégia semelhante para a normalização dos intervalos, com a diferença de que ao invés de utilizar apenas o histórico recente, o cálculo necessita de uma média do comprimento de todos os intervalos R-R presentes no sinal. Essa abordagem impossibilita a detecção em tempo real, pois demanda que o registro esteja finalizado para o cálculo das características. A abordagem proposta na presente tese adapta essa técnica, mantendo suas vantagens, mas viabilizando a classificação em tempo real, que pode ser realizada a partir da sexta batida detectada (quando torna-se possível o cálculo do histórico recente).

De maneira semelhante, Krasteva, Jekova e Christov (2006) propõem a utilização de outra característica que será adotada nos testes, dada pela equação 4.4, que representa a

diferença entre as durações de dois intervalos R-R ao redor de uma determinada batida de interesse. Nela, a normalização também é realizada a partir dos últimos cinco intervalos R-R, e o valor obtido é independente da taxa cardíaca atual.

$$Diff-RR-Norm = \frac{(Pos-RR - Pre-RR) * 100}{Recent-RR} \quad (4.4)$$

Para o cálculo das características dinâmicas, são realizadas algumas subtrações e o cálculo da média de cinco valores, anteriores à batida atual, para subsequente normalização, que é realizada por operações de divisão. Assim como no caso da segmentação dinâmica, seu custo computacional é baixo, uma vez que a quantidade de passos computacionais é fixa e independe do tamanho da entrada (comprimento da batida). Portanto, as características dinâmicas são calculadas em tempo constante para cada batida, ou $O(1)$.

4.5.2 Características de Amplitude

A partir das variações de amplitude do sinal e seu comportamento no tempo, é possível extrair algumas características importantes, comumente referidas na literatura como características morfológicas. Muitos trabalhos da área utilizam este tipo de característica em conjunto com outras, de extração mais elaborada (CHAZAL; O'DWYER; REILLY, 2004; LLAMEDO; MARTÍNEZ, 2011; ZHANG et al., 2014).

Neste trabalho, para a composição do padrão de entrada para o classificador, também são extraídos três valores relacionados à amplitude de cada um dos segmentos obtidos na fase de segmentação (I, II e III): amplitude máxima, amplitude mínima e amplitude média. Essas características acrescentam ao sistema informações sobre presença e ausência de ondas típicas de cada segmento e prevalência positiva ou negativa do sinal. As características foram obtidas a partir de Código 4.4, escrito no MATLAB®.

Código 4.4: Obtendo características de Amplitude.

```

max1 = max(batida(1:seg1)); % valor máximo
min1 = min(batida(1:seg1)); % valor mínimo
med1 = mean(batida(1:seg1)); % valor médio
max2 = max(batida(seg1+1:seg2));
min2 = min(batida(seg1+1:seg2));
med2 = mean(batida(seg1+1:seg2));
max3 = max(batida(seg2+1:seg3));
min3 = min(batida(seg2+1:seg3));
med3 = mean(batida(seg2+1:seg3));

```

A Figura 22 ilustra a grande diferença morfológica entre batidas de duas classes. Nela, duas batidas normais (classe N) são seguidas por uma batida ventricular prematura (classe V, em destaque), reconhecível pelo formato anômalo do complexo QRS e pelo aparecimento mais cedo do que o esperado. Apesar desse exemplo tornar clara a relevância das características de amplitude, Clifford, Azuaje e Mcsharry (2006) alertam que há muita variação na morfologia de batidas cardíacas de uma mesma classe, até mesmo para um mesmo paciente, e que sua utilização de forma isolada não é suficiente para a determinação da classe da batida. No entanto, quando associadas a outras características, elas podem ser importantes para o sucesso da classificação.

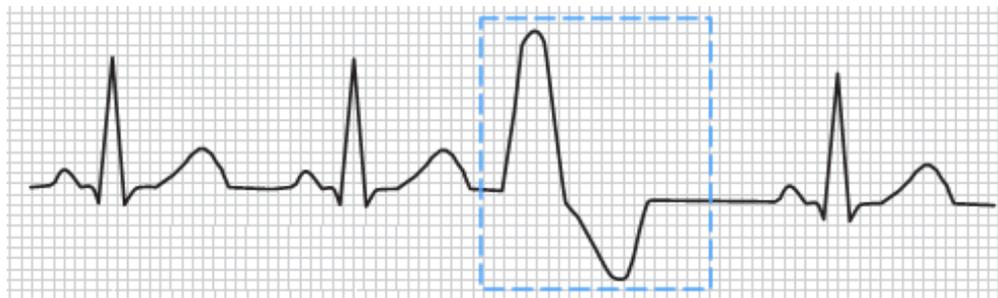


Figura 22: Diferença de amplitude entre batidas normais e prematuras ventriculares (KASTOR, 2008).

O cálculo das características de amplitude demanda uma varredura no sinal da batida, que a análise, amostra por amostra, em busca de seus valores máximo e mínimo, e realize a soma de todas as amostras para o cálculo da média. Todas as comparações e somas podem ser realizadas dentro de uma mesma estrutura de repetição (um laço “*for*”, por exemplo), que percorre as n amostras do sinal, executando um número constante de operações a cada iteração. O tempo gasto nesse processo depende diretamente do comprimento da batida, e resulta em um algoritmo com baixa complexidade, linear, ou $O(n)$.

4.5.3 Parâmetros de Hjorth

A necessidade de métodos quantitativos para descrição de sinais provenientes do exame de eletroencefalograma (EEG) levou Hjorth (1970) à formulação de um conjunto de três parâmetros capazes de caracterizar não apenas sinais cerebrais, mas qualquer sinal e seus equivalentes nos domínios do tempo e frequência, a partir de alguns métodos matemáticos e estatísticos aplicados a uma série temporal não-linear. Os três parâmetros são chamados de: atividade, mobilidade e complexidade.

Segundo o próprio Hjorth (1973), os parâmetros propostos possuem forte relação com

o sistema físico que representam, indicando respectivamente suas variações de amplitude (atividade) e frequência (mobilidade), além de sua complexidade quando comparado a um sinal senoidal simples (complexidade). Possuem também, como vantagem, o fato de serem calculados com pequeno custo computacional, possibilitando seu uso em tempo real e em plataformas com recursos reduzidos.

Para entender melhor a origem dos parâmetros, é preciso seguir a linha de raciocínio de Hjorth (1970), partindo da representação do sinal no domínio da frequência, na equação 4.5, até a definição dos parâmetros nas equações 4.10 a 4.12. Primeiramente, o sinal do ECG pode ser expresso como uma função no tempo $y(t)$ e, também, por meio da transformada de Fourier, traduzido em uma função de frequência $F(\omega)$. A fase do sinal é excluída com a multiplicação de $F(\omega)$ pelo seu conjugado $F^*(\omega)$, que resulta no espectro de potência $S(\omega)$, como mostrado na equação 4.5.

$$S(\omega) = F(\omega).F^*(\omega) \quad (4.5)$$

Essa descrição do espectro de potência obtida a partir da transformada de Fourier é sempre simétrica com relação à frequência zero. Como consequência, tem-se que, em uma análise estatística da distribuição de frequência, todos os momentos ímpares são iguais a zero. Portanto, não haverá informação sobre os primeiro e terceiro momentos estatísticos, que são a média linear e a assimetria (*skewness*), de acordo com a definição geral de momento estatístico (ordem n), dada pela equação 4.6.

$$m_n = \int_{-\infty}^{+\infty} \omega^n . S(\omega) d\omega \quad (4.6)$$

A transformação dos parâmetros entre os domínios do tempo e frequência é baseada na igualdade de energia dentro da época atual, o que significa que a potência total do sinal no domínio da frequência é igual à sua potência média no domínio do tempo (HJORTH, 1970), como descrito na equação 4.7. A potência média da função de tempo, descrita do lado direito da equação 4.7 é reconhecida pelos estatísticos como sua variância σ_y^2 . Barbour e Parker (2015) apresentam mais detalhes sobre esse equacionamento.

$$m_0 = \int_{-\infty}^{+\infty} S(\omega) d\omega = \frac{1}{T} \int_{t-T}^t y^2(t) dt = \sigma_y^2 \quad (4.7)$$

Os próximos dois momentos pares também podem ser calculados, com as equações 4.8 e 4.9, e também representam variâncias no domínio do tempo, mas dos sinais resultantes

das derivadas primeira e segunda do sinal original $y(t)$, σ_d^2 e σ_{dd}^2 respectivamente.

$$m_2 = \int_{-\infty}^{+\infty} \omega^2 . S(\omega) d\omega = \frac{1}{T} \int_{t-T}^t \left(\frac{dy(t)}{dt} \right)^2 dt = \sigma_d^2 \quad (4.8)$$

$$m_4 = \int_{-\infty}^{+\infty} \omega^4 . S(\omega) d\omega = \frac{1}{T} \int_{t-T}^t \left(\frac{d^2y(t)}{dt^2} \right)^2 dt = \sigma_{dd}^2 \quad (4.9)$$

É a partir dos valores dos momentos pares m_0 , m_2 e m_4 que são calculados os três parâmetros de Hjorth, de acordo com as equações 4.10, 4.11 e 4.12, respectivamente.

$$\textit{Atividade}(y(t)) = m_0 = \sigma_y^2 \quad (4.10)$$

$$\textit{Mobilidade}(y(t)) = \sqrt{\frac{m_2}{m_0}} = \sqrt{\frac{\sigma_d^2}{\sigma_y^2}} = \frac{\sigma_d}{\sigma_y} \quad (4.11)$$

$$\textit{Complexidade}(y(t)) = \frac{(m_4/m_2)^{1/2}}{(m_2/m_0)^{1/2}} = \frac{(\sigma_{dd}/\sigma_d)^{1/2}}{(\sigma_d/\sigma_y)^{1/2}} = \frac{\sigma_{dd}/\sigma_d}{\sigma_d/\sigma_y} \quad (4.12)$$

No entanto, sabendo que o cálculo dos parâmetros depende da obtenção das derivadas primeira e segunda do sinal e de cálculos de variância amostral, a implementação torna-se matematicamente mais simples e com custo computacional baixo, e equações alternativas e simplificadas são propostas para o cálculo dos parâmetros.

Cálculos de variância podem ser realizados de acordo com a equação 4.13, onde N é a quantidade de amostras, x_i é o i -ésimo termo da série x , e \bar{x} é a média de todos os elementos da mesma série.

$$\textit{var}(x) = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (4.13)$$

Além disso, no código, as derivadas do sinal $y(t)$ são calculadas a partir da técnica de derivação central (OLVER, 2014), computacionalmente simples, na qual uma boa aproximação para a derivada em um dado ponto a é dada pela equação 4.14, onde h é um número suficientemente pequeno, que representa uma pequena mudança no tempo.

$$f'(a) \approx \frac{f(a+h) - f(a-h)}{(a+h) - (a-h)} \approx \frac{f(a+h) - f(a-h)}{2h} \quad (4.14)$$

O Código 4.5 foi utilizado como implementação da técnica de diferenciação central, onde a função recebe o sinal original, a frequência de amostragem Fa e a ordem da derivada a ser calculada (1 ou 2), e retorna o sinal diferencial f_{xi} .

Código 4.5: Cálculo de derivada baseada na técnica de diferenciação central.

```
function [fxi] = derivada_central(y, Fa, ordem)

no_elementos = length(y); % quantidade de amostras
Ta = 1/Fa; % Período de amostragem
fxi = zeros(1, no_elementos); % inicialização do sinal diferencial

if ordem == 1 % derivada primeira
    for i = 2:no_elementos-1
        fxi(i-1) = (y(i+1) - y(i-1))/(2*Ta);
    end
elseif ordem == 2 % derivada segunda
    for i = 2:no_elementos-1
        fxi(i-1) = (y(i+1) - 2*y(i) + y(i-1))/(Ta^2);
    end
end
```

Finalmente, os parâmetros de Hjorth são definidos e calculados da seguinte maneira (VIDAURRE et al., 2009):

Atividade: Representa a medida do quadrado do desvio padrão da amplitude do sinal, também conhecida como variância ou potência média. No domínio da frequência, indica a superfície do espectro de potência, ou sua potência total, como descrito na equação 4.7. É calculado pela equação 4.15.

$$Atividade(y(t)) = \sigma_y^2 = var(y(t)) \quad (4.15)$$

Mobilidade: Definida como a raiz quadrada da razão entre a variância da primeira derivada do sinal e a variância da amplitude do sinal original. Uma vez que os dois valores são dependentes da amplitude média, a mobilidade é dependente apenas do formato da curva, resultando em uma medida da inclinação relativa média. Este parâmetro, calculado pela equação 4.16, representa a frequência média do sinal.

$$Mobilidade(y(t)) = \frac{\sigma_d}{\sigma_y} = \sqrt{\frac{Atividade\left(\frac{dy(t)}{dt}\right)}{Atividade(y(t))}} \quad (4.16)$$

Complexidade: Dada como a razão entre a mobilidade da derivada da série temporal e a mobilidade da própria série. A mobilidade da derivada é obtida de maneira análoga à do sinal original, mas com a variância da derivada de segunda ordem. Traduzindo para seu real significado, este parâmetro indica a mudança na frequência do sinal, comparando sua similaridade com um sinal senoidal puro. A partir da equação 4.17, seu valor se aproxima da unidade quanto mais for similar a uma senóide pura.

$$Complexidade(y(t)) = \frac{\sigma_{dd}/\sigma_d}{\sigma_d/\sigma_y} = \frac{Mobilidade(\frac{dy(t)}{dt})}{Mobilidade(y(t))} \quad (4.17)$$

Ainda que tenham sido projetados para a caracterização de sinais cerebrais e tenham mostrado resultados importantes nessa área (VIDAURRE et al., 2009; CECCHIN et al., 2010; CHARBONNIER et al., 2011; OH; LEE; KIM, 2014), o uso dos parâmetros de Hjorth não está restrito a esse segmento. Pesquisadores vem explorando seu potencial no processamento de outros sinais biológicos, como na análise de eletromiografia (EMG) (MOUZÉ-AMADY; HORWAT, 1996) e caracterização de sons pulmonares (RIZAL; HIDAYAT; NUGROHO, 2015). Sua utilização no processamento de exames de ECG está geralmente relacionado a outras aplicações, como a classificação automática de estágios do sono (NOVIYANTO et al., 2011). Para a classificação de batidas cardíacas, no entanto, seu potencial permanece inexplorado.

A extração de parâmetros de Hjorth para este trabalho foi feita em cada um dos segmentos obtidos da fase de segmentação (I, II e III), resultando em 9 valores calculados para cada batida processada. A implementação da extração foi codificada no software MATLAB®, na forma de uma função, que recebe como argumento um vetor de amostras e retorna um conjunto de três valores contendo a atividade, mobilidade e complexidade obtidas para essa série, de acordo com o Código 4.6. Um fluxograma mostrando os passos do algoritmo está ilustrado na Figura 23.

