

**UNIVERSIDADE FEDERAL DO PARÁ
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
DOUTORADO EM ENGENHARIA ELÉTRICA**

JOÃO EVANGELISTA NETO

**DESENVOLVIMENTO DE MÉTODOS DE PROCESSAMENTO E INTELIGÊNCIA
COMPUTACIONAL NO ECG AMBULATORIAL**

**BELÉM
2012**

JOÃO EVANGELISTA NETO

**DESENVOLVIMENTO DE MÉTODOS DE PROCESSAMENTO E INTELIGÊNCIA
COMPUTACIONAL NO ECG AMBULATORIAL**

Tese de Doutorado apresentada no Programa de Pós-graduação em Engenharia Elétrica da UFPA, como parte dos requisitos para obtenção do grau de doutor em Engenharia Elétrica.

Área de concentração: Computação Aplicada

Orientador: Prof. Dr. Roberto Limão Célio de Oliveira.

Co-orientador: Prof. Dr. Carlos Román Vázquez Seisdedos.

**BELÉM
2012**

Evangelista Neto, João.

Desenvolvimento de métodos de processamento e inteligência computacional no ECG ambulatorial / João Evangelista Neto; orientador, Roberto Célio Limão de Oliveira. – 2012.

Tese (Doutorado) – Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2012.

1. Engenharia biomédica. 2. Eletrocardiografia.
3. Processamento de sinais - Técnicas digitais. 4. Inteligência computacional. I. Orientador. II. Título.

CDD 22. Ed. 610.28

JOÃO EVANGELISTA NETO**DESENVOLVIMENTO DE MÉTODOS DE PROCESSAMENTO E INTELIGÊNCIA
COMPUTACIONAL NO ECG AMBULATORIAL**

Tese apresentada para obtenção do grau de
Doutor em Engenharia Elétrica pelo Instituto
de Tecnologia da Universidade Federal do
Pará - UFPA.

Área de concentração: Computação Aplicada

Data da aprovação: Belém-PA: ____/____/____

Banca Examinadora

Prof. Dr. Roberto Célio L. de Oliveira
(UFPA/PPGEE)
Orientador

Prof. Dr. Carlos Román Vázquez Seisdedos
(UO/CENPIS)
Co-orientador

Prof. Dr. Adson Ferreira da Rocha (UNB)
Membro da Banca Examinadora

Prof. Dr. Raimes Moraes (UFSC)
Membro da Banca Examinadora

Prof. Dr. Francisco Beraldo Herrera Fernández
(UCLV)
Membro da Banca Examinadora

Prof. Dr. Ronaldo de Freitas Zampolo (UFPA)
Membro da Banca Examinadora

Prof. Dr. Alessandro Beda (UFPA/PPGEE)
Membro da Banca Examinadora

Prof. Dr. Marcus Vinícius Alves Nunes
Coordenador do PPGEE/CT/UFPA

*À minha esposa e aos meus filhos
que me apoiaram na conquista de mais
um objetivo, mesmo estando eu nos
trabalhos e nos estudos.*

AGRADECIMENTOS

À Deus nosso criador pela existência e por sua indulgência para com a nossa idiossincrasia que ainda é muito limitada para compreender a sua magnanimidade.

Ao Prof. Dr. Roberto Célio Limão de Oliveira (UFPA), Prof. Dr. Abel Torres Cebrian (UPC) e Prof. Dr. Carlos Roman Vázquez Seisdedos (UO) pela orientação, extrema competência, segurança e a lucidez que transmite como professor e orientador. O Prof. Carlos extrapolou os limites da orientação, me incentivou a vislumbrar o mundo das pesquisas e consolidamos uma amizade muito sólida entre nossas famílias.

Ao Prof. Francisco Beraldo Herrera Fernández pelo apoio e amizade, por sempre conseguir tempo para orientar repassando a sua extrema competência.

Ao colegiado de pesquisadores do Centro em Estudos de Neurociências, Processamento de Sinais e Imagens da Universidade do Oriente, Cuba (CENPIS), especialmente aos professores Alexander Suárez León e Enrique Marañón Reyes pela colaboração imprescindível.

A todos os Professores do programa, sem exceções, pela competência e dedicação que empreenderam na aplicação dos conteúdos desse curso.

Aos meus pares do curso, que promoveram uma sinergia positiva ao longo do curso, com quem também podemos aprender muito.

Aos meus pais (*in memoriam*) onde quer que estejam, pela dedicação e principalmente pela base ética sólida que me transmitiram, sobretudo pelo exemplo.

Aos meus familiares, principalmente a esposa Ana Cecília da Costa Macedo Evangelista e os filhos, pela resignação nos momentos de ausência.

“É melhor tentar e falhar,
que se preocupar e ver a vida passar;
é melhor tentar, ainda que em vão,
que se sentar fazendo nada até o
final.

Eu prefiro na chuva caminhar,
que em dias tristes em casa me
esconder.

Prefiro ser feliz, embora louco,
que em conformidade viver”.

Martin Luther King

RESUMO

A monitorização ambulatorial do eletrocardiograma (ECG) permite seguir as atividades cotidianas do paciente durante períodos de 24 horas (ou ainda maiores) possibilitando o estudo de casos que pudessem ter episódios arrítmicos fatais. Entretanto, o maior desafio tecnológico que este tipo de monitorização enfrenta é a perda de informação pela presença de ruídos e artefatos quando o paciente se move. A análise do intervalo QT de despolarização e repolarização ventricular do eletrocardiograma superficial é uma técnica não invasiva com um grande valor para a diagnose e prognósticos de cardiopatias e neuropatias, assim como para a predição da morte cardíaca súbita. A análise do desvio padrão do intervalo QT proporciona informação sobre a dispersão (temporal ou espacial) da repolarização ventricular, entretanto a influencia do ruído provoca erros na detecção do final da onda T que são apreciáveis devido ao fato dos valores pequenos do desvio padrão do QT tanto para sujeitos patológicos e quanto para os sãos. O objetivo geral desta tese é melhorar os métodos de processamento do sinal de ECG ambulatorial usando inteligência computacional, especificamente os métodos relacionados com a detecção do final da onda T, e os de reconhecimento morfológico de batimentos que invalidam a análise da variabilidade do intervalo QT. É proposto e validado (em termos de exatidão e precisão) um novo método e algoritmo para estimar o final da onda T baseado no calculo de áreas de trapézios, empregando sinais da base de dados QT da *Physionet*. O desempenho do método proposto foi testado e comparado com um dos métodos mais usados para detectar o final da onda T: o método baseado no limiar na primeira derivada. O método de inteligência computacional sugerido combina a extração de características usando o método de análise de componentes principais não lineares e a rede neural de tipo perceptron multicamada. O método de áreas de trapézios teve um bom desempenho em condições ruidosas e não depende de nenhum limiar empírico, sendo adequado para situações com níveis de elevados de ruído de banda larga. O método de reconhecimento morfológico de batimentos foi avaliado com sinais ambulatoriais com e sem artefatos pertencentes a bases de dados de prestígio internacional, e mostrou um bom desempenho.

Palavras-chave: 1. ECG ambulatorial. 2. Ruído. 3. Artefatos. 4. Onda T.

ABSTRACT

Ambulatory monitoring of the electrocardiogram (ECG) allows to follow the patient's daily activities during periods of 24 hours (or more) making possible the study of cases with potentially fatal arrhythmic episodes. However, the major technological challenge that this type of monitoring faces is the loss of information due to the presence movement-related noise and artefacts. The analysis of the QT interval of the surface electrocardiogram or ventricular depolarization and repolarization interval is a non-invasive technique with a high value for the diagnosis and prognostics of cardiopathies and neuropathies, as well as for the prediction of sudden cardiac death. The analysis of the QT-interval standard deviation provides information about the dispersion (time or spatial) of ventricular repolarization. However the presence of noise leads to errors in the detection of the T-wave end, which are non negligible due to small values of QT standard deviation in both pathological and healthy subjects. The main aim of this PhD thesis is to improve ambulatory ECG processing methods using computational intelligence, and specifically those involved in the detection of the T wave end and morphologic recognition of heartbeats, which could invalidate the QT interval variability analysis. A new approach and algorithm was proposed to identify the T-wave end, based on the computation of Trapezium's areas. The method was validated (in terms of accuracy and repeatability), using signals from the Physionet QT Database. The performance of the proposed method in noisy conditions has been tested and compared with one of the most used approaches for estimating the T-wave end point, based on the threshold on the first derivative. The suggested computational intelligence method combines the features extraction using non-linear principal components analysis method and the multilayer perceptron neural network. The trapezium-based approach showed a good performance in noisy conditions and does not rely on any empirical threshold. It is adequate for use in scenarios where the levels of broadband noise are significant. The beats morphologic recognition methods were evaluated using ambulatory signals with and without artefacts from international prestigious databases, showing a good performance.

Keywords: 1. Ambulatory ECG. 2. Noise. 3. Artefacts. 4. T-wave.

LISTA DE FIGURAS

CAPÍTULO 1

FIGURA 1.1	Ilustração das diversas ondas e dos intervalos RR e QT no eletrocardiograma.....	15
FIGURA 1.2	Ruído de banda larga de origem muscular superposto ao sinal de ECG.....	17
FIGURA 1.3	Sistema de condução da atividade elétrica do coração.....	18

CAPÍTULO 2

FIGURA 2.1	Etapas de processamento para obtenção de séries temporais RR e RTe.....	23
FIGURA 2.2	Estrutura eletrônica dos eletrodos.....	25
FIGURA 2.3	(a) Estrutura amplificadora formada por dois seguidores não acoplados em AC e um amplificador diferencial integrado, (b) Estrutura modelada de (a), que introduz as fontes de ruídos.....	26
FIGURA 2.4	Flutuações da linha base devido a: (a) desbalanceamento dos potenciais de contato dos eletrodos (b) artefatos de movimento no sinal de ECG.....	29
FIGURA 2.5	(a) Diagrama de blocos de um detector de QRS não sintático (b) Distribuição genérica da saída do pré-processador. FP: Falsos positivos, FN: Falsos negativos, TP: Verdadeiros positivos TN: verdadeiros negativos (TN).....	32
FIGURA 2.6	Alternativas de funções para detectar a morfologia da onda T	34
FIGURA 2.7	Janela de observação da onda T.....	35
FIGURA 2.8	Segmentação de batimentos por 2 métodos diferentes. L é a distância temporal entre duas ondas R consecutivas. Sombreado aparece o segmento selecionado por cada método.....	37
FIGURA 2.9	Mapeamento do espaço de entrada para o espaço de propriedades.....	43
FIGURA 2.10	Algoritmo para extração de componentes com KPCA.....	46
FIGURA 2.11	Arquitetura da rede MLP.....	52
FIGURA 2.12	Dois conjuntos de dados de diferentes classes linearmente separáveis (a) regiões de decisão (b) hiperplano ótimo no sentido da máxima margem.....	58
FIGURA 2.13	Vetores, suporte e separabilidade com hiperplanos canônicos.	59

CAPÍTULO 3

FIGURA 3.1	Etapas de um sistema classificador de sinais de ECG.....	63
FIGURA 3.2	Matriz de confusão para avaliar o rendimento na saída dos classificadores (MLP, LVQ, RBF, SVM) para cada método de extração de características (DCT, PCA, KPCA).....	68
FIGURA 3.3	Matriz de confusão para avaliar o rendimento na saída dos classificadores (MLP, LVQ, RBF, SVM) para cada método de extração de características (DCT, PCA, KPCA).....	76

CAPÍTULO 4

FIGURA 4.1	Método de limiar na primeira derivada aplicada a uma onda T positiva.....	86
FIGURA 4.2	Determinação do final da onda T (para uma onda monofásica) mediante o calculo das áreas dos trapézios formados por dois pontos fixos e dois moveis (x_i, y_i) e (x_r, y_r).....	88
FIGURA 4.3	Determinação do ponto T_e para uma morfologia bifásica (positivo-negativa).....	90
FIGURA 4.4	Indeterminação do ponto T_e devido a artefatos em um segmento do registro: (a) sel213 e (b) sel223, da base de dados QTDB.	91
FIGURA 4.5	Erro relativo percentual modular versus nível de ruído para os algoritmos: TRA e THD. O valor dos diversos testes de hipótese (T-student) para cada algoritmo com respeito ao algoritmo dos trapézios está demarcado por uma probabilidade $p \leq 8,9 \times 10^{-7}$	98
FIGURA 4.6	Exemplo de um batimento da QTDB (registro sel32, primeiro canal) com diversos níveis de ruído: (a) Batimento original, (b) Versão filtrada passa-faixa de (a), (c) 3% de ruído de ATWP, (d) 5% de ruído de ATWP, (e) 10 % de ruído de ATWP e (f) 20% de ruído de ATWP.	101
FIGURA 4.7	Exemplo de um batimento da QTDB (registro sel32, primeiro canal) com diversos níveis de ruído: (a) Batimento original, (b) Versão filtrada passa-faixa de (a), (c) 3% de ruído de A_{TWP} , (d) 5% de ruído de A_{TWP} , (e) 10 % de ruído de A_{TWP} e (f) 20% de ruído de A_{TWP} .	102

LISTA DE TABELAS

CAPÍTULO 2

TABELA 2.1	Funções de ativação por tipo de neurônios.....	48
TABELA 2.2	Algumas funções que satisfazem o teorema de Mercer.....	61

CAPÍTULO 3

TABELA 3.1	Métodos de extração de características mais utilizados em sinais eletrocardiográficos.....	65
TABELA 3.2	Registros selecionados para a classificação.....	66
TABELA 3.3	Matriz de confusão do classificador DCT + MLP (treinamento)	69
TABELA 3.4	Matriz de confusão do classificador DCT + MLP (validação)...	69
TABELA 3.5	Matriz de confusão do classificador PCA + MLP (treinamento)	69
TABELA 3.6	Matriz de confusão do classificador PCA + MLP (validação)....	70
TABELA 3.7	Matriz de confusão do classificador KPCA + MLP (treinamento)	70
TABELA 3.8	Matriz de confusão do classificador KPCA + MLP (validação).	70
TABELA 3.9	Tempo de execução (s) dos classificadores.....	70
TABELA 3.10	Serie 100 do MIT-BIH DB.....	72
TABELA 3.11	Serie 200 do MIT-BIH DB.....	72
TABELA 3.12	Classificador 10 FE - DCT.....	77
TABELA 3.13	Classificador 15 FE - DCT.....	78
TABELA 3.14	Classificador 20 FE – DCT.....	78
TABELA 3.15	Classificador 10 FE – PCA.....	78
TABELA 3.16	Classificador 15 FE – PCA.....	78
TABELA 3.17	Classificador 20 FE - PCA.....	78
TABELA 3.18	Classificador 10 FE - KPCA.....	79
TABELA 3.19	Classificador 15 FE - KPCA.....	79
TABELA 3.20	Classificador 20 FE – KPCA.....	79
TABELA 3.21	Classificador DCT + MLP.....	80
TABELA 3.22	Classificador PCA + MLP.....	80
TABELA 3.23	Classificador KPCA + MLP.....	80
TABELA 3.24	Resultados do Test de McNemar para todos os classificadores e batimentos da base de dados. O método de agrupamento em todos os casos é MLP.....	81

CAPÍTULO 4

TABELA 4.1	Média (me) e desvio padrão (sd) das diferenças entre as anotações automáticas e dos cardiologistas para os dois métodos e os dois critérios de avaliação. TRA: Áreas de Trapézios, THD: Limiar na primeira derivada.....	97
------------	--	----

TABELA 4.2	Comparação dos erros relativos percentual modular (ENX) entre o algoritmo dos Trapézios e o algoritmo THD (fator de limiar igual a 10%).....	99
------------	--	----

LISTA DE ABREVIÇÕES

BB	Método de melhor batimento por registro (<i>Best Beat per Record</i>)
BL	Método de melhor derivação por registro (<i>Best Lead per Record</i>)
CENPIS	Centro de Estudos de Neurociências e Processamento de Imagens
DCT	Transformada discreta do cosseno
E	Especificidade
EC	Extração de características
ECG	Eletrocardiograma
EMG	Eletromiograma
FCM	Fuzzy C-Means
FIR	Filtro de resposta a impulso finita
FN	Falso negativo
FP	Falso positivo
HRV	Variabilidade da Frequência Cardíaca (<i>Heart Rate Variability</i>)
IAM	Infarto de miocárdio agudo
KLT	Transformada de Karhunen-Loeve
KPCA	Análise de componentes principais não linear ou Kernel PCA
LPC	Coeficientes de predição linear
LVQ	Quantificação vetorial adaptativa (<i>Learning Vector Quantization</i>)
MITDB	Base de dados do MIT
MLP	Perceptron multicamadas
PCA	Análise de componentes principais
PP	Intervalo PP
QRS	Complexo que abrange as ondas Q, R e S do eletrocardiograma
QT	Intervalo QT
QTD	Variabilidade espacial do intervalo QT
QTDB	Base de dados QT
QTV	Variabilidade temporal do intervalo QT (<i>QT Variability</i>)
RR	Intervalo RR
RV	Repolarização ventricular
S	Sensibilidade
SCD	Morte cardíaca súbita (<i>Sudden Cardiac Death</i>)
SD	Desvio padrão (<i>Standard Deviation</i>)
SOM	Mapas auto-organizados
SVM	Máquina de Suporte Vetorial
THD	Método ou algoritmo de limiar na primeira derivada
TRA	Método ou algoritmo dos Trapézios
VN	Verdadeiro negativo
VP	Verdadeiro positivo
VPP	Valor preditivo positivo
WT	Transformada Wavelet

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	17
1.1 Motivação do trabalho e Revisão Bibliográfica	17
1.2 Objetivos	21
1.2.1 Objetivo geral	21
1.2.2 Objetivos específicos	21
1.3 Contribuições do trabalho	22
1.4 Limitações da Tese	22
1.5 Estrutura do trabalho	23
CAPÍTULO 2 - ESTADO DA ARTE	25
2.1 Fontes de ruídos no ECG	26
2.1.1 Ruído de eletromiograma	26
2.1.2 Ruído de eletrodo	26
2.1.3 Ruído do sistema de medida	28
2.2 Flutuações da linha base	30
2.2.1 Artefatos de movimento	31
2.3 Pré-processamento do sinal de ECG	32
2.4 Detecção de pontos característicos	33
2.4.1 Detecção de ondas R	33
2.4.2 Detecção de pontos característicos da onda T	35
2.4.2.1 Filtragem	35
2.4.2.2 Identificação da morfologia	36
2.4.2.3 Estimação do final da onda T (Te)	38
2.5 Segmentação e normalização de batimentos	39
2.6 Extração de características	41
2.6.1 Características morfológicas	41
2.6.2 Momentos estatísticos	41
2.6.3 Coeficientes de predição linear (LPC)	42
2.6.4 Métodos baseados em transformadas	42
2.6.4.1 DCT	43
2.6.4.2 PCA linear	44
2.6.4.3 Kernel PCA	44
2.6.5 Outras técnicas	48
2.7 Redes Neurais Artificiais para agrupamento de batimentos	48
2.7.1 Arquitetura de redes neurais	50
2.7.2 Perceptron simples	52
2.7.3 Perceptron multicamadas (MLP)	54
2.7.4 Funções de base radial (RBF)	56
2.7.5 Quantificação vetorial adaptativa (LVQ)	58
2.8 Máquinas de Suporte Vetorial (SVM)	59
2.9 Limitações do estado da arte: Resumo	63
2.9.1 Sobre os métodos de processamento do ECG ambulatorial no geral ...	63
2.9.2 Sobre os métodos da obtenção (e validação) da final de onda T	64
2.9.3 Sobre os métodos de reconhecimento morfológico de artefatos	64
CAPÍTULO 3 - RECONHECIMENTO MORFOLOGICO DE ARTEFATOS	65
3.1 Introdução	65

3.2 Caracterização de métodos de extração de características	68
3.2.1 Materiais e métodos	68
3.2.2 Resultados	71
3.3 Caracterização do desempenho conjunto: extração-agrupamento	73
3.3.1 Materiais e métodos	73
3.3.1.1 <i>Sinais usados</i>	73
3.3.1.2 <i>Etapas do sistema classificador de batimentos</i>	75
3.3.1.3 <i>Comparação dos métodos de classificação</i>	78
3.3.2 Resultados da avaliação parcial	79
3.3.3 Resultados da avaliação global	81
3.3.3.1 <i>Resultados da comparação dos métodos de classificação</i>	82
3.3.4 Avaliação dos recursos computacionais	83
3.4 Discussão	83
3.5 Considerações finais	84
CAPÍTULO 4 - DETECÇÃO DO FINAL DA ONDA T	86
4.1 Introdução	86
4.1.1 Método de limiar na primeira derivada	88
4.2 Método e algoritmo de áreas de trapézios	89
4.3 Avaliação do método dos trapézios: materiais e métodos	92
4.3.1 Base de dados, parâmetros e critérios de avaliação	92
4.3.2 Procedimento de avaliação	95
4.4 Resultados	99
4.5 Discussão	100
4.6 Considerações finais	104
CAPÍTULO 5 - CONCLUSÕES	106
REFERÊNCIAS	109
OBRAS CONSULTADAS	117

CAPÍTULO 1- INTRODUÇÃO

1.1 Motivação do trabalho e Revisão Bibliográfica

A monitorização ambulatorial do ECG permite seguir as atividades cotidianas do paciente possibilitando o estudo de casos que pudessem ter episódios arrítmicos fatais, incluindo morte cardíaca súbita (SCD, *Sudden Cardiac Death*). A causa principal da SCD é o infarto agudo de miocárdio (IAM). Estima-se que aproximadamente 75% dos pacientes que faleceram subitamente tiveram um infarto de miocárdio assintomático (SOCIEDADE BRASILEIRA DE CARDIOLOGIA, 2004). Aproximadamente 23% dos infartos de miocárdio são assintomáticos (FISHER, 1999).

É sabido (CINCA, 1980) que a isquemia miocárdica (fase prévia do IAM) provoca mudanças na amplitude, morfologia e duração dos potenciais de ação das células miocárdicas causando instabilidade elétrica nestas células, a qual é refletida no sinal de ECG (Figura 1.1) e nas séries temporais extraídas dele, por exemplo, nas series RR (entre picos de ondas R consecutivas) e QT (do início da onda Q ao final da onda T).

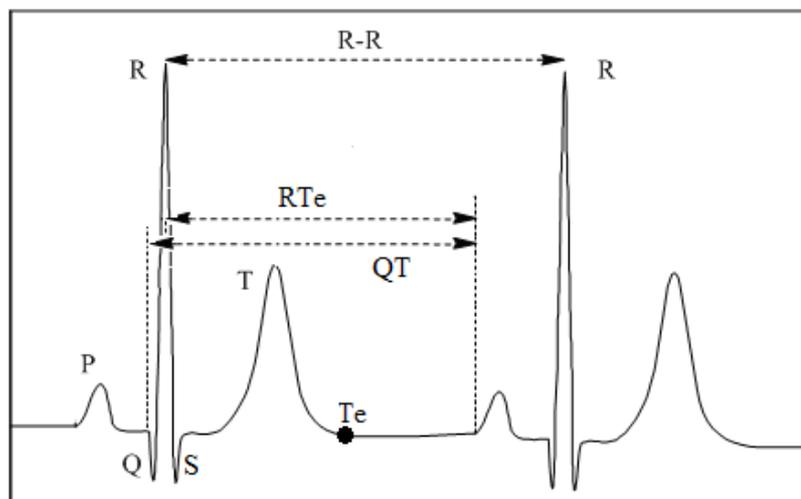


Figura 1.1 - Ilustração das diversas ondas e os intervalos RR e QT no eletrocardiograma.

O RR reflete a atividade no nodo sinoatrial (SA) enquanto que a duração e a morfologia do intervalo QT são influenciadas pelas características da contração ventricular, cujo conhecimento é de vital importância. As duas características essenciais da onda R são: grande amplitude e transições bruscas facilitam sua fácil

detecção. Nos últimos anos foram desenvolvidos diversos métodos e algoritmos para estimar o pico da onda R ou ponto R (PAHLM e SÖRNMO, 1984), (FRIESEN, 1990) (KÖHLER, 2002) o qual facilitou um amplo estudo das variações fisiológicas e patológicas do intervalo RR. O mesmo não se pode afirmar para a estimação do ponto final da onda T (Te), e dos intervalos associados, QT ou RTe (desde o ponto R ao ponto Te) (TIKKANEN et al., 1999). O Te é um dos pontos mais difícil de determinar devido à suave transição do sinal ao redor dele, eventualmente contaminado por ruído.

A diminuição da variabilidade (desvio padrão) do intervalo RR entre batimentos consecutivos (HRV: *Heart Rate Variability*) foi sugerido como um preditor independente de SCD em pacientes pós-infarto (KLEIGER et al., 1987). O alongamento do intervalo QT foi descrito como um preditor de morte súbita em pacientes pós-infarto (SCHWARTZ, 1978) e arritmias malignas (SCHWARTZ, 2003). A variabilidade temporal (batimento a batimento) do intervalo QT (QTV: *QT variability*) ou espacial (QTD: *QT Dispersion*) são medidas da heterogeneidade da repolarização ventricular e tem sido de grande relevância na predição de taquicardia e fibrilação ventricular a SCD (HAIGNEY, 2004).

Os valores do desvio padrão das séries QT são pequenos (menores de 20ms) tanto para sujeitos sãos quanto para sujeitos patológicos. Isso cria um desafio para determinar o ponto Te com uma exatidão e precisão tal que seja possível diferenciar pequenas margens de variabilidade. Por exemplo, se o período de amostragem do sinal de ECG for igual a 4 ms, um erro de detecção de 4 amostras (16ms) introduziria um erro significativo no diagnóstico usando a variabilidade do QT.

Para melhorar a exatidão e precisão da detecção do ponto Te, nos últimos vinte anos vários métodos e algoritmos têm sido propostos baseados em intersecção de linhas (FERRETI et al., 1992), limiar na amplitude (MCLAUGHLIN, 1995) ou na primeira derivada (LAGUNA, 1990) da onda T, cálculo de: distâncias (HELFENBEIN et al., 2006), ângulos (DASKALOV, 1999), e áreas (ZHANG et al., 2006); correlação com um padrão (LAST, 2004), uso de: modelos matemáticos (VILA et al., 2000) e a transformada *wavelet* (MARTINEZ et al., 2004), entre outros. De todos eles, os mais reportados nos últimos cinco anos são os algoritmos baseados na transformada *wavelet*, os quais continuam usando os critérios de limiar nas diferentes escalas da *wavelet*, o qual aumenta sua sensibilidade ao ruído.

Em situações de alta atividade física, o ruído devido à contrações musculares constitui a principal fonte de erro na estimação do ponto T_e (Figura 1.2) e portanto, da análise da QTV e QTD. Este tipo de ruído possui características espectrais de banda larga e pode ser modelado como ruído branco gaussiano de media zero, como feito em FRIESEN(1990). A análise da QTV em presença de ruído de banda larga requer uma detecção exata do final da onda T devido à pequena variabilidade do intervalo QT (ou RT).

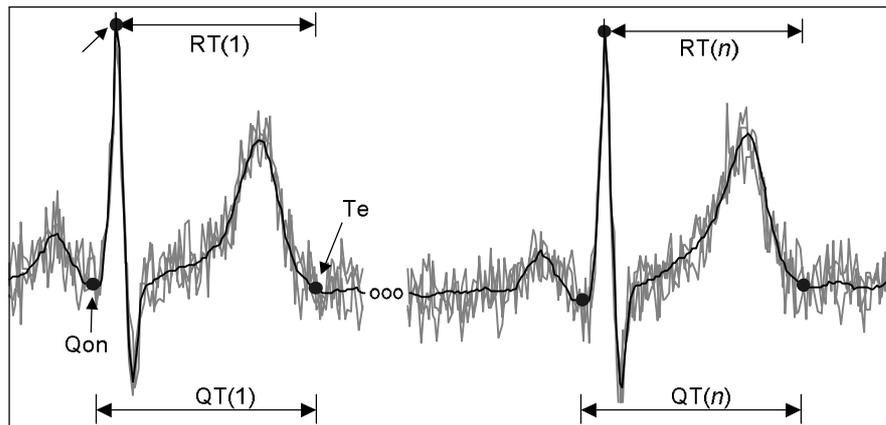


Figura 1.2 - Ruído de banda larga de origem muscular superposto ao sinal de ECG.

A melhora da exatidão e a precisão na estimação do ponto T_e em presença deste tipo de ruído e de outros que afetam ao sinal de ECG ambulatorial é um dos tópicos de investigação ainda aberto.

O grande desafio da monitorização ambulatorial é a presença de artefatos devido a causas de origem técnica e fisiológica (VÁZQUEZ, 2001). Os artefatos no ECG são perturbações que afetam (parcial ou totalmente) à morfologia do sinal eletrocardiográfico. Os algoritmos de detecção de pontos no ECG mais sofisticados falham em presença de artefatos, provocando falsos positivos (artefatos detectados como batimentos) e falsos negativos (batimentos não detectados) nas séries temporais RR, QT e outras.

Para que a análise da HRV ou QTV seja válida, segundo a comissão denominada como *Task Force* (TASK FORCE, 1996), deve-se verificar que cada onda R detectada corresponda a um batimento completo que tenha sido originado no nodo sinoatrial e onde não exista nenhum tipo de bloqueio da atividade elétrica quando o impulso elétrico transite pelos ramos direito e esquerdo do feixe de His e suas correspondentes ramificações finais ou fibras de Purkinje (Figura 1.3). Caso contrário e para fins de estudos da HRV e a QTV, o batimento será considerado

como um artefato localizado nas posições correspondentes das séries temporais RR ou QT, respectivamente, e deveria ser excluído da análise. Os artefatos no ECG podem ser de origem fisiológica e técnica (por exemplo, os artefatos devido ao movimento do paciente). Para atingir o critério anterior é necessário realizar um reconhecimento morfológico automatizado, batimento a batimento no sinal de ECG, que valide os batimentos validos (normais) e não validos (a partir daqui denominados de artefatos). Por exemplo, um extra-sístoles supraventricular possui um padrão muito parecido a um batimento normal, mas não possui onda P. Portanto, se nesse batimento fossem obtidos os pontos R e Te, e posteriormente o intervalo RTe, estar-se-ia cometendo um erro. O mesmo ocorreria com um artefato de origem técnica que tenha uma morfologia parecida a uma onda R, e seja detectado como tal.

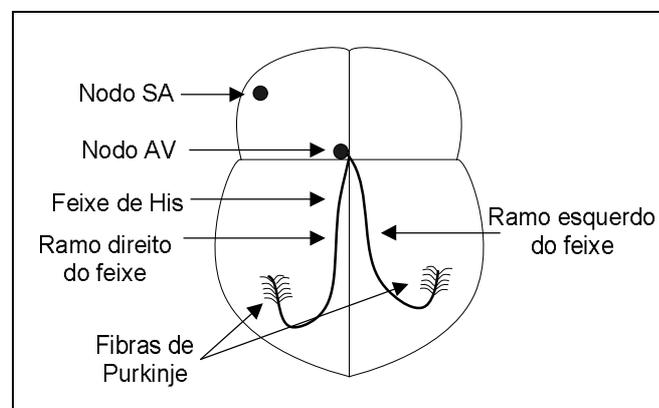


Figura 1.3 - Sistema de condução da atividade elétrica do coração.

A monitorização ambulatorial expôs um problema que ainda não está completamente resolvido: a obtenção de um diagnóstico que seja robusto à presença de artefatos no ECG, e de falsos positivos e negativos nas séries temporais RR e QT.

Até o presente, muitos trabalhos foram desenvolvidos para o reconhecimento morfológico de batimentos especialmente para diagnosticar diversos tipos de arritmias atriais ou ventriculares (NADAL, 1993; DIMINSKI, 2000; WANG, 2001; ROJAS, 2002; WOLF, 2003; CEYLAN, 2007). A metodologia de validação emprega sinais reais, mas não são usados sinais sintéticos. Visto que o uso destes sinais permite a inclusão de artefatos (fisiológicos e técnicos) de múltiplas morfologias em um batimento, que não são observados nas bases de dados reais disponíveis. Apesar de que os sinais de ECG de bases de dados constituem situações reais, a validação robusta e sensível a rápidas mudanças morfológicas entre batimentos

requer uma ampla variedade de morfologias, que também não estão disponíveis nestas bases de dados de sinais. Não foi encontrada nenhuma publicação para classificar batimentos que constituírem artefatos para efeitos da análise da HRV e a QTV. Este tipo de enfoque não aparece reportado na bibliografia.

Os aspectos mencionados nos parágrafos anteriores inspiraram a ideia de desenvolver diversos métodos de processamento de sinal, usando métodos de inteligência computacional, que sejam mais exatos e robustos em presença de elementos que contaminem a informação diagnóstica presente no sinal de ECG nos diversos cenários da monitorização ambulatorial. Especificamente esta tese centra seu interesse em resolver dois problemas relacionados com a análise do intervalo de repolarização ventricular durante monitorização ambulatorial do ECG. O primeiro é a pesquisa de um método para o reconhecimento de batimentos que constituírem artefatos para efeito do estudo de sua variabilidade. Para essa finalidade são usadas técnicas de inteligência computacional. O segundo é a pesquisa de um algoritmo para a detecção do final da onda T, que seja pouco sensível à presença de ruído branco gaussiano.

1.2 Objetivos

1.2.1 Objetivo geral

- Aperfeiçoar os métodos de processamento do sinal de ECG ambulatorial usando inteligência computacional.

1.2.2 Objetivos específicos

1. desenvolver um método mais eficiente para a identificação do final da onda T no ECG em condições de monitorização ambulatorial, especialmente em presença de ruído de banda larga.
2. desenvolver um método mais eficiente para o reconhecimento morfológico de artefatos presentes no sinal ECG usando técnicas de inteligência computacional.

1.3 Contribuições do trabalho

As contribuições do trabalho são:

- Um novo método para detectar o final da onda T com uma alta exatidão e um alto desempenho com respeito ao ruído.
- Um novo método para reconhecer artefatos usando técnicas de inteligência computacional.

Adicionalmente, os resultados desta tese podem ser utilizados pelos fabricantes de equipamentos médicos de monitorização, ambulatórios e estacionários. A utilidade e impacto da presente pesquisa são fundamentalmente sociais, pois os resultados ao serem aplicados contribuem em melhorar o diagnóstico de cardiopatias e neuropatias. Existe também uma contribuição econômica no sentido de que o diagnóstico cardíaco pode ser estendido usando sinais de baixo custo.

Esta pesquisa foi possível graças à colaboração interdisciplinar de diferentes centros e instituições, entre os que se encontram: o Centro de Estudos de Neurociências e Processamento de Imagens (CENPIS) e Sinais da Faculdade de Engenharia Elétrica da Universidade do Oriente de Cuba, o Hospital “Saturnino Lora” de Santiago de Cuba, a Universidade Federal do Pará, a Universidade Politécnica da Catalunha e a Universidade do Estado do Amazonas.

1.4 Limitações da Tese

A tese não tem a finalidade de gerar com um produto de software integro e, portanto, não foi objetivo a implementação nem a automatização de todas as etapas de processamento relacionadas. Na tese se pretende caracterizar com a maior exatidão e confiabilidade possível os dois métodos propostos para estimação do final da onda T e a classificação de batimentos de ECG em duas classes: normais e artefatos.