Código 4.6: Função para cálculo de parâmetros de Hjorth.

```

% Calcula os parametros de Hjorth para o sinal de ECG.
function [act, mob, comp] = hjorth(sig)
    % calculando as derivadas primeira e segunda
    der1 = derivada_central(sig, 1, 1); % 1a derivada
    der2 = derivada_central(sig, 1, 2); % 2a derivada

    act = var(sig); % atividade
    mob = sqrt(var(der1)/act); % mobilidade
    comp = (sqrt(var(der2)/var(der1)))/mob; % complexidade
end

```

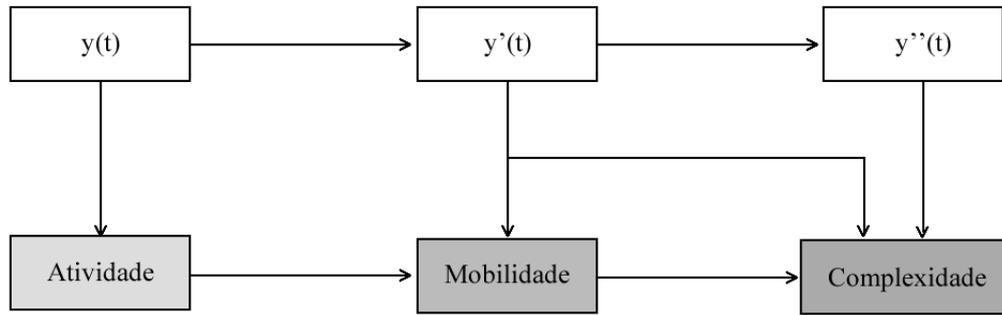


Figura 23: Algoritmo para o cálculo dos Parâmetros de Hjorth.

4.5.3.1 Análise de Custo Computacional

Todos os cálculos realizados para obtenção dos parâmetros de Hjorth se resumem à aplicação das equações de variância e derivada (4.13 e 4.14), cujos custos computacionais variam linearmente com o comprimento do vetor de amostras ao qual são aplicadas.

A variância consiste no somatório de n diferenças, entre os n valores de amostras e a média do sinal, dividida pelo número de amostras menos um. Portanto, é calculado em uma estrutura de repetição única, e o tempo gasto para sua execução varia linearmente com o tamanho da entrada, resultando em complexidade $O(n)$. Sua execução depende do cálculo prévio da média do sinal, que é, também, linear.

A técnica de diferenciação central é aplicada para cada uma das n amostras, também em uma estrutura de repetição, onde é executada uma quantidade constante de operações básicas de subtração, soma e divisão a cada iteração. O produto do algoritmo é o sinal diferencial, e seu cálculo demanda kn operações para um sinal de tamanho n , onde k é um valor constante. Portanto, o algoritmo é, também, $O(n)$.

Para obtenção dos parâmetros de Hjorth, são calculadas inicialmente as derivadas primeira e segunda do sinal, com custo linear $O(n)$. A seguir, são calculados os três parâmetros, que são uma combinação de cálculos de variância, com complexidade $O(n)$, e algumas divisões. Portanto, em síntese, é executado um número pequeno e constante de operações para cada amostra do sinal, dividido em algumas estruturas de repetição, resultando em uma complexidade linear $O(n)$.

4.5.3.2 Comparação com outras técnicas

Os parâmetros de Hjorth são, devido à sua simplicidade de implementação e baixa complexidade computacional, uma alternativa interessante a outros métodos de extração de características que também incluem informações sobre o sinal no domínio da frequência, como as transformadas rápida de Fourier e *wavelet* discreta (MOUZÉ-AMADY; HORWAT, 1996). Vidaurre et al. (2009) destacam, ainda, que a técnica de Hjorth extrai menos parâmetros que as demais, o que é uma vantagem durante a etapa de classificação.

De acordo com Cormen et al. (2001), a complexidade computacional da transformada rápida de Fourier no tempo é $O(n \cdot \log n)$, maior do que a complexidade $O(n)$ necessária para o cálculo dos parâmetros de Hjorth. Além disso, a transformada rápida de Fourier não é adequada para sinais não-estacionários, como o próprio sinal de ECG, uma vez que não mantém informações sobre a evolução do sinal no tempo e faz apenas um quadro geral com as componentes de frequência presentes no sinal como um todo (MICHEL et al., 2010). Por este motivo, é uma técnica pouco utilizada para o processamento de ECG, com destaque para o trabalho de Zidelmal et al. (2013).

A transformada *wavelet* representa o próximo passo, combinando informação sobre componentes de frequência e sua evolução no tempo, o que a torna elegível para sinais não-estacionários. A implementação da transformada *wavelet* discreta (DWT, de *Discrete Wavelet Transform*) baseia-se na decomposição do sinal a partir de um banco de filtros de frequência (MICHEL et al., 2010), onde o sinal é seguidamente decomposto em dois, através da aplicação de um filtro passa-alta e outro passa-baixa. Os resultado do sinal passa-baixa é novamente decomposto, até que se atinja o nível desejado. Dos sinais produzidos pela decomposição, são extraídos coeficientes, que passam por algum tipo de processamento para extração de características (MAZOMENOS et al., 2013). Trata-se de uma das técnicas mais populares no processamento de sinais de ECG para classificação de batidas (CHRISTOV et al., 2006; ELHAJ et al., 2016), e são utilizadas nos estudos de Llamedo e Martínez (2011) e Ye, Kumar e Coimbra (2012).

Segundo Mallat (2008), a complexidade computacional da DWT é $O(n)$. No entanto, devido à própria estrutura do algoritmo, o número de operações realizadas durante sua execução é elevado, fruto da seguida aplicação de filtros de frequência, no sinal e em suas partes. Os passos de filtragem são realizados através da convolução de um filtro com o sinal, o que resulta em um número alto de multiplicações e somas, em especial para *wavelets* do tipo Daubechies (DAUBECHIES et al., 1991), que, segundo Güler e Übeyli (2005), são o tipo mais apropriado para utilização em classificação de batidas cardíacas.

Com relação ao cálculo dos parâmetros de Hjorth, para cálculo da média e variância, apenas uma operação (soma e subtração, respectivamente) é necessária para cada uma das amostras, seguida de uma única divisão ao final. Para a geração da derivada do sinal, apenas uma divisão e uma subtração são necessárias por amostra do sinal. Portanto, apesar de terem complexidades igualmente lineares, $O(n)$, as técnicas de Hjorth e DWT diferem com relação ao número de operações realizadas para cada amostra do sinal, muito maior nesta última. A Tabela 3 resume as características de cada uma das técnicas.

Tabela 3: Complexidade Computacional das Técnicas de Extração de Características.

Técnica	Complexidade	Número de Operações
Hjorth	$O(n)$	Baixo
DWT	$O(n)$	Alto
FFT	$O(n \cdot \log n)$	Alto

A Figura 24 mostra uma comparação entre as complexidades no tempo das três técnicas, estimando o consumo de tempo durante a execução de cada uma das três técnicas para entradas de diferentes tamanhos. A curva que representa a FFT cresce mais acentuadamente com o aumento da entrada, enquanto as técnicas de DWT e Hjorth aumentam linearmente, mas com inclinações diferentes, que refletem a quantidade de operações realizadas durante suas respectivas execuções.

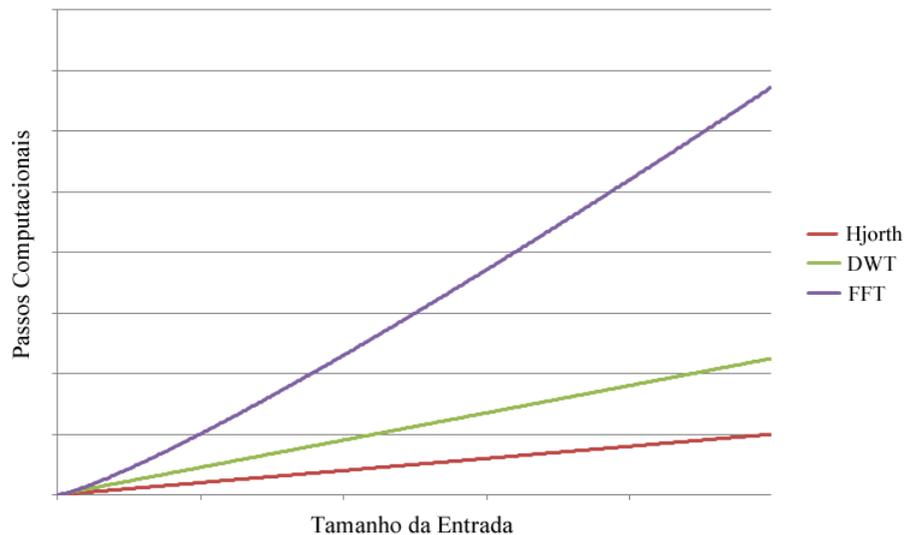


Figura 24: Comparação entre técnicas: Hjorth, DWT e FFT.

4.6 Modelo Classificador

O produto da fase anterior é um conjunto de vetores de características, cada um deles composto por uma combinação ou pelo total de características extraídas dos três segmentos de uma determinada batida. Cada um desses vetores, que alimentarão o modelo responsável pela classificação das batidas, podem ser também chamados de “padrão de entrada”. É a partir de conjuntos desses padrões que o modelo classificador é treinado (CD1) e testado (CD2), segundo divisão ilustrada na Figura 18.

Vários modelos já foram aplicados ao problema de classificação de batidas cardíacas. Entre os principais, temos os mapas auto-organizáveis (SOM, do inglês *Self-Organizing Maps*) (LAGERHOLM et al., 2000), *Learning Vector Quantization* (LVQ) (MELIN et al., 2014), as máquinas de vetor de suporte (SVM, de *Support Vector Machines*) (ELHAJ et al., 2016; ZHANG et al., 2014; YE; KUMAR; COIMBRA, 2012), redes neurais artificiais (YU; CHEN, 2007), discriminantes lineares (LDA, de *Linear Discriminant Analysis*) (CHAZAL; O'DWYER; REILLY, 2004) e *Extreme Learning Machines* (KARPAGACHELVI; ARTHANARI; SIVAKUMAR, 2012).

Para este trabalho, foi escolhida como modelo classificador a Máquina de Vetor de Suporte (SVM), devido à sua utilização bem sucedida no problema de interesse e ao seu desempenho geral em problemas de classificação, incluindo genética (ROUSSEAU et al., 2014), tratamento de imagens (WANG et al., 2013), processamento de texto (SINGH et al., 2015), determinação de padrões cerebrais e musculares (SUBASI, 2013), e muitos outros. Como destacado no Capítulo 1, da “Introdução”, este trabalho não tem como objetivo explorar diferentes tipos de modelos para essa finalidade. Classificadores mais simples como discriminantes lineares já foram utilizados por outros pesquisadores, mas fiam-se em algumas suposições sobre os dados de entrada, nem sempre realistas. As máquinas de vetor de suporte são classificadores mais abrangentes e, de acordo com sua configuração, podem produzir regiões de decisão não-lineares capazes de atingir um bom desempenho de classificação independentemente da separabilidade linear dos dados.

4.6.1 SVM - Máquina de Vetor de Suporte

As máquinas de vetor de suporte constituem uma classe de máquinas de aprendizado proposta por Vladimir Vapnik (CORTES; VAPNIK, 1995), baseada nos conceitos da teoria estatística da aprendizagem (VAPNIK, 1998), que utiliza o conceito de aprendizagem supervisionada e pode ser utilizada tanto para classificação de padrões quanto para

problemas de regressão linear.

A ideia deste tipo de máquina é a construção de um hiperplano como superfície de decisão de tal forma que a margem de separação entre exemplos de classes distintas seja máxima (HAYKIN, 1999), como ilustrado pela Figura 25. Por serem derivadas do conceito de minimização estrutural de risco, as máquinas de vetor de suporte podem fornecer um bom desempenho de generalização em problemas de classificação de padrões, apesar de não incorporar conhecimento do domínio do problema (HAYKIN, 1999).

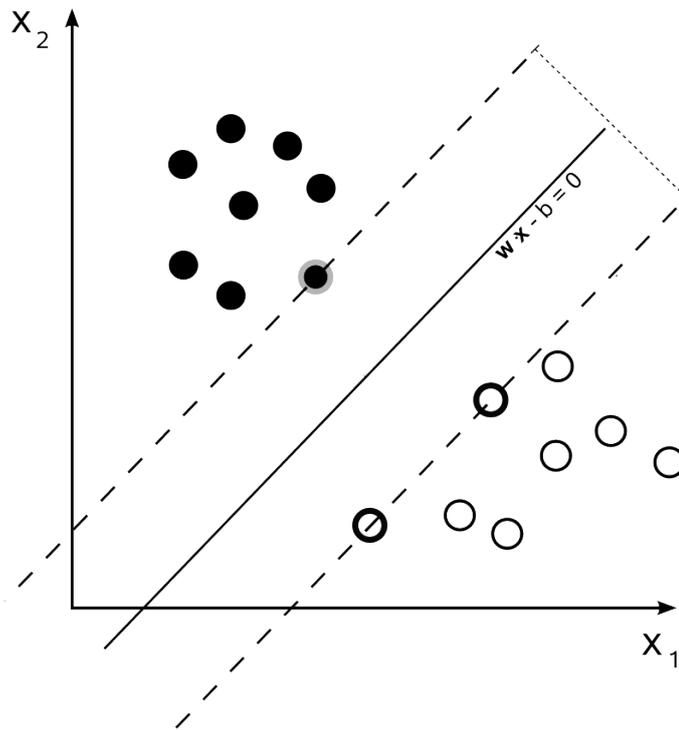


Figura 25: Hiperplano gerado pela SVM para classificação de padrões.

O funcionamento da máquina de vetor de suporte depende da extração de um subconjunto dos dados de treinamento que representem características estáveis dos dados, chamados de vetores de suporte, que servem como nós ocultos da rede. Os vetores de suporte são apenas uma fração do espaço de entrada e são escolhidos automaticamente pelo algoritmo e não pelo usuário. Para cada padrão da entrada é calculado um núcleo do produto interno $K(\mathbf{x}_i, \mathbf{x}_j)$ entre essa entrada \mathbf{x}_i e cada vetor de suporte \mathbf{x}_j . Dependendo de como esse núcleo é gerado, é possível construir diferentes máquinas de aprendizado (polinomial, função de base radial), que se caracterizam por superfícies de decisão não-lineares próprias. Assim, é válido dizer que a SVM funciona como uma rede alimentada adiante com uma única camada oculta de unidades não-lineares, formadas por vetores de suportes extraídos pelo algoritmo, como ilustrado na Figura 26.

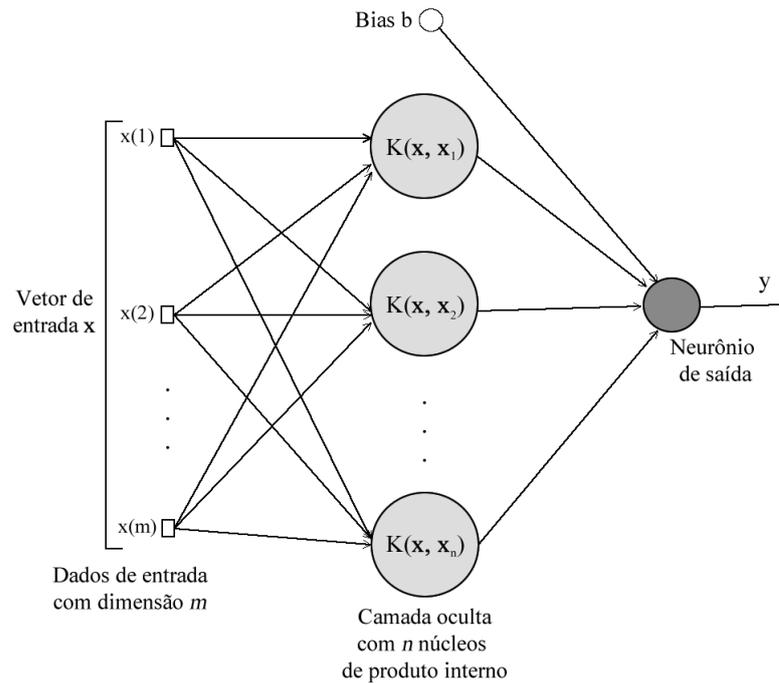


Figura 26: Arquitetura da máquina de vetor de suporte.