Para esses efeitos, é assumida a existência de um método infalível para estimar os pontos R no ECG o qual é um passo prévio requerido para detectar a onda T e para segmentar os batimentos a classificarem. Assim, são usadas as marcações dos pontos R realizados pelos especialistas nas bases de dados

correspondentes. Este procedimento pressupõe que os resultados obtidos só dependem dos métodos propostos na tese e não do método de detecção da onda R. Obviamente o desenvolvimento de um futuro produto tecnológico necessitaria automatizar a etapa de detecção de ondas R.

Para validar os métodos de detecção da onda T, foram descartados alguns batimentos de baixa qualidade da base de dados QTDB, nos quais o segmento próximo ao ponto final da onda T tinha muitos artefatos. Esse procedimento é realizado em outros trabalhos (ZHANG, 2006; MARTÍNEZ, 2010) para evitar a aparição de erros aberrantes.

1.5 Estrutura do trabalho

Neste texto serão descritos os aspectos básicos que envolverão (direta ou indiretamente) o tema da tese. O texto iniciará no segundo capítulo e revisa os principais conceitos da monitorização ambulatorial do ECG e de suas etapas de aquisição e processamento. Apesar de que a ênfase desta tese esta focalizada no processamento e não na aquisição do ECG, o melhor conhecimento das causas que provocam as interferências, ruídos e artefatos, é muito importante para reduzir seus efeitos. O resultado final da etapa de aquisição é entregar um sinal eletrocardiográfico, por isso serão descritas as características dos sinais adquiridos por aparelhos comerciais e que formam parte de diversas bases de dados de prestigio internacional que foram utilizadas no trabalho experimental da tese. A seguir, serão descritas as principais técnicas de processamento para detecção de pontos característicos e especialmente no final de onda T, que é o ponto mais problemático de obter para sinais de ECG ambulatoriais. Finalmente serão revisadas as principais técnicas de extração de características e de agrupamentos de batimentos que são usadas para reconhecer batimentos.

No capítulo três são caracterizados os principais métodos de extração de características e agrupamento de batimentos, para classificar batimentos com artefatos a efeitos dos estudos da variabilidade da frequência cardíaca.

No capítulo quatro é proposto e descrito um novo método, baseado no calculo de áreas de trapézios, para estimar o final da onda T, assim como seu algoritmo associado. A seguir, se avalia e analisa seu desempenho em condições ruidosas, e se compara com um método similar baseado em limiar (LAGUNA, 1990).

Finalizando o texto da tese, no capítulo cinco são destacadas as conclusões e recomendações de trabalhos futuros.

Nos anexos A e B são mostrados a composição dos sinais usados para validação dos métodos propostos. No anexo C é mostrado o índice de especificidade obtido para cada classificador depois de avaliar todas as combinações de classificadores com 4000 batimentos procedentes de uma base de dados real de amplo uso internacional. Nos anexos D, E e F são detalhados os valores obtidos dos tempos de extração dos vetores de características para cada um dos métodos de extração avaliados experimentalmente. Finalmente no anexo G, é apresentado um desenvolvimento secundário desta tese que é um novo método e sua ferramenta associada para gerar batimentos sintéticos de forma controlada.

CAPÍTULO 2 - ESTADO DA ARTE

A monitorização ambulatorial ou eletrocardiografia de longa duração foi introduzida por Norman Holter em 1947 e por essa razão foi denominada de monitorização Holter. Esta monitorização abrange as seguintes etapas: (1) aquisição, (2) processamento e (3) diagnóstico. A ênfase deste trabalho está na etapa (2) com o objetivo de propiciar as condições para aumentar a exatidão na etapa (3).

Na Figura 2.1 são mostradas as diferentes etapas de processamento para a obtenção de séries temporais RR e RTe, com vistas a um diagnóstico baseado na análise das variabilidades do RR e RT, respectivamente. O processamento inclui o uso de métodos de inteligência computacional para identificar os batimentos validos ou normais (TASK FORCE, 1996), o qual justifica a existência das etapas de segmentação, extração de características, e agrupamento. Os batimentos que forem reconhecidos como artefatos (fisiológicos ou técnicos) serão excluídos da análise. Este processo é de grande importância para atingir um diagnóstico preciso.

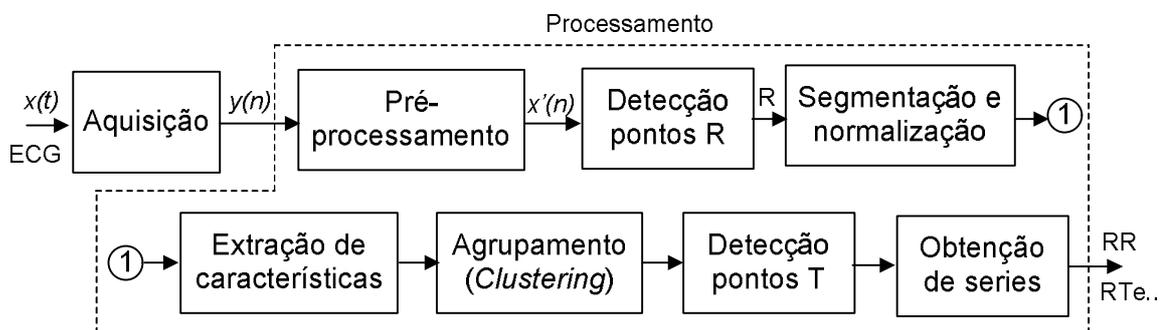


Figura 2.1 - Etapas de processamento para obtenção de séries temporais RR e RTe.

A etapa de aquisição inclui, basicamente, funções de processamento analógico (filtragem analógica, amplificação e proteção contra as sobre-tensões do desfibrilador) e conversão analógica digital do sinal contínuo de ECG, $x(t)$. O sinal discreto adquirido $y(n)$ poderá ser apresentado como a combinação de elementos espúrios segundo a seguinte equação:

$$y(n) = x(n) + r(n) + b(n) + i(n) \quad (2.1)$$

Onde:

- $x(n)$ é o sinal eletrocardiográfico produzido pela atividade cardíaca que se deseja analisar;
- $r(n)$ é o ruído geral, incluindo os artefatos. No item 2.1 serão descritas as principais fontes de ruído que afetam o ECG;
- $b(n)$ são as flutuações da linha base. No item 2.2 serão descritas as causas destas flutuações;
- $i(n)$ é a Interferência da rede elétrica, tipicamente de 60Hz no Brasil.

Em todos os casos n representa o índice temporal discreto.

A qualidade do sinal registrado dependerá, em grande parte, das características do sistema de aquisição.

2.1 Fontes de ruídos no ECG

As principais fontes de ruídos no sinal de ECG (FRIESEN, 1990) são:

- Ruído de eletromiograma devido às contrações musculares;
- Ruído de eletrodo;
- Ruído do sistema de medida.

2.1.1 Ruído de eletromiograma

O eletromiograma (EMG) é a principal fonte de ruído no registro de ECG quando adquirido sob exercícios físicos do paciente (PAUL, 2000). Sua origem são os potenciais de ação associados à atividade muscular dos músculos esqueléticos. As contrações musculares provocam ruídos na faixa de micro volts que são incrementados pelo amplificador. Os sinais resultantes das contrações musculares podem ser considerados como ruído gaussiano de média zero (FRIESEN, 1990). Os parâmetros típicos são: desvio padrão de até 10 por cento da amplitude pico a pico do ECG, e frequências de 0 Hz até 1000 Hz no ECG superficial.

2.1.2 Ruído de eletrodo

Os eletrodos são os primeiros e principais elementos na cadeia de medida. Portanto, o ruído que pode ser gerado nesse elemento adquire especial importância.

O eletrodo converte as correntes iônicas, que são os mecanismos de condução dos sinais bioelétricos nos tecidos, em correntes eletrônicas. Esta conversão deve ser feita com a maior facilidade possível e, além disso, não deve perturbar o sinal a ser medido.

O eletrodo é formado por uma superfície metálica e um eletrólito em contato com a epiderme. Portanto, existem duas transições no trajeto do sinal bioelétrico entre o interior do corpo e o sistema de medida. A primeira é o contato entre a pele e o eletrólito e a segunda é o contato entre o eletrólito e a parte metálica do eletrodo. A presença dessas interferências provocará um intercâmbio iônico com a conseguinte aparição de um potencial de eletrodo, o qual tem uma grande variabilidade dependendo do material do eletrodo, por exemplo, para o eletrodo Ag/AgCl, de amplo uso no registro de biopotenciais, o potencial de contato é de aproximadamente 0,222 V. Esse potencial é alto e não apresenta problemas de biocompatibilidade. Na Figura 2.2 é mostrado o modelo mais universal da medida com dois eletrodos. No rodapé da figura é identificado cada um de seus componentes.

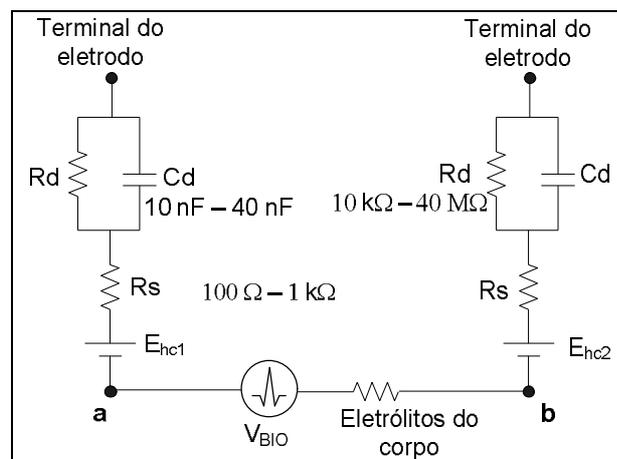


Figura 2.2 - Estrutura eletrônica dos eletrodos. R_s é a resistência série associada à resistência do eletrólito e aos efeitos da interface; R_d e C_d são os componentes da impedância associada com a interface eletrodo-eletrólito e os efeitos da polarização; C_d é a capacidade da dupla camada da carga; E_{hc} é o potencial do eletrodo (em inglês, *half-cell potential*).

Os valores de R_s , R_d e C_d dependem do material do eletrodo e em menor escala, do eletrólito e sua concentração. O biopotencial é o potencial elétrico a medir entre os terminais dos eletrodos que nesta tese seria o sinal do ECG.

A impedância da interface eletrodo-pele tem sido medida por diversos pesquisadores e foi possível comprovar que para um mesmo paciente a impedância apresenta variações dependendo da zona do corpo onde seja aplicado o eletrodo, do

tempo transcorrido desde sua aplicação, da composição do eletrólito e do estado da epiderme e sua preparação (DE TALHOUET e WEBSTER, 1996). O ruído oriundo dessas interfaces costuma ser maior que o ruído térmico associado à parte real da impedância, principalmente nas baixas frequências, apresentando um comportamento $1/f\alpha$ com α dentro do intervalo $(1,2 \leq \alpha \leq 2)$ (FERNÁNDEZ, 1992).

2.1.3 Ruído do sistema de medida

Uma das características mais importantes do sistema de medida é o nível de ruído que é introduzido na saída pelo amplificador. Este ruído será causado principalmente pelo amplificador de biopotenciais segundo a conhecida fórmula de *Friis*. Para analisar o ruído, primeiro deve ser selecionada a estrutura amplificadora. A partir daí, se calcula os efeitos de cada fonte de ruído na saída do amplificador usando os diversos tipos e modelos de ruído de cada componente do circuito (PALLÀS-ARENY e WEBSTER, 1999). Por exemplo, para analisar o ruído na saída, o amplificador da Figura 2.3a pode ser modelado como é mostrado na Figura 2.3b.

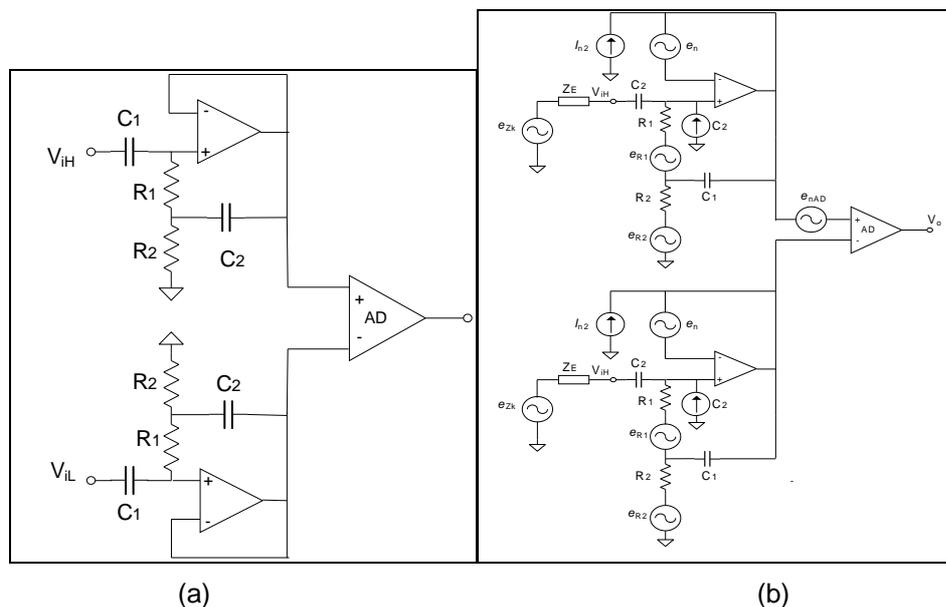


Figura 2.3 - (a) Estrutura amplificadora formada por dois seguidores não acoplados em AC e um amplificador diferencial integrado, (b) Estrutura modelada de (a), que introduz as fontes de ruídos.

No circuito da Figura 2.3b podem ser observadas todas as fontes de ruído consideradas. O ruído gerado pelos resistores é de origem térmica e sua densidade espectral de potência é $e_R^2(f) = 4kTRV^2/\text{Hz}$, sendo k a constante de Boltzman ($1,38 \times 10^{-23} \text{ J/K}$) e T a temperatura absoluta do resistor R . O ruído gerado pelos

amplificadores operacionais é modelado com uma fonte de tensão $e_n^2(f) = K_V^2 \left[1 + \frac{f_{CV}}{f} \right] V^2/\text{Hz}$ e uma fonte de corrente $I_n^2(f) = K_I^2 \left[1 + \frac{f_{CI}}{f} \right] A^2/\text{Hz}$, sendo f_{CV} y f_{CI} as frequências de esquina abaixo das quais começa a predominar o ruído de tipo *flicker* do componente. K_V e K_I determinam a tensão e a corrente de ruído, respectivamente, para frequências maiores da frequência de esquina, onde predomina o ruído térmico e impulsivo (*shot*) do componente.

Para analisar o ruído do amplificador diferencial integrado se pode utilizar um modelo similar, embora neste caso a contribuição das correntes de ruído é virtualmente nula por estarem conectadas às saídas dos seguidores às entradas do amplificador diferencial. Desta forma, a fonte de tensão de ruído se expressa como:

$$e_{nAD}^2(f) = K_{VAD}^2 \left[1 + \frac{f_{CVAI}}{f} \right] V^2/\text{Hz} \quad (2.2)$$

Para o cálculo da densidade espectral de ruído total à saída de um seguidor, usualmente, é considerado que todas as fontes de ruído não são correlacionadas. Assim, é obtida cada uma das funções de transferência correspondentes às diferentes fontes de ruído analisando cada um dos circuitos resultantes. A densidade espectral de ruído total à saída de cada seguidor será:

$$e_{buff}^2(f) = \left[\begin{aligned} &|H_{R1}(j2\pi f)|^2 e_{R1}^2 + |H_{R2}(j2\pi f)|^2 e_{R2}^2 + |H_{Zs}(j2\pi f)|^2 e_{Zs}^2 + \\ &+ |H_{e_n}(j2\pi f)|^2 e_n^2 + |H_{I_n}(j2\pi f)|^2 I_n^2 \end{aligned} \right] \quad (2.3)$$

A densidade espectral de ruído total à saída do amplificador diferencial (de instrumentação) é expressa por:

$$e_{AD}^2(f) = (2e_{buff}^2(f) + e_{nAD}^2(f))G_{AD}(f) \quad (2.4)$$

Os valores da densidade espectral de ruído do amplificador de biopotencial dependerão dos parâmetros de ruído dos componentes usados (resistores, capacitores, amplificadores), dos valores dos resistores, da margem de frequências considerada, da faixa de temperatura do trabalho do circuito, entre outros fatores. O cálculo do ruído à saída mostra que os níveis de ruído que podem existir na saída diminuem a resolução efetiva do conversor A/D usado para digitalizar o ECG (PALLÀS–ARENY e WEBSTER, 1999).

2.2 Flutuações da linha base

As flutuações da linha base são devidas às variações do potencial de contato dos eletrodos por diversas causas: respiração, sudoração, movimentos do corpo e maus contatos dos eletrodos. Segundo o modelo da Figura 2.2:

$$V_{ab} = (E_{hc1} - E_{hc2}) + V_{\text{BIO}} \text{ (Biopotencial)} \quad (2.5)$$

Onde:

- V_{ab} : é a tensão diferencial medida à saída dos eletrodos, a qual é aplicada à entrada do amplificador diferencial de biopotenciais;
- E_{hc1} e E_{hc2} : são os potenciais de contato dos eletrodos 1 e 2, respectivamente;
- V_{BIO} (Biopotencial): é o sinal ECG medido (da ordem de 1 a 5 mV).

Os potenciais E_{hc1} e E_{hc2} são apresentadas na Figura 2.2 como uma fonte de tensão contínua, mas na prática, eles representam flutuações de muita baixa frequência que dependem das atividades eletrolíticas, da respiração do paciente e do contato dos eletrodos. Desta forma, a equação 2.5 tem duas componentes: o sinal de ECG (biopotencial) e uma tensão de DC que resulta da diferença do potencial do contato dos eletrodos.

Como os eletrodos não estão colocados no mesmo lugar do tórax e, além disso, não estão 100% balanceados, então a diferença ($E_{hc1} - E_{hc2}$) não é constante nem zero. Isto é um sinal de baixa frequência que se acrescenta no ECG, denominado de flutuações da linha base (Figura 2.4a).

Estas flutuações estão na faixa de 0 a 0,5 Hz (na prova de esforço o conteúdo espectral é maior) (LAGUNA e SÖRNMO, 2005), que podem ser minimizadas mediante uma filtragem passa-altas, inicialmente analógica (implementada pelo amplificador de biopotencial acoplado em AC) e, posteriormente, digital (realizada pelo *software* de processamento).

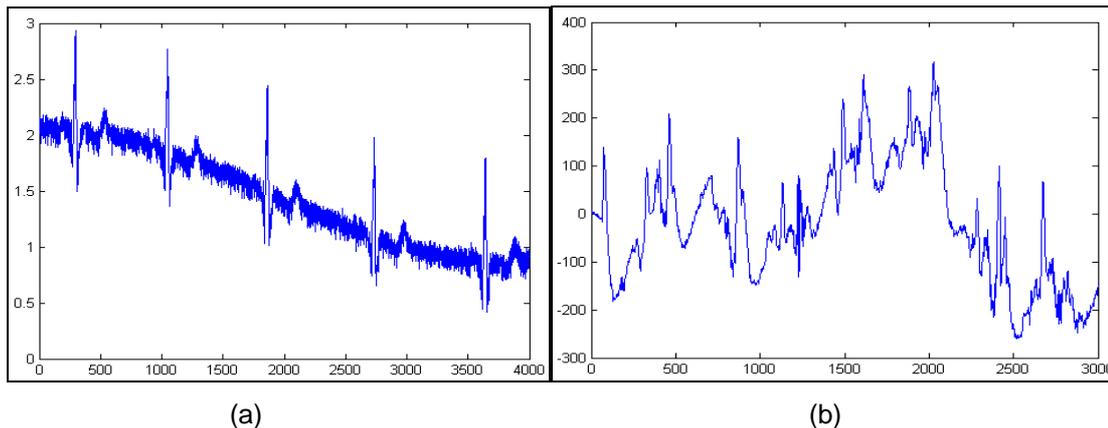


Figura 2.4 - Flutuações da linha base devido a: (a) desbalanceamento dos potenciais de contato dos eletrodos (b) artefatos de movimento no sinal de ECG.

2.2.1 Artefatos de movimento

Os artefatos de movimento podem ser originados nos próprios eletrodos ou na interface eletrodo-pele (DE TALHOUET, 1996) devido ao movimento relativo entre eletrodo e eletrólito, e as variações das propriedades da pele (impedância e potenciais internos), ou ambas as causas. Os artefatos produzem variações do potencial de contato e da impedância no conjunto eletrodo-pele (THAKOR, 1978) e constituem a principal causa de ocorrência dos artefatos de origem técnica.

Os artefatos de movimento estão caracterizados por saltos transitórios abruptos da linha base e ondas de grande amplitude (Figura 2.4b). Seu conteúdo espectral se solapa consideravelmente com o complexo PQRST. Ocorrem principalmente na faixa de 1 a 10 Hz (LAGUNA e SÖRNMO, 2005).

Apesar do grande esforço durante vários anos para encontrar métodos de medida que minimizem a influencia dos artefatos de movimento, ainda se continua adotando soluções clássicas, como a ligeira abrasão da pele e a ligeira punção da pele abaixo dos eletrodos (WEBSTER, 1998). Entretanto, essas soluções propostas irritam a pele e pode levar a um incremento da impedância da epiderme.

A solução em *hardware* atual para rebater os artefatos é o uso de sistemas de várias derivações (redundância espacial), visto que a presença de artefatos nem sempre é simultânea em todas as derivações se forem selecionadas adequadamente. Outra solução consiste em registrar o ECG em períodos de poucos artefatos, por exemplo, durante o sono (VÁZQUEZ, 2001). Do anterior, conclui-se, que a etapa de processamento continua sendo determinante na identificação e exclusão dos artefatos.

2.3 Pré-processamento do sinal de ECG

O objetivo do pré-processamento é reduzir ao máximo a presença de $r(n)$, $i(n)$ e $b(n)$ na equação 2.1 para que o sinal obtido $y(n)$ seja semelhante a $x(n)$.

Os métodos para reduzir $r(n)$, $i(n)$ e $b(n)$ podem ser diversos, e são baseados em técnicas de filtragem linear e não linear (HAMALAINEN, 1994). Os filtros lineares podem ser fixos (LAGUNA, 1990), adaptativos (JANE, 1992) ou variantes com o tempo (SÖRNMO, 1993).

A redução das flutuações da linha base requer uma filtragem passa-altas, a redução do ruído de alta frequência (eletromiograma, ruído de instrumentação, de contato dos eletrodos) e as interferências da rede elétrica requer uma filtragem passa-baixas, embora às vezes, neste último caso é usado um filtro supressor de banda. Além disso, para estimar as flutuações da linha base, sinal $b(n)$ é realizado um ajuste de curva (batimento a batimento) com as amostras de algum segmento isoeletrico (tipicamente, PR), posteriormente, uma interpolação entre os consecutivos segmentos isoeletricos e finalmente o sinal estimado $b(n)$ é subtraído da equação 2.1 para reduzir seu efeito.

O desempenho destes métodos está associado a um compromisso entre o nível de distorção do sinal (por exemplo, a forma da onda T, ou segmento ST) e o custo computacional.

A precisão do método de ajuste e interpolação dependerá muito da precisão na seleção dos pontos adequados e da ordem do ajuste polinomial. Na prática é um método exato para estimar as flutuações da linha base que forem muito irregulares, mas seu custo computacional é muito elevado quando são usados polinômios de alta ordem (LAGUNA e SÖRNMO, 2005).

Para conseguir um corte abrupto usando filtros lineares de tipo FIR (*Finite Impulse Response*) é necessário um número elevado de componentes, e por tanto o custo computacional é alto. Se forem usados filtros IIR (*Infinite Impulse Response*), seria necessário empregar menos coeficientes, mas a fase resultante seria não linear (sinal distorcido). A opção mais usada quando se trata com sinais *off-line* (caso dos aparelhos Holter) é usar um filtro IIR bidirecional (fase zero) com uma ordem que não necessita ser tão elevada (LAGUNA e SÖRNMO, 2005).

2.4 Detecção de pontos característicos

Para obter as séries temporais RR e RTe (Figura 2.1) é necessário estimar previamente os pontos característicos R e Te (final de T) batimento a batimento, a partir do sinal de ECG. Assim, o intervalo $RTe(n) = Te(n) - R(n)$, sendo n o número de batimento e, o intervalo $RR(n) = R(n) - R(n-1)$, sendo n e $n-1$ os batimentos atual e anterior, respectivamente. A seguir, serão revisados os fundamentos gerais da detecção de pontos característicos, especificamente os pontos R e Te, que são o alvo principal desta tese.

2.4.1 Detecção de ondas R

Dentro do complexo QRS a onda mais distintiva é a R. A detecção da onda R é um passo fundamental para identificar as demais ondas no ECG. Esta detecção pode ser realizada mediante técnicas de *hardware* ou *software*, que são baseadas nas duas características essenciais da onda R: grande amplitude e transições bruscas.

A detecção por *software* do complexo QRS é realizada por métodos não sintáticos, sintáticos e híbridos (KÖHLER, 2002). Os métodos sintáticos são baseados em aplicar regras sintáticas previamente definidas segundo a morfologia, duração e sequências possíveis de aparição das ondas do ECG. A partir destas regras mediante uma inferência gramatical no segmento do ECG analisado, são determinados os pontos característicos para cada tipo de padrão. Os métodos sintáticos são pouco empregados devido a sua baixa velocidade de detecção.

Os métodos não sintáticos são os mais empregados e estão baseados no esquema básico (Figura 2.5a) composto pelo pré-processador e a regra de decisão. No caso do complexo QRS o pré-processador ressalta a esses complexos, elimina o ruído, artefatos e demais ondas do ECG. O pré-processador consta de duas etapas: filtragem linear e transformação não linear.

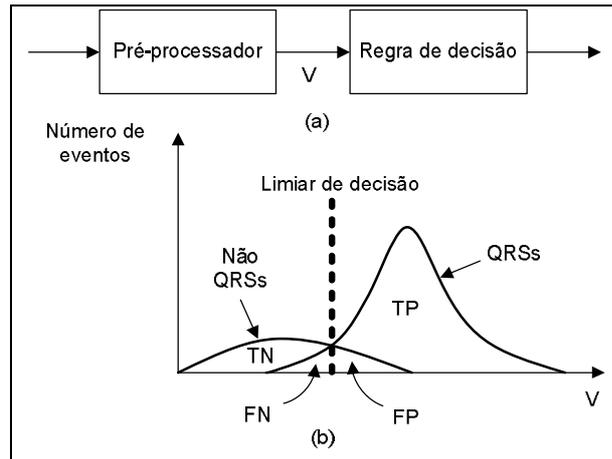


Figura 2.5 - (a) Diagrama de blocos de um detector de QRS não sintático (b) Distribuição genérica da saída do pré-processador. FP: Falsos positivos, FN: Falsos negativos, TP: Verdadeiros positivos TN: verdadeiros negativos (TN).

A filtragem linear possui características passa-faixas para preservar o conteúdo espectral do complexo QRS e rejeitar outras componentes, como por exemplo, as ondas P e T. A frequência central do filtro varia desde 10 a 25 Hz e a largura de banda desde 5 a 10 Hz. A deformação morfológica implícita na filtragem não é crítica para a detecção da onda R, diferente do que acontece com outras ondas do ECG. O alvo é melhorar a relação sinal-ruído para atingir um bom desempenho do detector.

A transformação não linear ressalta a onda R em relação com o ruído de fundo, transformando a onda R num simples pico positivo que é mais adequado para detectar segundo um limiar. Uma transformação não linear muito usada é a elevação ao quadrado do sinal filtrado passa-faixas. Todos os pré-processadores não incluem a transformação não linear, mas sim a etapa de filtragem.

A regra de decisão é a etapa encarregada de verificar se ocorreu ou não um QRS, quando o sinal de saída do pré-processador ultrapassa certo limiar (fixo ou adaptativo). Frequentemente é usado um bloco de processamento adicional para a determinação exata da posição da onda R candidata.

A Figura 2.5b mostra uma distribuição possível na saída V do pré-processador, dos eventos QRS certos ou falsos devidos a artefatos e ruído. A seleção do limiar de decisão define os batimentos perdidos (região de falsos negativos, FN) e os batimentos detectados erroneamente (região de falsos positivos, FP).

Os algoritmos de detecção de complexos QRS propostos nos últimos 30 anos são diversos e são baseados (KÖHLER, 2002):

1. Em derivadas e filtros digitais.
2. Na Transformada *Wavelet* (detecção de singularidade, bancos de filtros, métodos relacionados).
3. Em redes neurais.
4. Em outros métodos (filtros adaptativos, modelos ocultos de Markov, morfologia matemática, filtros adaptados, algoritmos genéticos, baseados na Transformada de Hilbert, transformações de comprimento e energia, métodos sintáticos, baseados em detecção de cruze por zero etc.).

Em um texto de tese fica impossível descrever os detalhes de cada um destes métodos, os quais aparecem descritos nas publicações originais. Em (KÖHLER, 2002) aparece uma extensa revisão dos métodos utilizados na década passada e suas correspondentes referências.

2.4.2 Detecção de pontos característicos da onda T

A estimação do ponto T_e é especialmente problemática devido ao fato do mesmo está localizado num segmento que possui uma suave e gradual transição com o segmento isoelétrico. De fato, a delimitação entre cardiologistas pode ter diferenças de até 100ms (CSE WORKING PARTY, 1985). Apesar destas dificuldades, o ponto T_e é muito importante para calcular a duração e a variabilidade (temporal e espacial) do intervalo QT. Os passos para determinar o ponto T_e são: (a) filtragem, (b) identificação da morfologia e (c) estimação do instante de ocorrência ou detecção.

2.4.2.1 Filtragem

A filtragem passa-baixas (FPB) é realizada para reduzir o ruído na onda T. A maior parte da energia da onda T é inferior a 15 Hz, razão pela qual a frequência de corte da FPB é fixada entre 15 e 40 Hz. A filtragem passa-altas (FPA) é usada para eliminar as flutuações da linha base; a frequência de corte está entre 0,05 e 0,5 Hz. Normalmente se costuma combinar ambos os filtros em um único filtro passa-banda.

Nos trabalhos de McLaughlin (1994, 1995) foi analisado o efeito do filtro digital no intervalo QT em 30 casos, tomando como referência a delimitação manual (marcação por especialista) do final da onda T. Eles sugerem que a FPA seja realizada entre 0,05Hz e 0,25Hz, e a FPB a 40Hz. Na prática, existe um compromisso entre a frequência de corte inferior e distorção morfológica da onda T. Na medida em que as flutuações da linha base aumentam de frequência é necessário aumentar a frequência de corte inferior para reduzi-las, mas a distorção da onda T aumenta até o ponto que uma onda T monofásica positiva pode converter-se numa bifásica positiva-negativa o qual poderia provocar erros na estimação do ponto Te.

2.4.2.2 Identificação da morfologia

Para determinar o pico e o final da onda T, previamente deve ser reconhecida a morfologia da onda T. Existem seis tipos básicos de morfologias de onda T: monofásica positiva (a mais típica), monofásica negativa (T invertida), bifásica positivo-negativa, bifásica negativo-positiva, somente ascendente, e somente descendente (MARTINEZ, 2004).

Sua identificação é feita mediante métodos de busca de máximos e mínimos no sinal de ECG diferenciado (LAGUNA, 1990), cálculo de áreas (ZHANG, 2006) e busca de pontos de picos e vales no sinal de ECG diferenciado em valor absoluto (XUE, 1996). Este último procedimento reduz as quatro morfologias básicas a duas formas: monofásica (2 picos e 1 vale) e bifásica (3 picos e 2 vales) como se observa na Figura 2.6.

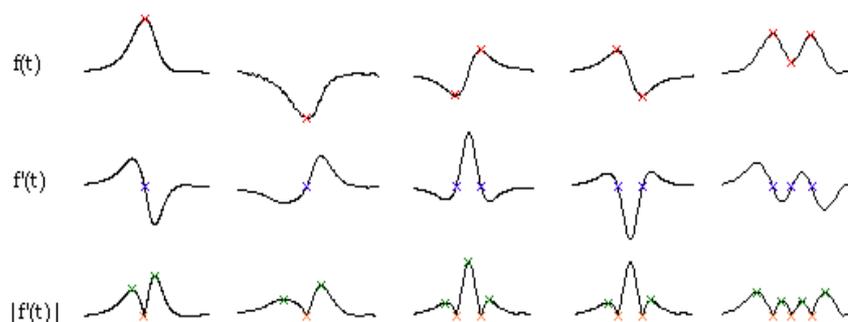


Figura 2.6 - Alternativas de funções para detectar a morfologia da onda T: $f(t)$: ECG original; $f'(t)$: ECG diferenciado; $|f'(t)|$: valor absoluto do ECG diferenciado.

O procedimento usado nesta tese foi o proposto em (LAGUNA, 1990). A partir da onda R detectada e o intervalo RR prévio, se define uma janela que abranja a inclusão da onda T (Figura 2.7). Os limites sugeridos da janela são:

$$(\text{inicio}, \text{final}) = \begin{cases} (140; 500) \text{ ms} & \text{RR} \geq 700 \text{ ms} \\ (100; 0,7 \text{ RR}) \text{ ms} & \text{RR} < 700 \text{ ms} \end{cases} \quad (2.6)$$

Desta forma, a janela se adapta às mudanças no intervalo RR e evita a possível detecção de uma onda P.

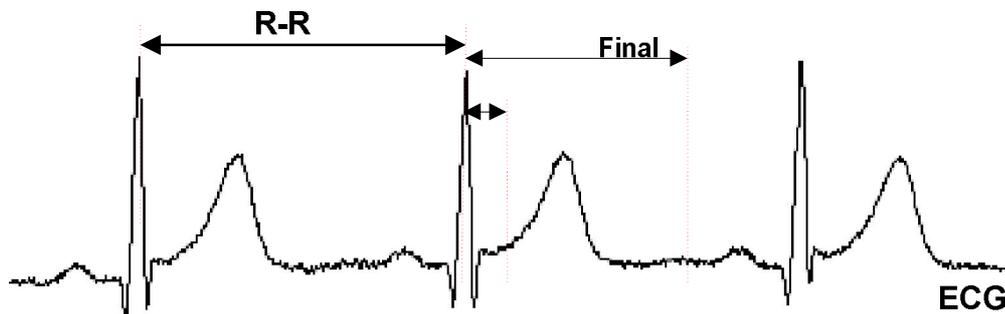


Figura 2.7 - Janela de observação da onda T

Os critérios para detectar as possíveis morfologias são:

- 1) Buscar um valor máximo (max) ou mínimo (min) no sinal diferenciado, dentro da janela de tempo definida.
- 2) Se a posição do valor máximo é anterior à posição do valor mínimo, se considera que a onda T pode ser do tipo bifásica positiva-negativa ou monofásica positiva.
 - a) Se $|\text{max}| > 4 |\text{min}|$ então se considera que a onda é monofásica positiva, caso contrario se considera que a onda é bifásica positiva-negativa.
- 3) Se a posição do valor mínimo é anterior à posição do valor máximo, é buscado um segundo ponto do valor mínimo (min) entre o ponto máximo e o final da janela.
 - a) Se $|\text{max}| < 4 |\text{min}|$ então se considera que a onda é do tipo monofásica positiva, caso contrario se verifica a seguinte condição:
 - b) e $|\text{min}| > 4 |\text{max}|$ então se considera que a onda é monofásica negativa, caso contrário se considera que a onda é bifásica negativa-positiva.

2.4.2.3 Estimação do final da onda T (T_e)

Para estimar o ponto T_e existem diversos métodos: intersecção de linhas (FERRETI, 1992), limiar na amplitude (MCLAUGHLIN, 1995) ou na primeira derivada (LAGUNA, 1990) da onda T, cálculo de: comprimento da curva (GRITZALI, 1989) distâncias (HELFENBEIN, 2006), ângulos (DASKALOV, 1999), e áreas (ZHANG, 2006); correlação com um padrão (LAST, 2004), o uso de modelos matemáticos (VILA, 2000) e da transformada wavelet (MARTÍNEZ, 2004), assim como combinações de alguns dos métodos anteriores (SCHREIER, 2003), entre outros.

Os métodos baseados em limiar são de baixo custo computacional e permitem prever o ponto T_e em situações de encurtamento do segmento isoeletrico T-P, por exemplo, durante exercício intenso. Entretanto, são dependentes do limiar escolhido e são afetados fortemente pelo ruído. O método do cálculo do comprimento da curva é simples, mas é pouco robusto ao ruído. A intersecção das retas é um dos critérios mais empregados pelos cardiologistas, mas depende do critério de seleção das retas. Os métodos baseados na correlação (ou subtração) com um padrão são robustos ao ruído, mas não existe um padrão universal que se adapte à variabilidade morfológica das ondas e que seja válido para todas as situações. Além disso, seu custo computacional é elevado.

Os métodos baseados em modelos matemáticos ajustam uma curva aos segmentos do ECG mediante um procedimento de otimização. Logo, o modelo de cada segmento é usado para detectar os pontos de início e fim desejados, por exemplo, o ponto T_e . O método é robusto ao ruído e pode ser adaptado às variações morfológicas, mas é altamente custoso em termos de cálculo numérico e pode ser muito sensível às inicializações de parâmetros.

Os métodos baseados em *wavelets* podem ser analisados como um banco de filtros diferenciadores passa-baixas com frequências de corte variáveis. São robustos às variações morfológicas, mas o uso da diferenciação aumenta sua sensibilidade ao ruído. Os algoritmos baseados em wavelets também têm uma carga computacional elevada a qual dificulta seu uso em aplicações em tempo real.

Da revisão bibliográfica, foi identificado um objetivo desta tese: obter um novo método de estimação do ponto T_e com as seguintes características: robusto a ruído, independente de limiar e com custo computacional adequado para aplicações com sinais ambulatoriais de longa duração.

2.5 Segmentação e normalização de batimentos

A segmentação consiste em delimitar um segmento temporal para cada batimento do sinal de ECG. Para isso, a partir da detecção do ponto R, é selecionado um conjunto de amostras usando determinado método.

O primeiro método consiste em segmentar os batimentos entre dois pontos R consecutivos (Figura 2.8a). Devido à variabilidade da frequência cardíaca, a duração entre ondas R consecutivas não é igual, então, para padronizar a duração de todos os batimentos do registro, devem-se inserir um número de amostras no segmento isométrico para torná-las igual ao batimento mais longo (OLMOS, 1998).

Esse método apresenta dois possíveis problemas: (a) a existência de pontos R que não forem detectados (falsos negativos) vai originar uma segmentação errônea provocando erros aberrantes, e (b) a inserção de amostras nos segmentos isométricos poderia ocasionar descontinuidades na amplitude que afetem à morfologia de cada batimento e, portanto provocaria falhas do algoritmo de classificação. Esse último aspecto pode ser melhorado usando técnicas de interpolação (EVANGELISTA et al., 2007a).

O segundo método (PAN, 1985) consiste em escolher um segmento do sinal, de duração L_1 , cujo início esteja situado em um ponto à esquerda da onda R detectado (Figura 2.8b), e outro segmento, com duração L_2 , cujo final esteja situado em um ponto à direita da onda R. Neste método não é relevante que fique excluída alguma parte do segmento isométrico.

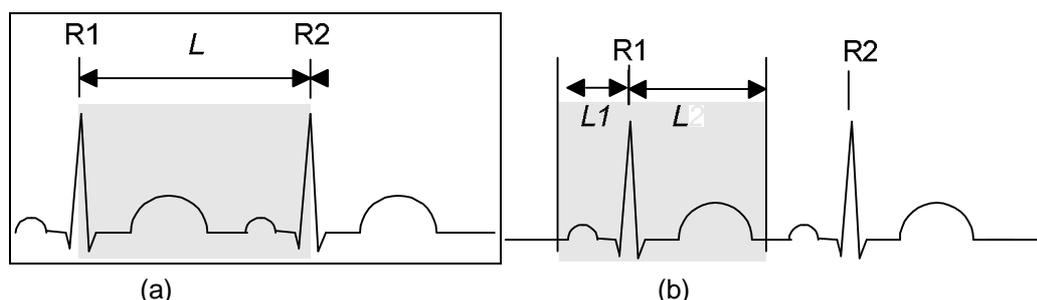


Figura 2.8 - Segmentação de batimentos por 2 métodos diferentes. L é a distância temporal entre duas ondas R consecutivas. Sombreado aparece o segmento selecionado por cada método.

A longitude L_1 pode ser calculada por vários critérios, por exemplo, como a média das distâncias percentuais: (PR_{\min}/PT_{\min}) e (PR_{\max}/PT_{\max}) convertida a amostras, sendo $PT = PR + QT$. Se o valor da média for igual a $N1\%$, então L_2 é calculada como a porcentagem restante $(100 - N1\%)$ convertida a amostras. Desta

forma, a janela será assimétrica entorno do ponto R. Esse método pressupõe menor probabilidade de erro pelo fato de depender só de um ponto R e não de dois, inclusive é mais sensível para detectar os erros na obtenção de pontos R (EVANGELISTA et al., 2010b).

Depois de feita a segmentação, para levar a cabo qualquer tipo de comparação deve-se ter algum critério de similaridade entre a morfologia de dois batimentos quaisquer. Assim, dois batimentos $p_i(n)$ e $p_j(n)$ podem ser considerados que tem a mesma morfologia se cumprir a relação (SÖRNMO et al., 1981):

$$p_i(n) = \alpha p_j[f(n) + \tau] \quad (2.7)$$

Sendo α um escalar maior que zero, $f(n)$ uma função monótona crescente (alongamento ou encolhimento) e um τ um deslocamento em amostras. Da equação 2.7 se deduz que as mudanças em amplitude α , duração $f(n)$ e translação temporária τ entre dois batimentos quaisquer, não devem afetar à comparação pelo que só seriam relevantes as mudanças na forma de onda do sinal. Por este motivo, é necessário normalizar previamente ao cálculo da dissimilaridade, para que a comparação de batimentos seja invariável em relação aos parâmetros α , $f(n)$ e τ .

Na determinação da invariância com respeito a cada batimento é aplicado o método da normalização em amplitude em torno do valor médio do sinal, aplicando um fator de normalização obtido a partir da equação 2.8.

$$M_i = \frac{\sum_{n=0}^{N_i} |p_i(n)|}{N_i} \quad (2.8)$$

Onde N_i é o número de amostras.

Cada batimento ficará da forma:

$$p_i'(n) = \frac{p_i(n)}{M_i}. \quad (2.9)$$

O fato de utilizar esta normalização permite que os possíveis ruídos que apareçam no sinal não influam neste, pois são incluídas em todas as amostras, e não unicamente os valores máximos e mínimos, que são usados em outros casos

para a normalização em amplitude. Finalmente, a própria segmentação do sinal permitirá que a translação no tempo dada por τ não afete à comparação.

Outro tipo de normalização aplicada a um sinal x consiste em transformá-lo em um sinal y de variância unitária subtraindo o seu valor médio \bar{x} e dividindo-o por seu desvio padrão σ .

2.6 Extração de características

A extração de características é uma forma de reduzir a dimensão do vetor de entrada de um algoritmo de classificação ou reconhecimento, quando os dados de entrada têm uma dimensão suficientemente grande para que o referido algoritmo não tenha que processar os dados diretamente. Nestas condições o espaço de entrada se transforma em um conjunto reduzido de propriedades que devem conter as características relevantes para a tarefa de classificação. Existem inúmeras técnicas de extração de características, a seguir são expostas, resumidamente, algumas delas.

2.6.1 Características morfológicas

Esta técnica é baseada no cálculo de determinados parâmetros que são expressão da forma ou morfologia do sinal. Alguns destes parâmetros são: Área do segmento ST, Intervalo RS, Derivada do intervalo ST, Intervalo RT, Área do complexo QRS, Intervalo QT, Amplitude da onda R e frequência do batimento (HOSSEINI, 2006). Outras publicações selecionam um conjunto de amostras do sinal, por exemplo, do complexo QRS (HE, 2006) ou do segmento ST (AFSAR, 2007). Também são empregadas propriedades do intervalo RR, como a frequência à direita e à esquerda do batimento atual (HE, 2006).

2.6.2 Momentos estatísticos

Esta técnica consiste em calcular alguns dos parâmetros estatísticos do sinal e utilizá-los como propriedades na entrada do agrupador. Entre os parâmetros mais utilizados no sinal estão o desvio padrão, a media, o valor máximo, valor mínimo e outros. Em (HOSSEINI, 2006) são empregados quatro propriedades estatísticas

especiais: média da energia do complexo QRS, média da densidade de potência espectral, média dos coeficientes de auto-correlação e média do histograma do sinal.

2.6.3 Coeficientes de predição linear (LPC)

Os coeficientes de predição linear são determinados a partir da matriz de auto-correlação dos vetores do sinal e resolvendo o sistema de equações que resulta mediante o processo de recursão de Levinson-Durbin.

Em Cavalieri (2006) são selecionadas como vetor de entrada a um número variável de coeficientes (8, 10, 12) os quais são empregadas para treinar uma rede neural, entretanto, em Engin (2004) são empregados dois coeficientes LPC para compor um vetor de propriedades que incluem também momentos estatísticos de terceira ordem e coeficientes de uma decomposição *wavelet*.

2.6.4 Métodos baseados em transformadas

Nestes métodos o conjunto de dados de entrada é transformado com o objetivo de reduzir o número de componentes do vetor sinal. Dentre as transformações mais usadas estão a transformada rápida de Fourier (FFT) (BENÍTEZ et al., 2009), a transformada de Karhunen-Loeve ou método de análise de componentes principais (PCA) (NADAL, 1993), a transformada discreta do cosseno (DCT) (GHONGADE, 2009) e a transformada *wavelet* (WT).

A transformada *wavelet* (WT) é uma decomposição do sinal original como uma combinação de um conjunto de funções base obtidas por meio de transformações de dilatação e translação de uma única função protótipo *wavelet*. Este método foi abordado como etapa de extração de propriedades usando variantes de *wavelet* (STERNICKEL, 2002) ou integrando a WT com outros métodos. (ENGIN, 2004; ÜBEYLI, 2007; CEYLAN, 2007).

Neste trabalho é usada a DCT como etapa de extração por duas razões fundamentais: é um método estabelecido em inúmeros algoritmos de compressão e seu custo computacional é relativamente baixo. De fato, o algoritmo da DCT está implementado até em nível de hardware.

2.6.4.1 DCT

A DCT é a forma discreta da Transformada de Fourier do Cosseno (FCT). Define-se discretizando a FCT dentro de uma janela retangular finita de altura unitária, a matriz de transformação é obtida por:

$$[C]_{m \times n} = \sqrt{\frac{2}{N}} \left\{ k_m k_n \cos\left(\frac{mn\pi}{N}\right) \right\} \quad m, n = 0, 1, \dots, N \quad (2.10)$$

Onde:

$$k_i = 1 \quad \forall i \neq 0, \quad k_i = N \quad i = 0 \quad (2.11)$$

$$k_i = \frac{\sqrt{2}}{2} \quad i = 0, \quad k_i = N \quad \forall i \neq 0 \quad (2.12)$$

Esta expressão pode ser escrita em forma matricial:

$$X_c = C \cdot x \quad (2.13)$$

De forma análoga se define a transformada inversa que vem dada por:

$$x(n) = \sqrt{\frac{2}{N}} \sum_{m=0}^N k_m k_n \cos\left(\frac{mn\pi}{N}\right) X_c(m) \quad (2.14)$$

Os vetores X_c e x são conhecidos como pares da DCT. A DCT tem a característica de compactar a energia do sinal em poucos coeficientes. Esta característica permite sua aplicação em técnicas de compressão e extração de propriedades, pois permite a redução dimensional dos dados de entrada sem eliminar os coeficientes que aportam a maior dinâmica ao sinal.

2.6.4.2 PCA linear

A Análise de Componentes Principais (PCA) é uma das técnicas de extração de características mais amplamente utilizadas. Este método consiste em obter as projeções de um vetor no subespaço gerado pelos M vetores próprios que correspondem aos M maiores autovalores da matriz de covariância dos dados. Esta transformação resulta em um novo sistema de coordenadas ortogonal no que qualquer vetor do espaço de entrada pode ser representado através da expressão:

$$\mathbf{x} = \sum_{i=1}^d \alpha_i \cdot \mathbf{b}_i : \mathbf{x} \in \mathfrak{R}^d \quad (2.15)$$

Seja um conjunto de N vetores \mathbf{x} de d componentes e média zero, a matriz de covariância é:

$$\mathbf{C} = \frac{1}{N} \sum_{j=1}^N \mathbf{x}_j \mathbf{x}_j^T \quad (2.16)$$

Na continuação se expõe e resolve o problema de autovalores:

$$\lambda \mathbf{v} = \mathbf{C} \mathbf{v} \quad \lambda \geq 0 \wedge \mathbf{v} \in \mathfrak{R}^n \setminus \{\mathbf{0}\} \quad (2.17)$$

Selecionando somente M vetores ($M < N$) associados aos maiores valores próprios se obtêm um subespaço de \mathbf{R}^d sobre o qual se projeta o vetor de entrada. Isto permite reduzir o dimensionamento dos dados de entrada e às vezes conservar o relevante da informação que possuem.

2.6.4.3 Kernel PCA

O Kernel PCA (KPCA) tem como fundamento um feito que se desprende da teoria estatística da aprendizagem de Vapnik-Chervonenkis (VAPNIK, 1999). Esta teoria estabelece que a classificação seja uma tarefa que pode realizar-se de forma mais simples, isto é, com um classificador o mais simples possível, em um espaço de dimensão maior que o espaço de entrada.

Este método foi proposto por Schölkopf (1998) e está baseado em expressar o problema de autovalores do PCA linear em forma de produto escalar em certo

espaço vetorial (espaço de características) de dimensão maior que o espaço de entrada e, relacionado com este por meio de uma aplicação não linear.

Sejam M observações de media igual a zero ($\bar{\mathbf{x}}_k = 0$) onde:

$$k = 1, 2, \dots, M, \mathbf{x}_k \in \mathcal{R}^n \quad (2.18)$$

A análise de componentes principais lineares (PCA) aborda o problema de encontrar os vetores próprios da matriz de covariância definida na equação 2.8. A determinação dos vetores próprios requer a resolução do problema de autovalores para a matriz simétrica \mathbf{C} , a forma canônica deste problema foi mostrada na equação 2.17.

A equação 2.17 pode ser escrita em termos de o produto escalar com um vetor arbitrário \mathbf{x}_k :

$$\lambda(\mathbf{x}_k \cdot \mathbf{v}) = (\mathbf{x}_k \cdot \mathbf{C}\mathbf{v}) \quad \forall k = 1, 2, \dots, M \quad (2.19)$$

A equação 2.18 é outra forma de descrever o problema de autovalores em termos do produto interno. Esta forma de descrição é útil para definir o Kernel PCA, com este fim, é introduzido certo espaço \mathbf{F} , denominado espaço de propriedades. O espaço de propriedades está relacionado com o espaço vetorial de entrada \mathcal{R}^n mediante uma função de mapeamento Φ que pode ser não linear:

$$\begin{aligned} \Phi : \mathcal{R}^n &\mapsto \mathbf{F} \\ \mathbf{x} &\mapsto \mathbf{X} \end{aligned} \quad (2.20)$$

Desta maneira a função Φ é uma aplicação provavelmente não linear entre dois espaços vetoriais (Figura 2.9).

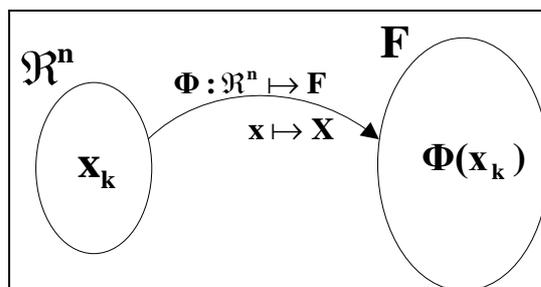


Figura 2.9 - Mapeamento do espaço de entrada para o espaço de propriedades.

A seguir, é definida a matriz de covariância $\bar{\mathbf{C}}$ no novo espaço segundo:

$$\bar{\mathbf{C}} = \frac{1}{M} \sum_{j=1}^M \Phi(\mathbf{x}_j) \Phi(\mathbf{x}_j)^T \quad (2.21)$$

Desta forma é possível escrever neste novo espaço a equação de autovalores:

$$\lambda \mathbf{V} = \bar{\mathbf{C}} \mathbf{V} \quad \lambda \geq 0 \wedge \mathbf{V} \in \mathbf{F} \setminus \{\mathbf{0}\} \quad (2.22)$$

Analogamente é possível reescrever (equação 2.11) no novo espaço:

$$\lambda (\Phi(\mathbf{x}_k) \cdot \mathbf{V}) = (\Phi(\mathbf{x}_k) \cdot \bar{\mathbf{C}} \mathbf{V}) \quad (2.23)$$

É possível representar os vetores próprios \mathbf{V} em \mathbf{F} assumindo que o sistema de vetores $\Phi(\mathbf{x}_i)$ é gerador do subespaço vetorial de \mathbf{F} que contém em \mathbf{V} . Esta afirmação é equivalente a indicar:

$$\exists \alpha_i, i=1,2,\dots,M \ni \mathbf{V} = \sum_{i=1}^M \alpha_i \Phi(\mathbf{x}_i) \quad (2.24)$$

Substituindo (2.21) e (2.24) em (2.23) obtemos:

$$\lambda \Phi(\mathbf{x}_k) \cdot \sum_{i=1}^M \alpha_i \Phi(\mathbf{x}_i) = \Phi(\mathbf{x}_k) \cdot \frac{1}{M} \sum_{j=1}^M \Phi(\mathbf{x}_j) \Phi(\mathbf{x}_j)^T \sum_{i=1}^M \alpha_i \Phi(\mathbf{x}_i) \quad (2.25)$$

$$\lambda \sum_{i=1}^M \alpha_i (\Phi(\mathbf{x}_k) \cdot \Phi(\mathbf{x}_i)) = \frac{1}{M} \sum_{j=1}^M \alpha_j (\Phi(\mathbf{x}_k) \cdot \sum_{i=1}^M \Phi(\mathbf{x}_i)) (\Phi(\mathbf{x}_j) \cdot \Phi(\mathbf{x}_i)) \quad (2.26)$$

Definindo uma matriz \mathbf{K} , de dimensão $M \times M$:

$$\mathbf{K}_{ij} = (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)) \quad (2.27)$$

Então:

$$M \lambda \mathbf{K} \boldsymbol{\alpha} = \mathbf{K}^2 \boldsymbol{\alpha} \quad (2.28)$$

Finalmente:

$$M\lambda\alpha = \mathbf{K}\alpha \quad (2.29)$$

Nesta expressão se identifica o mesmo problema de autovalores que em PCA (equação 2.17); observar que \mathbf{K} foi obtido em termos do produto escalar. Em seguida são calculados os autovalores de \mathbf{K} (equação 2.27). Esses M autovalores são ordenados em ordem crescente $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_M$ tomando os r autovalores desde M até p , onde p é a ordem do último valor próprio diferente de zero. A seguir, são obtidos e normalizados os vetores próprios associados a esses autovalores usando a condição:

$$\mathbf{V}^k \cdot \mathbf{V}^k = \mathbf{1} \quad k = p, \dots, M \quad (2.30)$$

Trabalhando nesta equação, teremos:

$$\sum_{i,j=1}^M \alpha_i^k \alpha_j^k (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)) = 1 \quad (2.31)$$

$$\sum_{i,j=1}^M \alpha_i^k \alpha_j^k K_{ij} = 1 \quad (2.32)$$

$$(\alpha^k \cdot \mathbf{K}\alpha^k) = 1 \quad (2.33)$$

$$\lambda(\alpha^k \cdot \alpha^k) = 1 \quad (2.34)$$

Na Figura 2.10 é mostrado um resumo dos passos a seguir para extrair as componentes principais de um vetor arbitrário de prova \mathbf{x} com o algoritmo de Kernel PCA. A expressão \mathbf{k} é uma função que represente em \mathbf{F} o produto escalar, de maneira que seja possível operar neste espaço sem a necessidade de utilizar diretamente Φ , isto é, não é necessário realizar explicitamente o mapeamento $\mathcal{R}^n \mapsto \mathbf{F}$. Isto é de grande importância, pois evita o cálculo explícito em \mathbf{F} , evadindo a possível alta dimensão deste espaço vetorial.

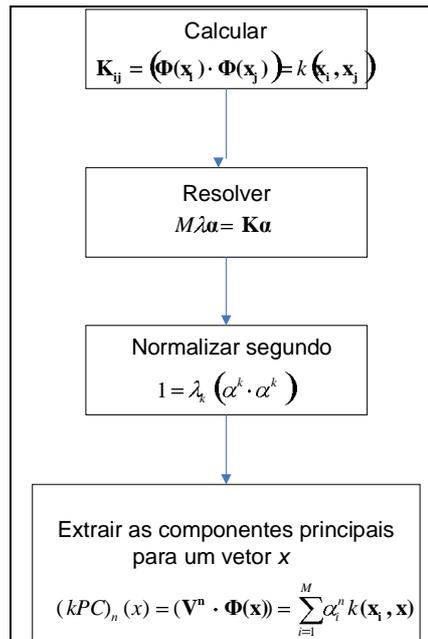


Figura 2.10 - Algoritmo para extração de componentes com KPCA.

2.6.5 Outras técnicas

Além disso, das técnicas e métodos de extração de características já mostradas, podem ser mencionadas outras, por exemplo, os métodos de agrupamento: FCM (*Fuzzy Clustering Methods*) (CEYLAN, 2007) (PATRA, 2009) (ÖZBAY, 2006), a regra dos K vizinhos mais próximos (CHRISTOV, 2005) e a Análise de Componentes Independentes (ICA) (KARDEC, 1998). Também é comum combinar técnicas de extração, por exemplo, a obtenção de um vetor de propriedades empregando parâmetros estatísticos como: valores médio, máximo e mínimo, e o desvio padrão de um sinal de ECG transformado em cinco sub-bandas mediante a transformada *wavelet* (ÜBEYLI, 2007).

2.7 Redes Neurais Artificiais para agrupamento de batimentos

As redes neurais artificiais são sistemas capazes de aprender a partir de exemplos empregando a computação paralela, distribuída e adaptativa como paradigma essencial e tendo como base biológica a estrutura e função do sistema nervoso e do cérebro humano.

Do ponto de vista funcional, os neurônios constituem processadores de informação simples com os seguintes elementos: um canal de entrada de informação, os dendritos, um órgão de cômputo, a soma, e um canal de saída, o axônio. Nos inter-neurônios o axônio envia a informação a outros neurônios,

enquanto que nos neurônios motores, fazê-lo diretamente ao músculo. Existe um terceiro tipo de neurônios, os receptores ou sensores, que recebem a informação diretamente do exterior. Estatisticamente um neurônio do córtex cerebral recebe informação de uns 10.000 neurônios (convergência), e envia impulsos a varias centenas deles (divergência).

Com este fundamento biológico foi proposto em 1943 um primeiro modelo matemático de neurônio. Na década de 70, foi generalizado este modelo e estabeleceram o conceito de neurônio artificial como um processador elementar que a partir de um vetor de entrada procedente do exterior ou de outros neurônios proporciona uma única resposta ou saída.

Seja o neurônio i , os elementos que compõem o modelo de neurônios são os seguintes:

- Conjunto de entradas $x_j(t)$;
- Os pesos sinápticos do neurônio i , ω_{ji} , representam a intensidade da interação entre os neurônios pré-sinápticos j e ou neurônio pós-sináptico i ;
- Regra de propagação $\sigma(\omega_{ji}, x_j(t))$: Proporciona o valor do potencial pós-sináptico: $h_i(t) = \sigma(\omega_{ji}, x_j(t))$, do neurônio i em função de seus pesos e entradas;
- A função de ativação $f_i(a(t-1), h(t))$, proporciona o estado de ativação atual $a(t) = f_i(a(t-1), h(t))$, do neurônio i , em função de seu estado anterior $a(t-1)$ e de seu potencial pós-sináptico atual;
- A função de saída $F_i(a(t))$, proporciona a saída atual $y(t) = F_i(a(t))$ do neurônio i em função de seu estado de ativação.

Deste modo, a operação do neurônio i pode expressar-se como:

$$y_i(t) = F_i\left(f_i\left[a(t-1), \sigma(\omega_{ij}, x_j(t))\right]\right) \quad (2.35)$$

Na prática o modelo geral de neurônios se transforma em modelos mais específicos, um dos mais difundidos é o modelo padrão. Neste modelo se estabelecem as seguintes limitações:

- A regra de propagação é igual à soma ponderada das entradas e os pesos,

$$h_i(t) = \sigma(\omega_{ji}, x_j(t)) = \sum_{j=1}^n \omega_{ij} x_j(t) \quad (2.36)$$

- A função de saída é a identidade,

$$F_i(a(t)) = a(t) \quad (2.37)$$

- O estado de ativação atual do neurônio depende somente de seu potencial pós-sináptico atual,

$$a(t) = f_i(h(t)) \quad (2.38)$$

É acrescentado um parâmetro adicional denominado limiar θ_i que é subtraído do potencial pós-sináptico. Utilizando (2.36), (2.37) e (2.38) e substituindo em (2.35) é obtido o modelo de neurônio padrão:

$$y_i(t) = f_i\left(\sum_{j=1}^n \omega_{ij} x_j(t) - \theta_i\right) \quad (2.39)$$

Finalmente, Haykin (2001) propõe a função de ativação que pode ser escolhida segundo o tipo de neurônio desejado. Na Tabela 2.1 são apresentados alguns tipos de neurônios dependendo da função de ativação.

Tabela 2.1: Funções de ativação por tipo de neurônios.

Tipo	Equação
Limiar	$f(x) = \begin{cases} U_1 & : x \geq 0 \\ U_2 & : x < 0 \end{cases}$
Linear	$f(x) = x$
Sigmoide $f(x) \in [0,1]$	$f(x) = \frac{1}{1 + e^{-x}}$
Sigmoide $f(x) \in [-1,1]$	$f(x) = \tanh(x)$

2.7.1 Arquitetura de redes neurais

A arquitetura de uma rede neural é a estrutura ou padrão topológico da conexão dos neurônios da rede, e que determina o seu desempenho.

Estruturalmente, os neurônios são agrupados em unidades denominadas camadas. Existem três tipos de camadas diferentes:

- Camada de entrada: Agrupam neurônios que recebem informação do exterior, estes neurônios se conectam a elementos sensores;
- Camada de saída: Agrupam neurônios que proporcionam a resposta da rede neural, estes neurônios se conectam a elementos atuadores;
- Camada oculta: Agrupa neurônios que não tem conexão direta com o entorno, ou seja, recebem e entregam informação desde e até outros neurônios da rede.

As conexões entre os neurônios podem ser de excitação ou de inibição. Um peso sináptico negativo define uma conexão de inibição, enquanto que um positivo determina uma conexão de excitação. Por outra parte, se pode distinguir entre conexões intra-camadas e inter-camadas. As conexões intra-camadas, (laterais), tem lugar entre os neurônios pertencentes a uma mesma camada, enquanto que as conexões inter-camadas se produzem entre os neurônios de diferentes camadas. Existem, além disso, conexões realimentadas, que tem um sentido contrário ao de entrada-saída. Em alguns casos pode existir realimentação inclusive de um neurônio consigo mesmo.

Outros critérios podem estabelecer diferentes tipos de arquiteturas neuronais (YAMAZAKI, 2004). Assim, em relação a sua estrutura em camadas, é possível classificar a redes em redes monocamadas e redes multicamadas. As redes monocamadas são aquelas compostas por uma única camada de neurônios. As redes multicamadas são aquelas cujos neurônios se organizam em varias camadas.

Atendendo ao fluxo de dados na rede neural, as redes são classificadas em redes unidirecionais (*feedforward*) e redes recorrentes (*feedback*). Nas redes unidirecionais, a informação circula em um único sentido, desde os neurônios de entrada para os de saída. Nas redes recorrentes ou realimentadas a informação pode circular entre as camadas em qualquer sentido, incluído a da saída-entrada.

Finalmente, quanto a sua operação, podem ser classificadas em redes auto-associativas e hetero-associativas. Se uma rede é treinada para que quando seja apresentado um padrão **A** responda com outro diferente **B**, se diz que a rede é hetero-asociativa. A rede é auto-associativa se é treinada para que associe um padrão **A** consigo mesma.

2.7.2 Perceptron simples

O termo Perceptron foi empregado originalmente no início da década de 60 para se referir a uma classe de modelo de redes neurais. Esta rede está estruturada em uma primeira etapa com elementos de processamento fixos, que são consideradas como funções de base generalizadas de certo discriminante linear. Na generalidade dos casos estes elementos de processamento consistem em pesos fixos conectados a subconjuntos aleatórios da entrada e funções limiars da forma:

$$g(a) = \begin{cases} 0: & a < 0 \\ 1: & a \geq 0 \end{cases} \quad (2.40)$$

Geralmente se adiciona uma função base cuja ativação sempre é 1 e se conjuga com seu peso correspondente ω_0 .

Nestas condições a saída do Perceptron estará dada por a equação:

$$y = g\left(\sum_{j=0}^M \omega_j \phi_j(x)\right) = g(\boldsymbol{\omega}^T \boldsymbol{\phi}) \quad (2.41)$$

Onde $\boldsymbol{\phi}$ denota o vetor formado pelas ativações ϕ_0, \dots, ϕ_M . É usual selecionar à função de ativação de saída do tipo limiar anti-simétrico, ou seja, da forma:

$$g(a) = \begin{cases} -1: & a < 0 \\ +1: & a \geq 0 \end{cases} \quad (2.42)$$

Devido a que o objetivo é construir um sistema de classificação efetivo, é frequente definir a função de erro em termos do número total de classificações erradas sobre o conjunto de treinamento. Entretanto, este critério não é empregado na prática devido a que pequenas mudanças nos valores dos pesos provocam que os limites da região de decisão apresentem descontinuidades. Desta maneira, a função de erro é constante a trechos, fato que faz impraticável a aplicação de métodos como o do gradiente descendente.

É então é considerado o critério do Perceptron, fundamentando previamente as seguintes premissas: seja o vetor de entrada \mathbf{x}^n que se apresenta às entradas da

rede (etapa de funções base) gerando o correspondente vetor de ativações ϕ^n , se associar a cada vetor de entrada \mathbf{x}^n uma saída da rede t^n , tal que:

$$\begin{cases} t^n = -1: \mathbf{x}^n \in C_1 \\ t^n = +1: \mathbf{x}^n \in C_2 \end{cases} \quad (2.43)$$

O critério de treinamento para o Perceptron é:

$$E(\omega) = - \sum_{\phi^n \in \Omega} \omega^T \phi^n t^n \quad (2.44)$$

Sendo Ω o conjunto de vetores ϕ^n que não são corretamente classificados com o vetor de pesos ω . Como se observa em (2.53) a função de erro é uma somatória de termos positivos com o sinal negativo diante; $\Omega \equiv \emptyset$ significa que todos os vetores têm sido corretamente classificados e $E(\omega) = 0$. No processo de treinamento a região de decisão se move ao mudar o vetor de pesos ω de maneira que os padrões que anteriormente tinham sido classificados incorretamente, então com a mudança em ω serão classificados corretamente.

O processo inverso também ocorre, ou seja, padrões corretamente classificados na iteração anterior estarão mal classificados na iteração atual. Isto indica que o conjunto de padrões que conformam Ω muda em cada iteração, o critério é linear por intervalos com descontinuidades no gradiente.

Uma vez estabelecido o critério de erro, é necessário especificar o algoritmo de treinamento. Dado que a função de erro é linear por intervalos é possível então aplicar a técnica do gradiente descendente que finalmente resulta na equação:

$$\omega_j(t+1) = \omega_j(t) + \eta \phi_j^n t_j^n \quad (2.45)$$

A equação 2.45 tem uma simples interpretação algorítmica que se pode resumir da seguinte forma:

- Calcular a saída de todos os padrões de entrada para o vetor de pesos atual ω^T ;

- Agrupar todos os vetores que forem mal classificados (formar $\{\mathbf{p}_1, \dots, \mathbf{p}_r \subset \Omega\}$). Se não existem vetores mal classificados ($\Omega \equiv \emptyset$), então terminar.
- Iterar em Ω da seguinte maneira:

$$\mathbf{p}_i \in C_1 \Rightarrow \omega(t+1) = \omega(t) + \eta \Phi_i^n t_i^n \quad (2.46)$$

$$\mathbf{p}_i \in C_2 \Rightarrow \omega(t+1) = \omega(t) - \eta \Phi_i^n t_i^n \quad (2.47)$$

- Saltar ao passo 1.

2.7.3 Perceptron multicamadas (MLP)

Se forem adicionadas camadas intermédias a um Perceptron simples se obtém um Perceptron multicamadas ou MLP (*Multi-Layer Perceptron*). Esta arquitetura, da mesma forma que sua predecessora, pertence à variante de redes de aprendizagem supervisionadas.

Topologicamente a estrutura do MLP é a de uma arquitetura dirigida para adiante (Figura 2.11), onde cada neurônio se conecta com os neurônios da camada anterior através de caminhos ponderados.

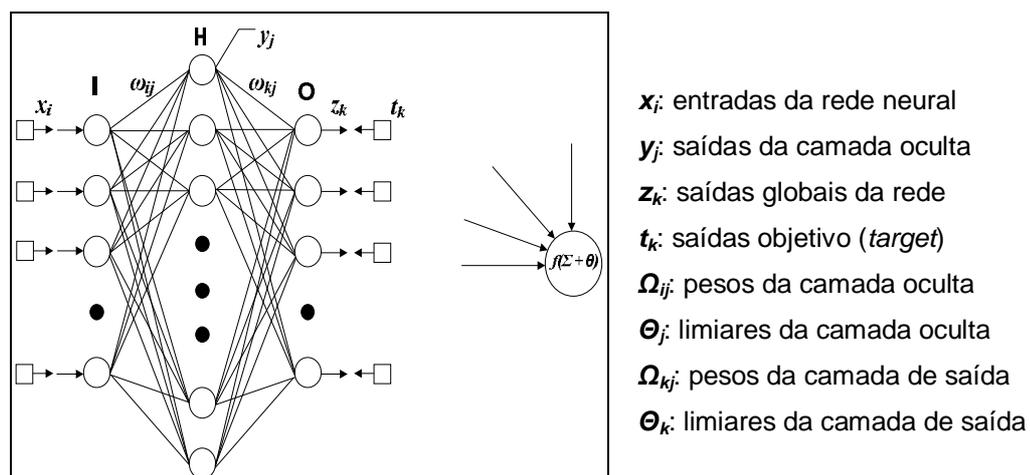


Figura 2.11 - Arquitetura da rede MLP.