Basicamente, a SVM depende de dois processos matemáticos:

- Considerando um espaço de entrada constituído de padrões não linearmente separáveis, o Teorema de Cover (COVER, 1965) afirma que este espaço multidimensional pode ser transformado para um novo espaço de características onde os padrões são linearmente separáveis com maior probabilidade, desde que essa transformação seja não-linear e que a dimensionalidade do espaço de características seja suficientemente alta. Portanto, a primeira operação básica da SVM é o mapeamento $\phi(\cdot)$ dos dados de entrada para um espaço de características oculto de alta dimensionalidade, como representado na Figura 27.

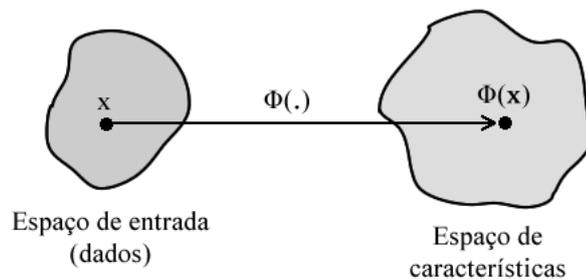


Figura 27: Mapa não linear $\phi(\cdot)$ do espaço de entrada para o espaço de características.

- A segunda operação é a construção de um hiperplano ótimo para separação dos padrões no espaço de características, onde eles são linearmente separáveis. É o cálculo do núcleo do produto interno que nos permite construir uma superfície de decisão que é não-linear no espaço de entrada, mas cuja imagem no espaço de características é linear.

Este tipo de modelo classificador pertence a uma classe de modelos baseados em núcleo, ou *kernel*, em que uma função $\phi(x)$ mapeia o espaço vetorial de entrada para outro espaço vetorial de maior dimensionalidade, onde a separação de vetores de classes diferentes por um hiperplano passa a ser possível. No entanto, a efetiva construção desse hiperplano em um espaço de alta dimensionalidade, e o custo computacional associado a ela, é evitada através do cálculo do núcleo de produto interno, que possibilita que o problema seja solucionado em sua forma *dual*, no próprio espaço de entrada.

O valor do *kernel* $K(\mathbf{x}_i, \mathbf{x}_j)$ é calculado pelo produto interno de dois vetores \mathbf{x}_i e \mathbf{x}_j no espaço de características, de maneira que $K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i) * \phi(\mathbf{x}_j)$. Segundo Carpinteiro et al. (2012), a vantagem da utilização da função de *kernel* reside no fato de que, através dela, é possível manipular um espaço de características de dimensionalidade arbitrária sem a necessidade de se computar explicitamente a transformação $\phi(x)$. Segundo Vapnik (CORTES; VAPNIK, 1995), qualquer função que satisfaça o Teorema de Mercer (MERCER, 1909) pode ser utilizada como função de *kernel*. Dois exemplos típicos (HAYKIN, 1999) são os núcleos polinomial e de função de base radial (RBF, de *Radial Basis Function*), definidos pelas equações 4.18 e 4.19, onde p e σ^2 equivalem, respectivamente, ao grau do polinômio e a largura da gaussiana no kernel RBF, escolhidos pelo usuário.

$$K(\mathbf{x}_i, \mathbf{x}_j) = ((\mathbf{x}_i \mathbf{x}_j) + 1)^p \quad (4.18)$$

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{x}_i - \mathbf{x}_j\|^2\right) \quad (4.19)$$

Do ponto de vista da implementação, o treinamento das máquinas de vetor de suporte equivale à solução de um problema de otimização quadrática (HAYKIN, 1999) do tipo: dada uma amostra de treinamento $\{(\mathbf{x}, d_i)\}_{i=1}^N$, encontre os multiplicadores de Lagrange $\{\alpha_i\}_{i=1}^N$ que maximizam a função objetivo:

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (4.20)$$

sujeita às restrições:

1. $\sum_{i=1}^N \alpha_i d_i = 0$
2. $0 \leq \alpha_i \leq C$ para $i = 1, 2, \dots, N$, onde C é um parâmetro especificado pelo usuário.

Desta maneira, o treinamento da SVM torna-se, geralmente, um problema de programação quadrática baseado em Multiplicadores de Lagrange (BERTSEKAS, 1999), garantindo que se encontre um extremo global da superfície de erro (chamado de ponto de sela), onde o erro se refere à diferença entre a resposta desejada e a saída da SVM, e que a computação seja realizada eficientemente.

Em outras abordagens, a complexidade do modelo é normalmente controlada mantendo-se o número de características ou de neurônios pequeno. Nas máquinas de vetor de suporte, a dimensionalidade do espaço de características é feita propositalmente grande para possibilitar a construção da superfície de decisão, e a complexidade do modelo é controlada pela extração de uma fração dos dados de treinamento que servem como vetores de suporte e resolução do problema de otimização dual, no espaço de entrada.

Para este trabalho, utilizou-se a implementação provida pela biblioteca LIBSVM (CHANG; LIN, 2011). Para o cálculo do núcleo interno, utilizou-se o *kernel* RBF definido pela equação 4.19. Parâmetros necessários para o treinamento (g e C) foram selecionados empiricamente, utilizando validação cruzada *10-fold* no conjunto de dados de treinamento. O parâmetro g regula a largura da gaussiana, enquanto o parâmetro C é um parâmetro de custo, necessário para a construção do hiperplano, que define um custo para a classificação errada de padrões: quando pequeno torna-se mais permissivo e suaviza as margens do hiperplano; quando muito grande torna as margens estreitas e a classificação rigorosa, podendo arriscar o desempenho e aproximando-se do *overfitting*, que é uma excessiva conformidade aos dados de treinamento que prejudica sua capacidade de generalização. Deve-se buscar um equilíbrio entre custo e benefício.

As máquinas de vetor de suporte são um raro exemplo de metodologia onde intuição geométrica, métodos matemáticos, garantias teóricas e algoritmos práticos se encontram. Seus resultados finais são estáveis, reproduzíveis e independentes do algoritmo específico utilizado para otimizar o modelo. Se dois usuários utilizarem o mesmo modelo, mesmos parâmetros e dados terão os mesmos resultados (BENNETT; CAMPBELL, 2000).

4.7 Medidas de Desempenho

Durante a etapa anterior, os dados provenientes do banco de dados MIT-BIH-AR são divididos em dois subconjuntos; um destinado ao treinamento da máquina de vetor de suporte e outro utilizado para seu teste, ou seja, para a verificação de seu desempenho. Para análise do desempenho, é necessário estabelecer alguns índices, que o tornem quantificável e passível de comparação com outros modelos. Para que essa comparação seja justa e significativa, é preciso tomar cuidado com a escolha dos índices e seguir o padrão utilizado na maioria dos trabalhos da área.

O índice de acurácia global (*global accuracy* em inglês), dado pela razão entre a quantidade de classificações bem-sucedidas e a totalidade das classificações (normalmente dado em um valor de porcentagem), possui restrições quando aplicado a problemas em que estão disponíveis quantidades muito diferentes de exemplos de cada classe. Para ilustrar o problema dessa abordagem, consideremos alguns cenários que possam gerar conjuntos de dados cuja proporção de exemplos de cada classe seja de 9 para 1:

- Para cada 9 produtos em perfeito estado, 1 com defeito de fabricação.
- Para cada 9 carros dentro do limite de velocidade, 1 excede o limite.
- Para cada 9 batidas cardíacas normais, 1 é ectópica.

Em um conjunto com esse desequilíbrio, um modelo classificador cuja resposta esteja fixa na classe majoritária, ainda assim, acertaria 90% de suas previsões, o que poderia ser erroneamente considerado um resultado aceitável ou até bom. No entanto, na grande maioria das vezes, a real dificuldade está na identificação da classe minoritária.

Aplicações com sinais biomédicos frequentemente se encaixam nesse perfil, uma vez que normalmente há um número maior de pacientes saudáveis do que pacientes com algum tipo de anomalia. Mesmo um paciente com algum problema pode apresentar comportamento normal em, digamos, 90% do tempo. A classificação de batidas cardíacas é um exemplo dessa situação: o banco de dados MIT-BIH-AR possui mais de 80% de batidas do tipo normal, com o restante dividido entre todas as demais classes. Nesse cenário, a classificação de batidas ectópicas como normais poderia levar ao abandono de um tratamento vital para a recuperação do paciente.

A avaliação do desempenho do modelo classificador, portanto, deve ser realizada a partir dos índices estatísticos recomendados pela AAMI (ANSI/AAMI, 1998) de Sensibili-

dade (Se) e Preditividade Positiva (+P), em conjunto com a medida da acurácia global (Acc, de *accuracy*), que perde um pouco de sua importância mas ainda é desejável por sua abrangência. O cálculo desses índices possibilita a comparação do resultado com diversos trabalhos importantes, como os de Chazal, O’Dwyer e Reilly (2004), Llamedo e Martínez (2011), Ye, Kumar e Coimbra (2012), Zhang et al. (2014) e Chen et al. (2017).

Além disso, a fim de detalhar os resultados obtidos para cada classe e prover informação sobre como cada uma delas é percebida pelo classificador, uma “matriz de confusão” (TING, 2010) é elaborada após cada teste. Seu nome vem do fato de que essa representação torna mais clara a maneira como um modelo classificador “confunde” as classes, ou seja, tem dificuldades em diferenciá-las. Neste tipo de tabela, as linhas representam quantidades reais de instâncias de uma determinada classe, enquanto as colunas representam a quantidade de vezes que o classificador obteve uma determinada classe como resposta. Todas as classificações corretas se encontram na diagonal principal da matriz, que representa as oportunidades em que a previsão coincide com a classe real. A Tabela 4 apresenta um exemplo de matriz de confusão elaborada para o problema de classificação de batidas.

Tabela 4: Exemplo de matriz de confusão.

	n	s	v	f	q
N	38444	1904	303	3509	98
S	173	1395	252	16	1
V	117	321	2504	176	103
F	33	1	7	347	0
Q	4	0	3	0	0

Os índices de Sensibilidade e Preditividade Positiva são calculados para cada uma das classes, baseados em quatro quantidades obtidas a partir da matriz de confusão:

- **Verdadeiros Positivos** (TP de *true positive*), de batidas corretamente detectadas, quando a classificação coincide com a classe desejada;
- **Falsos Negativos** (FN de *false negative*), de batidas não detectadas, quando o classificador deveria retornar a classe desejada, mas acaba classificando de maneira diferente;
- **Verdadeiros Negativos** (TN de *true negative*), de batidas corretamente não detectadas, quando o classificador corretamente não classifica uma entrada como a classe desejada;
- **Falsos Positivos** (FP de *false positive*), de batidas incorretamente detectadas, quando o classificador retorna uma determinada classe erroneamente.

As equações 4.21 e 4.22 são usadas para o cálculo dos índices.

$$Se = \frac{TP}{(TP + FN)} * 100 \quad (4.21)$$

$$+P = \frac{TP}{(TP + FP)} * 100 \quad (4.22)$$

A Figura 28, adaptada de Chazal, O'Dwyer e Reilly (2004), mostra como são obtidos os parâmetros TP, FP, TN e FN para cada uma das classes, assim como a acurácia global, de acordo com as recomendações da AAMI. É interessante notar que os cálculos listados em (a) não penalizam o classificador pela classificação errada de batidas ectópicas ventriculares (VEB) nas classes de fusão (F) e inclassificáveis (Q), que não são contabilizadas como falsos positivos. Similarmente, os cálculos em (b) não penalizam a classificação errada de batidas inclassificáveis (Q) em batidas ectópicas supraventriculares (SVEB).

	(a)					(b)					(c)							
	n	s	v	f	q		n	s	v	f	q		n	s	v	f	q	sum
N	Nn	Ns	Nv	Nf	Nq	N	Nn	Ns	Nv	Nf	Nq	N	Nn	Ns	Nv	Nf	Nq	ΣN
S	Sn	Ss	Sv	Sf	Sq	S	Sn	Ss	Sv	Sf	Sq	S	Sn	Ss	Sv	Sf	Sq	ΣS
V	Vn	Vs	Vv	Vf	Vq	V	Vn	Vs	Vv	Vf	Vq	V	Vn	Vs	Vv	Vf	Vq	ΣV
F	Fn	Fs	Fv	Ff	Fq	F	Fn	Fs	Fv	Ff	Fq	F	Fn	Fs	Fv	Ff	Fq	ΣF
Q	Qn	Qs	Qv	Qf	Qq	Q	Qn	Qs	Qv	Qf	Qq	Q	Qn	Qs	Qv	Qf	Qq	ΣQ
																		Σ

$TN_v = Nn + Ns + Nf + Nq + Sn$ $+ Ss + Sf + Sq + Fn + Fs + Ff$ $+ Fq + Qn + Qs + Qf + Qq$ $FN_v = Vn + Vs + Vf + Vq$ $TP_v = Vv$ $FP_v = Nv + Sv$ $VEB\ Se = TP_v / (TP_v + FN_v)$ $VEB\ +P = TP_v / (TP_v + FP_v)$	$TN_s = Nn + Nv + Nf + Nq + Vn$ $+ Vv + Vf + Vq + Fn + Fv + Ff$ $+ Fq + Qn + Qv + Qf + Qq$ $FN_s = Sn + Sv + Sf + Sq$ $TP_s = Ss$ $FP_s = Ns + Vs + Fs$ $SVEB\ Se = TP_s / (TP_s + FN_s)$ $SVEB\ +P = TP_s / (TP_s + FP_s)$	$TP_N = Nn$ $TP_V = Vv$ $TP_S = Ss$ $TP_F = Ff$ $TP_Q = Qq$ $F\ Se: TP_F / \Sigma F,$ $Q\ Se: TP_Q / \Sigma Q$ $Acc: (TP_N + TP_S + TP_V + TP_F + TP_Q) / \Sigma$
--	---	---

Figura 28: Cálculo de parâmetros TP, FP, TN e FN segunda a AAMI.

Sensibilidade e Preditividade Positiva são também conhecidos na área de reconhecimento de padrões por revocação (*recall*) e precisão (*precision*), respectivamente, e são importantes para a determinação da relevância do desempenho de um sistema de classificação. Suponhamos, por exemplo, que exista um classificador que realize o reconhecimento de imagens de animais. Durante uma tarefa, o classificador identifica sete cães em uma cena contendo nove cães e alguns gatos. Se quatro das identificações forem realmente cachorros, mas três forem gatos, a precisão (+P) do modelo é 4/7, enquanto a revocação (Se) é de 4/9. Portanto, podemos dizer que a precisão pode ser traduzida como uma

medida da qualidade dos resultados obtidos, enquanto a revocação é uma medida de sua completude. Em termos mais simples, um sistema com alto valor preditivo positivo retorna mais valores relevantes que irrelevantes, enquanto um sistema com alta sensibilidade retorna a maioria dos resultados relevantes.

Neste trabalho, valores altos para a sensibilidade indicam que a maioria das instâncias de uma determinada classe presentes no banco de dados foi identificada e classificada corretamente, enquanto altos valores de preditividade positiva nos mostram que, das vezes que um classificador identificou um padrão como sendo de uma determinada classe, ele acertou na maioria das vezes.