Matematicamente uma MLP de uma camada oculta se expressa segundo a equação:

$$\mathbf{O} = \mathbf{g}\left(\boldsymbol{\omega}_{jk}^T \mathbf{f}(\boldsymbol{\omega}_{ij}^T \mathbf{x} + \Theta_j) + \Theta_k\right) \quad (2.48)$$

Para treinar uma MLP é empregado o algoritmo de retropropagação de erros ou BP (*backpropagation*). O algoritmo de treinamento denominado retropropagação de erros ou BP, foi desenvolvido primeiramente por Werbos (1974) e tempo depois por Rumelhart (1986). O princípio deste algoritmo é fundamentado em um critério de erro global baseado em mínimos quadrados onde a partir da função de erro é obtida a regra de atualização dos pesos em cada interação.

Inicialmente é definido uma função custo ou erro que mede o rendimento da rede. Na continuação é introduzido um procedimento de otimização que determina a regra de atualização dos pesos da rede. O método de otimização mais empregado é o método do gradiente descendente que tem como fundamento a equação 2.49.

$$\boldsymbol{\omega}(t+1) = \boldsymbol{\omega}(t) - \varepsilon \nabla E(\boldsymbol{\omega}(t)) \quad (2.49)$$

Onde $E(\boldsymbol{\omega}, t)$ é o erro quadrático médio, definido como:

$$E(\boldsymbol{\omega}(t)) = \frac{1}{2} \sum_i^p \sum_k^n (t_k^i - y_k^i)^2 \quad (2.50)$$

As expressões de atualização dos pesos são obtidas derivando a função de erro e aplicando a regra da cadeia. Outras investigações têm enriquecido o algoritmo BP original, gerando diversas variantes que na atualidade são empregadas com frequência no treinamento deste tipo de redes. Nesta tese é empregado o algoritmo de segunda ordem Levenberg-Marquardt (LM) citado por Hagan (1999) para treinar as redes propostas. Este algoritmo se fundamenta no método de Newton da segunda derivada, como visto na equação 2.51:

$$\Delta \boldsymbol{\omega}(t) = -[\mathbf{H}(t)]^{-1} \nabla E(\boldsymbol{\omega}(t)) \quad (2.51)$$

Onde $\mathbf{H}(t)$ é a matriz Hessiana; se a função de erro tem forma de soma quadrada é possível aproximar $\mathbf{H}(t)$ em função da matriz Jacobiana:

$$\mathbf{H}(t) = \mathbf{J}(t)^T \mathbf{J}(t) \quad (2.52)$$

Para o gradiente a expressão é:

$$\nabla E(\boldsymbol{\omega}(t)) = \mathbf{J}(t)^T \mathbf{E}(t) \quad (2.53)$$

Substituindo:

$$\Delta \boldsymbol{\omega}(t) = -[\mathbf{J}(t)^T \mathbf{J}(t)]^{-1} \mathbf{J}(t)^T \mathbf{E}(t) \quad (2.54)$$

Na prática com o propósito de controlar o desempenho do algoritmo, é introduzido um fator de ajuste μ pelo que a expressão final fica:

$$\Delta \boldsymbol{\omega}(t) = -[\mathbf{J}(t)^T \mathbf{J}(t) + \mu \mathbf{I}]^{-1} \mathbf{J}(t)^T \mathbf{E}(t) \quad (2.55)$$

O fator μ permite controlar a operação do algoritmo, de maneira que para μ próximo a zero, o algoritmo se aproxima ao método de Newton, para μ maior o algoritmo se aproxima ao método do gradiente descendente.

2.7.4 Funções de base radial (RBF)

As redes neurais de funções de base radial ou RBF (*Radial Basis Functions*) são um modelo de rede unidirecional para aproximação funcional, mas que pode considerar-se de tipo híbrido por incorporar aprendizagem supervisionada e não supervisionada.

As redes RBF permitem modelar sistema não lineares arbitrários, com a particularidade de que o tempo requerido para seu treinamento é em geral muito mais reduzido que o do BP clássico.

A arquitetura de uma rede RBF conta de três camadas de neurônios: entrada, oculta e saída. Os neurônios da camada de entrada recebem a informação do exterior e a dirigem para os neurônios da camada oculta. Os neurônios da camada de saída têm função de ativação linear e calculam a soma ponderada das saídas da camada oculta.

A diferença fundamental entre a arquitetura deste modelo e a do MLP se centra na operação dos neurônios ocultos. Os neurônios desta camada operam com base à distância que separa o vetor de entradas com respeito ao vetor sináptico que cada uma armazena, denominado centróide. Uma vez calculada a distância, aplicam uma função radial com forma gaussiana. Desta maneira, os neurônios RBF só

respondem com uma intensidade apreciável quando o vetor de entradas apresentado e o centróide do neurônio pertencem a uma zona próxima no espaço de entrada (resposta localizada).

O modelo matemático desta rede é obtido primeiro para a camada oculta de neurônios:

$$y_j = \phi_j(\mathbf{x}_i) = e^{-\frac{\|\mathbf{x}_i - \mathbf{c}_j\|^2}{2\sigma^2}} \quad (2.56)$$

Para a camada de saída:

$$y_k = \sum_j \omega_{kj} \phi_j(\mathbf{x}_i) \quad (2.57)$$

O modelo da rede finalmente resulta em:

$$y_k = \sum_j \omega_{kj} e^{-\frac{\|\mathbf{x}_i - \mathbf{c}_j\|^2}{2\sigma^2}} + \theta_k \quad (2.58)$$

No treinamento das redes RBF devem ser levados em conta alguns aspectos. Primeiramente é necessário eleger o número de nodos radiais (ocultos). Cada nodo radial cobre uma parte do espaço de entrada de modo que é imprescindível eleger o número de nodos correto que cubra suficientemente (para uma aplicação dada) do dito espaço. O problema surge ao tratar com espaços de entrada de muitas variáveis, pois o número de nodos necessários cresce exponencialmente quando aumenta a dimensão do espaço de entrada. Deste modo, deve chegar-se a um compromisso entre o número de nodos radiais selecionados, o erro atingido no ajuste dos padrões de aprendizagem, e a capacidade de generalização (pode ocorrer sobre treinamento quando são empregados muitos neurônios ocultos). Para resolver este problema são aplicadas técnicas de prova e erro e outros procedimentos.

O outro problema é encontrar os parâmetros da arquitetura. Normalmente é usada a aprendizagem por etapas, na qual, inicialmente é realizado o treinamento

dos neurônios ocultos gaussianos e finalmente são treinados os neurônios da camada de saída. Na aprendizagem dos neurônios da camada oculta é comum empregar métodos não supervisionados como o algoritmo de k -medias (k -means). Para os neurônios da camada de saída é empregado o método de mínimos quadrados (LMS).

2.7.5 Quantificação vetorial adaptativa (LVQ)

As redes LVQ (*Learning Vector Quantization*) definem uma família de algoritmos de quantificação vetorial adaptativa de tipo supervisionada, originalmente criada por Kohonen (1990) para classificar padrões. Esta rede está composta por uma camada simples de neurônios de Kohonen sem relações de vizinhança, e supõe também que cada um dos n neurônios representa uma classe, e armazena um vetor de referência $\omega_j (j=1,2,\dots,n)$ que representa o protótipo de uma classe. Quando se apresenta à rede um padrão de entrada \mathbf{x} , composto por m entradas, cada neurônio calcula a distância que separa seu vetor de referência do vetor de entrada:

$$d^2(\omega_j, \mathbf{x}) = \sum_{k=1}^M (\omega_{jk} - x_k)^2 \quad (2.59)$$

O neurônio c com vetor de referência ω_c cuja distância d seja mínima representa à classe à qual pertence o vetor \mathbf{x} de maneira que este ficará classificado.

A aprendizagem é baseada em premiar ao neurônio que classifica corretamente um padrão, atualizando seus pesos com a regra de Kohonen, e penalizar a que realiza uma classificação errônea, modificando seus pesos em sentido contrario.

O algoritmo de treinamento se efetua assumindo que se dispõe de um conjunto de treinamento Θ de p padrões $\Theta = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_p\}$ perfeitamente etiquetados, ou seja, cada padrão pertence a uma classe C_1, C_2, \dots, C_n conhecida. Existem, além disso, tantas classes como neurônios, cada uma com um vetor ω_k e etiquetado com uma classe C_k . Se ω_h é o vetor de referência mais próximo ao

padrão de entrada x_p apresentado e C_h é a classe representada por dito vetor, se tem a seguinte regra de atualização para cada neurônio:

Se $C_h = C_k$, atualizar o vetor ω_k segundo a expressão:

$$\omega_k(t+1) = \omega_k(t) + \alpha [\mathbf{x}_p - \omega_k] \quad (2.60)$$

Se $C_h \neq C_k$ atualizar o vetor ω_k segundo a expressão:

$$\omega_k(t+1) = \omega_k(t) - \alpha [\mathbf{x}_p - \omega_k] \quad (2.61)$$

Onde $0 < \alpha \ll 1$, é um escalar que decresce quando aumenta o número de interações na execução do algoritmo.

2.8 Máquinas de Suporte Vetorial (SVM)

SVM é um classificador linear proposto por Vapnik (1999) que tem como princípio construir o hiperplano que melhor separa duas classes dadas no sentido de máxima distância entre classes. Na Figura 2.12a são mostrados dois conjuntos pertencentes a duas classes distintas.

Existem infinitas superfícies de decisão que permitem discriminar entre ambas as classes, duas delas são mostradas em linhas de traços. Não obstante, o melhor discriminador no sentido de máxima margem entre classes é o amostrado na Figura 2.12b. A margem é a distância desde o hiperplano H até os dois hiperplanos paralelos S_0 e S_1 que contêm os elementos mais próximos a H de ambas as classes.

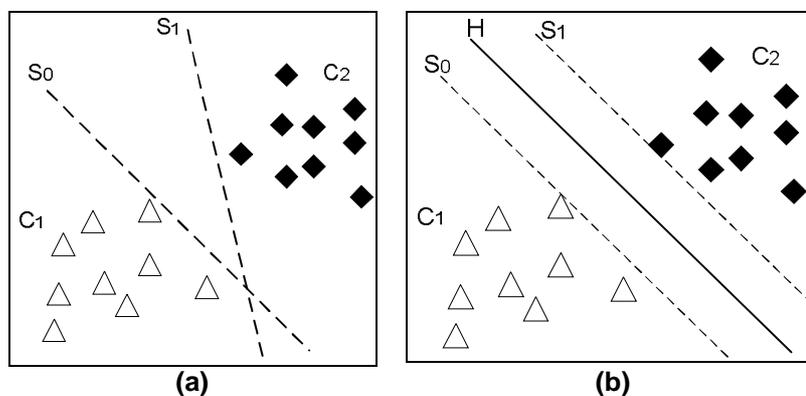


Figura 2.12 - Dois conjuntos de dados de diferentes classes linearmente separáveis (a) regiões de decisão (b) hiperplano ótimo no sentido da máxima margem.

Para formalizar a ideia constrói-se um hiperplano que permita classificar padrões de duas classes supostamente separáveis linearmente no espaço de dimensão n . Tem-se um conjunto de padrões $\{x_i, i=1..n\}$ os quais pertencem a uma das duas classes C_1 e C_2 , etiquetadas com os valores $y_i = \pm 1$ (+1 para C_1 e -1 para C_2). Seja o discriminante linear:

$$g(\mathbf{x}) = \boldsymbol{\omega}^T \mathbf{x} + \omega_0 \quad (2.62)$$

Com a regra de decisão:

$$\boldsymbol{\omega}^T \mathbf{x} + \omega_0 \begin{cases} > 0 \\ < 0 \end{cases} \Rightarrow \mathbf{x} \in \begin{cases} C_1, & y_i = +1 \\ C_2, & y_i = -1 \end{cases} \quad (2.63)$$

O conjunto de padrões estará corretamente classificado se:

$$y_i g(\mathbf{x}) = y_i (\boldsymbol{\omega}^T \mathbf{x} + \omega_0) > 0 \quad \forall i = 1, 2, \dots, n \quad (2.64)$$

E a região que separa ambas as classes será:

$$g(\mathbf{x}) = \boldsymbol{\omega}^T \mathbf{x} + \omega_0 = 0 \quad (2.65)$$

Para os hiperplanos da Figura 2.13 a margem definida mais acima tem por expressão:

$$m(\boldsymbol{\omega}, \omega_0) = \min_{\mathbf{x}_i \in C_1} d(\boldsymbol{\omega}, \omega_0; \mathbf{x}_i) + \min_{\mathbf{x}_j \in C_2} d(\boldsymbol{\omega}, \omega_0; \mathbf{x}_j) \quad (2.66)$$

$$m(\boldsymbol{\omega}, \omega_0) = m(\boldsymbol{\omega}) = \frac{2}{\sqrt{\boldsymbol{\omega}^T \boldsymbol{\omega}}} = \frac{2}{\|\boldsymbol{\omega}\|} \quad (2.67)$$

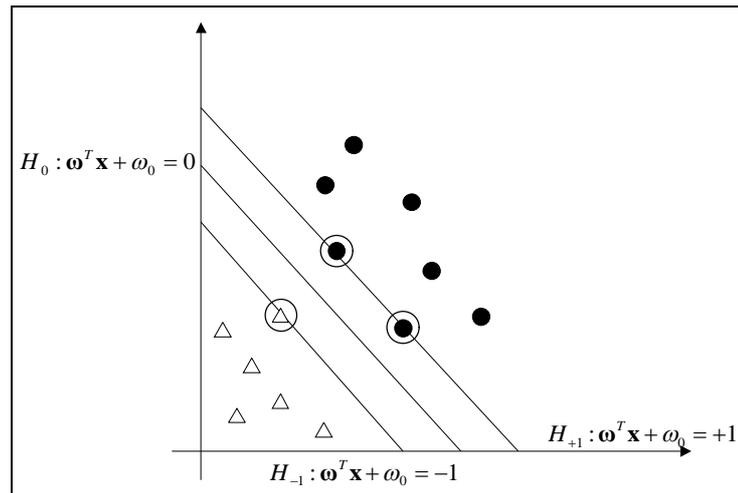


Figura 2.13 - Vetores, suporte e separabilidade com hiperplanos canônicos.

Maximizar a margem $m(\omega)$, é equivalente a minimizar a função $J(\omega)$:

$$J(\omega) = \frac{1}{2} \omega^T \omega \quad (2.68)$$

Segundo as condições:

$$y_i(\omega^T \mathbf{x}_i + \omega_0) \geq 1 \quad \forall i = 1, 2, \dots, n \quad (2.69)$$

Esta equação expressa um problema de otimização quadrático sujeito a um conjunto de restrições lineares. Nesta classe de problemas são aplicáveis as condições de Karush – Kuhn – Tucker:

$$\frac{\partial}{\partial \omega} L(\omega, \omega_0, \alpha) = 0 \quad (2.70)$$

$$\frac{\partial}{\partial \omega_0} L(\omega, \omega_0, \alpha) = 0 \quad (2.71)$$

$$\alpha_i \geq 0 \quad \forall i = 1, 2, \dots, n \quad (2.72)$$

$$\alpha_i [y_i(\omega^T \mathbf{x}_i + \omega_0) - 1] = 0 \quad \forall i = 1, 2, \dots, n \quad (2.73)$$

Onde α é o vetor de multiplicadores de Lagrange, α_i e $L(\omega, \omega_0, \alpha)$ é a função de Lagrange definida como:

$$L(\boldsymbol{\omega}, \omega_0, \boldsymbol{\alpha}) = \frac{1}{2} \boldsymbol{\omega}^T \boldsymbol{\omega} - \sum_{i=1}^n \alpha_i (y_i [\boldsymbol{\omega}^T \mathbf{x}_i + \omega_0] - 1) \quad (2.74)$$

Só alguns vetores cumprem a equação (2.73), esses vetores de treinamento são denominados vetores suporte (Figura 2.13). Logo aplicando (2.70) e (2.71) em (2.74) tem-se:

$$\boldsymbol{\omega} = \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i \quad (2.75)$$

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad (2.76)$$

Utilizando (2.75) e (2.76) em (2.74), se obtém:

$$L_D(\boldsymbol{\omega}, \omega_0, \boldsymbol{\alpha}) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{j=1}^n \sum_{i=1}^n \alpha_i \alpha_j y_i y_j \mathbf{x}_j^T \mathbf{x}_i \quad (2.77)$$

A expressão (2.77) é conhecida como forma dual da função de Lagrange. O problema de otimização exposto se resume à maximização da função de Lagrange em sua forma dual, sujeita às condições (2.72) e (2.73).

A equação (2.77) tem, além disso, uma vantagem que é preciso considerar, é que expressa sua solução em função do produto interno dos vetores de treinamento. Desta maneira, é possível expor a solução do problema de otimização independentemente da dimensão do espaço de entrada. Esta característica tem a particularidade de que a extensão a um classificador não linear é também mais expedita. Para ele, é suficiente mudar o produto interno euclidiano pela função que representa o produto interno num espaço de propriedades de alta dimensão. Nestas condições é possível escrever:

$$L_D(\boldsymbol{\omega}, \omega_0, \boldsymbol{\alpha}) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{j=1}^n \sum_{i=1}^n \alpha_i \alpha_j y_i y_j K(\mathbf{x}_j, \mathbf{x}_i) \quad (2.78)$$

A função K deve cumprir as condições do teorema de Mercer para que seja considerado um produto escalar no espaço de propriedades (MERCER, 1909). Em

correspondência com este teorema, na Tabela 2.2 são mostradas algumas alternativas de produto escalar em espaços de alta dimensão.

Tabela 2.2: Algumas funções que satisfazem o teorema de Mercer.

Nome	Equação
Quadrático	$K(\mathbf{x}_j, \mathbf{x}_i) = (\mathbf{x}_j \cdot \mathbf{x}_i)^2$
Polinomial	$K(\mathbf{x}_j, \mathbf{x}_i) = (\mathbf{x}_j \cdot \mathbf{x}_i + 1)^n$
Funções de base radial (RBF)	$K(\mathbf{x}_j, \mathbf{x}_i) = e^{-\frac{\ \mathbf{x}_i - \mathbf{x}_j\ ^2}{r^2}}$
Tipo Rede neural	$K(\mathbf{x}_j, \mathbf{x}_i) = \tanh(\mathbf{x}_j \cdot \mathbf{x}_i + b)$

Finalmente para construir o classificador são empregados os vetores suporte encontrados no processo de otimização e o discriminante linear:

$$f(\mathbf{x}) = \text{sgn} \left[\sum_{i=1}^{n_h} y_i \alpha_i \mathbf{x}_i \cdot \mathbf{x} + \omega_0 \right] \quad (2.79)$$

Onde n_h é o número de vetores suporte encontrado, analogamente se pode escrever uma expressão para o caso não linear:

$$f(\mathbf{x}) = \text{sgn} \left[\sum_{i=1}^{n_h} y_i \alpha_i K(\mathbf{x}_i, \mathbf{x}) + \omega_0 \right] \quad (2.80)$$

2.9 Limitações do estado da arte: Resumo

2.9.1 Sobre os métodos de processamento do ECG ambulatorial no geral

Na literatura não aparecem métodos nem metodologia explicitamente concebidos para reconhecimento morfológico de batimentos no ECG que não sejam validos para os efeitos da análise da HRV e QTV.

2.9.2 Sobre os métodos da obtenção (e validação) da final de onda T

Nos algoritmos mais reportados nos últimos anos, a posição do ponto Te depende de um limiar empírico (LAGUNA, 1990; MCLAUGHLIN, 1995; DASKALOV, 1999; VILA et al., 2000; MARTINEZ et al., 2004), o qual é pouco robusto ao ruído:

- na proposta de cada algoritmo não se realiza um análise quantitativa com respeito ao ruído (LAGUNA, 1990; MCLAUGHLIN, 1995; DASKALOV, 1999; VILA et al., 2000; MARTINEZ et al., 2004). Somente se calcula a sensibilidade, especificidade e precisão.

- há poucos estudos sobre a influência do ruído de banda larga no QT ou estimativas. Os três existentes (PORTA et al., 1998; TIKKANEN et al., 1999; MARTINEZ, 2010) usam apenas sinais sintéticos de poucos batimentos e morfologias, mas não usam sinais ambulatoriais reais.

- não há nenhum estudo sobre a influência do ruído diretamente na detecção do ponto Te. Só existem sobre os pontos R (FRIESEN, 1990).

2.9.3 Sobre os métodos de reconhecimento morfológico de artefatos

Não aparece reportado na bibliografia nenhum trabalho para classificar batimentos que constituírem artefatos para efeitos da análise HRV e a QTV. Este tipo de enfoque não aparece reportando na bibliografia. As publicações mais relacionadas possuem outros objetivos científicos: detecção de diversos tipos de arritmias (DIMINSKI, 2000; WANG, 2001; ROJAS, 2002; WOLF, 2003; CEYLAN, 2007).

Como consequência do exposto anteriormente, também não existe nenhum estudo quantitativo comparativo combinado dos diversos métodos de EC e agrupamento no ECG para classificação de batimentos validos para efeitos da análise da HRV e QTV, nem inclusive para detecção de arritmias cardíacas.

Não aparece reportado na bibliografia nenhum método de geração de batimentos sintéticos para a validação dos algoritmos de reconhecimento de padrões de ECG.

CAPÍTULO 3 - RECONHECIMENTO MORFOLOGICO DE ARTEFATOS

3.1 Introdução

Os esquemas para o reconhecimento morfológico de batimentos no ECG usam o esquema da Figura 3.1 onde o classificador é composto por uma etapa de extração de características (EC) e outra de agrupamento baseada em técnicas de inteligência computacional (IC).

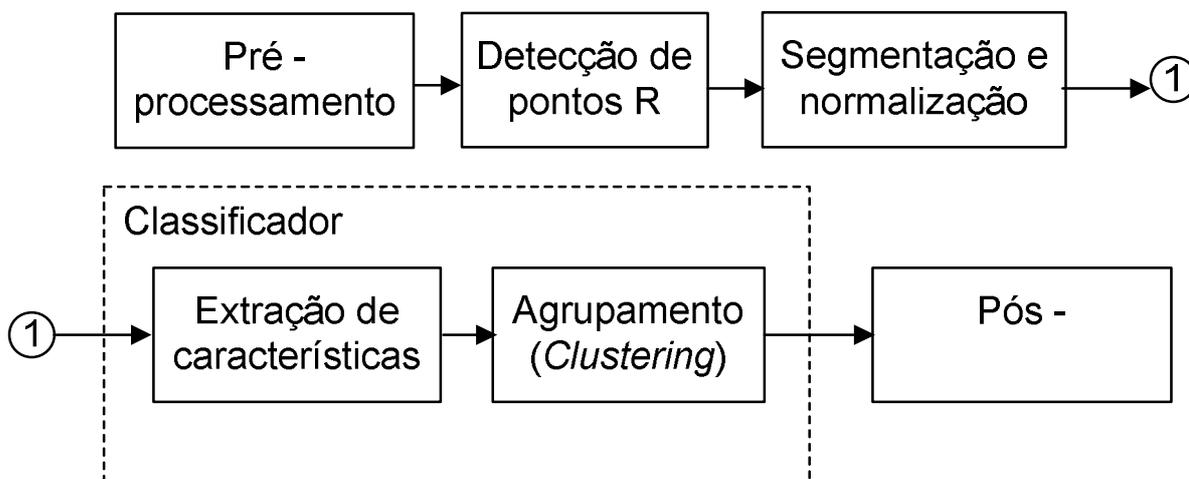


Figura 3.1 Etapas de um sistema classificador de sinais de ECG

Os principais métodos de EC são resumidos a seguir:

1. Características morfológicas extraídas diretamente do sinal (MITRA, 2009), como amplitude de ondas ou segmentos, durações de segmentos ou intervalos, e áreas, entre outras.
2. Uso de parâmetros estatísticos, como a média, o desvio padrão, o valor máximo, valor mínimo e outros, tais como a: média da energia do complexo QRS, média da densidade de potência espectral, média dos coeficientes de auto-correlação e média do histograma do sinal. (HOSSEINI, 2006).
3. Uso de modelos matemáticos para representar as curvas do sinal do ECG (OLSZEWSKY, 2001). Dentre os mais usados estão os modelos auto-regressivos, os coeficientes de predição linear (LPC), o uso de funções definidas (ex.: constante, reta, triangular) para a aproximação de segmentos do sinal, entre outros.

4. Uso de diversas transformadas: (a) *Karhunen-Loeve* ou método de análise de componentes principais, linear (NADAL, 1993) e não linear ou KPCA (*Kernel PCA*), (b) discreta do co-seno (GHONGADE, 2009), (c) wavelets, (d) distribuições tempo-frequência e (e) as funções do Hermite, entre outras.

Dentre as técnicas de inteligência computacionais mais usadas no sinal de ECG estão as Redes Neurais Artificiais (RNA), a Lógica *Fuzzy*, os Algoritmos Genéticos (GA) (VALFREDO, 1999) e outras técnicas híbridas, por exemplo, Neuro-Fuzzy (WANG, 2001; ENGIN, 2004; CEYLAN, 2008). Também existem outras técnicas estatísticas e sintáticas, que foram usadas anteriormente.

Os métodos baseados em redes neurais são usados na classificação quando se dispõe de pouca informação a priori sobre as classes. As Redes Neurais Artificiais tentam emular o raciocínio humano, mediante um processo de aprendizagem, onde ocorre um ajuste nas interligações dos neurônios artificiais, para que a rede possa responder corretamente às solicitações realizadas, e um processo de teste para que se possa avaliar o seu desempenho (OLIVEIRA, 1999).

A Lógica Fuzzy é ideal para ambientes onde as informações são parciais ou incompletas, por exemplo, para a classificação de arritmias no sinal de ECG (SILIPO, 1999).

Existe uma extensa diversidade de publicações sobre o reconhecimento morfológico de arritmias (GHONGADE, 2009; CEYLAN, 2007; SIMON, 2002; DIMINSKI, 2000). Entretanto, não foi encontrada nenhuma publicação que caracterize quantitativamente o desempenho dos métodos de extração de características e de classificação para casos de batimentos com artefatos fisiológicos e técnicos. Existe apenas um trabalho recente (KARPAGACHELVI, 2010) que compara diversos métodos de EC, quanto à simplicidade, exatidão e valor preditivo positivo, mas só do ponto de vista qualitativo. Neste trabalho não são analisados aspectos importantes como são o tempo de execução (dá ideia do custo computacional), nem o desempenho de métodos do EC de amplo uso, como são a DCT e o PCA linear e não linear.

Na Tabela 3.1, a seguir, resume os principais métodos de EC e agrupamentos reportados para a classificação de batimentos no sinal de ECG.

Tabela 3.1 - Métodos de extração de características mais utilizados em sinais eletrocardiográficos (MLP: Perceptron multicamada, PCA: Análise de componentes principais, KLT: Transformada de Karhunen-Loeve, SOM: Mapas auto-organizados, LVQ: *Learning Vector Quantization*, LPC: Coeficientes de predição linear, FCM: Fuzzy C-Means, SVM: Máquina de suporte vetorial).

EXTRAÇÃO DE PROPIEDADES	AGRUPAMENTO	REFERÊNCIA
Propriedades morfológicas e estatísticas	MLP	Hosseini, 2006
PCA (KLT)	MLP	Afsar, 2007
Propriedades do intervalo R-R. Propriedades morfológicas do ECG	SOM LVQ MLP	He, 2006
LPC	MLP	Avalieri, 2006
Wavelet Estatísticos de ordem superior LPC	Neuro-fuzzy (FCM + MLP)	Engin, 2004
FCM + PCA	MLP	Patra, 2009
Estatísticos das decomposições wavelet	SVM + RBF	Übeyli, 2007
FCM Wavelet PCA	MLP	Ceylan, 2007
Propriedades morfológicas	MLP SOM	Hu, 1997
LPC + PCA	GMM	Joy, 2009
Parâmetros do ECG e do VCG	K vizinhos mais próximos	Christov, 2005
Segmentos ST reprocessados	SVM	Mohebbi, 2007
FCM	MLP	Özbay, 2006

Dentre os métodos de extração de características mais usados estão o PCA linear e a transformada discreta do cosseno (DCT). O método de agrupamento mais usado é o Perceptron multicamada (MLP). Em menor proporção (em ordem descendente) são empregados os seguintes métodos de agrupamento: Máquina de suporte vetorial (SVM), Quantificação vetorial adaptativa (LVQ) e Funções de base radial (RBF).

Baseado no exposto anterior, o alvo neste capítulo será caracterizar o desempenho destes métodos para o reconhecimento de batimentos não válidos para efeitos da análise da HRV, visando propor uma nova combinação de métodos de EC e agrupamento de desempenho ótimo.

A metodologia de pesquisa evoluiu seguindo a seguinte cronologia:

1. Caracterização do desempenho dos três métodos de ECG para um classificador padrão ideal: MLP neste caso. O objetivo é determinar o método de EC de melhor desempenho usando 2800 batimentos reais.

2. Caracterização do desempenho conjunto dos três métodos de extração e os quatro classificadores citados anteriormente:

- 2.1. Determinação da combinação EC - agrupamento de melhor desempenho realizando uma avaliação parcial com 4000 batimentos reais. O

objetivo é investigar se existe outro método de agrupamento com um desempenho ainda melhor que o MLP.

2.2. Avaliação global dos três métodos de EC para o método de agrupamento selecionado no passo 2.1. O objetivo final é validar a melhor combinação EC - agrupamento para todos os batimentos da base MIT-BIH *Arrhythmia Data base* (110192 batimentos).

3.2 Caracterização de métodos de extração de características

3.2.1 Materiais e métodos

Para realizar a caracterização dos três métodos foram usados 2800 batimentos extraídos de 12 registros da base de dados MIT-BIH *Arrhythmia Data base* (MOODY, 1990) a qual contém 48 fragmentos de 30 minutos correspondentes a registros ambulatoriais de dois canais. A frequência de amostragem é de 360 Hz, com 11bits de resolução e uma faixa dinâmica de 10 mV. Através do Physionet (<http://www.physionet.org/>) se podem obter 25 dos 48 registros.

Foram consideradas oito morfologias diferentes: batimento normal (NRB), bloqueio de ramo esquerdo (LBBB), bloqueio de ramo direito (RBBB), misto normal + *paced* (PNB), misto normal + ventricular (VNB), contração ventricular prematura (PVCB), contração atrial prematura (APCB) e *paced* (PCB). Na Tabela 3.2 são mostrados os registros selecionados para o experimento.

Tabela 3.2: Registros selecionados para a classificação.

Registros	Batimentos	Classificação
201	200	NRB
202	200	NRB
203	200	NRB
210	100	NRB
213	400	NRB (200), VNB (200)
214	200	LBBB
217	500	NRB (100), PCB (200), PNB (200)
230	200	NRB
231	300	NRB (100), RBBB (200)
232	200	APCB (200)
233	200	PVCB (200)
234	100	NRB (100)
Total	2800	

Os 2800 batimentos são divididos em duas classes: batimentos normais ou gerados no nodo sinoatrial (NRMB) e batimentos identificados como artefatos fisiológicos (ARTF), que são aqueles que não são originados no dito nodo e portanto, não são válidos para a análise da HRV. A divisão é realizada aleatoriamente, mas conservando em cada classe o mesmo número de subclasses de maneira que cada grupo contenha 700 NRB, 100 LBBB, 100 RBBB, 100 PVCB, 100 VNB, 100 APCB, 100 PCB e 100 PNB.

Os sinais de ECG foram filtrados com um filtro bidirecional de Butterworth de ordem 6, passa-faixas, com frequência de corte inferior de 0,6 Hz e superior de 45 Hz. A segmentação de batimentos empregada é centrada ao redor do ponto R com uma janela simétrica de ± 90 (180) amostras garantindo a inclusão total das ondas P e T do batimento. Como pré-processamento final é eliminado o valor médio de cada batimento garantindo um nível de DC igual a zero. Posteriormente, os valores são normalizados com respeito ao desvio padrão.

A rede neural é do tipo MLP com arquitetura *feedforward*, e uma camada oculta. Em forma matricial esta rede é modelada como:

$$\mathbf{O} = \mathbf{g}(\mathbf{W}_{jk}^T \cdot \mathbf{f}(\mathbf{W}_{ij}^T \cdot \mathbf{I})) \quad (3.1)$$

Sendo \mathbf{I} e \mathbf{O} os vetores de entrada e saída respectivamente, \mathbf{W}_{ij} é a matriz dos pesos cujos elementos w_{ij} relacionam à entrada i com o neurônio j da camada oculta. \mathbf{W}_{jk} é a matriz cujos elementos w_{jk} relacionam a saída do neurônio j da camada oculta com o neurônio k da camada de saída, \mathbf{f} e \mathbf{g} são funções vetoriais geralmente de tipo sigmoideal ou linear. O algoritmo utilizado para o treinamento é o de retro-propagação Levenberg-Marquardt, com o critério do erro mínimo quadrático (MSE). A rede implementada tem 10 neurônios na camada de entrada, 20 neurônios na camada oculta e 1 neurônio na camada de saída (10 – 20 – 1). A função de ativação em todas as camadas é a tangente hiperbólica:

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.2)$$

A avaliação do desempenho do classificador MLP para os três métodos de extração foi realizada mediante o cálculo:

- (a) do rendimento usando vários indicadores extraídos da matriz de confusão para as 2 classes definidas: NRMB e ARTF (Figura 3.2) e;

(b) dos tempos de execução dos casos melhores, pior e médio.

As colunas da matriz de confusão expressam o valor real de cada classe e as linhas expressam o valor estimado destas. Para cada método de extração foram usados 700 batimentos para o treinamento e igual número para a validação.

NRMB ARTF (Estimação)	VP %VP	FP %FP	VPP (%)
	FN %FN	VN %VN	VPN (%)
	S (%VP)	E (%VN)	ACC(%)
	NRMB (Real)	ARTF (Real)	

$$S(\%) = \frac{VP}{VP + FN} \times 100 \quad E(\%) = \frac{VN}{VN + FP} \times 100$$

$$VPP(\%) = \frac{VP}{VP + FP} \times 100 \quad VPN(\%) = \frac{VN}{VN + FN} \times 100$$

$$ACC(\%) = \frac{VP + VN}{VP + FP + VN + FN} \times 100$$

Figura 3.2 - Matriz de confusão para avaliar o rendimento do classificador MLP para cada método de extração de características. VP: verdadeiros positivos, %VP y %VN: Porcentagem de batimentos de tipo VP e VN, respectivamente; VN: verdadeiros negativos, FP: Falsos positivos, FN: Falsos negativos, S: Sensibilidade, E: Especificidade, ACC: exatidão, VPP: Valor preditivo positivo, VPN: Valor preditivo negativo.

Método DCT: A partir do cálculo da transformada discreta do cosseno (equações 2.13 e 2.10) foram selecionadas as 10 primeiras componentes **C** do vetor **Xc**.

Método PCA: A partir da solução do problema de autovalores (equação 2.17) foram selecionados os 10 primeiros vetores próprios ($M = 10$).

Método KPCA: O algoritmo da figura 2.10 foi usado para extrair as 10 primeiras componentes principais usando o método KPCA. O procedimento da Figura 2.10 (repetido por conveniência) consta dos seguintes passos:

1. Calcular k_{ij} segundo a expressão $K_{ij} = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j) = k(\mathbf{x}_i, \mathbf{x}_j)$
2. Resolver a expressão $M\lambda\alpha = \mathbf{K}\alpha$
3. Normalizar segundo $1 = \lambda_k (\alpha^k \alpha^k)$

4. Extrair as 10 primeiras componentes do vetor \mathbf{x} , resolvendo a seguinte expressão:

$$(kPC)_n(x) = (\mathbf{V}^n \cdot \Phi(\mathbf{x})) = \sum_{i=1}^M \alpha_i^n k(\mathbf{x}_i, \mathbf{x}) \quad (3.3)$$

Para a caracterização da eficiência na execução foi tomado só o processo de extração de propriedades e não a etapa previa de solução do problema de autovalores (em PCA e KPCA). O computador usado foi uma IBM PC com processador Pentium™ IV; 2,66 GHz, 1 GB de memória RAM DDR400 do tipo *Dual Channel*.