5 Testes e Resultados

Para a realização de testes e análise de desempenho foram seguidas as recomendações da AAMI (ANSI/AAMI, 1998) para tipos de batidas e apresentação de resultados, visando uma comparação adequada com outros trabalhos que compõem o estado da arte nesse campo de estudo. Além disso, para todos os testes, foi utilizada a base de dados MIT-BIH *Arrhythmia* (MARK; MOODY, 1997), cujos 44 registros são divididos de acordo com o método “orientado a sujeitos” proposto por Chazal, O’Dwyer e Reilly (2004), onde 22 registros são utilizados para treinamento do modelo e 22 para teste, cada um com aproximadamente o mesmo número de batidas de cada tipo, como definido na Seção 4.2.

Para os testes, foi utilizada a SVM com *kernel* do tipo RBF (*Radial Basis Function*), definida na Seção 4.6. Este tipo de *kernel* é o mais indicado para classificação utilizando SVM, devido a algumas vantagens, como sua capacidade de obter bons resultados mesmo quando a relação entre rótulos de classes e atributos não é linear (HSU et al., 2003). Além disso, na biblioteca LIBSVM, o *kernel* RBF possui poucos parâmetros cujos valores precisam ser definidos (menos que o *kernel* polinomial, por exemplo), o que diminui a complexidade do modelo e simplifica a busca pela melhor configuração.

Os parâmetros da LIBSVM (C e g) foram selecionados experimentalmente, utilizando validação cruzada *10-fold* no conjunto de dados de treinamento, seguida de um ajuste fino empírico. A validação cruzada *10-fold* consiste em dividir um dado conjunto em dez subconjuntos mutuamente exclusivos de mesmo tamanho, onde 9 deles são utilizados para treino e um para teste, em um processo repetido 10 vezes que resulta em um valor médio de acurácia. Para o conjunto de parâmetros de melhor resultado obtido no processo de validação cruzada, novos testes foram realizados no conjunto de testes propriamente dito, visando um ajuste fino e obtenção do melhor desempenho.

5.1 Testes Preliminares

A fase inicial de testes foi dedicada à avaliação do desempenho das técnicas de segmentação dinâmica e normalização de intervalos entre batidas, descritas no Capítulo 4, e de sua interação com as características escolhidas para representar o sinal, inclusive os parâmetros de Hjorth. Com essa finalidade, os testes seguiram um curso progressivo, iniciando de maneira mais simples e incorporando gradativamente as técnicas que viriam a ser importantes no modelo definitivo. A cada um dos passos, é discutido o efeito da inclusão da técnica no modelo final. Esses testes foram realizados com os dados de apenas uma derivação do sinal de ECG, a MLII (derivação de membros II modificada, ou *modified limb lead II* em inglês), geralmente presente no canal A do banco de dados.

O primeiro dos testes (Seção 5.1.0.1) utiliza a técnica de segmentação de batidas mais trivial, a partir de valores fixos, seguido de um teste (Seção 5.1.0.2) que muda a estratégia de segmentação para a estratégia dinâmica, proposta neste trabalho, comparando seus resultados. Finalmente, é acrescentada ao modelo com segmentação dinâmica a técnica de normalização de intervalos R-R, visando a realização de um teste (Seção 5.1.0.3) que leve em consideração a taxa cardíaca atual do paciente. A cada passo, é destacado o benefício trazido pela técnica acrescentada com relação ao teste anterior.

5.1.0.1 Segmentação com Comprimento Fixo

O primeiro teste consiste na utilização do modelo mais simples possível para o aproveitamento das características extraídas. Nele, optou-se pela delimitação e segmentação das batidas a partir de valores fixos, como descrito em parte da bibliografia (CHRISTOV et al., 2006; YE; KUMAR; COIMBRA, 2012; CHEN et al., 2017). Para isso, foi tomado um valor de comprimento fixo de 256 amostras para cada batida, sendo 90 delas antes do ponto fiducial e 165 após o mesmo ponto, resultando em um tempo aproximado de 711 milissegundos por batida, independentemente da condição do paciente no momento. Os comprimentos dos segmentos I, II e III também foram definidos com valores fixos, dados pela proporção de 25-25-50% entre onda P, complexo QRS e onda T, respectivamente, e resultando em segmentos de 64, 64 e 128 amostras.

Foram extraídas 21 características de cada batida cardíaca presente nos registros do banco de dados. Nesta etapa, não foi aplicada nenhuma forma de normalização às características extraídas. São elas:

- 3 características extraídas de **intervalos R-R**: Pos-RR, Pre-RR e Recent-RR.

- 9 dados de **amplitude**, 3 para cada segmento: amplitude máxima, mínima e média.
- 9 parâmetros de **Hjorth**, 3 por segmento: atividade, mobilidade e complexidade.

Os melhores resultados obtidos para essa configuração estão dispostos na Tabela 5 através da matriz de confusão e Tabela 6, com indicadores de desempenho. Os valores encontrados para os parâmetros C e g da LIBSVM com *kernel* RBF que possibilitaram o melhor resultado foram, respectivamente, 2048 e 0,5.

Tabela 5: Matriz confusão - Segmentação de comprimento fixo.

	N	S	V	F	Q
N	36674	241	3623	3498	4
S	1388	133	87	221	0
V	535	78	2566	28	0
F	32	2	354	0	0
Q	4	0	3	0	0

Tabela 6: Índices de desempenho - Segmentação de comprimento fixo.

	Se (%)	$+P$ (%)
Classe N	83,274	94,929
Classe S	7,272	29,295
Classe V	80,012	40,886
Classe F	0	0
Classe Q	0	0
Acurácia Global	79,588 %	

O modelo apresentou acurácia global de 79,6%, com bons valores de sensibilidade para classes N e V, de 83% e 80%, próximos aos obtidos por Chazal, O’Dwyer e Reilly (2004) e Llamedo e Martínez (2011). No entanto, a classificação falhou na identificação de batidas supraventriculares em mais de 90% dos casos (7% de acerto), e apresentou desempenho abaixo da média dos outros trabalhos utilizados como referência.

5.1.0.2 Segmentação Dinâmica

Visando melhorar os índices de desempenho e avaliar a contribuição da nova abordagem de segmentação desenvolvida, foi acrescentada ao modelo a técnica de “segmentação dinâmica”, descrita na Seção 4.4, que substitui a segmentação com valores fixos. A utilização desta nova abordagem tem como objetivo aumentar a qualidade das características extraídas de cada batida cardíaca presente no sinal, isolando cada uma delas das demais

com maior exatidão e adaptando-se melhor à taxa cardíaca atual do paciente. Essa técnica provê condições para que as características extraídas contenham informações específicas apenas sobre uma determinada batida de interesse, livre da interferência de batidas vizinhas. Para esse teste, as mesmas características do teste anterior foram utilizadas, ainda sem nenhum tipo de normalização nas características dinâmicas, de intervalos R-R.

Os melhores resultados entre os testes realizados com essa nova configuração foram obtidos com $C = 10000$ e $g = 0,05$ para a SVM de *kernel* RBF, e estão dispostos nas Tabelas 7 e 8.

Tabela 7: Matriz de confusão - Segmentação dinâmica.

	N	S	V	F	Q
N	42578	54	362	1036	10
S	1421	311	77	20	0
V	373	71	2758	1	4
F	242	0	146	0	0
Q	3	0	3	0	1

Tabela 8: Índices de desempenho - Segmentação dinâmica.

	Se (%)	$+P$ (%)
Classe N	96,680	95,430
Classe S	17,004	71,330
Classe V	85,999	86,268
Classe F	0	0
Classe Q	14,286	6,667
Acurácia Global	92,272 %	

A inclusão da segmentação dinâmica no processamento das batidas cardíacas melhorou o desempenho geral do modelo, que passou a apresentar acurácia global de 92,3% (uma melhoria de mais de 15% quando comparada aos 79,6% obtidos no teste anterior). Também os índices de desempenho para as classes N, S, V e Q apresentaram evolução, de maneira que as sensibilidades das classes N e V alcançaram os valores de 96,6% e 86%, respectivamente. Há também um aumento nos valores de preditividade positiva para as classes N, S e V, o que representa uma diminuição na quantidade de falsos positivos gerados pelo classificador, especialmente para classes de batidas ectópicas. Esse aumento de preditividade positiva aumenta, também, a confiabilidade de classificações de batidas ectópicas, que passam a ser acertadas na maioria das vezes.

5.1.0.3 Características Normalizadas

No terceiro teste, último da fase preliminar, as três características dinâmicas, obtidas a partir de intervalos R-R (Pre-RR, Pos-RR e Recent-RR), são condensadas em apenas dois valores “normalizados” (Pre-RR-Norm e Pos-RR-Norm), calculados pelas equações 4.2 e 4.3, descritas no Capítulo 4. A normalização dos intervalos visa tornar mais evidente a relação entre a duração da batida atual e a duração das batidas imediatamente anteriores, indicando possíveis mudanças de ritmo. Além disso, é acrescentada ao modelo a característica Diff-RR-Norm, igualmente normalizada, a fim de auxiliar, também, na detecção de mudanças instantâneas no ritmo cardíaco, que podem indicar a presença de batidas prematuras ou de escape.

Neste teste, o modelo classificador é, também, alimentado por 21 características extraídas de uma única derivação do sinal (MLII) – 3 de intervalos, 9 de amplitude e 9 de Hjorth – e difere do teste anterior apenas na construção das características dinâmicas.

Os melhores resultados para esta configuração estão nas Tabelas 9 e 10, com $C = 60000$ e $g = 0,001$ para a SVM de *kernel* RBF. Com relação aos testes anteriores, há uma melhoria no desempenho geral do modelo, com acurácia global de 94,3%, um aumento na sensibilidade das classes N e S, que atingem os valores de 98,5% e 34%, e a manutenção de uma sensibilidade superior a 80% para a classe V. Os valores de preditividade positiva se mantêm próximos aos obtidos no teste anterior, já com a segmentação dinâmica.

Tabela 9: Matriz confusão - Intervalos R-R normalizados.

	N	S	V	F	Q
N	43372	236	266	164	2
S	1175	622	29	3	0
V	421	116	2667	2	1
F	323	0	64	1	0
Q	3	0	3	1	0

Tabela 10: Índices de desempenho - Intervalos R-R normalizados.

	Se (%)	$+P$ (%)
Classe N	98,483	95,757
Classe S	34,008	63,860
Classe V	83,162	90,041
Classe F	0,258	0,585
Classe Q	0	0
Acurácia Global	94,322 %	

5.1.1 Comparação com Outros Trabalhos

Os melhores resultados obtidos, ou seja, os resultados do terceiro teste, foram comparados com cinco outros trabalhos da área, que representam o estado da arte no campo: Chazal, O’Dwyer e Reilly (2004), Llamedo e Martínez (2011), Ye, Kumar e Coimbra (2012), Zhang et al. (2014) e Chen et al. (2017). Todos esses trabalhos utilizam a mesma base de dados, métricas de desempenho e divisão de dados orientada a sujeitos utilizadas neste trabalho. Além disso, todos eles utilizam as anotações do banco de dados para detecção de complexos QRS e localização de batidas no sinal de ECG, o que torna a comparação justa e válida. A Tabela 11 mostra um resumo técnico desses trabalhos, com relação a características extraídas, modelo classificador utilizado e técnica de segmentação.

Tabela 11: Resumo técnico dos trabalhos utilizados para comparação.

	Segmentação	Características	Classificador
Chazal (2004)	<i>ecgpuwave</i>	Morfológicas + R-R	Discr. Linear
Llamedo (2011)	<i>Wavelets</i>	R-R + <i>Wavelets</i> + VCG	Discr. Linear
Ye (2012)	Valores Fixos	R-R + <i>Wavelets</i> + ICA	SVM
Zhang (2014)	<i>ecgpuwave</i>	Morfológicas + R-R	SVM
Chen (2017)	Valores Fixos	R-R + Matrizes Projeção	SVM

É importante salientar que os cinco trabalhos utilizados como referência apresentam etapas cujo custo computacional é superior ao da etapa correspondente no modelo proposto, seja com relação à segmentação de batidas, onde Chazal, O’Dwyer e Reilly (2004) e Zhang et al. (2014) utilizam o delineador de sinal *ecgpuwave*, ou à etapa de extração de características, onde Llamedo e Martínez (2011) e Ye, Kumar e Coimbra (2012) fazem uso das transformadas *wavelet*, e Chen et al. (2017) utilizam matrizes de projeção (BASILEVSKY, 2013).

A Tabela 12 contém índices de desempenho do modelo proposto e desses outros trabalhos, com todos os valores expressos como porcentagem. A classe Q foi deixada de fora devido à sua pequena representatividade no banco de dados MIT-BIH *Arrhythmia*. Os valores mais altos para cada índice encontram-se destacados em verde, enquanto a cor vermelha realça os valores mais baixos. A análise dessa tabela mostra que o modelo proposto apresenta desempenho compatível com os de outros modelos em quase todos os índices, inclusive com alguns resultados ligeiramente superiores com relação à acurácia global e sensibilidade da classe N. O valor obtido para a preditividade positiva da classe S é bastante superior aos demais, indicando que apesar de ter dificuldades para identificar instâncias desta classe (sensibilidade de 34%, superior apenas a Chen et al.

(2017)), a maioria das instâncias classificadas como S são realmente batidas ectópicas supraventriculares, o que é uma vantagem.

Tabela 12: Comparação de resultados obtidos nos testes preliminares com outros estudos.

	Chazal	Llamedo	Ye	Zhang	Chen	Este Trabalho
Acc.	85,9%	78,0%	86,4%	88,3%	93,1%	94,3%
N Se	86,9%	77,6%	88,5%	88,9%	98,4%	98,5%
N +P	99,2%	99,5%	97,5%	99,0%	95,4%	95,8%
S Se	75,9%	76,5%	60,8%	79,1%	29,5%	34,0%
S +P	38,5%	41,3%	52,3%	36,0%	38,4%	63,9%
V Se	77,7%	82,9%	81,5%	85,5%	70,8%	83,2%
V +P	81,9%	88,1%	63,1%	93,0%	86,0%	90,0%
F Se	89,4%	95,4%	19,6%	93,8%	0,0%	0,3%
F +P	8,6%	4,2%	2,5%	13,7%	0,0%	0,6%

Uma desvantagem do modelo é seu baixo desempenho com relação às batidas da classe F, de fusão entre batida ectópica ventricular e batida normal. Segundo Das (2015), este tipo de batida é difícil de distinguir das batidas normais, uma vez que sua morfologia e intervalos R-R se assemelham fortemente às dessas últimas. Outros trabalhos importantes, como Ye, Kumar e Coimbra (2012) e Chen et al. (2017) também apresentaram índices baixos para esse tipo de batida, e os relacionam à baixa representatividade dos dados deste tipo no banco de dados MIT-BIH *Arrhythmia* (menos de 1%) e à sua similaridade com batidas normais.

Um baixo desempenho com relação à sensibilidade da classe S também é notado, mas um dos fatores que contribuem para este resultado, segundo Ye, Kumar e Coimbra (2012) e Chen et al. (2017), é o forte desequilíbrio do banco de dados com relação à quantidade de batidas de cada tipo: há uma proporção muito maior de batidas dos tipos N e V e menor de batidas do tipo S. Poucos pacientes apresentaram batidas cardíacas do tipo S, o que dificulta o processo de generalização do classificador. A SVM, durante seu treinamento, pode acabar tomando características pessoais desses poucos pacientes do conjunto de treinamento como características gerais de batidas do tipo S, resultando em um desempenho pouco expressivo quando confrontada com dados de outros pacientes.