3.2.2 Resultados

As Tabelas 3.3 a 3.8 mostram os indicadores de desempenho tanto no treinamento como na validação do classificador MLP, para os 3 métodos de extração de características analisados.

Tabela 3.3: Matriz de confusão do classificador DCT + MLP (treinamento).

NRMB	690	47	93,6%
	49,3%	3,4%	
ARTF	10	653	98,5%
	0,7%	46,6%	
	98,6%	93,3%	95,9%
	NRMB	ARTF	

Tabela 3.4: Matriz de confusão do classificador DCT + MLP (validação).

NRMB	687	40	98,1%
	49,1%	2,9%	
ARTF	13	660	98,1%
	0,9%	47,1%	
	98,1%	94,3%	96,2%
	NRMB	ARTF	

Tabela 3.5: Matriz de confusão do classificador PCA + MLP (treinamento).

NRMB	679	76	89,9%
	48,5%	5,4%	
ARTF	21	624	96,7%
	1,5%	44,6%	
	97,0%	89,1%	93,1%
	NRMB	ARTF	

Tabela 3.6: Matriz de confusão do classificador PCA + MLP (validação).

NRMB	671	69	90,7%
	47,9%	4,9%	
ARTF	29	631	95,6%
	2,1%	45,1%	
	95,9%	90,1%	93,0%
	NRMB	ARTF	

Tabela 3.7: Matriz de confusão do classificador KPCA + MLP (treinamento).

NRMB	696	8	98,9%
	49,7%	0,6%	
ARTF	4	692	99,4%
	0,3%	49,4%	
	99,4%	98,9%	99,1%
	NRMB	ARTF	

Tabela 3.8: Matriz de confusão do classificador KPCA + MLP (validação).

NRMB	690	8	98,9%
	49,3%	0,6%	
ARTF	10	692	98,6%
	0,7%	49,4%	
	98,6%	98,9%	98,7%
	NRMB	ARTF	

Os tempos de execução (em segundos) nos casos melhores, piores e intermediários são mostrados na Tabela 3.9.

Tabela 3.9: Tempo de execução (s) dos classificadores.

	Melhor	Pior	Médio
DCT	$1,67 \cdot 10^{-4}$	$2,17 \cdot 10^{-2}$	$3,44 \cdot 10^{-4}$
PCA	$5,20 \cdot 10^{-5}$	$7,47 \cdot 10^{-2}$	$1,16 \cdot 10^{-4}$
KPCA	$1,19 \cdot 10^{-1}$	1,58	$1,27 \cdot 10^{-1}$

O método Kernel PCA tem o melhor rendimento, mas também o pior tempo de execução. Isto é consequência de que para extrair as componentes principais de um vetor arbitrário é necessário avaliar M vezes, a função Kernel, onde M é o número de observações. Não obstante, a extração das componentes principais de um vetor consome, em média, 127 ms aproximadamente. Schölkopf (1998) sugeriu algumas recomendações para diminuir este problema, que é o foco atual da pesquisa dos autores.

A contraparte é o método da PCA Linear que é o mais rápido, pois só requer uma operação de multiplicação de matrizes, mas as vezes é o que apresenta pior rendimento com uns 93% em cada caso. A DCT é o caso intermediário com uma exatidão media de 96 %, e um tempo médio de menos de 0,4 ms por vetor.

3.3 Caracterização do desempenho conjunto: extração-agrupamento

A caracterização dos métodos de EC realizada na epígrafe anterior deixou a seguinte incógnita: existirá outro método de classificação que apresente um desempenho ainda melhor?

O objetivo da presente epígrafe é avaliar o desempenho conjunto de combinações de métodos de EC e de agrupamento para detectar batimentos com artefatos no sinal de ECG.

3.3.1 Materiais e métodos

3.3.1.1 Sinais usados

Para avaliar o desempenho foram realizados experimentos com diferentes conjuntos de dados para cada classificador. Como conjunto de treinamento e validação foi usado os batimentos da base de dados MIT-BIH *Arrhythmia Data base*. Essa base de dados possui 48 registros amostrados a 360 Hz durante 30 minutos cada, totalizando 24 horas. A distribuição por derivações de cada registro é apresentada nas tabelas 3.10 e 3.11.

No Anexo A é apresentado uma distribuição global das classes de batimentos presentes nesta base de dados. Aproximadamente 70% dos batimentos presentes foram classificados como batimentos normais (originados no nodo SA) o restante correspondeu a 17 classes distintas de batimentos. Entre estes se encontram batimentos ectópicos, bloqueios de rama esquerda e direita, de entre outros. Para os fins deste experimento estas 17 classes são agrupadas na classe genérica ARTEFATO. Todo batimento normal pertence então à classe NORMAL.

Tabela 3.10: Serie 100 do MIT-BIH DB.

Serie 100	360 Hz	650000 amostras/registro
Registro	Derivações	
100	MLII	V5
101	MLII	V1
102	V5	V2
103	MLII	V2
104	V5	V2
105	MLII	V1
106	MLII	V1
107	MLII	V1
108	MLII	V1
109	MLII	V1
111	MLII	V1
112	MLII	V1
113	MLII	V1
114	V5	MLII
115	MLII	V1
116	MLII	V1
117	MLII	V2
118	MLII	V1
119	MLII	V1
121	MLII	V1
122	MLII	V1
123	MLII	V5
124	MLII	V4

Tabela 3.11: Serie 200 do MIT-BIH DB.

Serie 200		360 Hz		650000 amostras/registro
Derivações: MLII, V1				
Registros				
200	201	202	203	205
207	208	209	210	212
213	214	215	217	219
220	221	222	223	228
230	231	232	233	234

Inicialmente foi feita uma avaliação parcial (preliminar) usando 4000 batimentos: 2000 para treinamento e 2000 para validação e a partir dos resultados obtidos foi feita uma avaliação global usando todos os batimentos (110192) da base de dados.

Dos 4000 batimentos de diferentes registros da base de dados, foram selecionados 2000 batimentos para cada classe. Foram escolhidos batimentos de todos os registros da base de dados seguindo o seguinte critério: de cada registro

que acumule mais de 50 batimentos da classe NORMAL (40 registros) foram selecionados de maneira aleatória 50 batimentos. Para os batimentos da classe ARTEFATO o critério é: de cada registro que acumule mais de 375 batimentos (25 registros) da classe ARTEFATO são extraídos de maneira aleatória 80 batimentos desta classe.

No Anexo B é apresentada a tabela de seleção de batimentos por registro neste processo, mostrando-se que foram selecionados batimentos de todos os registros da base de dados. Nessa seleção foi impossível controlar a qualidade dos batimentos selecionados pertencentes à classe NORMAL. No caso da classe ARTEFATO, também não foi possível controlar a proporção dos exemplos das classes que compõem à classe ARTEFATO, ou seja, a aleatoriedade na seleção não garante que as diferentes subclasses da classe artefato aportem o mesmo número de batimentos.

3.3.1.2 Etapas do sistema classificador de batimentos

Pré-processamento

Para eliminar as flutuações da linha base e o ruído de alta frequência é empregado um filtro passa-faixas (BP), composto por um filtro passa-altas (HP) Butterworth de 6ª ordem e frequência de corte de 0,6 Hz em cascata com um filtro passa-baixas (LP) Butterworth de 12ª ordem e frequência de corte de 45 Hz.

O outro passo no pré-processamento é eliminar o valor médio do sinal e transformá-lo em um sinal de variância unitária segundo a expressão:

$$y = (x - \bar{x}) / \sigma \quad (3.4)$$

Detecção da onda R

Conforme foi explicado na epigrafe 1.4, neste experimento (e ao longo do documento) são usadas as anotações dos pontos R realizados pelos especialistas para cada batimento, o que equivale a empregar a um algoritmo infalível para estimar os pontos R no ECG.

Segmentação

Para segmentar os batimentos são adotados os seguintes critérios (DALE, 2003): a longitude típica dos intervalos PR e QT normais têm as seguintes cotas (todos os valores em segundos),

1. Intervalo PR normal [0,12 – 0,20]
2. Intervalo QT normal [0,35 – 0,45]

Destes dados se podem inferir outros elementos:

- I. Intervalo PT min 0,47. A 360 Hz: 169,2 amostras (170 amostras aprox.).
- II. Intervalo PT max 0,65. A 360 Hz: 234 amostras (235 amostras, incluindo ao ponto R).
- III. Relação PR/QT para valores mínimos: 34,3%
- IV. Relação PR/QT para valores máximos: 44,4%
- V. Relação PR/QT para valores min-max: 26,7% (PRmin/QTmax)
- VI. Relação PR/QT para valores max-min: 57,1 % (PRmax/QTmin)

Para a segmentação foi empregada uma janela assimétrica, de tamanho fixo, entorno do ponto R. A longitude da janela adotada foi igual a 235 amostras (ou seja, o valor máximo) incluído o ponto pico de R. Para a seleção do número de amostras à direita e à esquerda do pico R foi empregada a media das relaciones PR/PT (III) e (IV), ou seja, aproximadamente o 39% das amostras estão localizadas à esquerda (92 amostras) e o 61% à direita (142 amostras).

Classificadores

Dentro da etapa de classificação foram avaliados os algoritmos de extração de características citados na coluna da esquerda com cada um dos tipos de RNA da coluna da direita abaixo de acordo com os critérios apresentados:

- | | |
|---------|--------|
| 1. DCT | 1. MLP |
| 2. PCA | 2. LVQ |
| 3. KPCA | 3. RBF |
| | 4. SVM |

De cada etapa de extração é possível obter o número de componentes seguintes:

$$\begin{array}{ccc}
 \text{DCT} & \text{PCA} & \text{KPCA} \\
 1 \leq N_{DCT} \leq V_L & 1 \leq N_{PCA} \leq V_L & 1 \leq N_{KPCA} \leq N
 \end{array}$$

Onde V_L é a longitude em amostras de cada vetor, neste experimento V_L é igual a 235 amostras e o número de vetores N , neste caso é 2000. Para os experimentos foram selecionados 10, 15 e 20 componentes de cada etapa de extração. Este procedimento gera 3 classificadores por combinação. A seguir são mostrados os classificadores:

$$\text{DCT}(10, 15, 20) \left| \begin{array}{l} \text{MLP} \\ \text{LVQ} \\ \text{RBF} \\ \text{SVM} \end{array} \right.$$

$$\text{PCA}(10, 15, 20) \left| \begin{array}{l} \text{MLP} \\ \text{LVQ} \\ \text{RBF} \\ \text{SVM} \end{array} \right.$$

$$\text{KPCA}(10, 15, 20) \left| \begin{array}{l} \text{MLP} \\ \text{LVQ} \\ \text{RBF} \\ \text{SVM} \end{array} \right.$$

❖ Particularidades do classificador MLP

Para treinar os classificadores MLP para cada valor distinto de componentes foi criado uma rede com uma camada oculta de arquitetura: $n - 2n - 1$, ou seja, n neurônios de entrada, $2n$ neurônios na camada oculta e um neurônio de saída. A função de transferência na camada oculta é a tangente hiperbólica (**tanh**) e para a camada de saída a função de ativação é linear. Desta maneira, o MLP está conformado pelas arquiteturas seguintes: 10 – 20 – 1, 15 – 30 – 1 e 20 – 40 – 1.

❖ Particularidades do classificador LVQ.

Para este classificador são empregados n neurônios na camada competitiva e dois neurônios na camada de saída (2 classes).

❖ Particularidades do classificador RBF

No classificador RBF é empregado um algoritmo simples de busca do parâmetro de dispersão ótimo no intervalo (0,1 – 10). Cada classificador tem n neurônios de base radial e um neurônio de saída linear.

❖ Particularidades do classificador SVM

Este classificador é o único para o qual N é igual a 1000 por problemas de custo computacional. Desta maneira é de esperar um menor rendimento, pois só a quarta parte do conjunto disponível é empregada na busca dos vetores suporte.

A avaliação do desempenho foi realizada mediante o cálculo:

(a) do rendimento, usando os indicadores: Especificidade (E), Sensibilidade (S) e Valor Preditivo Positivo (VPP), extraídos das tabelas de confusão de cada classificador para as 2 classes definidas: NORM e ARTF, como mostrado na Figura 3.3.

(b) dos recursos computacionais: tempos de extração de características e memória utilizada.

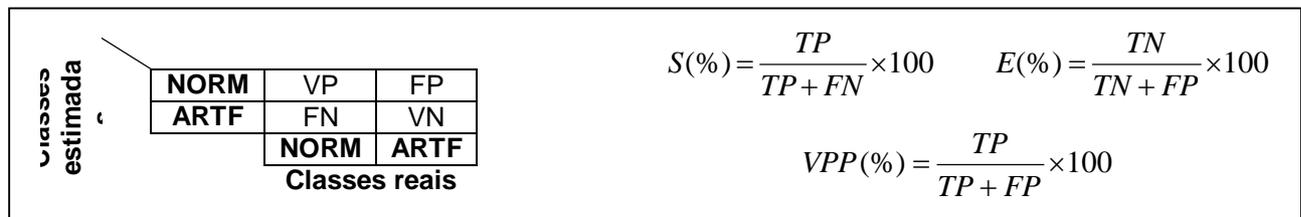


Figura 3.3: Matriz de confusão para avaliar o rendimento na saída dos classificadores (MLP, LVQ, RBF, SVM) para cada método de extração de características (DCT, PCA, KPCA). VP: verdadeiros positivos, VN: verdadeiros negativos, FP: Falsos positivos, FN: Falsos negativos, S: Sensibilidade, E: Especificidade, VPP: Valor preditivo positivo.

3.3.1.3 Comparação dos métodos de classificação

Para verificar se as diferenças entre as diferentes implementações de classificadores são estatisticamente significativas, foi usado o Test de *McNemar*, o qual é um método estatístico não paramétrico aplicado em tabelas de contingência de 2x2 com ramos dicotômicos, ou seja, para dois classificadores A e B. O Test é baseado no cálculo do estadígrafo z de McNemar, definido como:

$$z = \frac{|n_{01} - n_{10}| - 1}{\sqrt{n_{01} + n_{10}}} \quad (3.5)$$

Sendo:

n_{01} : número de amostras mal classificadas por A mas não por B.

n_{10} : número de amostras mal classificadas por B mas não por A.

A quantidade z^2 se distribui aproximadamente como χ^2 com um grau de liberdade. A hipótese nula H_0 (os dois classificadores têm o mesmo erro) pode ser rejeitada com uma probabilidade de erro de 0,05 se $|z| > 1,96$. A hipótese alternativa H_1 é que os classificadores têm erros distintos.

Se o resultado $|z|$ é significativo, então há suficiente evidência para rejeitar a hipótese nula em favor da hipótese alternativa, o que significa que as frequências marginais são significativamente diferentes entre ambos classificadores. Em outras palavras, os classificadores não têm o mesmo erro e, por conseguinte as diferenças nos índices de rendimento são estatisticamente significativas.

Para efeitos de comparar estatisticamente todos os classificadores entre si, foi calculado o estadígrafo $|z|$ para cada par de classificadores dentre todas as combinações possíveis, para o caso da avaliação global que constitui a população experimental maior e portanto o caso mais desfavorável.

3.3.2 Resultados da avaliação parcial

Nas tabelas 3.12 a 3.20 são mostrados os indicadores de rendimento tanto no treinamento como na validação dos quatro classificadores usados, nos casos de 10, 15 e 20 componentes (características) extraídas para cada método de extração de características analisado.

Tabela 3.12: Classificador 10 FE – DCT.

Classificador	Treinamento			Validação		
	E(%)	S(%)	VPP(%)	E(%)	S(%)	VPP(%)
DCT + MLP	97.8	97.7	97.8	93.3	94.2	93.2
DCT+LVQ	75.8	91.6	79.5	71.8	91.7	76.2
DCT+RBF	87.2	86.6	87.3	83.9	85.9	84.0
DCT+SVM	72.8	80.1	76.0	72.5	79.6	73.8

Tabela 3.13: Classificador 15 FE – DCT.

Classificador	Treinamento			Validação		
	E(%)	S(%)	VPP(%)	E(%)	S(%)	VPP(%)
DCT + MLP	97.1	97.9	97.1	93.2	96.3	93.3
DCT+LVQ	83.6	90.2	84.8	80.8	88.9	82.0
DCT+RBF	87.6	89.8	88.0	82.9	89.7	83.8
DCT+SVM	80.9	82.4	82.3	77.5	81.2	77.9

Tabela 3.14: Classificador 20 FE – DCT.

Classificador	Treinamento			Validação		
	E(%)	S(%)	VPP(%)	E(%)	S(%)	VPP(%)
DCT + MLP	97.4	97.6	97.4	94.6	96.6	94.6
DCT+LVQ	79.4	95.6	82.5	75.2	96.2	79.2
DCT+RBF	90.8	93.6	91.2	89.9	92.5	90.0
DCT+SVM	82.0	81.7	82.9	79.8	81.0	79.6

Tabela 3.15: Classificador 10 FE – PCA

Classificador	Treinamento			Validação		
	E(%)	S(%)	VPP(%)	E(%)	S(%)	VPP(%)
PCA + MLP	96.9	97.8	97.0	94.2	94.5	94.2
PCA+LVQ	80.2	93.8	82.8	78.1	91.3	80.4
PCA+RBF	90.1	89.4	90.2	89.2	88.5	89.0
PCA+SVM	82.8	79.2	83.2	81.4	81.3	81.0

Tabela 3.16: Classificador 15 FE – PCA.

Classificador	Treinamento			Validação		
	E(%)	S(%)	VPP(%)	E(%)	S(%)	VPP(%)
PCA + MLP	98.6	97.7	98.6	95.9	96.2	95.9
PCA+LVQ	79.0	93.1	81.3	81.9	94.1	84.1
PCA+RBF	90.4	90.5	90.6	88.9	88.5	88.7
PCA+SVM	84.4	84.6	85.4	82.5	84.7	82.6

Tabela 3.17: Classificador 20 FE – PCA.

Classificador	Treinamento			Validação		
	E(%)	S(%)	VPP(%)	E(%)	S(%)	VPP(%)
PCA + MLP	98.5	97.4	98.5	95.9	94.9	95.8
PCA+LVQ	84.7	95.4	86.4	82.2	93.8	83.9
PCA+RBF	93.5	93.0	93.6	92.3	91.5	92.1
PCA+SVM	84.4	85.9	85.6	82.1	84.2	82.2

Tabela 3.18: Classificador 10 FE – KPCA.

Classificador	Treinamento			Validação		
	E(%)	S(%)	VPP(%)	E(%)	S(%)	VPP(%)
KPCA + MLP	96.8	98.0	96.9	94.0	94.9	94.0
KPCA+LVQ	84.4	89.1	85.3	83.0	88.0	83.6
KPCA+RBF	87.6	88.8	87.9	87.0	88.3	87.0
KPCA+SVM	79.3	84.4	81.4	79.8	84.5	80.4

Tabela 3.19: Classificador 15 FE – KPCA.

Classificador	Treinamento			Validação		
	E(%)	S(%)	VPP(%)	E(%)	S(%)	VPP(%)
KPCA + MLP	98.4	98.6	98.4	96.8	96.3	96.8
KPCA+LVQ	84.2	93.1	85.7	82.9	90.4	83.9
KPCA+RBF	91.8	88.6	91.7	91.2	88.5	90.8
KPCA+SVM	89.8	86.7	90.2	88.6	87.4	88.2

Tabela 3.20: Classificador 20 FE – KPCA.

Classificador	Treinamento			Validação		
	E(%)	S(%)	VPP(%)	E(%)	S(%)	VPP(%)
KPCA + MLP	98.3	98.8	98.3	96.0	95.9	96.0
KPCA+LVQ	93.9	90.0	90.5	89.5	91.9	89.6
KPCA+RBF	90.1	94.9	90.7	88.6	92.7	88.9
KPCA+SVM	91.1	87.5	91.3	89.2	89.0	88.9

No Anexo C são mostrados graficamente os resultados do índice Especificidade (E). Inspeccionando os resultados anteriores é comprovado que o classificador MLP tem os melhores resultados para cada uma das diferentes etapas de extração.

3.3.3 Resultados da avaliação global

Baseado nos resultados anteriores, o seguinte passo é avaliar só os classificadores MLP não só para uma amostra de 4000 batimentos senão para todos os batimentos da base de dados. Nas tabelas 3.21 a 3.23 são apresentados os resultados da avaliação para 110192 batimentos extraídos da base de dados. Só foram excluídos 96 batimentos, o primeiro e o último de cada registro.

Tabela 3.21: Classificador DCT + MLP.

Classificador	E(%)	S(%)	VPP(%)
DCT_10	93.9	94.6	97.1
DCT_15	95.4	95.2	97.8
DCT_20	96.2	94.7	98.1

Tabela 3.22: Classificador PCA + MLP.

Classificador	E(%)	S(%)	VPP(%)
PCA_10	95.4	93.9	97.8
PCA_15	95.9	94.8	98.0
PCA_20	96.7	93.9	98.4

Tabela 3.23: Classificador KPCA + MLP.

Classificador	E(%)	S(%)	VPP(%)
KPCA_10	94.6	94.4	97.4
KPCA_15	96.4	95.2	98.2
KPCA_20	96.7	95.4	98.4

Das tabelas 3.21 a 3.23 fica evidente que para 10 componentes no vetor de características o algoritmo PCA + MLP supera em especificidade e valor preditivo positivo aos outros dois métodos, não obstante é menos sensível que DCT + MLP e KPCA + MLP, nesta ordem. Para 15 e 20 componentes o algoritmo KPCA + MLP é superior a DCT + MLP e PCA + MLP, mostrando índices superiores ou iguais aos melhores mostrados pelos outros dois métodos.

3.3.3.1 Resultados da comparação dos métodos de classificação

Os resultados do Test de *McNemar* para todos os classificadores tomados por pares e avaliados para os 110192 batimentos da base de dados do MIT são mostrados na Tabela 3.24. O estadígrafo de $McNemar|z|$ para cada par de classificadores é obtido interceptando a linha e a coluna da tabela anterior.

Tabela 3.24 Resultados do Test de McNemar para todos os classificadores e batimentos da base de dados. O método de agrupamento em todos os casos é MLP.

	PCA10	PCA15	PCA20	DCT10	DCT15	DCT20	KPCA10	KPCA15
PCA10								
PCA15	12,538							
PCA20	7,1254	5,6478						
DCT10	100,85	106,29	104,15					
DCT15	154,77	159,95	158,84	74,296				
DCT20	170,96	176,21	173,67	88,065	28,146			
KPCA10	208,51	210,50	209,62	140,32	80,199	60,885		
KPCA15	218,84	222,27	221,48	150,97	98,472	83,702	25,326	
KPCA20	193,31	197,12	195,53	119,28	53,620	30,619	32,714	58,082

Como se observa, para todos os classificadores, pode ser rejeitado a hipótese nula e por tanto é possível estabelecer que as diferenças encontradas nos índices de rendimento para cada um dos classificadores propostos são estatisticamente significativas.

3.3.4 Avaliação dos recursos computacionais

Nesta parte foram medidos os tempos de extração dos vetores de características para os casos de 10, 15 e 20 componentes por registro assim como a quantidade de memória utilizada para implementar cada método de extração de características. Os resultados dos tempos de extração podem ser consultados nos anexos D, E e F.

É necessário esclarecer que no caso do algoritmo KPCA foi empregado um algoritmo funcional, ou seja, o algoritmo não está programado para que seja ótimo. Logo, os resultados para KPCA são factíveis de melhorar.

O KPCA apresenta um expressivo custo computacional e memória de armazenamento comparado com outros dois métodos. KPCA necessita manter 3 matrizes grandes, dois de 2000x2000 (61,04 MB) e uma de 2000x235 (3,6 MB) para um total de 64,64 MB. PCA requer manter uma matriz de 235x235 (431,45 KB). DCT não requer manter matriz alguma.

3.4 Discussão

Neste trabalho são investigadas diferentes variantes de classificadores com a finalidade de encontrar a um classificador ótimo para o reconhecimento morfológico de artefatos no sinal do ECG. Os métodos MLP, LVQ, RBF e SVM são combinados com três algoritmos conhecidos de extração de características: PCA, DCT e KPCA para gerar classificadores diferentes e comparar seu rendimento. Neste contexto se incorporou um grau de liberdade com o número de componentes variável entre 10, 15 e 20.

Apesar de que as diferenças em rendimento entre classificadores são pequenas o Test de McNemar mostra a independência estatística entre os classificadores, selecionados por pares. Esta prova evidencia as diferenças no erro de classificação dos métodos avaliados e oferece um respaldo adicional a qualquer

afirmação realizada sobre a base da análise dos indicadores de rendimento obtidos neste estudo.

A análise do rendimento do método de máquinas de vetores suporte (SVM) deve-se tratar de maneira especial com respeito ao resto dos classificadores devido a que não emprega a mesma quantidade de vetores para o treinamento e a avaliação do método. Assim, os resultados desfavoráveis deste método devem ser tomados com major reserva para que em estudos futuros o treinamento e avaliação dos métodos sejam desenvolvidos em igualdade de condições.

Não foi possível comparar os resultados obtidos com outros trabalhos sobre reconhecimento morfológico de artefatos, pois não existem. Apesar de que não foram encontradas referências que se concentrem no reconhecimento morfológico de artefatos com algoritmos de inteligência computacional; e sim existe um amplo tratamento do tema em detecção de arritmias e isquemias, é necessário estabelecer as diferenças de cada processo. Nos detectores de arritmias é de interesse classificar cada batimento em n classes distintas, entretanto, neste trabalho só se estratifica em duas classes (NORMAL e ARTEFATO). Apesar de que é mais simples treinar um classificador de duas classes que outro de n classes, se estas classes forem gerais (como é o caso) a diversidade morfológica das subclasses subjacentes (neste caso a superclasse ARTEFATO e as subclasses interiores) pode contribuir a um rendimento pobre na tarefa de classificação. Isto é refletido no fato de que unicamente os métodos que empregam MLP mostram um rendimento superior aos 95% a diferença do restante onde os resultados não superam esta cota.

Os experimentos realizados mostram que KPCA tem um maior rendimento que seus pares PCA e DCT. A causa deste comportamento pode estar localizada na capacidade dos algoritmos do PCA não linear de capturar correlações não lineares entre os dados que conduzem à possibilidade de encontrar um maior grau de informação útil para a classificação com um número limitado de componentes.

3.5 Considerações finais

O compromisso entre os indicadores de rendimento e o tempo de execução para os três métodos analisados sugere o uso do KPCA para a o reconhecimento morfológico de artefatos no sinal do ECG, em lugar de outros métodos tradicionalmente usados como: PCA Linear e DCT. Apesar de ser o método de maior

tempo de execução, pode ser implementado com recursos razoáveis tendo em conta as atuais tecnologias computacionais.

De forma geral, os classificadores construídos empregando o algoritmo KPCA na etapa de extração, mostraram melhores desempenhos que seus pares baseados nos algoritmos PCA e DCT para os conjuntos de padrões considerados. Assim mesmo, dentre todos os métodos de inteligência computacional avaliados, as redes Perceptron multicamada (MLP) mostraram uma irrefutável superioridade sobre o resto dos algoritmos avaliados.

O aperfeiçoamento e otimização futura do algoritmo KPCA poderia garantir sua aplicação prática com uma maior eficiência e rapidez. Algumas das variantes que podem ser estudadas são: (1) a implementação de primitivas de hardware (usando dispositivos programáveis) que acelerarem o cálculo das componentes principais e (2) a modificação do algoritmo para melhorar sua eficiência apoiado em diversos critérios, por exemplo, o tipo de kernel selecionado a priori.

Apesar do grande número de batimentos reais usados na validação dos resultados, a possibilidade de gerar batimentos sintéticos, de forma controlada, com uma elevada variabilidade morfológica permitiria caracterizar ainda melhor o desempenho dos classificadores inteligentes a pequenas mudanças na amplitude, morfologia e duração dos sinais de ECG de entrada. No anexo G é proposto um novo método e sua ferramenta associada (EVANGELISTA et al., 2010a), para essa finalidade, que cita as bases para o trabalho futuro.

CAPÍTULO 4 - DETECÇÃO DO FINAL DA ONDA T

4.1 Introdução

Na epígrafe 2.4.2 foi descrita a problemática da estimação do final da onda T (ponto T_e) e foram revisados os principais métodos usados para essa finalidade, analisando suas vantagens e limitações, principalmente seu desempenho em presença de ruído.

No processamento de sinais ECG ambulatoriais ou procedentes de provas de esforço, a presença de ruídos ocasiona inexatidão na determinação do final da onda T, e, portanto, na análise da duração e da variabilidade do QT, pelo qual a caracterização da influência do ruído na estimação do ponto T_e é de extrema importância. Do nosso conhecimento só há três estudos sobre a influência do ruído na detecção do final de onda T.

Em Porta (1998) os intervalos RT_a (do pico da R ao pico da T) e RT_e (estimado por 2 métodos diferentes: limiar na primeira derivada e intersecção de retas) foram analisados usando dois sinais sintéticos de ECG gerados por computador com uma única morfologia para a onda T. As conclusões desse trabalho indicam que o ruído afetou apreciavelmente à variabilidade embora quase não afetou à duração média destes intervalos. Do ponto de vista de variabilidade, o RT_a foi mais robusto à ruído de banda larga que o RT_e , e o RT_e calculado pelo método de limiar foi ligeiramente menos afetado pelo ruído que pelo método de intersecção de retas.

Em Tikkanen (1999), o efeito do ruído foi analisado baseado no índice estatístico RMSSD (TASK FORCE, 1996) computados, novamente, de oito estimações diferentes de séries temporais do “intervalo QT”, usando sinais simulados com somente seis morfologias diferentes. Com respeito à influência do ruído de banda larga, os resultados indicaram que o melhor desempenho correspondente foi para o intervalo RT_a .

Em ambos os artigos anteriores, os esforços estiveram focalizados em determinar a influencia do ruído em diversas estimativas de intervalos associados à repolarização ventricular. Em um intervalo qualquer, por exemplo, RT_e :

$$RT_e(n) = T_e(n) - R(n) \tag{4.1}$$

O erro associado a essa série temporal é:

$$\text{Err}[RT_e(n)] = \text{Err}[T_e(n)] + \text{Err}[R(n)] \quad (4.2)$$

Assim, o erro final é a soma dos erros individuais pelo que nesses trabalhos fica mascarado o erro próprio na estimação do ponto T_e devido ao ruído. Outra deficiência dos trabalhos anteriores é o escasso número de morfologias e nenhuma pertencente a sinais reais.

Em Martinez (2010) o erro de localização do T_e foi estudado acrescentando ruído branco gaussiano a um numero maior (50) de registros de morfologias de ECG sintético, mas não foram usados sinais reais. Um dos interesses desta tese é determinar a influencia do ruído no ponto T_e , usando diversas morfologias de sinais reais.

Das revisões bibliográficas anteriores podem ser resumidas as seguintes limitações do estado da arte:

1. A proposta de novos algoritmos para estimar o ponto T_e nunca vai acompanhada de uma análise de seus desempenhos em presença de ruído. A única exceção (MARTINEZ, 2010) não realiza experimentos com sinais reais. A robustez ao ruído só aparece avaliada de forma qualitativa, mas não quantitativa.

2. Existem poucos trabalhos comparativos do desempenho de métodos de estimação do ponto T_e em presença de ruído. A metodologia de avaliação dos exemplos citados usa sinais sintéticos com poucas morfologias.

3. Muitos métodos de estimação acabam empregando regras de decisão baseadas em limiar.

A tendência nos últimos anos é usar os métodos de estimação do T_e baseados em wavelets, devido ao desenvolvimento das tecnologias dos computadores. Esses métodos ainda usam os princípios do limiar na primeira derivada para detectar os inícios e finais de ondas nas diferentes escalas da *wavelet* (MARTÍNEZ, 2004). Por esse motivo, a seguir será descrito resumidamente o método de limiar na primeira derivada, que é um dos métodos mais referenciados nos últimos anos.

4.1.1 Método de limiar na primeira derivada

Este método permite detectar o ponto T_e baseado no princípio de que a derivada de um segmento isoelétrico (após reduzir o ruído e as flutuações da linha base) é aproximadamente nula, no entanto a derivada das ondas do ECG, não é nula. Este define o final da onda T como o ponto onde a derivada ultrapassa certo limiar proporcional ao valor absoluto máximo da derivada da onda T (LAGUNA, 1990).

A figura 4.1 apresenta a implementação deste método para uma onda T com morfologia monofásica positiva. O sinal superior corresponde à onda T do ECG, e o inferior é sua derivada ($dECG$). Para essa morfologia, primeiro, é calculado o ponto de derivada mínima ($A = \min(dECG)$), segundo, este valor é dividido por um fator constante K (fator de proporcionalidade), obtendo um valor de limiar igual a $Thi (= A/K)$. O ponto que corresponde ao final da onda T é definido como a primeira amostra onde o valor da primeira derivada da onda T ultrapassa ao limiar Thi , transferida para o sinal original.

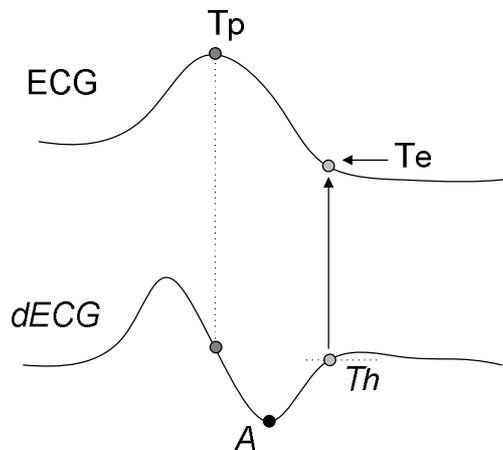


Figura 4.1 - Método de limiar na primeira derivada aplicada a uma onda T positiva. O limiar para o i -ésimo batimento é calculado dividindo o valor da mínima derivada por um fator empírico (K). A primeira amostra antes do limiar Thi é definida como o final da onda T (T_e).

Quando K é alto (por exemplo, 10), o ponto obtido estará mais próximo ao segmento isoelétrico, caso contrário estará mais próximo ao ponto de mínima (máxima) derivada após o pico da onda T. Este método foi aplicado em vários estudos, e demonstrou robustez. Tem baixo custo computacional, é muito útil para determinar o final da onda T em sinais com segmentos TP pequenos (por exemplo, durante exercícios intensos) porque prediz o ponto T_e a partir do cálculo da máxima

(ou mínima) inclinação do segmento final da onda T (após o pico T_p) e, portanto, não necessita de nenhuma referência no segmento isoeletrico TP. Porém, tem o problema da seleção empírica do limiar que deve ser adaptado ao nível de um ruído, eventualmente não estacionário.

Como foram mencionados anteriormente, os sinais de ECG são freqüentemente contaminados por ruídos e interferências. Em situações de alta atividade física (durante a realização de exercícios físicos ou prova de esforço) o ruído do EMG é a principal fonte de erro da detecção do T_e devido a sua aleatoriedade altamente elevada que afeta a transição de cada final de onda T. Este tipo de ruído tem componentes espectrais na faixa de frequências da onda T, da mesma forma que o ruído de instrumentação. A principal motivação deste capítulo foi encontrar um algoritmo para a detecção do T_e que fosse menos sensível à presença de ruído de banda-larga ou ruído branco gaussiano (WN) e que não dependa de nenhum limiar. A detecção com alta exatidão do final da onda T ou ponto T_e , no ECG é determinante para analisar a QTV por causa da sua pequena variabilidade (poucos milissegundos), principalmente, em presença de ruído de banda larga.