Por fim, vale a pena notar também que, a cada passo dado nos testes preliminares, houve uma melhoria significativa nos índices de desempenho ou, no mínimo, sua manutenção aproximada. Este fato é ilustrado através da Figura 29, onde os gráficos mostram a evolução dos índices de sensibilidade (*Se*) e preditividade positiva (*+P*) à medida que os testes (1, 2 e 3) foram executados.

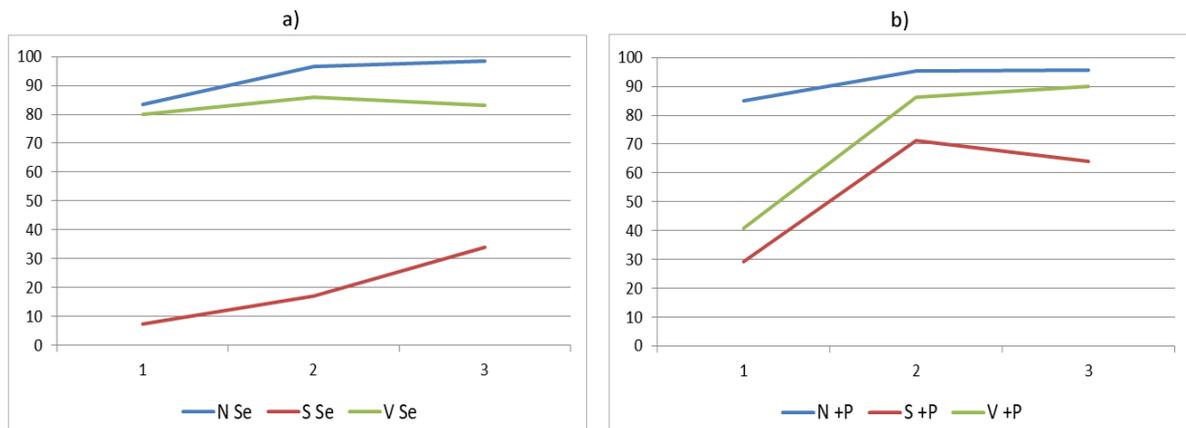


Figura 29: Evolução dos índices de desempenho a cada teste realizado na fase preliminar. a) Sensibilidade (Se); b) Preditividade Positiva (+P).

5.2 Teste com Duas Derivações

Todos os trechos de ECG presentes no banco de dados MIT-BIH foram registrados utilizando-se dois canais, A e B, cada um deles com sinais referentes a uma derivação diferente, geralmente MLII e V1. Os testes realizados na fase preliminar contaram apenas com dados de uma única derivação, mas estudos importantes da área indicam que a utilização das informações presentes nos dois canais pode beneficiar o modelo, complementando-se e apresentando um panorama mais completo da condição cardíaca atual do paciente, como é o caso dos trabalhos de Chazal, O'Dwyer e Reilly (2004) e Ye, Kumar e Coimbra (2012).

A utilização das duas derivações oferece diferentes “pontos de vista” para o modelo classificador, ou seja, observações de um mesmo evento realizadas de ângulos distintos, que podem se complementar e serem utilizadas em conjunto para uma tomada de decisão final. Essa seção apresenta os resultados de testes realizados a partir de dados extraídos dos dois canais presentes no banco de dados. Os novos vetores de características passam a ser compostos pelas mesmas três características de intervalos R-R utilizadas na Seção 5.1.0.3 (Pre-RR-Norm, Pos-RR-Norm e Diff-RR-Norm), que são únicas e não variam de acordo com a derivação, em conjunto com as demais características, de amplitude e Hjorth, calculadas para cada segmento em cada derivação, somando 39 características:

- **Amplitude:** Valores máximo, mínimo e médio, calculados para cada um dos três segmentos da batida em cada uma das duas derivações, somando 18 ($3 \times 3 \times 2$).
- **Parâmetros de Hjorth:** Atividade, mobilidade e complexidade de cada segmento de cada derivação, totalizando também 18 características ($3 \times 3 \times 2$).

A finalidade dessa implementação é melhorar, em particular, os índices de desempenho relacionados à classificação de batidas ectópicas supraventriculares (S) e de fusão (F), ambas muito semelhantes às batidas normais quando observadas apenas através da derivação de membros II modificada, a MLII (canal A). Os melhores resultados obtidos para a nova configuração com duas derivações estão expostos nas Tabelas 13 e 14, e foram obtidos a partir da SVM de *kernel* RBF com valores dos parâmetros C e g iguais a 15000 e 0,002. Para os testes dessa fase, também foi utilizada a técnica de segmentação dinâmica.

Tabela 13: Matriz Confusão - Duas derivações e 39 características.

	N	S	V	F	Q
N	40669	367	828	2172	4
S	852	930	34	4	9
V	413	83	2536	173	2
F	51	0	7	330	0
Q	6	0	1	0	0

Tabela 14: Índices de Desempenho - Duas derivações e 39 características.

	Se (%)	$+P$ (%)
Classe N	92,346	96,852
Classe S	50,847	67,391
Classe V	79,077	74,632
Classe F	85,052	12,318
Classe Q	0	0
Acurácia Global	89,881 %	

Os resultados mostram uma melhoria significativa com relação ao modelo com apenas uma derivação no que diz respeito à sensibilidade da classe S, que vai de 34% para 50.8%, o que representa um aumento de quase 50% no número de batidas dessa classe corretamente identificadas e classificadas. O novo modelo também mantém a vantagem de um valor alto de preditividade positiva para a classe S, de 67,4%, mais de 27% maior do que o obtido por Ye, Kumar e Coimbra (2012), o segundo melhor no quadro de comparação. Além disso, o novo modelo com duas derivações obtém resultados melhores do que o de apenas uma derivação e os dos modelos propostos por Ye, Kumar e Coimbra (2012) e Chen et al. (2017) com relação à sensibilidade da classe F, indo de 0,3% para 85,1%, contando também com uma melhoria na preditividade positiva da mesma classe que a aproxima do melhor resultado (ZHANG et al., 2014).

5.2.1 Algumas Observações

A Tabela 15 completa os dados da Tabela 12 com os resultados obtidos para o modelo com duas derivações. Nela, a coluna “Teste 1” se refere ao teste de melhor desempenho realizado com apenas uma derivação do sinal de ECG (Seção 5.1.0.3) e “Teste 2” ao teste com duas derivações. Os valores mais altos para cada índice encontram-se novamente destacados em verde, enquanto a cor vermelha realça os valores mais baixos.

Tabela 15: Comparação de índices de desempenho com outros estudos.

	Chazal	Llamedo	Ye	Zhang	Chen	Teste 1	Teste 2
Acc.	85,9%	78,0%	86,4%	88,3%	93,1%	94,3%	89,9%
N Se	86,9%	77,6%	88,5%	88,9%	98,4%	98,5%	92,3%
N +P	99,2%	99,5%	97,5%	99,0%	95,4%	95,8%	96,9%
S Se	75,9%	76,5%	60,8%	79,1%	29,5%	34,0%	50,8%
S +P	38,5%	41,3%	52,3%	36,0%	38,4%	63,9%	67,4%
V Se	77,7%	82,9%	81,5%	85,5%	70,8%	83,2%	79,1%
V +P	81,9%	88,1%	63,1%	93,0%	86,0%	90,0%	74,6%
F Se	89,4%	95,4%	19,6%	93,8%	0,0%	0,3%	85,1%
F +P	8,6%	4,2%	2,5%	13,7%	0,0%	0,6%	12,3%

Há uma relação custo-benefício observada nos índices de desempenho dos modelos analisados. Neste último teste, o modelo com duas derivações obteve valores mais altos para os índices relacionados às classes S e F, em troca de uma diminuição na sensibilidade da classe V, que foi de 83,2% para 79,1%, na preditividade positiva para a mesma classe, que caiu de 90% para 74%, e na sensibilidade da classe N, que caiu de 98,5% para 92,3%.

Com a melhor caracterização dos padrões de batidas, propiciada pelo uso das duas derivações, o sistema passou a reconhecer batidas supraventriculares e de fusão com mais eficiência, mas também passou a classificar batidas normais como outros tipos com maior frequência (Tabela 13). Este fato explica seu desempenho mais baixo quando comparado ao modelo de apenas uma derivação e o trabalho de Chen et al. (2017) com respeito à acurácia global, uma vez que esses modelos conseguiram distinguir batidas da classe N das demais em mais de 98% das vezes. Como batidas desse tipo formam mais de 80% do banco de dados, um aumento no seu índice de sensibilidade representa um impacto grande na acurácia global. De acordo com Ye, Kumar e Coimbra (2012), batidas ectópicas são mais discerníveis que batidas normais no sinal da derivação do canal B, o que pode ser a razão da melhora nos índices das classes S e F, e da diminuição na sensibilidade relativa à classe N.

Os resultados obtidos nesse último teste são melhores do que 4 dos 5 trabalhos utiliza-

dos como referência em 3 índices: acurácia global, sensibilidade da classe N e preditividade positiva da classe S. Para 5 das outras 6 métricas, os resultados obtidos pelo modelo proposto são muito similares aos demais. Se utilizarmos o trabalho de Chen et al. (2017) como referência, o modelo proposto possui índices mais baixos com relação à acurácia global e sensibilidade da classe N, mas o supera em outros 6 índices, incluindo a preditividade positiva da própria classe N. Na prática clínica, a preditividade positiva da classe N é uma métrica importante, uma vez que diagnosticar erroneamente um paciente como uma pessoa saudável pode atrasar a terapia e agravar um possível problema existente (ZHANG et al., 2014).

Portanto, existe um equilíbrio almejado para os índices de desempenho: é desejável manter um alto valor de preditividade positiva da classe N ao mesmo tempo em que são buscadas altas sensibilidades para classes de batidas ectópicas S e V. Uma análise dos resultados aponta na direção de que uma melhoria na sensibilidade da classe N é frequentemente acompanhada por uma degradação das sensibilidades das classes S e V (CHEN et al., 2017). O sistema com dados de duas derivações proposto contribui nesse sentido, uma vez que mantém a maioria dos índices com valores altos - inclusive a acurácia global, maior do que 4 dos trabalhos utilizados para comparação.

A estratégia de segmentação também mostrou-se muito importante para o desempenho do modelo, especialmente na detecção e classificação de batidas ectópicas supraventriculares. Batidas desse tipo são caracterizadas por ondas P levemente anormais e pela taxa cardíaca associada a elas, uma vez que normalmente aparecem de forma prematura. A técnica de segmentação dinâmica provê informação mais acurada sobre o comprimento das batidas, o que contribui na detecção desse tipo de batida. Além disso, sua característica minimiza a presença de dados indesejados de batidas adjacentes e potencializa a utilidade dos parâmetros de Hjorth, que são bastante sensíveis a ruídos.

Para cada um dos testes realizados, versões alternativas utilizando segmentação de valores fixos também foram testadas. A utilização da segmentação dinâmica aumenta os valores de preditividade positiva para todas as classes, aproximadamente mantém os níveis de sensibilidade para classes N e V, e aumenta a sensibilidade da classe S em todos os casos. A Tabela 16 mostra uma comparação entre os melhores resultados obtidos para cada um dos dois tipos de segmentação em testes envolvendo os sinais das duas derivações, com características de intervalos R-R normalizadas. Nesse caso, o uso da segmentação dinâmica também levou a um aumento significativo nos dois índices de desempenho da classe F.

Tabela 16: Índices de desempenho - Estratégias de Segmentação.

	Seg. Valores Fixos		Seg. Dinâmica	
	Se (%)	$+P$ (%)	Se (%)	$+P$ (%)
Classe N	89,641	94,860	92,346	96,852
Classe S	28,595	52,722	50,847	67,391
Classe V	79,981	55,992	79,077	74,632
Classe F	27,062	4,656	85,052	12,318
Acurácia Global	86,255 %		89,881 %	

5.3 O Desbalanceamento do Banco de Dados

O banco de dados MIT-BIH-AR é composto por cerca de 100 mil batidas cardíacas, divididas em 16 tipos diferentes que podem ser reagrupados nas 5 classes propostas pela AAMI. No entanto, não há uma proporção equilibrada de batidas de cada tipo, o que pode ser explicado pelo fato natural de que batidas normais ocorrem com frequência muito maior que as de batidas ectópicas. De todo o banco, 82,7% das batidas são do tipo normal (N), enquanto 2,5% são de batidas ectópicas supraventriculares (S) e 6,6% são ectópicas ventriculares (V) (CHAZAL; O'DWYER; REILLY, 2004). Vários autores, como Ye, Kumar e Coimbra (2012) e Chen et al. (2017), destacam esse problema como possível explicação para desempenhos inferiores em classes menos representadas no banco de dados. Zhang et al. (2014) também destaca que um conjunto de dados de treinamento desbalanceado pode ser motivo para perda de sensibilidade, especialmente para as classes S e F.

Segundo Liu, Wu e Zhou (2009), o desequilíbrio entre classes tem um sério impacto no desempenho dos classificadores. Os algoritmos de aprendizagem que não consideram essa condição tendem a ser dominados pela classe majoritária e ignorar as classes minoritárias. Visando solucionar essa questão, testes adicionais foram projetados. Neles, uma técnica de subamostragem (*undersampling*, em inglês) foi aplicada às amostras de batidas da classe N do conjunto de dados de treinamento (CD1). Essa técnica consiste em selecionar aleatoriamente um subconjunto das amostras da classe dominante, de maneira a diminuir sua influência e, conseqüentemente, aumentar a relevância das demais classes durante a execução do algoritmo classificador (neste caso, na construção do hiperplano da SVM).

Drummond, Holte et al. (2003) mostram, em seu trabalho, que a técnica de subamostragem da classe majoritária é uma estratégia eficiente para lidar com problemas de desbalanceamento, diferente da superamostragem das classes minoritárias (chamada de *oversampling*, em inglês), que é pouco efetiva e não produz bons resultados. A supera-

mostragem consiste na repetição das amostras ou criação de amostras artificiais para as classes minoritárias (CHAWLA et al., 2002).

Neste trabalho, a técnica de subamostragem utilizada é simples. Antes da execução do treinamento, todos os dados passam por um algoritmo de pré-processamento, que seleciona aleatoriamente um subconjunto de dados da classe majoritária (classe N), cujo tamanho é escolhido pelo usuário, e os combina com a totalidade dos dados das classes minoritárias em um único conjunto de treinamento. A Figura 30 ilustra esse processo. Os índices de desempenho são medidos a partir da aplicação do modelo nos mesmos conjuntos de testes utilizados nas etapas anteriores, sem mudança, ainda que também estejam desbalanceados. A quantidade de batidas do tipo N no conjunto desbalanceado é de aproximadamente 45 mil, enquanto as batidas ectópicas S e V são representadas por 1 e 4 mil amostras, respectivamente, e batidas de fusão por apenas cerca de 500 amostras. A escolha do tamanho do subconjunto de batidas do tipo N foi realizada empiricamente, ou seja, através da utilização de vários valores e análise do melhor desempenho.

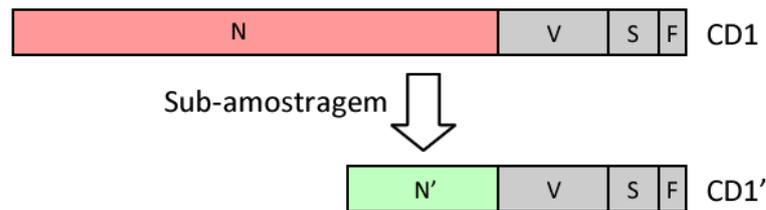


Figura 30: Técnica de subamostragem para balanceamento do banco de dados.