4.2 Método e algoritmo de áreas de trapézios

Neste item é proposto um novo método denominado como método de áreas de trapézios (TRA) para detectar inícios e finais de ondas no sinal de ECG (EVANGELISTA et al., 2008b). No contexto da tese, a ênfase do método é a determinação do final da onda T, mas pode ser aplicado a outros pontos do ECG.

É válido salientar que esta tese só considera a detecção do final da onda T. Obviamente, o ponto R precisa ser detectado previamente para delimitar o intervalo que contém a onda T. Como a detecção do ponto R tem sido um tema amplamente descrito na bibliografia, não será objeto de pesquisa nesta tese. Para os objetivos deste trabalho, focalizados na detecção do T_e , a detecção do ponto R constitui uma etapa previa para encontrar o pico da onda T ou ponto T_p (Figura 4.1). Conforme foi explicado na epigrafe 1.4, este método pressupõe que os picos das ondas R e T foram previamente identificados, o que equivale a empregar a um algoritmo infalível para estimar esses pontos. Assim, são usadas as marcações dos pontos R e T_p realizados pelos especialistas nas bases de dados correspondentes.

Primeiramente serão consideradas ondas T monofásicas (positiva ou negativa) como é mostrado na Figura 4.2. Qualquer outra morfologia, uma vez identificada, pode ser tratada como um caso particular da monofásica, o qual será detalhado na seguinte epigrafe.

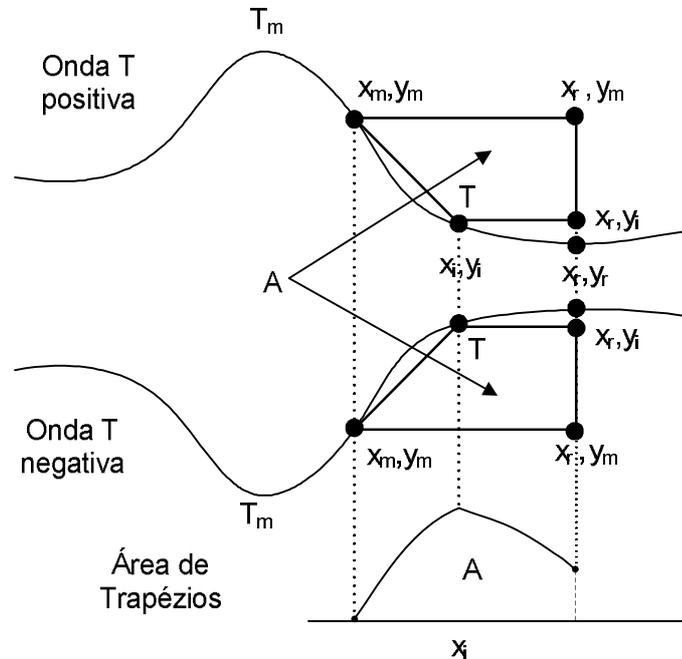


Figura 4.2 - Determinação do final da onda T (para uma onda monofásica) mediante o cálculo das áreas dos trapézios formados por dois pontos fixos e dois móveis (x_i , y_i) e (x_r , y_r). O ponto Te corresponde ao ponto no qual a área A é máxima.

O método TRA está baseado no cálculo de áreas sucessivas de trapézios retangulares com dois vértices fixos e dois móveis: (x_i , y_i) e (x_r , y_r). O ponto móvel (x_i , y_i) é deslocado pelo sinal de (x_m , y_m) a (x_r , y_r), enquanto a área total é calculada. O fim da onda T será definido como o ponto onde a área A do trapézio é máxima (Figura 4.2). A fórmula da área do trapézio é:

$$A = 0,5 (y_m - y_i) (2x_r - x_i - x_m) \quad (4.3)$$

Sendo:

- (x_m , y_m) a abscissa e a ordenada, respectivamente, de um ponto com a máxima derivada absoluta (máximo ou mínimo) após o pico da onda T. O valor da derivada neste ponto é um mínimo negativo para as ondas T positivas e é um máximo positivo para as ondas T negativas;

- (x_r, y_r) a abscissa e a ordenada, respectivamente, de um ponto de referência localizado no segmento T-P isoeletrico. O local exato não é muito importante contanto que o ponto esteja após o final da onda T;
- (x_i, y_i) é a abscissa e ordenada, respectivamente, de um ponto móvel entre os dois pontos mencionados antes.

Como mostrado em Figura 4.2, a área A será:

- Mínima ou zero quando (x_i, y_i) está nos vértices (x_r, y_r) ou (x_m, y_m) , respectivamente;
- Máxima quando (x_i, y_i) está no final da onda T.

O algoritmo TRA está baseado no método anteriormente descrito. As etapas deste algoritmo são as seguintes:

a. Pré-processamento

- 1) Filtragem *passa-altas* do sinal do ECG (*Butterworth*, bidirecional, 4ª ordem, à frequência de 0,5 Hz) para reduzir as flutuações da linha base.
- 2) Filtragem *passa-baixas* do ECG obtido em (1) (*Butterworth*, bidirecional, 4ª ordem, à frequência de 30 Hz) para reduzir ruídos e interferências.

b. Processamento (posição do pico da onda T previamente identificado)

- 3) Determinação do ponto identificado como " x_m " situado no segmento depois do ponto T_m , o qual tem um mínimo (máximo) valor na primeira derivada, e está depois do máximo (mínimo) para uma onda T positiva (negativa). Para isso o algoritmo procura numa janela de 200 de ms, a partir do pico da onda T (máximo ou mínimo). Este segmento é apropriado para abranger o ponto x_m no segmento final da onda T.
- 4) Determinação de um ponto identificado como " x_r " situado no segmento isoeletrico e procurado em uma janela entre 200 ms e 400 ms, a partir do pico (máximo ou mínimo) da onda T, preferivelmente com um valor da primeira derivada próximo a zero. Se nenhum ponto satisfizer esta condição, o ponto central é escolhido. De fato, a posição exata deste ponto não é muito importante contanto que esteja após o final de T.

- 5) Cálculo das áreas dos trapézios correspondente a todos os pontos localizados entre “ x_m ” e “ x_r ”.

c. Regra de decisão

- 6) Localização do ponto com área máxima, o qual é identificado como o T_e .

Até agora, o algoritmo de TRA só foi aplicado para ondas T monofásicas (positivas ou negativas). Para o caso de ondas bifásicas (positiva-negativa ou negativa-positiva) ou somente ascendente ou descendente, o ponto (x_m, y_m) é escolhido de tal modo que a seção da onda entre este ponto e o ponto (x_r, y_r) tenha um tendência monótona crescente ou decrescente, como mostrado na Figura 4.3 para uma morfologia positivo-negativa. A identificação da morfologia foi realizada usando o método descrito na epígrafe 2.4.2.2 (LAGUNA, 1990). A correta identificação de todas as morfologias pelo procedimento anterior também foi verificado visualmente de forma semi-automatizada para cada registro.

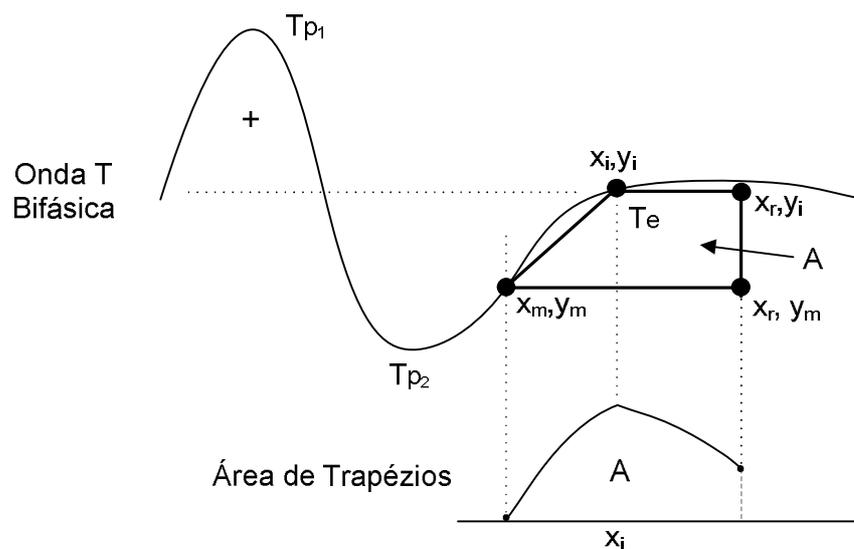


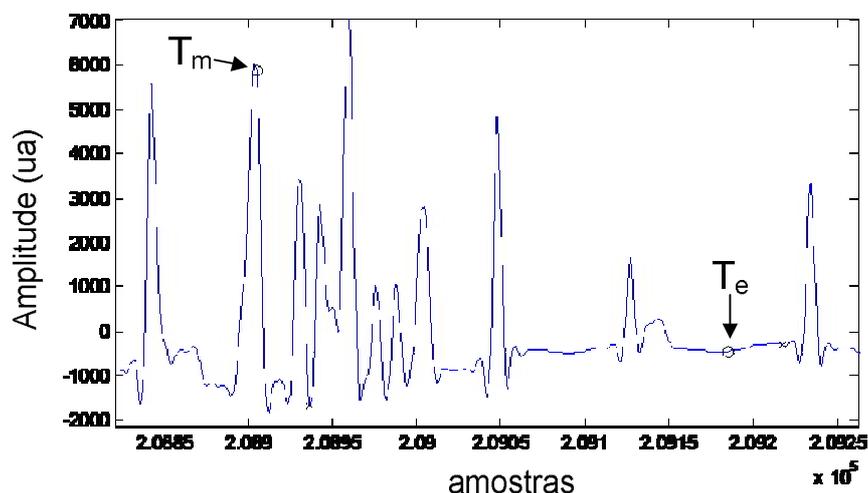
Figura 4.3: Determinação do ponto T_e para uma morfologia bifásica (positivo-negativa).

4.3 Avaliação do método dos trapézios: materiais e métodos

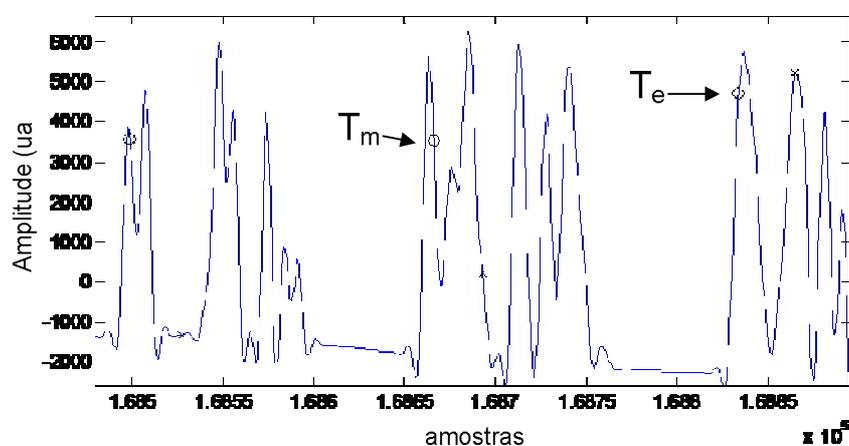
4.3.1 Base de dados, parâmetros e critérios de avaliação

A avaliação do método de áreas de Trapézios foi executada com a base de dados QTDB (LAGUNA, 1997) que constitui um padrão para validar e comparar os algoritmos de finais de onda T. Durante a validação do final da onda T, foram descartados alguns batimentos de baixa qualidade: 703 dos 3542 anotados pelo

cardiologista 1 e 402 dos 1291 anotados pelo cardiologista 2, totalizando 1105 batimentos descartados. Esse procedimento é frequentemente usado (JANE, 1997; VILA, 2000; LAST, 2004; ZHANG, 2006) para evitar erros aberrantes nos casos onde há indeterminação no entorno do ponto T_e por artefatos de natureza impulsiva que deformam completamente o sinal (Figura 4.4).



(a)



(b)

Figura 4.4: Indeterminação do ponto T_e devido a artefatos em um segmento do registro: (a) sel213 e (b) sel223, da base de dados QTDB.

Para validar os detectores de pontos característicos são usados, tradicionalmente, os seguintes parâmetros de validação (LAGUNA, 1997):

1. Sensibilidade (S): porcentagem de detecções corretas para cada ponto significativo

$$S(\%) = \frac{VP}{VP + FN} \times 100 \quad (4.4)$$

Onde VP é o número de detecções corretas (verdadeiros positivos), FN é o número de detecções automáticas que não aparecem no arquivo de anotações dos especialistas (falsos negativos). Todos esses valores são referidos ao conjunto de batimentos anotados da base de dados usada para validar.

2. Valor preditivo positivo (VPP) ou Preditividade positiva: porcentagem de,

$$VPP(\%) = \frac{VP}{VP + FP} \times 100 \quad (4.5)$$

Onde VP é o número de detecções corretas (verdadeiros positivos), FP é o número de detecções incorretas, ou seja, aquelas que não aparecem no arquivo de anotações dos especialistas (falsos negativos).

3. Exatidão: Expressa quanto perto está o resultado da detecção com respeito ao critério dos especialistas. É calculado como a média dos erros de detecção, ou seja, da diferença temporal entre as anotações automáticas e a dos cardiologistas, batimento a batimento.

4. Precisão: Serve para dar a idéia da estabilidade do resultado da detecção com respeito ao critério dos especialistas. É calculado como o desvio padrão dos erros de detecção.

Para calcular os erros de detecção são implementados dois critérios de avaliação:

1. Melhor batimento por registro (*Best Beat per Record*, BB): para cada par de batimentos simultâneos, é escolhido como o final da onda T o melhor resultado que minimiza o erro de detecção dentre os dois finais de onda T obtidos nas duas derivações. Este procedimento foi adotado primeiro por Martínez (2004) e depois em Zhang (2006). A justificativa dada por Martínez (2004) é que o cardiologista fez a sua anotação olhando ambas as derivações e optou por anotar à melhor derivação. Na prática clínica, este critério requer uma robusta regra de decisão automática.
2. Melhor derivação por registro (*Best Lead per Record*, BL): Dentre as duas derivações, são escolhidos como pontos T_e definitivos os

correspondentes à derivação que contribuiu com um maior número de pontos T_e , segundo o critério prévio descrito por Jane (1997). Se as contribuições forem iguais, então é selecionada à primeira derivação, e por tanto, seus correspondentes pontos T_e . Este procedimento é mais realístico do ponto de vista de um operador humano.

4.3.2 Procedimento de avaliação

Exatidão e a precisão média.

O procedimento para computar a média global (me) e o desvio padrão (sd) dos erros de detecção para cada critério da avaliação têm os seguintes passos:

- (1) para cada batimento anotado (por ambos os cardiologistas) em cada registro, são computados os erros de detecção.
- (2) para cada registro i , são calculados a média (M_i) e o desvio padrão (S_i) dos erros de detecção.
- (3) para todos os registros, são calculados a média de todos os M_i (me) e a média de todos os S_i (sd), ou seja, a exatidão e a precisão média, respectivamente.

Desempenho em condições ruidosas

Para a avaliação do desempenho em presença de ruído foi selecionada a melhor derivação para cada registro da QTDB (critério BL), sendo desta forma consonante com a prática clínica.

Como a relação sinal-ruído (S/N) para cada onda T (na mesma derivação) é diferente, não é possível adicionar ruído controlando a relação S/N para toda a derivação. Para garantir um nível de ruído uniforme o parâmetro de controle será a amplitude do pico da onda T (A_{TWP}) batimento por batimento.

Em vista a contribuir à caracterização do desempenho dos métodos de estimação do ponto T_e em presença de ruído usando sinais reais e visto o freqüente uso dos métodos baseados em limiar, neste trabalho será comparado o desempenho do algoritmo dos trapézios com o método de limiar na primeira derivada. Como cada método original (e seu algoritmo correspondente) usa diferentes tipos de filtragem, o

desempenho deles poderia depender das características dos filtros. Para homogeneizar esta dependência, o pré-processamento usado para o algoritmo dos trapézios foi o mesmo usado para o método da primeira derivada.

O procedimento para caracterizar o desempenho na presença de ruído, por cada método, consiste das etapas seguintes:

1. Filtragem passa-altas, em seguida passa-baixas, similar ao pré-processamento descrito para o algoritmo TRA.
2. Obtenção do final de onda T de referência usando o método $X (T_{RX})$. O sub índice de “X” será “D” para o método do limiar na primeira derivada; e “T” para o método de áreas de trapézios.
3. Cálculo da amplitude pico da onda T de referência (A_{TWP}) usando os valores anotados pelos especialistas.
4. Para cada batimento do sinal ECG filtrado, foi adicionado WN com amplitude igual a um $N\%$ de A_{TWP} , $N = \{3 \%, 5\%, 10\%, 20\%\}$. Para cada nível de ruído, foram geradas 200 realizações de WN e, acrescentadas ao sinal de ECG filtrado; então foi filtrado com o passa-baixa conforme a etapa 2 do algoritmo TRA, e finalmente foi calculada a média dos 200 respectivos finais de onda T. Este valor se torna o final de onda T para o nível de ruído N e método $X (T_{NX})$.
5. Obtenção das estimativas sucessivas do final de onda T para cada batimento i , nível de ruído N e método $X (T_{NXi})$.
6. Cálculo do erro relativo percentual modular (E_{NX}) para o algoritmo “X” e nível de ruído N de acordo com a expressão seguinte:

$$E_{NX} = \sum_{i=1}^k \left| \left(\frac{T_{NXi} - T_{RXi}}{T_{RXi}} \right) \right| \times 100 \quad (4.6)$$

Onde:

- k é o número total de batimentos anotados por ambos os cardiologistas (3112).

- T_{NXi} é o i -ésimo final de onda T obtido pelo algoritmo X quando o nível de ruído é $N\%$ de A_{TWP} . $N = \{3\%, 5\%, 10\%, 20\%\}$ referendado ao valor máximo da onda T (ponto T_m).
- T_{RXi} é o i -ésimo final de referência de onda T para o algoritmo X , referendado ao ponto T_m . Para o algoritmo de limiar na primeira derivada (THD), são usados os fatores de limiar seguintes: $K = 2$ (50%), $K = 5$ (20%) e $K = 10$ (10%).

O E_{NX} é a média global dos valores absolutos dos erros relativos de detecção devidos ao ruído somado. Este parâmetro dá uma idéia do deslocamento para diante ou para trás (ou seja, absoluto) da posição do final da onda T devido ao efeito do ruído. Assim, E_{NX} é uma medida do desempenho de método em condições ruidosas.

Por conveniência, o argumento interno da equação (4.6) será rescrito como:

$$E_{NX}(k) = \sum_{i=1}^k \left| \left(\frac{T_{NX}(i) - T_{RX}(i)}{T_{RX}(i)} \right) \right| \times 100 \quad (4.7)$$

Para provar, do ponto de vista estadístico, se o método proposto P (Trapézios: TRA) é menos afetado pelo ruído que o método convencional C (primeira derivada: THD), se realiza uma prova (t de Student) pareada de hipóteses sobre as medias dos erros calculados segundo (4.7) para os métodos convencional e proposto, respectivamente. Os valores dos erros $E_{NX}(k)$ das posições do T_e para cada método C (THD) e P (TRA) e para cada uma das quatro versões ruidosas do sinal de ECG (3%, 5%, 10%, 20% da A_{TWP}) com respeito à posição T_e de referencia (“sinal sem ruído”) podem ser tratados, do ponto de vista estatístico, como amostras de duas variáveis aleatórias E_C e E_P para cada nível de ruído N :

$$E_C = \sum_{i=1}^k \left| \left(\frac{T_{NTHD}(i) - T_{RTHD}(i)}{T_{RTHD}(i)} \right) \right| \times 100 \quad (4.8)$$

$$E_P = \sum_{i=1}^k \left| \left(\frac{T_{NTRA}(i) - T_{RTRA}(i)}{T_{RTRA}(i)} \right) \right| \times 100 \quad (4.9)$$

As medias (amostrais) das variáveis aleatórias são calculadas como:

$$E_{NTHD} = \frac{1}{k} \sum_{i=1}^k \left| \left(\frac{T_{NTHD}(i) - T_{RTHD}(i)}{T_{RTHD}(i)} \right) \right| \times 100 = \overline{E_C} \quad (4.10)$$

$$E_{NTRA} = \frac{1}{k} \sum_{i=1}^k \left| \left(\frac{T_{NTRA}(i) - T_{RTRA}(i)}{T_{RTRA}(i)} \right) \right| \times 100 = \overline{E_P} \quad (4.11)$$

Onde:

- $T_{NTHD}(i)$ é $T_{NTRA}(i)$ são os i -ésimos finais da onda T obtidos pelos métodos THD e TRA quando os níveis de ruído são $N\%$ de A_{TWP} referendados ao valor máximo da onda T (ponto T_m).
- T_{RTHD} e T_{RTRA} são os i -ésimos finais de referência de onda T (“sinal sem ruído”) para os métodos THD e TRA, respectivamente, referendados ao ponto T_m .

A hipótese nula (H_0) é que ambos os métodos são semelhantes, ou seja, que as medias de ambas as variáveis aleatórias E_C e E_P são iguais, para um nível de significação $\alpha = 0,05$. A hipótese alternativa (H_1) é que o método proposto é mais robusto ao ruído que o convencional, em termos das medias, ou seja, que a media de E_P é menor que a media de E_C :

$$\begin{aligned} H_0 : E[E_P] &= E[E_C] \\ H_1 : E[E_P] &< E[E_C] \end{aligned} \quad (4.12)$$

No experimento, se pretende rejeitar a hipótese nula e aceitar a hipótese alternativa, com uma probabilidade (p) bem pequena de equivocação ao aceitar a hipótese alternativa se H_0 é falsa.

O processamento dos sinais foi realizado com Matlab 7.7 (The Math-Works, Inc, Natick, MA, 2008).

4.4 Resultados

Exatidão e precisão média

Na Tabela 4.1 são apresentados os resultados de avaliação do algoritmo proposto, para os dois critérios de avaliação. O valor *me* dá a ideia de proximidade entre o valor do ponto detectado e a anotação do especialista (exatidão), e o valor *sd* provê informação sobre a estabilidade (repetitividade) dos critérios de detecção. Os resultados numéricos do algoritmo de limiar foram selecionados pelos critérios do melhor batimento por registro (MARTÍNEZ, 2004) e da melhor derivação por registro (JANE, 1997), simultaneamente. Os resultados do algoritmo THD são para o caso de um fator de limiar igual a 2, que correspondeu ao limiar de melhor desempenho (LAGUNA, 1990).

Tabela 4.1: Média (*me*) e desvio padrão (*sd*) das diferenças entre as anotações automáticas e dos cardiologistas para os dois métodos e os dois critérios de avaliação. TRA: Áreas de Trapézios, THD: Limiar na primeira derivada. A unidade de tempo é milissegundos.

	Melhor batimento por registro (BB)		Melhor derivação por registro (BL)	
	TRA	THD Martínez (2004)	TRA	THD Jane (1997)
<i>me</i>	-2,29	13,5	-1,98	18,68
<i>sd</i>	7,15	27,0	16,46	29,79

Os resultados apresentados na Tabela 4.1 mostram que, em termos de valor do erro médio e SD, o algoritmo proposto apresenta resultados bons e supera ao outro algoritmo pelos dois critérios. O sinal negativo significa que, em termo médio, o algoritmo TRA detecta o ponto T_e , antes que a posição anotada pelos especialistas.

Desempenho em condições ruidosas

A Figura 4.5 apresenta os valores do erro relativo percentual modular (E_{NX}) para cada algoritmo e nível de ruído. Em todos os casos, o erro do algoritmo TRA é menor que o obtido com o algoritmo THD com uma alta significância ($p \leq 8,9 \times 10^{-7}$ ou até menor). Este resultado mostra o melhor desempenho do algoritmo TRA em presença de níveis baixos, meio e altos de ruído.

Na Figura 4.5 não inclui os resultados para $K = 10$ (10%) porque, neste caso, os erros são extremamente altos, e o nível de significância do teste de hipótese é baixo ou não estatisticamente significativo, como mostrado na Tabela 4.2.

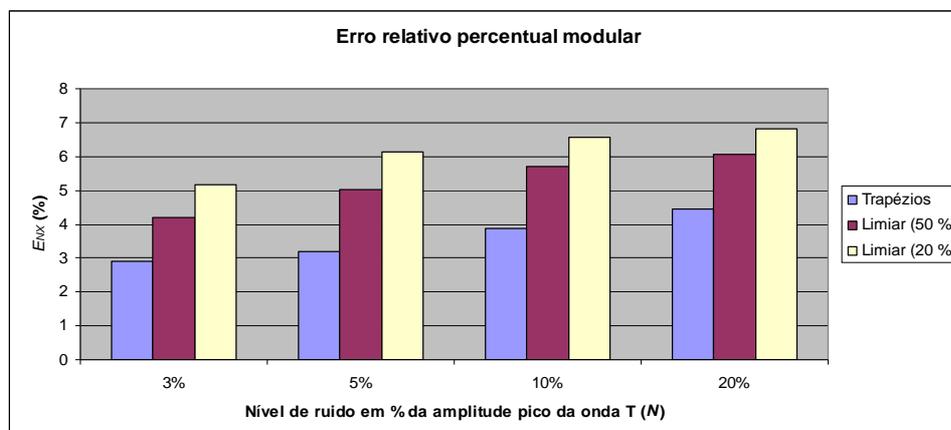


Figura 4.5 - Erro relativo percentual modular versus nível de ruído para os algoritmos TRA e THD. O valor dos diversos testes de hipótese (*T-student*) para cada algoritmo com respeito ao algoritmo dos trapézios está demarcado por uma probabilidade $p \leq 8,9 \times 10^{-7}$.

Tabela 4.2: Comparação dos erros relativos percentual modular (E_{NX}) entre o algoritmo dos Trapézios e o algoritmo THD (fator de limiar igual ao 10 %).

E_{NX}	3%	5%	10%	20%
TRA	2,9	3,1	3,8	4,4
THD 10 %	4,9	5,0	9,3	13,7
Nível de significância	$p \leq 0,071$	$p \leq 0,135$	$p \leq 0,047$	$p \leq 0,047$

Para o limiar de 50%, o erro médio do algoritmo THD é o menor, corroborando com os resultados apresentados por Laguna (1990) e é mais alto para o limiar $K = 10$. Nos experimentos de Laguna (1990), era só considerado o caso com $K = 2$ (50%) porque experimentalmente mostrou o melhor desempenho. Não obstante para $K = 2$, o ponto T_e fica mais longe do verdadeiro final.

4.5 Discussão

Exatidão e precisão média

Do ponto de vista de exatidão os resultados obtidos são bem similares aos reportados por outros detectores de final de onda T (ZHANG, 2006), (LAST, 2004), (VILA, 2000) (MARTÍNEZ, 2004) (MARTÍNEZ 2010), já que as diferenças no erro de detecção médio são irrelevantes: menor que, ou aproximadamente igual a uma

amostra (4ms). Na Tabela 4.3 são mostrados os valores de exatidão e precisão média de alguns métodos de estimação do ponto Te usando todos os batimentos da QTDB e o critério de melhor batimento por registro.

Tabela 4.3. Erros de diferentes métodos para a estimação do ponto Te usando a QTDB.

Método	me ± sd (ms)
Evangelista et al (2011)	-2,29 ± 7,15
Martinez et al (2010)	5,8 ± 22,7
Martinez et al (2004)	-1,6 ± 18,1
Vila et al (2000)	0,8 ± 30,3
Laguna et al (1994)	13,5 ± 27,0

Quanto ao desvio padrão médio, o nosso algoritmo apresenta uma excelente repetitividade quando comparado com vários algoritmos apresentados nos últimos dez anos (ZHANG, 2006). O desvio padrão é próximo a duas amostras pelo critério BB (BL), o qual está dentro dos limites de tolerância dos especialistas (30,6 ms para o desvio padrão) (CSE WORKING PARTY, 1985).

Na verdade, até agora resulta impossível comparar com exatidão os resultados de todos os trabalhos, senão somente de forma aproximada, pois raramente são usados todos os batimentos da QTDB na validação dos métodos para detectar o ponto Te, e por outro lado, os batimentos que são rejeitados assim como os processados, geralmente não são os mesmos. De um total de 3944 batimentos anotados da QTDB por ambos os cardiologistas, Jane (1997) usou 2996 batimentos (75,96%), Vila (2000) empregou 3528 (89,45 %) e Last (2004) utilizou 3000 (75,11%). Só, Martinez (2004) usou o 100 % dos batimentos da QTDB para validação.

Por exemplo, Jane (1997) subdividiu o total de batimentos usados para obter o ponto Te em quatro grupos, de acordo com a média (me) e o desvio padrão (sd) dos erros de detecção (o qual da idéia dos níveis de ruído existentes).

- Grupo I (2163 batimentos): sinais bem detectados (me<40 ms, sd<50 ms).
- Grupo II (342 batimentos): sinais com erros de identificação de morfologia, tipicamente, erros sistemáticos (me>40 ms, sd<50 ms).
- Grupo III (196 batimentos): batimentos com má relação sinal ruído, devido ao ruído ou amplitude da onda T pequena (me<40 ms, sd>50 ms).

- Grupo IV (296 batimentos): Combinação de características dos grupos II e III ($me > 40$ ms, $sd > 50$ ms). Usualmente, erros de identificação de morfologia com má relação sinal ruído.

No nosso trabalho foram aceitos 2839 para um 71,98 % do total, que é um valor muito próximo aos usados nos exemplos anteriores. Poderia ficar a dúvida se os 2839 batimentos da QTDB usados no nosso experimento pertenciam unicamente ao grupo I (batimentos bons). Não obstante, supondo que nesses 2839 batimentos foram incluídos todos os batimentos do grupo I, então ficariam 676 batimentos que pertenceriam aos grupos restantes (II, III e IV). A soma total dos batimentos dos grupos II, III e IV (JANÉ, 1997) é igual a 834 batimentos. Por tanto, esses 676 batimentos restantes corresponderiam a 81% do total de batimentos dos grupos II, III e IV. Na verdade, é muito provável que essa conta seja mais favorável, se dentre os 2839 batimentos usados na tese, os que coincidiriam com o grupo I, foram menos dos supostos. Obviamente, a população de batimentos usada neste trabalho foi 1,31 vezes maior que a usada no grupo I, pelo que o desempenho quanto a erros é melhor. Além disso, o algoritmo TRAP não depende de nenhum limiar, enquanto o algoritmo de limiar dependerá do fator de limiar usado e isso mudará os erros para cada limiar empregado.

Nos trabalhos de Ghaffari (2009) e Martínez (2010) foram re-annotados alguns batimentos, prévio à validação dos métodos, para resolver o problema das significativas e frequentes diferenças nas anotações do Te entre os dois cardiologistas da QTDB. Depois de revisar e re-annotar alguns registros de ECG por cardiologistas especialistas, o erro médio na detecção e o desvio padrão diminuíram consideravelmente nesses trabalhos comparados.

Examinando os erros do algoritmo proposto, foi observado visualmente que os erros maiores são principalmente devidos à eliminação incorreta das flutuações da linha base quando esta muda abruptamente. Na Figura 4.6 se mostra um exemplo de flutuações rápidas da linha base (sinal sel40 da QTDB) com o conseguinte aumento do erro entre os pontos Te obtido automaticamente (círculo verde) e anotado (cruz vermelha).

Por essa razão é importante desenvolver métodos mais precisos e robustos (por exemplo, métodos adaptativos ou de filtragem não linear) para eliminar as flutuações da linha base sem deformar a morfologia do segmento final da onda T.

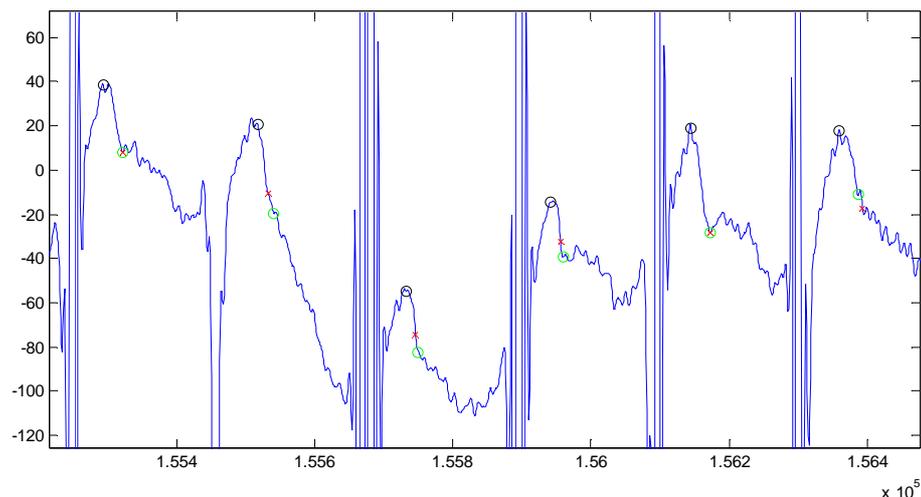


Figura 4.6 – Exemplo de diminuição da exatidão na detecção do ponto Te devido às flutuações abruptas da linha base (segmento do sinal sel40, primeiro canal, QTDB). Circulo preto: Ponto Tm anotado, Circulo verde: Ponto Te automatico, Cruz vermelha: ponto Te anotado.

Desempenho em condições ruidosas

Os resultados obtidos analisam a influencia do ruído diretamente no ponto Te e não em indicadores estatísticos do intervalo QT. Por outro lado neste caso foram usados sinais reais da QTDB. Esses aspectos impossibilitam qualquer estudo comparativo em presença de ruído com os trabalhos anteriormente citados (PORTA, 1998; TIKKANEN, 1999; MARTINEZ, 2010).

A justificativa para o adequado desempenho do algoritmo TRA pode ser atribuída ao seu próprio princípio de funcionamento, baseado no calculo de áreas, o que corresponde a um processo de integração e seus implícitos efeitos de filtragem passa-baixas e redução de ruído.

Em contraposição, o processo de diferenciação que está implícito no algoritmo de limiar é equivalente a uma filtragem passa-altas, e, portanto contribui para amplificar os efeitos do ruído. De forma geral a existência de um fator de limiar propicia sensibilidade ao ruído em maior ou menor grau.

Na Figura 4.7 apresenta um exemplo de um batimento de ECG (do registro “sel32” da QTDB) com diferentes níveis de ruído. A descrição de Figura 4.6 é explicada na legenda da mesma. A filtragem passa-faixas é a combinação da filtragem passa-altas que (etapa 1) e passa-baixas (etapa 2) do procedimento descrito previamente no (epigrafe 4.3.2).

Os níveis de ruídos selecionados são muito altos em alguns casos, principalmente para alguns registros da QTDB que tem níveis altos de ruído onde (e apesar da filtragem passa-baixas) os níveis adicionados aumentam consideravelmente o ruído presente. Para outras situações práticas, o nível de ruído é menor, e a característica mais expressiva (relevante) do algoritmo proposto é que não usa nenhum fator de limiar.

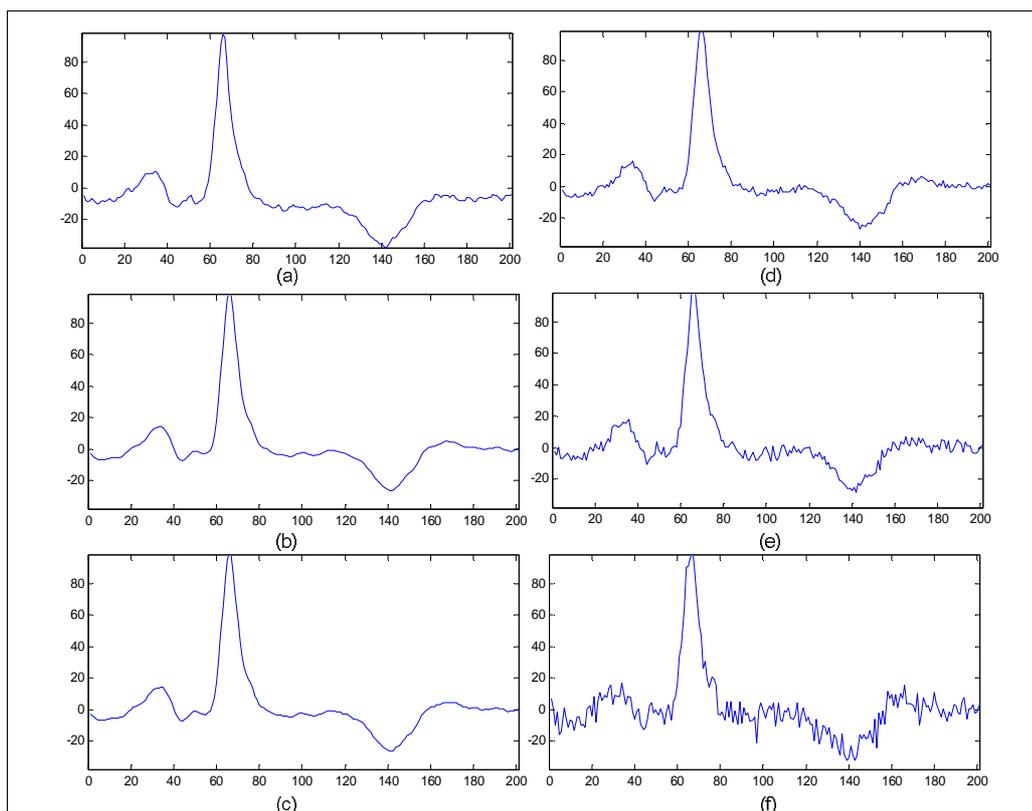


Figura 4.7 - Exemplo de um batimento da QTDB (registro sel32, primeiro canal) com diversos níveis de ruído: (a) Batimento original, (b) Versão filtrada passa-faixa de (a), (c) 3% de ruído de A_{TWP} , (d) 5% de ruído de A_{TWP} , (e) 10 % de ruído de A_{TWP} e (f) 20% de ruído de A_{TWP} .

4.6 Considerações finais

A proposta de um novo método e algoritmo para estimar inícios e finais de ondas (especialmente o final da onda T) baseado no cálculo da área de um trapézio permitiu de uma forma simples obter valores elevados de exatidão e precisão, assim como um alto desempenho na presença de ruído de banda larga, sem necessidade de usar nenhum fator de limiar. A excelente repetitividade do algoritmo de trapézios

sugere seu uso para estudo da QTV e QTD. A simplicidade facilita seu uso em aplicações em tempo real.

A validação do método, seguida de uma análise quantitativa do desempenho versus ruído com sinais ambulatoriais reais da QTDB com amplas morfologias, proporciona uma metodologia sistemática para propiciar uma mínima influência de erros na análise da duração e variabilidade de intervalos que contemplem o ponto T_e .

É válido salientar que no ECG ambulatorial e em provas de esforço, o ruído de banda larga (fundamentalmente, de origem eletromiográfico) é a principal fonte de ruído e por isso foi o centro do estudo. Não obstante, a análise do desempenho na presença de outros tipos de ruído, por exemplo, o ruído eletro-cirúrgico, poderia ser um objeto de estudo futuro, embora, sejam menos prováveis de se apresentar nos lugares habituais onde o paciente se move.

CAPÍTULO 5 - CONCLUSÕES

O ECG superficial não reflete os problemas funcionais em cada célula do miocárdio, mas sua análise pode ajudar a prevenir a morte cardíaca súbita porque a isquemia miocárdica (que é uma de suas causas mais frequentes) leva a mudanças na amplitude, morfologia e duração dos potenciais de ação dos miócitos cardíacos, e isto provoca instabilidade elétrica em ditas células. Nesta tese foram preparadas as condições para medir os pequenos valores associados à variabilidade temporal e espacial do intervalo de repolarização ventricular como possível marcador de essa instabilidade. O entorno escolhido foi a monitorização ambulatorial do ECG.

O uso da monitorização ambulatorial do ECG durante períodos longos aumenta a probabilidade de detectar anomalias cardíacas, em comparação com o ECG de curta duração. Como contrapartida, obriga a resolver a perda de informação relevante pela presença de ruídos e artefatos diversos quando o paciente se move em diversos cenários. A possibilidade de dispor de sinais de bases de dados internacionais adquiridos durante monitorização ambulatorial permitiu caracterizar os métodos propostos na tese.

Da revisão bibliográfica do estado da arte foram identificados os principais problemas a resolver do ponto de vista científico, a escassez de estudos sobre: a influência do ruído na detecção do final de onda T e o reconhecimento de artefatos fisiológicos e técnicos para os efeitos do estudo da variabilidade da frequência cardíaca. No primeiro aspecto os poucos estudos existentes mostraram limitações do ponto de vista metodológico: insuficientes sinais com poucas morfologias, a maioria eram sinais artificiais e não ambulatoriais. No segundo aspecto, não foi encontrado nenhum estudo quantitativo para caracterizar o desempenho (individual ou combinado) de diversos métodos de extração de características e agrupamento de batimentos com artefatos.

Atendendo aos objetivos da tese, foram melhorados os métodos para: (a) obter as séries temporais associadas ao intervalo QT especificamente as que implicam a detecção do ponto T_e e, (b) reconhecer morfologicamente os batimentos no ECG que devem ser excluídos para o estudo da HRV. A melhora dos métodos foi focalizada em condições ambulatoriais, ou seja, em presença de ruído de banda larga e de artefatos técnicos e fisiológicos.

Para melhorar a exatidão na detecção do ponto Te em condições ruidosas, foi proposto o método e algoritmo dos trapézios, o qual é relativamente simples de implementar, apresenta um baixo custo computacional, e não depende de nenhum fator de limiar empírico. Esse método demonstrou um elevado desempenho em presença de ruído de banda larga quando foi avaliado com sinais ambulatoriais da base de dados QTDB e comparado com um dos algoritmos mais reportados na bibliografia. Desta forma, nesta tese se sugere a adoção do método dos Trapézios em cenários onde o ECG esteja contaminado fortemente por ruído. O uso deste método poderia ser estendido para delimitar o início e o final de outras ondas no ECG.

Para melhorar o reconhecimento morfológico dos artefatos no ECG, para efeitos dos estudos da variabilidade da frequência cardíaca, e como resultado de uma profunda caracterização dos principais métodos de extração de características e agrupamento de batimentos, foi proposta uma nova combinação de métodos de extração de características (Kernel PCA) e de agrupamento (Perceptron multicamadas), que não aparece reportada na bibliografia para este finalidade. Assim mesmo, foi proposto um novo método e sua ferramenta associada para gerar batimentos sintéticos de forma controlada, o qual permitiu gerar sinais eletrocardiográficos com uma elevada variabilidade morfológica combinando diversas variantes de batimentos reais e sintéticos. A ferramenta permitiu caracterizar qualitativamente a sensibilidade dos classificadores inteligentes a pequenas mudanças na amplitude, morfologia e duração dos sinais de ECG de entrada. A similitude dos sinais gerados com os sinais reais foi validada por dois cardiologistas e três engenheiros biomédicos.

Desta forma, tem se cumprido o objetivo geral de melhorar os métodos de processamento do sinal de ECG ambulatorial usando inteligência computacional.

❖ **Recomendações para trabalhos futuros**

- Analisar a influencia da filtragem passa-altas na exatidão da detecção do ponto Te, devido ao tipo de filtro e a frequência de corte que influem consideravelmente nas mudanças de morfologias da onda T e, portanto no ponto Te finalmente determinado.

- Aumentar o número de morfologias da base de dados de edifícios que conformam a ferramenta baseada no método de segmentação de edifícios;
- Quantificar o desempenho dos métodos de reconhecimento de edifícios (extração e agrupamento) usando a ferramenta de geração de edifícios sintéticos.

REFERÊNCIAS

AFSAR, F. A.; ARIF, M. **Detection of ST Segment Deviation Episodes in the EGG using KLT with an Ensemble Neural Classifier**. IEEE International Conference on Emerging Technologies (ICET), Rawalpindi, Pakistan, 2007, p. 11-16.

BENÍTEZ, E. G.; PISARELLO, M. I.; PICAZAM C. A.; MONZÓN, J. E. **Un sistema inteligente para la clasificación de latidos en la señal electrocardiográfica**. XVII Congreso Argentino de Bioingeniería y VI Jornadas de Ingeniería Clínica, SABI 09, Rosario, Argentina, 2009, p. 102.

CAVALIERI, D. C.; JORGE, D. C. **Redes neurais artificiais aplicadas no auxílio de diagnósticos de Eletrocardiogramas**. In: Congresso Brasileiro de Automática, Salvador – BA, Brasil, 2006.

CEYLAN, R. **A novel approach for classification of ECG arrhythmias: Type-2 fuzzy clustering neural network**. Expert Systems with Applications: ESWA, 2008.

_____. ÖZBAY, Y. **Comparison of FCM, PCA and WT techniques for classification ECG arrhythmias using artificial neural network**. Expert Systems with Applications, 33, 2007, p. 286-295.

CHRISTOV, I.; G. BORTOLAN. **Premature ventricular contraction classification by the Kth nearest-neighbours rule**. Physiological Measurement, 26, 2005, p. 123-130.

CINCA, J.; JANSE, M. J.; MORÉNA, H.; CANDELL, J.; VALLE, V.; DURRER, D. **Mechanism and Time Course of the Early Electrical Changes During Acute Coronary Artery Occlusion* An Attempt to Correlate the Early ECG Changes in Man to the Cellular Electrophysiology in the Pig**. Chest, 77(4), 1980, p. 499–505.

CSE WORKING PARTY. **Recomendations form measurement standards in quantitative electrocardiography**. Eur. Heart Journal, 6, 1985, p. 815-825.

DALE, D, J, F; WERMTER, S. Y; AREVIAN, G, Z. **A Comparison of Feature Extraction and Selection Techniques**. Proceedings of the International Conference on Artificial Neural Networks. Istanbul, Turkey, 2003, p. 212-215.

DATASUS. Ministério da Saúde. **Departamento de Informática do SUS**. Disponível em: <http://www.datasus.gov.br>. Acesso: 04 dez. 2008.

DASKALOV, I.K.; CHRISTOV, I.I. **Automatic detection of the electrocardiogram T-wave end**. Med. Biol. Eng. Comput. 37, 1999, p. 348-353.

DE TALHOUE, H.; WEBSTER, J. **The origin of skin–stretch–caused motion artifact under electrodes**. Physiol. Meas. 17, 1996, p. 81-93.

DIMINSKI, A. S. **Análise de Problemas Geotécnicos Através de Redes Neurais**. Tese (Doutorado)- Universidade Federal do Rio de Janeiro, Programa de Engenharia Civil. Rio de Janeiro: COPPE/UFRJ, 2000.

ENGIN, M. **ECG beat classification using neuro-fuzzy network**. Pattern Recognition Letters, 25, 2004, p. 1715-1722.

EVANGELISTA NETO, J.; OLIVEIRA, R. C. L.; VÁZQUEZ SEISDEDOS, C.R.; MORENO, E. D. **Detección de artefatos no ECG: Proposta de algoritmo usando Análise de Componentes Principais**. In: Primeiro Simpósio de Cardiologia da Amazônia Ocidental. Studio 5, Centro de Convenções. Manaus, dezembro de 2007a.

_____; _____; _____; _____; VALENZUELA, V. L.; **Desenvolvimento de sistema móvel para aquisição de sinais ECG, 2007, Primeiro Simpósio de Cardiologia da Amazônia Ocidental**. Studio 5, Centro de Convenções de Manaus, 2007b.

_____; _____; _____; OLIVEIRA MIRANDA, M. JR.; LIMÃO DE OLIVEIRA, R. C. **Análisis del desempeño de los principales métodos de detección del final de la onda T en presencia de ruido**. In: XXI Congresso Brasileiro de Engenharia Biomédica. Salvador, Novembro de 2008a.

_____. **Detección de final de onda T en el electrocardiograma**, In: IV International Conference on Electrical Engineering FIE'08, Santiago de Cuba, July, 2008b.

_____. **Herramienta para generación de ECG sintéticos mediante el segmentado de latidos**. XXII Congresso Brasileiro de Engenharia Biomédica. Tiradentes, CBEB, Novembro 2010a.

_____; _____; SUAREZ LEON, A. A.; LIMÃO DE OLIVEIRA, R. C.; CASTAÑEDA F. F.; TORRES CEBRIÁN, A. **Análisis del desempeño de métodos de extracción de características en el ECG**. XXII Congresso Brasileiro de Engenharia Biomédica, 16-20 de Novembro, 2010, Tiradentes, Brasil, CBEB 2010b.

FERNÁNDEZ, M. AND R. PALLÁS-ARENY. **Electrode Contact Noise in Surface Biopotential Measurements**. In: Proceedings of the 14th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Paris, France. Octubre 1992, p. 123-124.

FERRETI GF, R.E. L; ZAYAT, M; MAZZARA, D; RIMATORI, C; PUPITA, G; MANNELLO, B; RUSSO, P. **A New Method for the Simultaneous Measurement of the RR and QT Intervals in Ambulatory ECG Recordings**. Computers in Cardiology, IEEE Computer Society, 1992, p. 171-174.

FISHER, J.C., SHUM, F., BAUMGARTEN, S. **Technologies For Early Detection of Heart Dysfunction**. Medical electronics, September, 1999, p. 33-37.

FRIESEN E COL. **A comparison of the noise sensitivity of nine QRS detection algorithms**. IEEE Trans. Biomed. Eng., 37 (1), 1990, p. 85-98.

GHAFFARI, A.; HOMAEINEZHAD, M. R.; AKRAMINIA, M.; ATAROD, M.; DAEVAEIHA, M. **A robust wavelet-based multi-lead electrocardiogram delineation algorithm**. Med. Eng. Phys. 31, 2009, p. 1219–27

GHONGADE, R. B.; GHATOL, A. A. **Deciding optimal number of exemplars for designing an ECG pattern classifier using MLP**. Indian Journal of Science and Technology, 2, 4, Mar. 2009, p. 40-42.

GRITZALI, F.; FRANGAKIS, G. E; PAPAKONSTANTINOY, G. **Detection of P and T waves in an ECG**. Computer and Biomedical Research, 1989, 22, p. 83-91.

HAGAN, M.T.; MENHAJ, M. **Training feed-forward networks with the Marquardt algorithm**. IEEE Transactions on Neural Networks, 5, No. 6, 1999, page(s): 989-993.

HAGNEY M.C., ZAREBA W., GENTLESK P.J., GOLDSTEIN R.E., ILLOVSKY M., MCNITT S., ANDREWS M.L., MOSS A.J., THE MADIT II INVESTIGATORS. **QT Interval Variability and Spontaneous Ventricular Tachycardia or Fibrillation in the Multicenter Automatic Defibrillator Implantation Trial (MADIT) II Patients**. J Am Coll Cardiol, vol 44 (7), 2004, p. 1481-87.

HAMALAINEN, M., LIPPING, T., NEUVO, Y. **Trends in Nolinear Signal Processing**. Methods of Information in Medicine, 1994, Vol. 33, No. 1.

HAYKIN, S. **Redes neurais. Princípios e prática**. Trad. Paolo Martins Engel, 2. ed. Porto Alegre: Bookman, 2001.

HE, L.; HOU, W.; ZHEN, X.; PENG; C. **Recognition of ECG Patterns Using Artificial Neural Network**. Proceedings of the Sixth International Conference on Intelligent Systems Design and Applications. (ISDA'06), IEEE Computer Society, 2, , 2006, p. 477-481.

HELFENBEIN, E. D; ZHOU, S. H; LINDAUER, J. M.; FIELD, D.Q.; GREGG, R. E, WANG, J. J.; KRESGE, S. S.; MICHAUD, F. P. **An algorithm for continuous real-time QT interval monitoring**. Journal of Electrocardiology, 39, 2006, p. 123-127.

HOSSEINI, H. G.; LUO, D.; REYNOLDS, K. J. **The comparison of different feed forward neural network architectures for ECG signal diagnosis**. Medical Engineering and Physics, Technical note, 28, 2006, p. 372-378.

JANE, R.; LAGUNA, P.; THAKOR, N.V.; CAMINAL, P. **Adaptative Baseline Wander Removal in the ECG: Comparative Analysis with Cubic Splines Technique**, Computers in Cardiology. IEEE Computer Society Press. Durham, 1992, p. 143-146.

_____. BLASI, A.; GARCÍA, J.; LAGUNA, P. (1997). **Evaluation of an automatic detector of waveforms limits in holter ECG with the QT database**. Computers in Cardiology, 24, 1997, p. 295-298.

JOY, M. R.; CHAKRABORTYA, CH.; AJOY, K. R. A. **Two-stage mechanism for registration and classification of ECG using Gaussian mixture model**, Pattern Recognition, Vol. 42, 11, 2009, p. 2979-2988.

KARDEC BARROS, A.; MANSOUR, A.; OHNISHI, N. **Removing artifacts from electrocardiographic signals using independent components analysis**. Neurocomputing, 22, 1998, p. 173-186.

KARPAGACHELVI, S.; ARTHANARI, M.; SIVAKUMAR, M. **ECG Feature Extraction Techniques-A Survey Approach**. International Journal of Computer Science and Information Security, Vol. 8, .n. 1, April, 2010, p. 76-80.

KLEIGER, R.E.; MILLER, J.P. ; BIGGER, J.T.; MOSS, A.J. AND THE MULTICENTER POST-INFARCTION RESEARCH GROUP. **Decreased heart rate variability and its association with increased mortality after acute myocardial infarction**. Am.J. Cardiol, 59, , 1987, p. 256-262.

KOHONEN, T. **The Self-organizing Map**. Proc. of the IEEE, 78, 9, 1990, p. 1464-1480.

KÖHLER, B.U.; HENNIG, C.; ORGLMEISTER, R. **The principles of software QRS detection**. IEEE Eng. Med. Biol. Mag. 21, 2002, p. 42-57.

LAGUNA, P.; THAKOR, N.V.; CAMINAL, P.; JANE, R.; YOON, H. R.; BAYES, D. E.; LUNA, A. **New algorithm for QT interval analysis in 24-hour Holter ECG: performance and applications**. Med. Biol. Eng. Comput. 28, 1990, p. 67-73.

_____. MARK, R. G.; GOLDBERGER, A.; MOODY, G. B. **A database for evaluation of algorithms for measurement of QT and other waveform intervals in the ECG**. Comput. Cardiology, vol. 24, 1997, p. 673-676.

_____. SÖRNMO, L. **Bioelectrical signal processing, in cardiac and neurological applications**. Elsevier, 2005, Cap 7, p. 453-556.

LAST T, Nugent CD, Owens F J. **Multi-component based cross correlation beat detection in electrocardiogram analysis**. Biomed. Eng. Online, 26, 2004. Disponível em: <http://www.biomedical-engineering-online.com/content/3/1/26>.

MARTINEZ, J.P.; ALMEIDA, R.; OLMOS, S. ROCHA, A. P.; LAGUNA, P. **A wavelet-Based ECG Delineator: Evaluation on Standard Databases**. IEEE Trans. Biomed. Eng. 51, 2004, p. 570-581.

MARTINEZ, A.; ALCARAZ, R.; RIETA, J. J. **Application of the phasor transform for automatic delineation of single-lead ECG fiducial points**. Physiol. Meas. 31, 2010, p. 1467-1485.

MCLAUGHLIN, N.B.; CAMPBELL, R.W.F.; MURRAY, A. **Effects of Filtering and Algorithm Parameters on Automatic QT Measurement Techniques**. Comput. Cardiol, IEEE Computer Society Press, 1994, p. 221-224.

_____. **Comparison of automatic QT measurement techniques in the normal 12 lead electrocardiogram.** Br Heart J. 74, 1995, p. 84-89.

MITRA, S.; MITRA, M.; CHAUDHURI, B.B. **Pattern defined heuristic rules and directional histogram based online ECG parameter extraction.** Measurement, 42, 2009, p. 150-156.

MOHEBBI, M.; MOGHADAM, H. A. **An Algorithm for Automated Detection of Ischemic ECG.** Beats Using Support Vector Machines. Signal Processing and Communications Applications, 2007, p. 1-4.

MOODY, G.B.; MARK, R.G. **The MIT-BIH Arrhythmia Database on CD-ROM and software for use with it.** In Computers in Cardiology, 1990, 17, page(s): 185-188.

NADAL, J.; BOSSAN, M.C. **Classification of Cardiac Arrhythmias Based on Principal Component Analysis.** 1993.

OLIVEIRA, R. C. L. **Rede Neural com Dinâmica Interna Aplicada a Problema de Identificação e Controle Não Linear.** Tese (Doutorado)- Universidade Federal de Santa Catarina, Programa de Pós Graduação em Engenharia Elétrica, 1999.

OLMOS, S. **Aportaciones a la compresión de datos de la señal electrocardiográfica mediante transformadas ortogonales.** Tesis doctoral dirigida por Pablo Laguna Lasaosa, Raimon Jané Campos. Universitat Politècnica de Catalunya (1998). <http://dialnet.unirioja.es/servlet/tesis?codigo=13605&info=resumen>
Acesso: 19 mar. 2012.

OLSZEWSKY, R. **Generalized feature extraction for structural pattern recognition in time-series data.** PhD Thesis, School of Computer Science, Carnegie Mellon University, Pittsburg, PA 15213, 2001.

ÖZBAY, Y.; CEYLAN, R.; KARLIK, B. **A fuzzy clustering neural network architecture for classification of ECG arrhythmias.** Computers in Biology and Medicine, 36, 2006, p. 376-388.

PAHLM, O.; SÖRNMO, L. **Software QRS detection in ambulatory monitoring-A review.** Med. Biol. Eng. Comput., Vol. 22, 1984, p 289-297.

PALLÀS-ARENY, R. **Analog Signal Processing.** Nova York: John Wiley & Sons, 1999.

PAN J; TOMPKINS, W.J. **A Real-Time QRS Detection Algorithm,** IEEE Transactions on Biomedical Engineering, 1985, p. 230-23.

PATRA, D.; DAS, M. K.; PRADHAN, S. **Integration of FCM, PCA and Neural Networks for classification of ECG arrhythmias.** IAENG International Journal of Computer Science, Agosto 2009.

PAUL, J. S.; READDY, M. R.; KUMAR, V. J. **A Transform Domain SDV Filter for Suppression of Muscle Noise Artefacts in Exercise ECG's**. IEEE Transactions on Biomedical Engineering, n. 5, vol. 47, 2000, p. 654-663.

PORTA, A.; BASELLI, G.; LAMBARDI, F.; CERUTTI, S.; ANTOLINI, R.; DEL GRECO, M.; RAVELLI, F.; NOLLO, G. **Performance assessment of standard algorithms for dynamic R-T interval measurement: Comparison between R-Tapex and R-Tend approach**. Med. Biol. Eng. Comput. 36, 1998, p. 35-42.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning internal representations by error propagation**. In RUMELHART, D. E.; McClelland, C. Eds., Parallel Data Processing, 1989, 1, Cambridge, MA: The M.I.T. Press, 1986, p. 318-362.

SCHÖLKOPF, B.; SMOLA, A. J.; MÜLLER, K. R. **Nonlinear component analysis as a kernel eigenvalue problem**. Neural Computation, 10, 1998, p. 1299-1319.

SCHREIER, G., HAYN, D. AND LOBODZINSKI, S. **Development of a New QT Algorithm With Heterogenous ECG Databases**. Journal of Electrocardiology, v. 36, 2003, p. 145-150.

SCHWARTZ P.J., WOLF S. **QT interval prolongation as predictor of sudden death in patients with myocardial infarction**. Circulation, 57, 1978, p. 1074-1079.

SCHWARTZ, P. ET AL. **Genotype-Phenotype Correlation in the Long-QT Syndrome: Gene-Specific Triggers for Life-Threatening Arrhythmias**. Circulation, 03, 2003, p. 89- 95.

SILIPO, R. **Investigating electrocardiographic features in fuzzy model for cardiac arrhythmia classification**. Methods of Information in Medicine, 40(5), 1999, p. 397-402.

SIMON, Y.; FOO, G.; STUART, B.; HARVEY, A. **Neural networkbased EKG pattern recognition**. Engineering Applications of Artificial Intelligence 15 (3-4), 2002, p. 253-260.

SOCIEDADE BRASILEIRA DE CARDIOLOGIA. **III Diretriz sobre tratamento do infarto agudo do miocárdio**, 2004. Disponível em http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0066-782X2004002200001. Acesso em: 25 mar. 2012.

SÖRNMO, L.; BÖRJESSON, P.O.; NYGARDS, M. E.; PAHLM, O. **A Method for Evaluation of QRS Shape Features Using a Mathematical Model for the ECG**. IEEE Transactions on Biomedical Engineering, 28(10), 1981, p. 713-7.

SÖRNMO, L. **Time-varying digital filtering of ECG baseline wander**. Medical and Biological Engineering and Computers, 1993, p. 503-508.

STERNICKEL, K. **Automatic pattern recognition in ECG time series**. Computer Methods and Programs in Biomedicine, 68, 2002, p. 109-115.

TASK FORCE OF THE EUROPEAN SOCIETY OF CARDIOLOGY AND THE NORTH AMERICAN SOCIETY OF PACING AND ELECTROPHYSIOLOGY. **Heart rate variability. Standards of measurement, physiological interpretation, and clinical use.** European Heart Journal, 17, 1996, p. 354-381.

THAKOR, N.; WEBSTER, J. The **origin of skin potential and its variations.** Proc. Ann. Conf. Eng. Biol. Eng., 20, 1978, p. 212.

TIKKANEN, P. E.; SELLIN, L. C.; KINNUNEN, H. O.; HUIKURI, H. V. **Using simulated noise to define optimal QT intervals for computer analysis of ambulatory ECG.** Medical Engineering & Physics, 21, 1999, p. 15-25.

ÜBEYLI, E. D. **ECG beats classification using multiclass support vector machines with error correcting output codes (2007).** Digital Signal Processing, 17, 2007, p. 675-684.

VALFREDO PILLA Jr, Heitor Silvério Lopes (1999). **Reconhecimento de Padrões em Sinais Eletrocardiográficos com Rede Neurofuzzy e Algoritmos Genéticos.** Proceedings of the IV Brazilian Conference on Neural Networks. In: IV Congresso Brasileiro de Redes Neurais pp. 042-046, July 20-22, 1999 - ITA, São José dos Campos – SP.

VAPNIK, V. M. **Learning Theory and It's Applications.** IEEE Transactions on Neural Networks, 10, 5, 1999, p. 985.

VÁZQUEZ SEISDEDOS, CARLOS R. **Análisis del ECG en monitorización ambulatoria para el diagnóstico cardíaco y la predicción de muerte cardíaca súbita.** 2001, p. 1-327. Disponível em: <http://www.tesisenxarxa.net/TDX-1105108-111710/>. Acesso em: 11 out. 2011.

VILA, J.; GANG, Y.; PRESEDO, J.; FERNÁNDEZ-DELGADO, M.; BARRO, S.; MALIK, M. **A new approach for TU complex characterization,** IEEE Trans. Biomed. Eng. 47, 2000, p. 764–772.

WANG. Y.; ZHU Y.; THAKOR, N.; XU, Y. **A Short-Time Multifractal Approach for Arrhythmia Detection Based on Fuzzy Neural Network.** IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING, Vol. 48, n. 9, 2001.

WEBSTER; J.G. **Medical Instrumentation. Application and Design.** 3ª ed. Nona York: John Wiley & Sons, 1998.

WERBOS, P. J. **Beyond Regression: New Tools for Prediction and Analysis in Behavioral Sciences.** Doctoral Dissertation, Applied Mathematics, Harvard University, Nov. 1974.

WOLF, A.; HALL BARBOSA, C.; COSTA MONTEIRO, E.; VELLASCO, M. **Multiple MLP Neural Networks Applied on the Determination of Segment Limits in ECG Signals.** International Work Conference on Artificial and Natural Neural Networks (IWANN), Espanha, 2003.

XUE, Q. Y.; REDDY, S. **New Algorithms for QT Dispersion Analysis. Computers in Cardiology.** IEEE Computer Society Press, 1996, p. 293-296.

YAMAZAKI, A. **Uma metodologia para otimização de arquiteturas e pesos de redes neurais.** Tese de doutorado, Centro de Informática, UFPE, 2004.

ZHANG, Q.; ILLANES MANRIQUEZ, A; MÉDIGUE, C.; PAPELIER, Y.; SORINE, M. **An Algorithm for Robust and Efficient Location of T-Wave Ends in Electrocardiograms.** IEEE Trans. Biomed. Eng. 53, 2006, p. 2544-2552.

OBRAS CONSULTADAS

ANLIKER, U. **AMON: a wearable multiparameter medical monitoring and alert system**". IEEE Trans. Inf. Technol. Biomed., vol. 8, 2004, p. 415-427.

ANTZELEVITCH, C.; SHIMIZY, W.; YAN, G. SICOURI, S. **Cellular Basis for QT Dispersion**. J. Electrocardiology. 30 (suppl), 1997, p. 168-175.

BUSTAMANTE, J., SAENZ, J.F., AMAYA, A. A. **Sistema de Tele-monitoreo Inalámbrico de Eventos Cardíacos para Seguimientos de Arritmias**. CLAIB 2007, IFMBE Proceedings 18. In: www.springerlink.com. © Springer-Verlag Berlin Heidelberg, Vol. 18, 2007, p. 948-952.

CLIFFORD, G. D; NEMATI, S; SAMENI, R. **An Artificial Multi-Channel Model for Generating Abnormal Electrocardiographic Rhythms**, Proc. Comput. Cardiol., 2008, p. 14-17.

GARCÍA-GONZÁLEZ, M.A.; PALLÀS-ARENY, R. **Novel robust index to assess beat-to-beat variability in heart rate time-series analysis**. IEEE Trans. Biomed. Eng. 48 (6), 2001, p. 617-21.

HAMSTRA, G. H.; PEPPER, A. Y; GRIMBERGEN, C.A. **Low-power, low noise instrumentation amplifier for physiological signals**. Med. Biol. Eng. Comput., 1984, 22, p. 272-274.

HAND, D. J. **Discrimination and Clasification**. John Wiley. New York, 198

HUHTA, J.C.; WEBSTER, J.G. **60-Hz Interference in Electrocardiography**. IEEE Transactions on Biomedical Engineering, 20 (2), 1973, p. 91-101.

KADAMBE, S.; MURRAY, R.; BOUDREAUX-BARTELS, G.F. **Wavelet transform-based QRS complex detector**. IEEE Trans. Biomed. Eng., vol. 46, 1999, p. 838-848.

LEVERT, J.V. E COL. **Similar Heart Rates, Different QT-intervals**. Computers in Cardiology, IEEE Computer Society Press, 1996, p. 277-280.

MCSHARRY, P., E.; CLIFFORD, G. D.; TARASSENKO, L.; SMITH, L. A. **A dynamic model for generating synthetic electrocardiogram signals IEEE**. Trans. Biomed. Eng. 50, 2003a, p. 289-294.

MCSHARRY, P. E.; CLIFFORD, G. D; **ECGSYN - A realistic ECG waveform generator**, 2003b. Disponible em: <http://www.physionet.org/physiotools/ecg-syn/>.

MEIJ, S.H. E COL. **An algorithm for automatic beat-to-beat measurement of the Q-T interval**. Computers in Cardiology, IEEE Computer Society Press, 1994, p. 597-600.

MERRI, M.; ALBERTI, M. E.; A. J. **Dynamic analysis of ventricular repolarization duration from 24-hour holter recording.** IEEE Trans. Biomed. Eng., 1993, 40 (12), p. 1219-1225.

METTING VAN RIJN, A. C. A.; PEPER AND, C. A.; GRIMBERGEN. **High-Quality Recording of Bioelectric Events.** Part 1: Interference Reduction, Theory and Practice Medical and Biological Engineering and Computing, 28, 1990, p. 389-397.

MIRANDA JUNIOR, M. O.; EVANGELISTA NETO, J.; VÁZQUEZ SEISDEDOS, C.R.; OLIVEIRA, R. C. L.; MORENO, E. D. **Desenvolvimento de uma interface de usuário para processamento e análise de sinais ECG.** In: Primeiro Simpósio de Cardiologia da Amazônia Ocidental. Studio 5, Centro de Convenções de Manaus, dezembro de 2007.

MONTES DE OCA, G.; RODRÍGUEZ, G.; RODRÍGUEZ, A.; ALMEIDA, R.; GONZÁLEZ, R. E PINA, N. **Analizador de un sistema de monitoreo HOLTER de 3 canales: EXCORDE 3C.** In: VII Congreso de la Sociedad Cubana de Bioingeniería, Habana, 2007. Disponível em: <http://cencomed.sld.cu/socbio2007/>. Acesso: 13 mar. 2011.

MOODY, G.B.; MULDROW, W.K.; MARK, R.G. **A noise stress test for arrhythmia detectors,** In: Computers in Cardiology 11, 1984, p. 381-384.

MOODY, GEORGE B.; MARK, ROGER G.; ARY, L. **GoldbergerPhysioNet: A Web-Based Resource for the Study of Physiologic Signals.** IEEE engineering in medicine and biology, May/June, 2001, p. 70-75.

NEUMAN, M. R. **Biopotential amplifiers.** In: Medical Instrumentation: application and design, 3. ed. John Wiley & Sons, N. Y., 1998, p. 233-286.

PALLÀS-ARENY, R.; WEBSTER, J.G. **Composite instrumentation amplifier for biopotentials.** Annals of Biomedical Engineerin, 18, 1990, p. 251-262.

_____. **Interference-rejection characteristics of biopotential amplifiers: a comparative analysis.** IEEE Transactions on Biomedical Engineering, 35 (11), 1988, p. 953-959.

POLI, R.; CAGNONI, S.; VALLI, G. **Genetic design of optimum linear and nonlinear QRS detectors.** IEEE Trans. Biomed. Eng., vol. 42, 1995, p. 1137-1141.

POWERS, Scott; HAWLEY, Edward, T. **Fisiologia do exercício.** São Paulo: Manole, 2009.

ROJAS J.C.C.; DA SILVA I.G.L.; CAMPOS P.G.; BATISTA C. E.; AMORIM B.P.; BRASIL L.M.; DE AZEVEDO F. M.; FILHO M.T.B.; DE ALMEIDA A.E.M. **Sistema Especialista Híbrido Aplicado à Área Médica.** In: XVII Congresso Brasileiro de Engenharia Biomédica (CBEB'2002), Florianópolis, SC, 2002, p. 824-829.

SAEEDHEH L M A, NADER J D, MOHAMMADREZA M. **Different Approaches for linear and non-linear ECG Generation**. International Conference on BioMedical Engineering and Informatics, 2008, p. 415- 419.