Os testes realizados foram muito semelhantes aos da Seção 5.2, a partir do sinal de duas derivações, com 39 características extraídas servindo de entrada para a SVM. A única diferença é a quantidade de amostras da classe majoritária N. O melhor resultado foi obtido para um subconjunto de 8 mil amostras da classe N, ou seja, cerca de 18% do conjunto inicial, com parâmetros $C = 65000$ e $g = 0,0015$ para a SVM de *kernel* RBF. Os resultados estão nas Tabelas 17 e 18.

Tabela 17: Matriz Confusão - Sub-amostragem.

	N	S	V	F	Q
N	37456	1068	2793	2705	18
S	306	1349	162	4	8
V	161	58	2845	140	3
F	36	4	62	286	0
Q	3	0	3	1	0

Tabela 18: Índices de desempenho - Sub-amostragem.

	Se (%)	$+P$ (%)
Classe N	85,050	98,667
Classe S	73,756	54,417
Classe V	88,712	49,052
Classe F	73,711	9,120
Classe Q	0	0
Acurácia Global	84,881 %	

Os resultados obtidos possuem algumas características interessantes, incluindo um aumento considerável nos índices de sensibilidade das classes de batidas ectópicas supraventriculares, que passam de 50,8% no teste com o conjunto completo para 73,8%, e ventriculares, que passam de 79.1% para 88.7%, o maior entre todos os modelos estudados. Tudo isso, no entanto, vem acompanhado de uma queda no índice de sensibilidade da classe N e índices de preditividade positiva das classes S e V, causadas pelo mesmo motivo: muitas batidas normais passam a ser classificadas como ectópicas, ou seja, há um aumento de falsos positivos. Há também uma queda dos índices relativos à classe F e acurácia global, sendo que este último fortemente impactado pela queda na sensibilidade da classe N, que ainda compõe majoritariamente o conjunto de testes. É importante salientar que, no ambiente clínico, um falso positivo, ainda que indesejado, é preferível a um falso negativo, que poderia levar à interrupção do tratamento de um paciente com condição cardíaca anormal.

5.4 Unindo as Duas Abordagens

Os dois últimos testes apresentaram potencialidades e falhas quando comparados a outros modelos que compõem o estado da arte. Quando utilizada a totalidade de dados disponível para o treinamento (Seção 5.2), o modelo classificador apresentou bons resultados de sensibilidade e preditividade positiva para a maioria das classes, mas falhou na identificação de quase 50% das batidas ectópicas supraventriculares (classe S). Já para o teste com subamostragem (Seção 5.3), o modelo atingiu um nível de desempenho comparável ao dos demais estudos para as classes S e V, às custas de uma diminuição da preditividade positiva das mesmas classes e aumento de falsos alarmes no monitoramento de batidas ectópicas (tanto S quanto V e F).

Para solucionar este problema, foram unidas as duas abordagens em uma estrutura

de classificação em dois passos, ilustrada na Figura 31, na qual:

1. as instâncias do conjunto de testes são classificadas por uma SVM cujo treinamento tenha sido realizado a partir do conjunto de treinamento subamostrado, de acordo com o método descrito na Seção 5.3. Para uma dada instância do conjunto de testes, caso o resultado da classificação seja a classe S, o resultado é definitivo; senão, a mesma instância passa a ser classificada pelo segundo modelo, completo;
2. as instâncias não classificadas como S pelo modelo subamostrado, são classificadas definitivamente pelo modelo completo, treinado com a totalidade dos dados (Seção 5.2). Essa segunda SVM é responsável, principalmente, pela classificação das instâncias de classes N, V e F. No entanto, em algumas ocasiões, podem ser reconhecidas instâncias da classe S, não identificadas pelo modelo anterior.

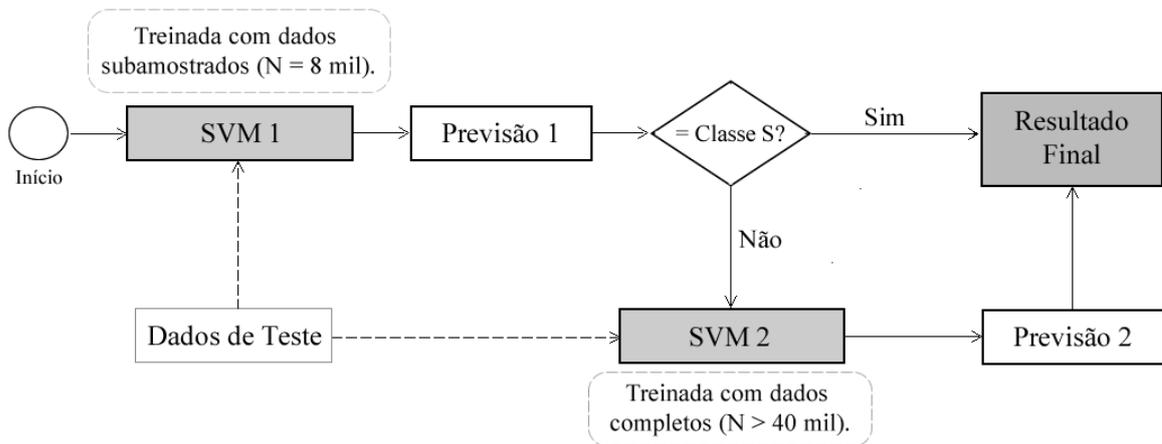


Figura 31: Arquitetura para classificação em dois passos (2-step).

O resultado obtido, exibido nas Tabelas 19 e 20, mostra um desempenho mais equilibrado que o atingido pelos dois modelos separadamente, aliando suas potencialidades e reduzindo as desvantagens. Para o treinamento das duas SVM, todos os parâmetros receberam valores iguais aos utilizados nos testes individuais (Seções 5.2 e 5.3).

Tabela 19: Matriz Confusão - Classificação em dois passos.

	N	S	V	F	Q
N	39949	1092	827	2168	4
S	406	1383	27	4	9
V	397	100	2535	173	2
F	47	4	7	330	0
Q	6	0	1	0	0

Tabela 20: Índices de desempenho - Classificação em dois passos.

	Se (%)	$+P$ (%)
Classe N	90,711	97,902
Classe S	75,615	53,625
Classe V	79,046	74,801
Classe F	85,052	12,336
Classe Q	0	0
Acurácia Global	89,339 %	

Com relação aos resultados obtidos pelo modelo sem subamostragem, este novo modelo em dois passos apresenta um ganho considerável na sensibilidade da classe S, que vai de cerca de 50% para 75,6%, além de um pequeno aumento nos índices de sensibilidade e preditividade positiva da classe de batidas normais (N).

Já com relação ao modelo com subamostragem, são mantidos os índices relativos à classe S, com ganho em praticamente todos os demais índices, exceto a sensibilidade da classe V. O índice de sensibilidade da classe V passa de cerca de 88% para 79%, ainda condizente com os valores obtidos pelos demais estudos utilizados na comparação. Este valor pode ser visto como um custo a ser pago pelo aumento de sua preditividade positiva, que vai de 49% para 74%, representando uma queda significativa na ocorrência de falsos positivos para batidas ectópicas ventriculares. A preditividade positiva da classe S, ainda que menor do que a obtida no teste sem subamostragem, continua sendo mais alta do que a obtida por todos os demais modelos utilizados como comparação (53,6%).

5.5 Observações sobre o Resultado Final

A Tabela 21 é um quadro comparativo, entre os estudos de Chazal, O'Dwyer e Reilly (2004), Llamedo e Martínez (2011), Ye, Kumar e Coimbra (2012), Zhang et al. (2014) e Chen et al. (2017), e os três melhores resultados obtidos neste estudo: com treinamento completo (comp), com subamostragem (sub), e com dois passos (*2-step*). Novamente, as células em verde e vermelho representam, respectivamente, os maiores e menores valores para cada índice.

A tabela destaca o equilíbrio atingido pelo modelo em dois passos, que através de uma mudança simples na arquitetura dos testes, alcança índices comparáveis ou superiores aos demais trabalhos com relação às classes de batidas normais e ectópicas, tanto para os índices de sensibilidade quanto para os de preditividade positiva. Nas três colunas com

dados de testes deste estudo (comp, sub e 2-step), não há células destacadas em vermelho, significando que nenhum resultado foi abaixo de todos os demais. Nesse sentido, conclui-se que a utilização dos parâmetros de Hjorth e outras técnicas propostas neste trabalho apresentaram resultado satisfatório, mesmo com baixa complexidade computacional.

Tabela 21: Comparação final de índices de desempenho com outros estudos.

	Chazal	Llamedo	Ye	Zhang	Chen	Comp	Sub	2-step
Acc.	85,9%	78,0%	86,4%	88,3%	93,1%	89,9%	84,9%	89,3%
N Se	86,9%	77,6%	88,5%	88,9%	98,4%	92,3%	85,1%	90,7%
N +P	99,2%	99,5%	97,5%	99,0%	95,4%	96,9%	98,7%	97,9%
S Se	75,9%	76,5%	60,8%	79,1%	29,5%	50,8%	73,8%	75,6%
S +P	38,5%	41,3%	52,3%	36,0%	38,4%	67,4%	54,4%	53,6%
V Se	77,7%	82,9%	81,5%	85,5%	70,8%	79,1%	88,7%	79,0%
V +P	81,9%	88,1%	63,1%	93,0%	86,0%	74,6%	49,1%	74,8%
F Se	89,4%	95,4%	19,6%	93,8%	0,0%	85,1%	73,7%	85,1%
F +P	8,6%	4,2%	2,5%	13,7%	0,0%	12,3%	9,1%	12,3%

O teste em dois passos é o mais equilibrado entre os três, apresentando bons índices de sensibilidade e preditividade positiva para a classe N, melhores do que 4 dos 5 trabalhos utilizados para comparação. Além disso, o índice de preditividade positiva para a classe S é levemente superior ao maior valor obtido pelos outros cinco trabalhos (53,6%, contra 52,3% de Ye, Kumar e Coimbra (2012)). Todos os demais índices estão muito próximos dos valores mais altos alcançados nos outros estudos, o que comprova seu valor.

Todos os métodos utilizados neste estudo são de baixa complexidade computacional, variando de métodos de complexidade constante $O(1)$ até complexidade linear $O(n)$. Dos cinco outros trabalhos, todos apresentam etapas de complexidade computacional superior a este trabalho, seja com relação à segmentação de batidas ou à extração de características.

Chazal, O'Dwyer e Reilly (2004) e Zhang et al. (2014) utilizam o delineador de sinal *ecgpuwave*, e Llamedo e Martínez (2011) fazem uso de transformadas *wavelet* para a segmentação de batidas, ambas de complexidade maior do que a técnica de segmentação dinâmica. Já Llamedo e Martínez (2011) e Ye, Kumar e Coimbra (2012) fazem uso das transformadas *wavelet* para extração de características, também de complexidade superior ao cálculo de parâmetros de Hjorth. A menor complexidade do modelo proposto, no entanto, não se traduz em uma queda acentuada no desempenho, que se mantém muito próximo do obtido pelos modelos mais complexos.

O modelo proposto por Chen et al. (2017) apresenta complexidade computacional também mais alta, devido à aplicação das matrizes de projeção, que utilizam multiplicação

de matrizes para extração de M coeficientes – utilizados como características – de um sinal de N amostras, onde $M \ll N$. Mesmo com complexidade mais alta, no entanto, seu trabalho apresenta índices baixos para batidas ectópicas, especialmente S e F, mas também para a classe V. Seus índices de desempenho são menores em 6 de 9 oportunidades, quando comparados aos índices obtidos pelo modelo de classificação em dois passos.

6 Considerações Finais

Neste trabalho, foram propostos métodos de baixa complexidade computacional para processamento e extração de características do sinal de eletrocardiograma, visando a classificação automática de batidas cardíacas. A partir desses métodos, as batidas passam a ser representadas por um conjunto de propriedades composto por valores de intervalos entre batidas, medidas de amplitude e, especialmente, parâmetros de Hjorth. Parâmetros de Hjorth possuem como vantagem o fato de agregarem informação sobre o sinal nos domínios de tempo e frequência em apenas três valores, que podem ser calculados com simplicidade. Além disso, uma nova abordagem foi proposta para o problema de segmentação de batidas, mais dinâmica e acurada, cuja finalidade é o aumento da eficiência das características extraídas do sinal, tornando-as mais puras com relação à batida de que foram extraídas.

Os resultados dos testes conduzidos para o modelo proposto foram comparados a outros cinco trabalhos de metodologia semelhante, e apresentaram índices de desempenho similares aos deles, ainda que sua implementação tenha custo computacional mais baixo e demande apenas cálculos simples. Os resultados indicam que a técnica utilizada neste trabalho pode ser aplicada com sucesso ao problema de classificação automática de batidas, além de permitir sua implementação posterior em dispositivos de hardware com recursos limitados, como FPGA, sistemas embarcados e circuitos integrados.

O modelo com duas derivações sem a utilização da técnica de subamostragem apresentou bons resultados, com uma melhora significativa nos índices de sensibilidade para classes S (34.0% para 50.8%) e F (0.3% para 85.1%) com relação ao melhor modelo de derivação única, mantendo valores altos para índices de acurácia global, sensibilidade das classes N e V e preditividade positiva para N, S e V. A utilização de dois canais proporcionou uma melhoria especial com relação à classe de batidas supraventriculares.

A técnica de subamostragem mostrou vantagens e desvantagens, ao mesmo tempo aumentando valores de sensibilidade e diminuindo valores de preditividade positiva. O

modelo reconhece a grande maioria das instâncias de batidas ectópicas, com aumento significativo para batidas supraventriculares (de 50,8% no modelo anterior para 73,8%), o que é bom para o paciente, diminuindo a chance de que uma possível condição cardíaca não seja tratada. No entanto, em um grande número de casos, o sistema classifica batidas normais como ectópicas, o que gera falsos alarmes e pode gerar preocupação desnecessária no paciente e na equipe médica.

A fim de aproveitar as potencialidades de cada um desses métodos, foi proposto um modelo de classificação em dois passos, onde existem duas SVM, treinadas a partir de conjuntos de dados diferentes: uma delas é treinada com o conjunto de dados completo, desbalanceado, e outra com um conjunto de dados subamostrado, com menor quantidade de batidas normais. O modelo treinado com dados subamostrados é responsável pelo primeiro passo, onde é identificada a maior parte das batidas do tipo S. As batidas restantes são, no passo seguinte, classificadas em um dos tipos restantes pelo segundo modelo, treinado com dados completos.

Essa nova técnica apresentou os resultados mais equilibrados entre todos os testes, mantendo altos níveis de acurácia global (89,3%), sensibilidade e preditividade positiva para a classe de batidas normais (90% e 97,0%, respectivamente), e índices muito próximos dos outros trabalhos com relação às batidas ectópicas – S, V e F. Esses resultados confirmam a viabilidade da técnica proposta e apresentam um novo caminho para a pesquisa de sistemas automáticos de classificação de batidas cardíacas.

6.1 Trabalhos Futuros

O próximo passo para a sequência deste estudo é sua implementação em um dispositivo de *hardware* com limitações de recursos. Essa fase englobará a adaptação do código escrito em MATLAB® e C++ para uma linguagem de programação compatível com a plataforma escolhida, e sua otimização, de acordo com os recursos providos pela linguagem. Além disso, durante este novo estudo, testes deverão ser realizados, relacionados ao consumo de tempo, memória e energia, visando a comparação com outras técnicas.

Com relação ao algoritmo para classificação de batidas desenvolvido, estudos podem ser realizados no sentido de sua validação a partir de outros bancos de dados disponíveis *online*, como o INCART (GOLDBERGER et al., 2000), utilizado por Llamedo e Martínez (2011). O aumento da base de dados aumenta, também, a quantidade de amostras de batidas ectópicas, especialmente supraventriculares, o que pode ser benéfico para o algoritmo.

Ainda, podem ser exploradas algumas informações de natureza pessoal dos pacientes presentes nos bancos de dados, como sexo, idade e medicamentos utilizados. Medicamentos como a digoxina, indicada para o tratamento de insuficiência cardíaca e taquicardia, podem mudar a aparência das batidas nos exames de ECG (LIFE IN THE FAST LANE, 2017), afetando o desempenho dos classificadores.

Finalmente, há uma diversidade de sinais biológicos nos quais os parâmetros de Hjorth foram pouco ou nada utilizados. Há uma demanda, por exemplo, relacionada ao desenvolvimento de sistemas capazes de realizar a interpretação de sinais de EEG, de maneira a captar intenções de movimento em pacientes com dificuldades motoras (MCFARLAND; WOLPAW, 2011). Uma técnica de extração de características inovadora pode ser útil na criação de próteses e melhoria da qualidade de vida de indivíduos imobilizados por doenças, como a esclorose lateral amiotrófica (ALS, de *Amyotrophic Lateral Sclerosis*).

APÊNDICE A - Análise de Custo Computacional

É comum que algoritmos criados para resolver um mesmo problema sejam bastante diferentes com relação ao consumo de recursos computacionais. De acordo com Ullman, Aho e Hopcroft (1974), algoritmos podem ser avaliados e comparados através de vários critérios. Geralmente, no entanto, a maior preocupação se dá com relação ao tempo gasto para a solução de um determinado problema, que está diretamente relacionado à quantidade de passos computacionais executados durante a tarefa.

Segundo Mazomenos et al. (2013), grande parte dos algoritmos para extração de características de batidas cardíacas são computacionalmente intensos, ou seja, realizam muitos passos computacionais (operações aritméticas, etc.) durante sua execução, especialmente aqueles que extraem informações no domínio da frequência. Este trabalho apresenta uma alternativa de baixo custo computacional, que viabiliza a solução do mesmo problema em menos tempo e, conseqüentemente, com menor consumo de energia.

A.1 Complexidade no Tempo

O número de passos computacionais necessários para o processamento de uma tarefa pode ser expresso como uma função $T(n)$, onde n representa o comprimento dos dados de entrada (DASGUPTA; PAPADIMITRIOU; VAZIRANI, 2006). No caso deste estudo, n é o comprimento da batida a ser processada, ou seja, a quantidade de amostras que a compõem. Geralmente, a tendência é que a quantidade $T(n)$ de passos computacionais aumente para entradas muito grandes e seja pequeno para entradas também pequenas. No entanto, dependendo da própria estrutura do algoritmo, a função $T(n)$ pode crescer mais depressa ou mais devagar com o aumento do tamanho da entrada.

A Figura 32 mostra, como exemplo, um gráfico com as curvas geradas duas funções: (a) 2^n e (b) $\log n$. As duas funções são crescentes, mas a função responsável pela curva (a) cresce muito mais rapidamente do que a função responsável por (b). Assim, pode-se

dizer que um algoritmo cuja quantidade de passos computacionais necessários para sua finalização seja da ordem de 2^n leva mais tempo em sua execução do que outro de ordem $\log n$, e que essa diferença se acentua à medida que o comprimento n da entrada aumenta.

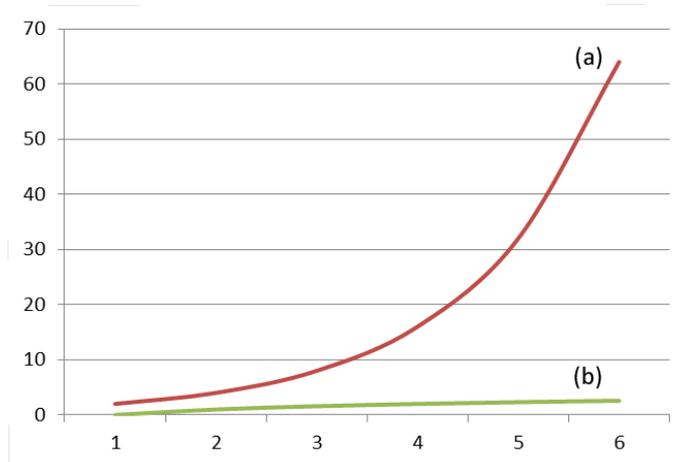


Figura 32: Crescimento de funções: (a) $T(n) = 2^n$ (b) $T(n) = \log n$.

Tomemos, por exemplo, um algoritmo cuja finalidade seja realizar a soma de todos os valores em um vetor de inteiros de tamanho n , de acordo com Código A.1, escrito em C++. Em seu cerne, uma única operação de soma é realizada para cada elemento do vetor, totalizando, também, n operações. Nesse caso, dizemos que o número $T(n)$ de passos computacionais varia linearmente com o tamanho n da entrada. Algoritmos muito similares são responsáveis pelo cálculo da média dos elementos de um vetor, assim como pela busca de valores em sua extensão (como valores mínimo e máximo). Todos eles podem ser classificados como $O(n)$ através da notação *big-O* (CORMEN et al., 2001), que indica sua ordem de crescimento com o aumento do tamanho a entrada. A notação *big-O* implica em algumas simplificações, deixando de lado uma contagem minuciosa das operações para que o foco esteja na ordem de crescimento da função $T(n)$.

Código A.1: Cálculo da soma dos elementos em um vetor.

```
int soma = 0; // inicializa soma
for(int i = 0; i < n; i++)
    soma = soma + vetor[i]; // inclui i-ésimo elemento na soma
```

Quando a quantidade de operações realizadas pelo algoritmo independe do tamanho n da entrada, dizemos que a complexidade no tempo do algoritmo é $O(1)$, ou seja, constante. Por exemplo, uma função que retorne o último elemento de um vetor de inteiros, como a do Código A.2, não realiza uma varredura no vetor, mas simplesmente acessa o elemento de índice $n - 1$. O mesmo vale para algoritmos que realizem mais operações, mas cujo

valor seja fixo e independente do tamanho n da entrada.

Código A.2: Função que retorna último elemento do vetor.

```
int retorna_ultimo(int* vetor, int n) {
    return vetor[n-1]; // único acesso: independe da dimensão do vetor.
}
```

Há algoritmos com outras ordens de crescimento, como quadráticos (n^2), cúbicos (n^3), logarítmicos ($\log n$), exponenciais (2^n) e outros. A Tabela 22 pode ser utilizada como referência para a comparação de algoritmos, listando as ordens mais comuns, da menos complexa (constante) à mais complexa (exponencial). Segundo Cormen et al. (2001), um algoritmo de menor complexidade será quase sempre a melhor escolha para a solução do problema, exceto, talvez, quando o tamanho da entrada for muito pequeno.

Tabela 22: Classes de algoritmos em ordem crescente de complexidade (cima para baixo).

Constante	$O(1)$
Logarítmica	$O(\log n)$
Linear	$O(n)$
linearítmica	$O(n \cdot \log n)$
Polinomial	$O(n^k)$, com $k \geq 2$
Exponencial	$O(k^n)$, com $k > 1$

O gráfico da Figura 33 ilustra o comportamento dessas classes de algoritmos mais comuns, e mostra o impacto da complexidade algorítmica à medida que a entrada torna-se maior. Algoritmos cuja complexidade é mais alta tornam-se impraticáveis, devido à limitação de recursos, à medida em que torna-se necessário processar entradas maiores.

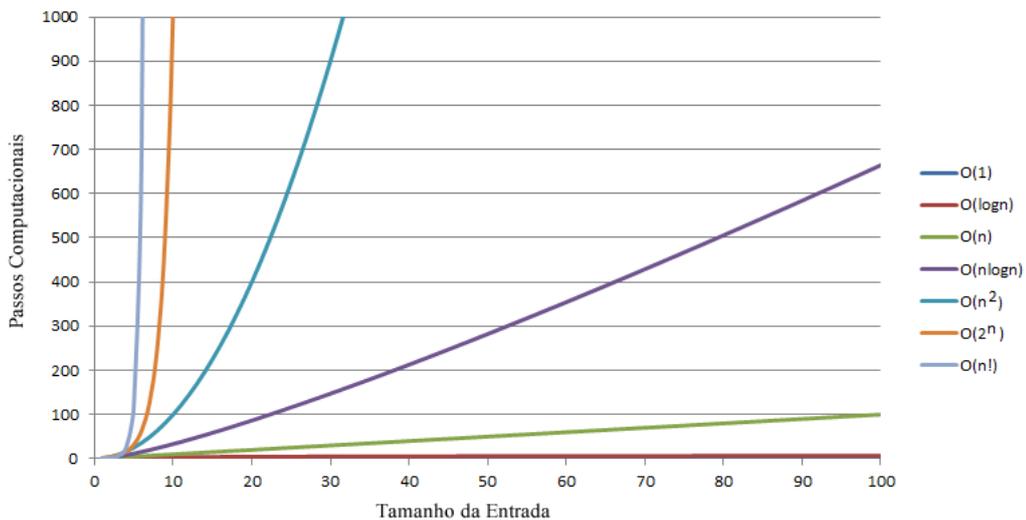


Figura 33: Comparação entre ordens de complexidade assintótica.

A análise de complexidade simplifica a comparação entre algoritmos e torna desnecessária a preocupação com detalhes sobre a arquitetura da máquina utilizada (processador, estratégia de *cache*, etc.) e com medidas precisas de tempo, uma vez que está focada ultimamente na própria estrutura do algoritmo e na quantidade de passos computacionais realizados. Portanto, é uma medida independente da máquina, o que quer dizer que um algoritmo $O(n)$ será mais eficiente que outro $O(n^2)$ tanto em um dispositivo limitado quanto em um supercomputador (ainda que o tempo gasto pelas máquinas seja diferente).

Para os casos em que algoritmos diferentes apresentem a mesma ordem de complexidade, como no caso dos parâmetros de Hjorth e a transformada *wavelet*, uma contagem mais criteriosa de operações realizadas pode ser feita. Ainda que qualquer algoritmo $O(n)$ cresça linearmente com o tamanho da entrada, uma técnica que realize, digamos, $5n$ operações aritméticas, ainda é 5 vezes mais rápida que outra, que execute $25n$ operações.

Referências

- AAMI. *AAMI, Association for the Advancement of Medical Instrumentation*. 2017. <http://http://www.aami.org>. Accessed: September 2017.
- AFONSO, V. X.; TOMPKINS, W. J. Detecting ventricular fibrillation. *IEEE Engineering in Medicine and Biology Magazine*, IEEE, v. 14, n. 2, p. 152–159, 1995.
- AMORIM, G. d. F. d. et al. Detecting a level change in a nonlinear time series using hjorth's descriptors. *Production*, SciELO Brasil, v. 25, n. 4, p. 812–825, 2015.
- ANSI/AAMI. Testing and reporting performance results of cardiac rhythm and st segment measurement algorithms. *ANSI/AAMI EC38*, v. 1998, 1998.
- BAILEY, J. J. et al. Recommendations for standardization and specifications in automated electrocardiography: bandwidth and digital signal processing. a report for health professionals by an ad hoc writing group of the committee on electrocardiography and cardiac electrophysiology of the council on clinical cardiology, american heart association. *Circulation*, v. 81, n. 2, p. 730, 1990.
- BALANI, R. Energy consumption analysis for bluetooth, wifi and cellular networks. *Online Httpnesl Ee Ucla Edufudocumentsreports2007PowerAnalysis Pdf*, 2007.
- BARBOUR, A. J.; PARKER, R. L. Normalization of power spectral density estimates. 2015.
- BASIC ARRHYTHMIA. *Ventricular Rhythms*. mar. 2018. Disponível em: <https://learningcentral.health.unm.edu/learning/user/onlineaccess/CE/bac_online/idio/vcb_interpret.html>.
- BASILEVSKY, A. *Applied matrix algebra in the statistical sciences*. [S.l.]: Courier Corporation, 2013.
- BENNETT, K. P.; CAMPBELL, C. Support vector machines: hype or hallelujah? *Acm Sigkdd Explorations Newsletter*, ACM, v. 2, n. 2, p. 1–13, 2000.
- BERTSEKAS, D. P. *Nonlinear programming*. Belmont, MA, EUA: Athena scientific, 1999.
- BRASIL. *Ministério da Saúde - Sistema de Informações sobre Mortalidade*. 2017. <http://svs.aids.gov.br/dantps/cgiae/sim/>. Acessado em: Dezembro 2017.
- BUTTERWORTH, S. On the theory of filter amplifiers. *Wireless Engineer*, v. 7, n. 6, p. 536–541, 1930.
- BYUN, H.; LEE, S.-W. Applications of support vector machines for pattern recognition: A survey. *Pattern recognition with support vector machines*, Springer, p. 571–591, 2002.

- CARPINTEIRO, O. A. et al. Forecasting models for prediction in time series. *Artificial Intelligence Review*, Springer, v. 38, n. 2, p. 163–171, 2012.
- CECCHIN, T. et al. Seizure lateralization in scalp EEG using hjorth parameters. *Clinical Neurophysiology*, Elsevier, v. 121, n. 3, p. 290–300, 2010.
- CHANG, C.-C.; LIN, C.-J. LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, v. 2, p. 27:1–27:27, 2011. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- CHARBONNIER, S. et al. Self-evaluated automatic classifier as a decision-support tool for sleep/wake staging. *Computers in Biology and Medicine*, Elsevier, v. 41, n. 6, p. 380–389, 2011.
- CHAWLA, N. V. et al. Smote: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, v. 16, p. 321–357, 2002.
- CHAZAL, P. D.; O'DWYER, M.; REILLY, R. B. Automatic classification of heartbeats using ECG morphology and heartbeat interval features. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 51, n. 7, p. 1196–1206, 2004.
- CHEN, S. et al. Heartbeat classification using projected and dynamic features of ECG signal. *Biomedical Signal Processing and Control*, Elsevier, v. 31, p. 165–173, 2017.
- CHRISTOV, I. et al. Comparative study of morphological and time-frequency ECG descriptors for heartbeat classification. *Medical engineering & physics*, Elsevier, v. 28, n. 9, p. 876–887, 2006.
- CLIFFORD, G. D.; AZUAJE, F.; MCSHARRY, P. Advanced methods and tools for ECG data analysis. Artech House, Inc., 2006.
- CONOVER, M. B. *Understanding electrocardiography*. [S.l.]: Elsevier Health Sciences, 2002.
- CORMEN, T. H. et al. *Introduction to Algorithms*. 2. ed. Cambridge, MA, EUA: The MIT Press, 2001.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, n. 3, p. 273–297, 1995.
- COVER, T. M. Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition. *IEEE transactions on electronic computers*, IEEE, n. 3, p. 326–334, 1965.
- DAS, M. K. *Electrocardiogram Signal Analysis for Heartbeat Pattern Classification*. Tese (Doutorado), 2015.
- DASGUPTA, S.; PAPADIMITRIOU, C. H.; VAZIRANI, U. *Algorithms*. [S.l.]: McGraw-Hill, Inc., 2006.
- DAUBECHIES, I. et al. Ten lectures on wavelets. In: *CBMS-NSF regional conference series in applied mathematics*. [S.l.: s.n.], 1991. v. 61, n. 4.

- DOQUIRE, G. et al. Feature selection for interpatient supervised heart beat classification. *Computational intelligence and neuroscience*, Hindawi Publishing Corp., v. 2011, p. 1, 2011.
- DRAZEN, E. et al. Survey of computer-assisted electrocardiography in the united states. *Journal of electrocardiology*, Elsevier, v. 21, p. S98–S104, 1988.
- DRUMMOND, C.; HOLTE, R. C. et al. C4. 5, class imbalance, and cost sensitivity: why under-sampling beats over-sampling. In: CITESEER. *Workshop on learning from imbalanced datasets II*. Washington DC, EUA, 2003. v. 11.
- ELHAJ, F. A. et al. Arrhythmia recognition and classification using combined linear and nonlinear features of ECG signals. *Computer methods and programs in biomedicine*, Elsevier, v. 127, p. 52–63, 2016.
- GOLDBERGER, A. L. et al. Physiobank, physiotoolkit, and physionet. *Circulation*, Am Heart Assoc, v. 101, n. 23, p. e215–e220, 2000.
- GONZALEZ, W.; WOODS, R. E. Eddins, digital image processing using MATLAB. *Third New Jersey: Prentice Hall*, 2004.
- GRADL, S. et al. Real-time ECG monitoring and arrhythmia detection using android-based mobile devices. In: IEEE. *Engineering in Medicine and Biology Society (EMBC), 2012 Annual International Conference of the IEEE*. San Diego, CA, EUA, 2012. p. 2452–2455.
- GÜLER, İ.; ÜBEYLI, E. D. Ecg beat classifier designed by combined neural network model. *Pattern recognition*, Elsevier, v. 38, n. 2, p. 199–208, 2005.
- HAMPTON, J. R. *The ECG made easy*. Livingstone, Scotland: Elsevier Health Sciences, 2013.
- HAYKIN, S. *Neural networks: a comprehensive foundation. 2nd. edition*. [S.l.]: Prentice-Hall, Englewood Cliffs, 1999.
- HJORTH, B. EEG analysis based on time domain properties. *Electroencephalography and clinical neurophysiology*, Elsevier, v. 29, n. 3, p. 306–310, 1970.
- HJORTH, B. The physical significance of time domain descriptors in EEG analysis. *Electroencephalography and clinical neurophysiology*, Elsevier, v. 34, n. 3, p. 321–325, 1973.
- HOLTER, N. J. New method for heart studies. *Science*, American Association for the Advancement of Science, v. 134, n. 3486, p. 1214–1220, 1961.
- HSU, C.-W. et al. A practical guide to support vector classification. Taipei, Taiwan, 2003.
- HU, Y. H.; PALREDDY, S.; TOMPKINS, W. J. A patient-adaptable ECG beat classifier using a mixture of experts approach. *IEEE transactions on biomedical engineering*, IEEE, v. 44, n. 9, p. 891–900, 1997.

- INAN, O. T.; GIOVANGRANDI, L.; KOVACS, G. T. Robust neural-network-based classification of premature ventricular contractions using wavelet transform and timing interval features. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 53, n. 12, p. 2507–2515, 2006.
- INFOGRAM. *Body Planes*. mar. 2018. Disponível em: <<https://infoqram.com/body-planes-1gqgk2653v18pn0>>.
- JIANG, W.; KONG, S. G. Block-based neural networks for personalized ECG signal classification. *IEEE Transactions on Neural Networks*, IEEE, v. 18, n. 6, p. 1750–1761, 2007.
- JIANG, X. et al. ECG arrhythmias recognition system based on independent component analysis feature extraction. In: IEEE. *TENCON 2006. 2006 IEEE Region 10 Conference*. Hong Kong, China, 2006. p. 1–4.
- KADAMBE, S.; MURRAY, R.; BOUDREAUX-BARTELS, G. F. Wavelet transform-based QRS complex detector. *IEEE Transactions on biomedical Engineering*, IEEE, v. 46, n. 7, p. 838–848, 1999.
- KARPAGACHELVI, S.; ARTHANARI, M.; SIVAKUMAR, M. Classification of electrocardiogram signals with support vector machines and extreme learning machine. *Neural Computing and Applications*, Springer, v. 21, n. 6, p. 1331–1339, 2012.
- KASTOR, J. A. *You and Your Arrhythmia: A Guide to Heart Rhythm Problems for Patients and Their Families*. [S.l.]: Jones & Bartlett Publishers, 2008.
- KASTOR, J. A. Cardiac arrhythmias. *Encyclopedia of Life Sciences*, Macmillan Publishers Ltd, Nature Publishing Group, 2012.
- KATZ, A. M. *Physiology of the Heart*. Philadelphia, PA, EUA: Lippincott Williams & Wilkins, 2010.
- KO, S.-Y. et al. A portable ECG recorder. In: IEEE. *Consumer Electronics, Communications and Networks (CECNet), 2012 2nd International Conference on*. [S.l.], 2012. p. 3063–3067.
- KRASTEVA, V. T.; JEKOVA, I. I.; CHRISTOV, I. I. Automatic detection of premature atrial contractions in the electrocardiogram. *Electrotechniques Electronics E & E*, v. 9, p. 10, 2006.
- LAGERHOLM, M. et al. Clustering ECG complexes using hermite functions and self-organizing maps. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 47, n. 7, p. 838–848, 2000.
- LAGUNA, P. et al. QRS detection and waveform boundary recognition using ecgpuwave. *PhysioToolkit Open Source Software for Biomedical Science and Engineering.*, 2002. Software available at <http://www.physionet.org/physiotools/ecgpuwave>.
- LI, P. et al. A low-complexity ECG processing algorithm based on the haar wavelet transform for portable health-care devices. *Science China Information Sciences*, Springer, v. 57, n. 12, p. 1–14, 2014.

LIFE IN THE FAST LANE. *ECG Library*. 2017. Disponível em: <<https://lifeinthefastlane.com/ecg-library/>>.

LIN, C.-C.; YANG, C.-M. Heartbeat classification using normalized RR intervals and morphological features. *Mathematical Problems in Engineering*, Hindawi Publishing Corporation, v. 2014, 2014.

LIU, X.-Y.; WU, J.; ZHOU, Z.-H. Exploratory undersampling for class-imbalance learning. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, IEEE, v. 39, n. 2, p. 539–550, 2009.

LLAMEDO, M.; MARTINEZ, J. An ecg classification model based on multilead wavelet transform features. In: IEEE. *Computers in Cardiology, 2007*. [S.l.], 2007. p. 105–108.

LLAMEDO, M.; MARTÍNEZ, J. P. Heartbeat classification using feature selection driven by database generalization criteria. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 58, n. 3, p. 616–625, 2011.

LLAMEDO, M.; MARTÍNEZ, J. P. An automatic patient-adapted ecg heartbeat classifier allowing expert assistance. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 59, n. 8, p. 2312–2320, 2012.

LUZ, E. J. d. S. et al. Ecg-based heartbeat classification for arrhythmia detection: A survey. *Computer methods and programs in biomedicine*, Elsevier, v. 127, p. 144–164, 2016.

MALLAT, S. *A wavelet tour of signal processing: the sparse way*. [S.l.]: Academic press, 2008.

MARK, R.; MOODY, G. MIT-BIH arrhythmia database. Available at <http://ecg.mit.edu/dbinfo.html>, 1997.

MARTÍNEZ, J. P. et al. A wavelet-based ECG delineator: evaluation on standard databases. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 51, n. 4, p. 570–581, 2004.

MAZOMENOS, E. B. et al. A low-complexity ECG feature extraction algorithm for mobile healthcare applications. *IEEE Journal of Biomedical and Health Informatics*, IEEE, v. 17, n. 2, p. 459–469, 2013.

MCFARLAND, D. J.; WOLPAW, J. R. Brain-computer interfaces for communication and control. *Communications of the ACM*, ACM, v. 54, n. 5, p. 60–66, 2011.

MEDLIBES. *Online Medical Library*. mar. 2018. Disponível em: <<http://medlibes.com/entry/premature-ventricular-contractions>>.

MELIN, P. et al. A new neural network model based on the LVQ algorithm for multi-class classification of arrhythmias. *Information sciences*, Elsevier, v. 279, p. 483–497, 2014.

MERCER, J. Functions of positive and negative type, and their connection with the theory of integral equations. *Philosophical transactions of the royal society of London. Series A, containing papers of a mathematical or physical character*, JSTOR, v. 209, p. 415–446, 1909.

- MICHEL, M. et al. Wavelet toolbox 4 user's guide. *The MathWorks, Inc*, 2010.
- MINAMI, K.-i.; NAKAJIMA, H.; TOYOSHIMA, T. Real-time discrimination of ventricular tachyarrhythmia with fourier-transform neural network. *IEEE transactions on Biomedical Engineering*, IEEE, v. 46, n. 2, p. 179–185, 1999.
- MOODY, G. B.; MARK, R. G. The impact of the MIT-BIH arrhythmia database. *IEEE Engineering in Medicine and Biology Magazine*, IEEE, v. 20, n. 3, p. 45–50, 2001.
- MOUZÉ-AMADY, M.; HORWAT, F. Evaluation of hjorth parameters in forearm surface EMG analysis during an occupational repetitive task. *Electroencephalography and Clinical Neurophysiology/Electromyography and Motor Control*, Elsevier, v. 101, n. 2, p. 181–183, 1996.
- NOVIYANTO, A. et al. Selecting features of single lead ECG signal for automatic sleep stages classification using correlation-based feature subset selection. *IJCSI International Journal of Computer Science Issues*, Citeseer, v. 8, n. 1-5, 2011.
- OH, S.-H.; LEE, Y.-R.; KIM, H.-N. A novel EEG feature extraction method using hjorth parameter. *International Journal of Electronics and Electrical Engineering*, v. 2, n. 2, p. 106–110, 2014.
- OLVER, P. J. *Introduction to partial differential equations*. Switzerland: Springer, 2014.
- OPIE, L. H. *Heart physiology: from cell to circulation*. Philadelphia, PA, EUA: Lippincott Williams & Wilkins, 2004.
- OSTER, J. et al. Semisupervised ECG ventricular beat classification with novelty detection based on switching kalman filters. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 62, n. 9, p. 2125–2134, 2015.
- PAN, J.; TOMPKINS, W. J. A real-time QRS detection algorithm. *IEEE transactions on biomedical engineering*, IEEE, n. 3, p. 230–236, 1985.
- PARK, J. et al. Nearest neighbor search with locally weighted linear regression for heartbeat classification. *Soft Computing*, Springer, p. 1–12, 2016.
- PARK, K. et al. Hierarchical support vector machine based heartbeat classification using higher order statistics and hermite basis function. In: IEEE. *Computers in Cardiology, 2008*. [S.l.], 2008. p. 229–232.
- PRUTCHI, D.; NORRIS, M. *Design and development of medical electronic instrumentation: a practical perspective of the design, construction, and test of medical devices*. [S.l.]: John Wiley & Sons, 2005.
- REDMOND, S. J.; HENEGHAN, C. Cardiorespiratory-based sleep staging in subjects with obstructive sleep apnea. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 53, n. 3, p. 485–496, 2006.
- RIZAL, A.; HADIYOSO, S. ECG signal classification using hjorth descriptor. In: IEEE. *Automation, Cognitive Science, Optics, Micro Electro-Mechanical System, and Information Technology (ICACOMIT), 2015 International Conference on*. [S.l.], 2015. p. 87–90.

- RIZAL, A.; HIDAYAT, R.; NUGROHO, H. A. Determining lung sound characterization using hjorth descriptor. In: IEEE. *Control, Electronics, Renewable Energy and Communications (ICCEREC), 2015 International Conference on*. [S.l.], 2015. p. 54–57.
- ROUSSEAU, M. et al. Classifying leukemia types with chromatin conformation data. *Genome biology*, BioMed Central, v. 15, n. 4, p. R60, 2014.
- SENHADJI, L. et al. Comparing wavelet transforms for recognizing cardiac patterns. *IEEE Engineering in Medicine and Biology Magazine*, IEEE, v. 14, n. 2, p. 167–173, 1995.
- SHERWOOD, L. *Human physiology: from cells to systems*. Boston, MA, EUA: Cengage learning, 2015.
- SILVA, I.; MOODY, G. B.; CELI, L. Improving the quality of ECGs collected using mobile phones: The physionet/computing in cardiology challenge 2011. In: IEEE. *Computing in Cardiology, 2011*. [S.l.], 2011. p. 273–276.
- SINGH, D. et al. An application of SVM in character recognition with chain code. In: IEEE. *Communication, Control and Intelligent Systems (CCIS), 2015*. [S.l.], 2015. p. 167–171.
- SUBASI, A. Classification of EMG signals using PSO optimized SVM for diagnosis of neuromuscular disorders. *Computers in biology and medicine*, Elsevier, v. 43, n. 5, p. 576–586, 2013.
- THALER, M. S. *The only EKG book you'll ever need*. Philadelphia, PA, EUA: Lippincott Williams & Wilkins, 2010.
- TING, K. M. Confusion matrix. In: _____. *Encyclopedia of Machine Learning*. Boston, MA: Springer US, 2010.
- ULLMAN, J. D.; AHO, A. V.; HOPCROFT, J. E. The design and analysis of computer algorithms. *Addison-Wesley, Reading*, v. 4, p. 1–2, 1974.
- UNIVERSITY OF NOTTINGHAM. *Cardiology Teaching Package*. mar. 2018. Disponível em: <https://www.nottingham.ac.uk/nursing/practice/resources/cardiology/function/chest_leads.php>.
- VAPNIK, V. N. *Statistical learning theory*. New York, NY, EUA: Wiley New York, 1998.
- VIDAURRE, C. et al. Time domain parameters as a feature for EEG-based brain-computer interfaces. *Neural Networks*, Elsevier, v. 22, n. 9, p. 1313–1319, 2009.
- WANG, X.-Y. et al. Image denoising using SVM classification in nonsubsampled contourlet transform domain. *Information Sciences*, Elsevier, v. 246, p. 155–176, 2013.
- WIEBEN, O.; TOMPKINS, W. J.; AFONSO, V. X. Classification of PVCs with a fuzzy logic system. In: IEEE. *Engineering in Medicine and Biology society, 1997. Proceedings of the 19th Annual International Conference of the IEEE*. [S.l.], 1997. v. 1, p. 65–67.
- WORLD HEALTH ORGANIZATION. *World Health Organization - The top 10 causes of death*. 2017. <http://www.who.int/mediacentre/factsheets/fs310/en/>. Acessado em: Dezembro 2017.

YE, C.; KUMAR, B. V.; COIMBRA, M. T. Heartbeat classification using morphological and dynamic features of ECG signals. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 59, n. 10, p. 2930–2941, 2012.

YEAP, T.; JOHNSON, F.; RACHNIOWSKI, M. ECG beat classification by a neural network. In: IEEE. *Engineering in Medicine and Biology Society, 1990., Proceedings of the Twelfth Annual International Conference of the IEEE*. [S.l.], 1990. p. 1457–1458.

YU, S.-N.; CHEN, Y.-H. Electrocardiogram beat classification based on wavelet transformation and probabilistic neural network. *Pattern Recognition Letters*, Elsevier, v. 28, n. 10, p. 1142–1150, 2007.

ZHANG, D. Wavelet approach for ECG baseline wander correction and noise reduction. In: IEEE. *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the*. Shanghai, 2005. p. 1212–1215.

ZHANG, Z. et al. Heartbeat classification using disease-specific feature selection. *Computers in biology and medicine*, Elsevier, v. 46, p. 79–89, 2014.

ZIDELMAL, Z. et al. Ecg beat classification using a cost sensitive classifier. *Computer methods and programs in biomedicine*, Elsevier, v. 111, n. 3, p. 570–577, 2013.