SAYADI, O.; SHAMSOLLAHI, M. B.; CLIFFORD, G. D, **Robust Detection of Premature Ventricular Contractions Using a Wave-Based Bayesian Framework**, IEEE Trans. Biomed. Eng, 57, 1989, p. 353-62.

SPINELLI, E. M.; PALLÀS-ARENAY, R.; MAYOSKY, M. A. **AC-Coupled Front-End for Biopotential Measurements**, IEEE Trans. Biomed. Eng., 2003, vol. 50, n. 3, p. 391-395.

STRECHMAN, V.L.; KUGE, K.A.; HARPER, R.M. **Time-domain system for assesing variation in heart rate**, Med. Biol. Eng. Comput., 26, 1988, p. 367–373.

SUAREZ LEON, A. A.; LÓPEZ-MORA, N. A.; LEITE, J. C.; LIMÃO DE OLIVEIRA, R. C. **Métodos de extracción de características en el ECG: análisis comparativo**. In: V Congreso Latinoamericano de Ingeniería Biomédica. Habana: Springer Verlab, Ref. 104, Mayo de 2011a.

TADDEI, A.; VARANINI, M.; MACERATA, A.; MARCHESI, C.; CONTINI, C.; BIAGINI, A.; BONGIORNI, M.G.; MAZZEI, M.G.; MAZZOCCA, G.F.; BARATTO, M. **An annotated database for the evaluation of algorithms for the analysis of arrhythmias and ischemic events**. In: Computers in Cardiology, 1983, 10, page(s): 191-194.

TADDEI, A.; DISTANTE, G.; EMDIN, M.; PISANI, P.; MOODY, G. B.; ZEELENBERG, C.; MARCHESI, C. **The European ST-T database: standard for evaluating systems for the analysis of ST-T changes in ambulatory electrocardiography**. Eur. Heart Journal, 1992, 13, page(s): 1164-1172.

TERESHCHENKO, L. G, ET AL. **Temporal QT Variability from Bipolar Ventricular Tip-to-Ring Electrograms Predicts Sustained Ventricular Tachyarrhythmia**. Circulation, 116, 2007, p. 634.

VÁZQUEZ SEISDEDOS, C. R.; EVANGELISTA NETO, J.; DE OLIVEIRA MIRANDA, M. JR.; LIMÃO DE OLIVEIRA, R. C. **Detección del final de la onda T en el ECG mediante áreas de trapecios**. XXI Congresso Brasileiro de Engenharia Biomédica, 2008, Brasil, ISBN: 978-85-60064-13-7.

_____; _____; _____. **Detección del final de la onda T en el ECG mediante áreas de trapecios**. Livro de Programa e Resumo, 21. In: Congresso Brasileiro de Engenharia Biomédica, 2008, Brasil, ISBN: 978-85-60064-14-4.

_____; _____; VALDÉS PÉREZ, FERNANDO E.; LIMÃO DE OLIVEIRA, ROBERTO C. **Procesamiento y análisis del ECG ambulatorio: algunos problemas y soluciones**, Revista Ciência, 2009. Indexada en LATINDEX.

VÁZQUEZ SEISDEDOS, C.R.; EVANGELISTA NETO, J.; MARAÑÓN REYES, E. J., KLAUTAU, A.; LIMÃO DE OLIVEIRA, R. C. **New approach for T-wave end**

detection on electrocardiogram: Performance in noisy conditions. BioMedical Engineering Online, DOI:10.1186/1475-925X-10-77, 2011b. Disponível em: <http://www.biomedical-engineering-online.com/qc/>. Acesso: 24 nov. 2011b.

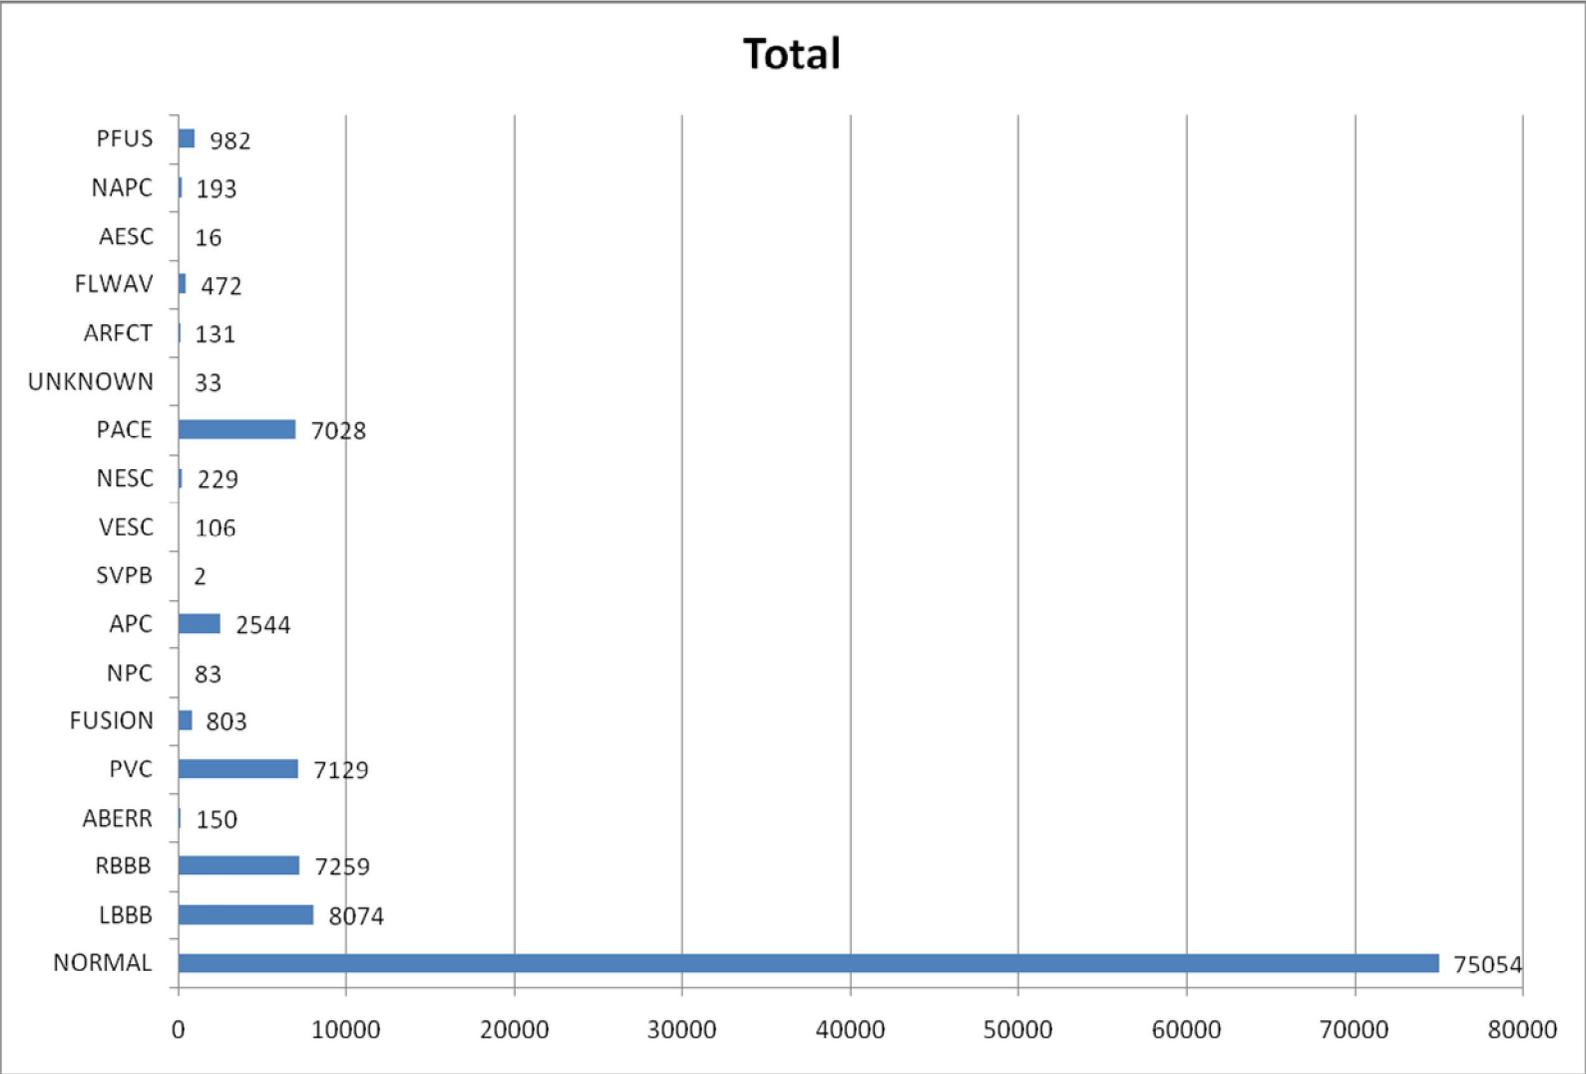
VIJAYA, G.; KUMAR, V.; VERMA, H. K. **ANN-based QRS-complex analysis of ECG**, J. Med. Eng. Technol., Vol. 22, n. 4, 1998, p. 160-167.

WINTER, B. B. E.; WEBSTER, J.G. **Reduction of interference due to common mode voltage in biopotential amplifiers**. IEEE Transactions on Biomedical Engineering, 1, 1983, p. 58-62.

WORLD HEART FEDERATION. **Global atlas on cardiovascular disease prevention and control 2011**. Page 4/ edited by Shanthi Mendis et al. Disponível em: http://www.world-heart-federation.org/fileadmin/user_upload/documents/Publications/Global_CVD_Atlas.pdf. Acesso em: 20 mar. 2012.

YANG, M. Y.; HU, W. C.; SHYU, L.Y. **ECG Events Detection and Classification Using Wavelet and Neural Networks**. Engineering in Medicine and Biology Society, 1997, Proceedings of the 19th Annual International Conference of the IEEE, p .289-292.

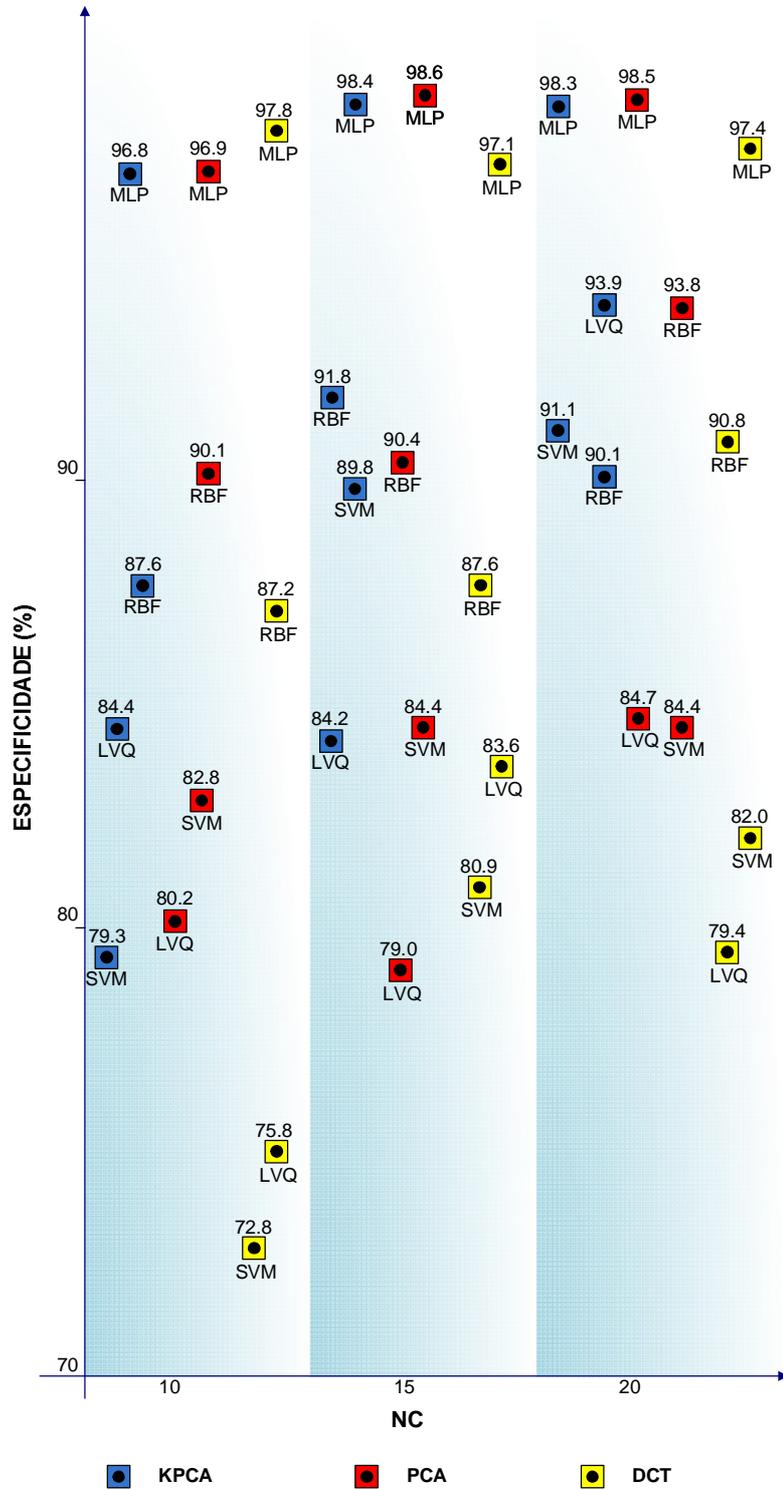
ANEXO A: Distribuição de batimentos por classe (MIT-BIH).



ANEXO B: Seleção de batimentos por registro (MIT-BIH).

No	REGISTRO	NORMAL	ARTEFATO	REGISTRO	NORMAL	ARTEFATO
1	100	50		200	50	80
2	101	50		201	50	80
3	102	50	80	202	50	
4	103	50		203	50	80
5	104	50	80	205	50	
6	105	50		207		80
7	106	50	80	208	50	80
8	107		80	209	50	80
9	108	50		210	50	
10	109		80	212	50	80
11	111		80	213	50	80
12	112	50		214		80
13	113	50		215	50	
14	114	50		217	50	80
15	115	50		219	50	
16	116	50		220	50	
17	117	50		221	50	80
18	118		80	222	50	80
19	119	50	80	223	50	80
20	121	50		228	50	
21	122	50		230	50	
22	123	50		231	50	80
23	124		80	232		80
24	-			233	50	80
25	-			234	50	

ANEXO C: Índice de especificidade para cada classificador.



ANEXO D: Tempo de execução do algoritmo PCA.

Reg.	PCA_10 (s)	PCA_15 (s)	PCA_20 (s)	Batimentos
00	0,0194	0,0618	0,0246	2271
101	0,0143	0,0403	0,0262	1867
102	0,0170	0,0287	0,0219	2185
103	0,0160	0,0265	0,0211	2082
104	0,0173	0,0289	0,0248	2227
105	0,0203	0,0308	0,0261	2600
106	0,0157	0,0259	0,0206	2025
107	0,0163	0,0269	0,0248	2135
108	0,0139	0,1873	0,0178	1780
109	0,0198	0,0333	0,0261	2530
111	0,0164	0,0271	0,0213	2122
112	0,0198	0,0325	0,0257	2537
113	0,0138	0,2281	0,0183	1793
114	0,0144	0,2128	0,0273	1878
115	0,0149	0,0251	0,0200	1957
116	0,0190	0,0371	0,0244	2410
117	0,0119	0,0197	0,0153	1533
118	0,0175	0,0301	0,0232	2286
119	0,0155	0,0256	0,0202	1985
121	0,0143	0,0235		1861
122	0,0197	0,0337	0,0248	2476
123	0,0118	0,0185	0,0150	1516
124	0,0124	0,0206	0,0164	1617
200	0,0202	0,0333	0,0289	2599
201	0,0153	0,0262	0,0204	1998
202	0,0161	0,0250	0,0218	2136

Reg.	PCA_1 (s)	PCA_15 (s)	PCA_20 (s)	Batimentos
203	0,0236	0,0382	0,0302	3003
205	0,0207	0,0341	0,0270	2655
207	0,0179	0,0286	0,0238	2332
208	0,0232	0,0382	0,0298	2961
209	0,0238	0,0383	0,0301	3009
210	0,0211	0,0340	0,0269	2649
212	0,0217	0,0351	0,0277	2747
213	0,0255	0,0417	0,0325	3249
214	0,0173	0,0292	0,0229	2264
215	0,0263	0,0432	0,0334	3361
217	0,0170	0,0284	0,0227	2207
219	0,0177	0,0294	0,0232	2285
220	0,0158	0,0296	0,0207	2046
221	0,0190	0,0319	0,0245	2425
222	0,0195	0,0339	0,0249	2481
223	0,0205	0,0333	0,0265	2603
228	0,0159	0,0264	0,0208	2075
230	0,0176	0,0292	0,0231	2255
231	0,0121	0,0204	0,0155	1571
232	0,0165	0,0230	0,0184	1778
233	0,0241	0,0395	0,0308	3079
234	0,0215	0,0360	0,0279	2751
Total	0,8614	2,0311	1,1393	110192

ANEXO E: Tempo de execução do algoritmo DCT.

Reg,	DCT_10 (s)	DCT_15 (s)	DCT_20 (s)	Batimentos	Reg,	DCT_10 (s)	DCT_15 (s)	DCT_20 (s)	Batimentos
100	0,6062	0,6148	1,0867	2271	220	0,5365	0,5324	0,5350	2046
101	0,4793	0,4750	0,4778	1867	221	0,6491	0,6491	0,6609	2425
102	0,5804	0,5789	0,5804	2185	222	0,6630	0,6715	0,6844	2481
103	0,5530	0,5563	0,5446	2082	223	0,7059	0,7167	0,7218	2603
104	0,5934	0,5950	0,5921	2227	228	0,5465	0,5527	0,5566	2075
105	0,7083	0,7184	0,7042	2600	230	0,5996	0,6116	0,6147	2255
106	0,5330	0,5442	0,5282	2025	231	0,3751	0,3886	0,3884	1571
107	0,5664	0,5753	0,5637	2135	232	0,4440	0,4453	0,4603	1778
108	0,4493	0,4491	0,4446	1780	233	0,8561	0,8660	0,8745	3079
109	0,6870	0,6998	0,6830	2530	234	0,7553	0,7700	0,7567	2751
111	0,5604	0,5715	0,5596	2122	Total	29,3598	29,5548	30,0222	110192
112	0,6885	0,6969	0,6983	2537					
113	0,4536	0,4638	0,4512	1793					
114	0,4875	0,4923	0,4804	1878					
115	0,5105	0,5117	0,5079	1957					
116	0,6463	0,6559	0,6445	2410					
117	0,3589	0,3600	0,3615	1533					
118	0,6033	0,6056	0,6099	2286					
119	0,5127	0,5135	0,5213	1985					
121	0,4691	0,4728	0,4803	1861					
122	0,6602	0,6636	0,6708	2476					
123	0,3490	0,3488	0,3540	1516					
124	0,3948	0,3992	0,3994	1617					
200	0,7152	0,7131	0,7098	2599					
201	0,5233	0,5227	0,5294	1998					
202	0,5702	0,5647	0,5646	2136					
203	0,8300	0,8339	0,8376	3003					
205	0,7237	0,7324	0,7300	2655					
207	0,6202	0,6310	0,6351	2332					
208	0,8182	0,8319	0,8308	2961					
209	0,8303	0,8321	0,8353	3009					
210	0,7233	0,7237	0,7284	2649					
212	0,7543	0,7590	0,7591	2747					
213	0,9068	0,9048	0,9156	3249					
214	0,6004	0,6029	0,6054	2264					
215	0,9491	0,9436	0,9474	3361					
217	0,5950	0,5853	0,5866	2207					
219	0,6179	0,6074	0,6093	2285					

ANEXO F: Tempo de execução do algoritmo KPCA.

Reg.	KPCA (s)	Batimentos
100	261,90	2271
101	209,19	1867
102	246,62	2185
103	238,49	2082
104	257,94	2227
105	283,74	2600
106	222,32	2025
107	232,88	2135
108	195,21	1780
109	278,23	2530
111	238,38	2122
112	285,91	2537
113	202,96	1793
114	211,53	1878
115	223,88	1957
116	272,25	2410
117	171,55	1533
118	263,00	2286
119	226,14	1985
121	224,49	1861
122	336,59	2476
123	173,55	1516
124	205,08	1617
200	302,81	2599
201	228,58	1998
202	241,83	2136
203	329,72	3003
205	293,61	2655
207	255,88	2332
208	330,43	2961
209	337,65	3009
210	303,67	2649
212	315,47	2747
213	367,08	3249
214	254,79	2264
215	390,15	3361
217	252,77	2207
219	263,14	2285

Reg.	KPCA (s)	Batimentos
220	233,67	2046
221	277,76	2425
222	284,20	2481
223	292,94	2603
228	236,98	2075
230	255,89	2255
231	174,23	1571
232	197,26	1778
233	350,74	3079
234	317,49	2751
Total	12550,57	110192

ANEXO G: Método e ferramenta para geração de batimentos sintéticos

O objetivo deste anexo é propor um novo método (e a ferramenta associada) para gerar batimentos eletrocardiográficos quase-artificiais de morfologia múltipla, com vistas ao reconhecimento de batimentos para o estudo da variabilidade de da frequência cardíaca no ECG ambulatorial.

O método proposto foi denominado como método de segmentação de batimentos (EVANGELISTA et al., 2010a) e consiste em concatenar seis segmentos diferentes aos quais podem ser aplicadas diversas transformações até configurar a morfologia do batimento final.

Os seis segmentos (Figura G.1) em que é subdividido cada batimento são os seguintes:

1. Segmento T – P (TP): desde o final da onda T do batimento anterior até o início da onda P do batimento atual.
2. Onda P (PW): desde o início ao final da onda P.
3. Segmento P – Q (PQ): desde o final da onda P até o início do complexo QRS.
4. Complexo QRS (QRSW): Inclui todo o complexo QRS, ou seja, desde o final do segmento PQ até o fim da onda S.
5. Segmento S – T (ST): desde o final da onda S até o início da onda T.
6. Onda T (TW): desde o início até o final da onda T.

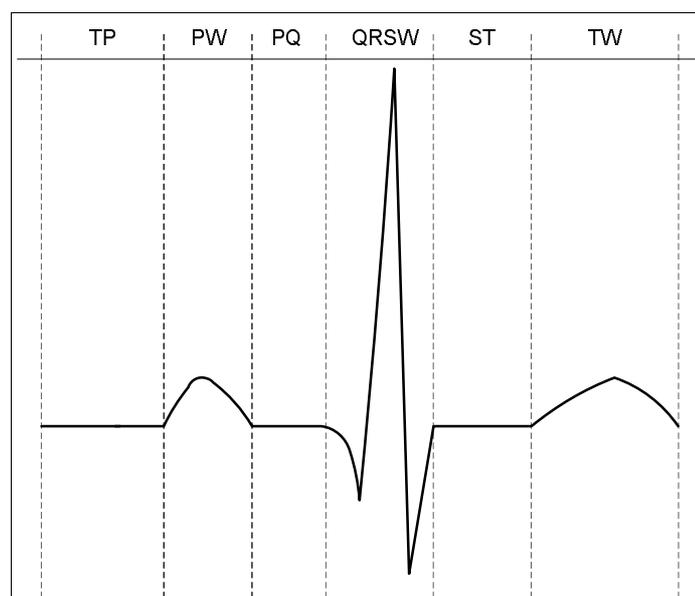


Figura G.1 - Subdivisão de um batimento em seis segmentos consecutivos: TP, PW, PQ, QRSW, ST, e TW.

Cada um dos seis segmentos possui diversas morfologias, obtidas de sinais reais e sintéticos, que podem ser combinados à vontade do usuário. A base de dados de cada segmento é aberta, ou seja, pode ser atualizada sistematicamente.

- (a) Para implementar o método de segmentação de batimentos foi criada uma ferramenta utilizando o programa Matlab™ r2008 de Mathworks™. Para a versão inicial da ferramenta foram usados:
 - (b) 12 batimentos reais da *MIT-BIH Arrhythmia Data base* (MIT-BIH DB) (MOODY, 1990) extraídos dos registros 100, 104, 108, 208, 214, 220, 232 e 234 (derivações II, V1 e V5),
 - (c) 12 batimentos reais da *European Society of Cardiology ST-T Data base* (ESCDB) (TADDEI, 1992) extraídos dos registros E0103, E0104, E0107, E0108 (derivação V4),
 - (d) 12 batimentos da *VALE Data base* (VALEDB) (TADDEI, 1983) extraídos dos registros VALE02, VALE06, VALE07 e VALE09 (derivações V2, V3, V4 e D3).
 - (e) 12 batimentos sintéticos gerados com funções do MATLAB.

Os batimentos foram ordenados da mesma forma descrita anteriormente, ou seja, o batimento 1 obtido da MITDB é o batimento número 1, o primeiro batimento da ESCDB é o número 13, e assim sucessivamente. Foram incluídos batimentos normais, extra-sístoles auriculares e ventriculares, bloqueios de ramos esquerda e direita, *flutter*, ondas invertidas (T e P), bifásicas (T e P) e segmentos S-T elevados, entre outros. A ferramenta permite adicionar, de forma simples, novas morfologias de batimentos.

Os batimentos oriundos das bases de dados MIT-BIH DB, ESCDB e VALEDB têm frequências de amostragem de 360 Hz, 250 Hz e 500 Hz, respectivamente. Para uniformizar a frequência de amostragem, os sinais anteriores foram reamostrados a 500 Hz usando a função “resample.m” do MATLAB, a qual realiza uma filtragem passa-baixas para evitar *aliasing*. A duração dos batimentos obtidos depende da composição final dos segmentos selecionados, e seu valor abrange desde 650 ms a 1200 ms. É válido salientar que o intervalo TP é

considerado só uma vez, tal como aparece na Figura G.1. Se for pretendido, por exemplo, determinar o final da onda T, então se sugere concatenar dois batimentos CONSECUTIVOS PARA QUE O SEGUIMENTO TP APAREÇA DEPOIS DA ONDA T DO PRIMEIRO BATIMENTO, E NÃO DA FORMA mostrada na Figura G.1.

A ferramenta SYNTHCECG 1.0, consiste em uma interface gráfica estruturada da seguinte forma (Figura G.2):

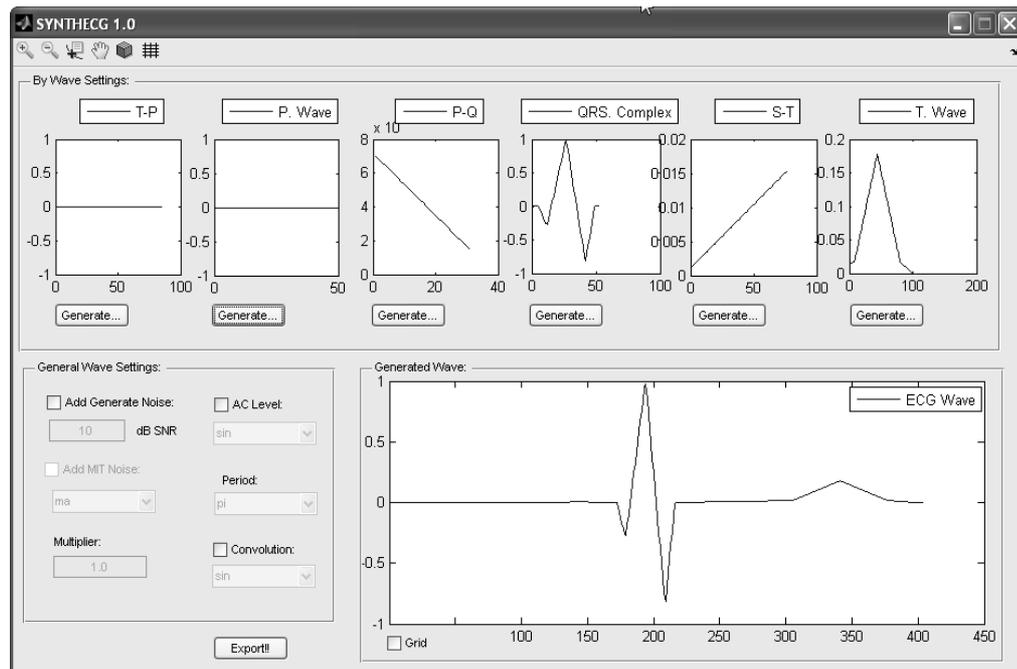


Figura G.2 - Janela principal da ferramenta SYNTHCECG 1.0.

- Três painéis: Painel de transformações locais (PTL), Painel de transformações globais (PTG), Painel de visualização (PV).
- Uma barra de ferramentas (Figura G.3) com as opções: (1) Zoom in, (2) Zoom out, (3) Data Cursor, (4) Pan, (5) Configuration, (6) Grid PTL.

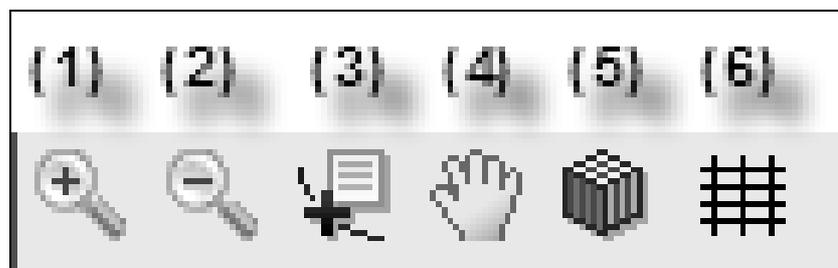


Figura G.3 - Barra de ferramentas.

PTL: É o painel de edição a nível local das ondas de um batimento de ECG. Neste pode-se editar cada um dos segmentos em que foi subdividido o sinal. Para tal deve-se clicar sobre o botão "*Generate*" do segmento que está sendo editado, uma vez que se haja seleccionada uma morfologia de segmento desejada.

O batimento assumido inicialmente para cada segmento é sintético e foi gerado com a função "*ecg.m*" do MATLAB.

Para facilitar a implementação da ferramenta, os seis segmentos anteriores voltaram a subdividir-se em dois grupos: o grupo (1) integrado pelos segmentos TP, PQ e ST e o grupo (2) pelas ondas PW, QRSW e TW. Assim, os elementos do grupo (1) são editados da mesma forma, ou seja, são aplicadas as mesmas transformações elementares mostradas na figura G.4. Estas transformações são:

- Mudar a onda base: Inicialmente, é isoeétrica, mas podem-se variar usando 12 morfologias de ondas base reais oriundas das bases de dados MIT-BIH, ESC-DB e VALEDB.
- Mudar a duração (comprimento) do sinal: se é maior que o original se preenche com zeros, se é menor se eliminam as últimas amostras.
- Acrescentar um ou mais artefatos na onda base: podem-se acrescentar artefatos com as morfologias seguintes: retangular, dente de serra ou pico. Sua amplitude e posição temporal são configuráveis.

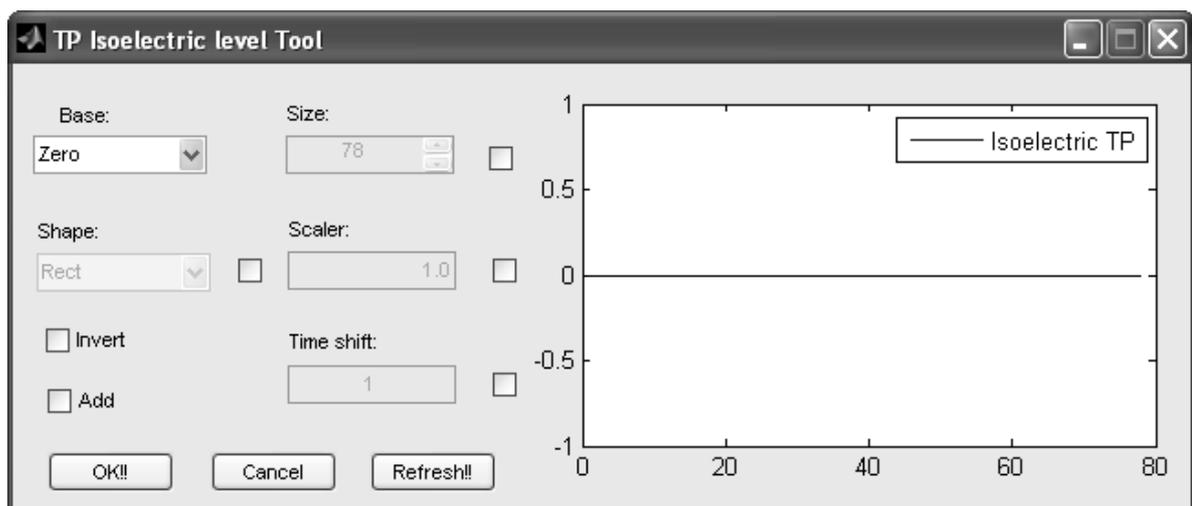


Figura G.4 - Janela de edição do grupo (1).

Para o grupo (2) aplicam-se outras transformações elementares que são relacionadas abaixo:

- Mudar a onda base: pode-se escolher 25 variantes de ondas P, 38 variantes de complexos QRS e 23 variantes de ondas T, a partir de 12 batimentos reais das bases de dados anteriores.
- Escalar: mudar a escala da onda multiplicando-a por um número.
- Inverter: mudar o sinal de cada um dos pontos que contém a onda.
- Reamostrar: mudar a quantidade de pontos da onda na fração que se especifique.
- Deslocar no tempo: retardo no tempo, ou seja, busca o efeito de eliminar as últimas amostras dependendo do valor do deslocamento.
- Acrescentar um nível de tensão contínua: soma uma quantidade fixa a cada amostra da onda.
- Suavizar: aplica um filtro temporal suavizador Savitzky–Golay com polinômio de ordem três (3) e janela configurável.
- Acrescentar um artefato na onda base: pode-se acrescentar com as morfologias: retangular, dente de serra e de pico. Também são configuráveis, a magnitude do artefato e sua posição temporal.

PTG: É o painel de transformações globais sobre o sinal de ECG, permite realizar as seguintes tarefas:

1. Acrescentar ruído de duas variantes:
 - Ruído gerado com a função "awgn.m".
 - Ruído real dos registros: em (*electro demotion artifact*), *bw* (*baselinewander*) e *ma* (*muscle noise*) da base de dados MIT-BIH *Noise Stress Test Data base* (MOODY, 1984).

Em ambos os casos, é controlada a relação sinal/ruído (SNR) do segmento adicionado.

2. Acrescentar sinais alternados: permite adicionar ao sinal de ECG, um período (ou um fragmento deste) de uma senoide, cossenoide ou uma exponencial decrescente.

3. Convolucionar o sinal com uma senoide, cossenoide ou uma exponencial decrescente.
4. Mover o batimento ao espaço de trabalho (*workspace*) do MatLab™ ou a um arquivo.

PV: É o painel de vista previa onde pode ser observado o resultado de cada uma das ações (globais ou locais) que são realizadas sobre o sinal de ECG. Contém um *checkbox* para ativar a grade da imagem.

Barra de ferramentas: Na mobilidade da barra de ferramentas os botões de *Zoom* e *Pan*, permitem ampliar, diminuir e qualquer das imagens da interface gráfica. O botão *Data Cursor* permite adicionar um *tooltip* na imagem selecionada.

O botão de configuração permite selecionar o caminho onde se encontra disponível a copia do usuário do MIT-BIH *Arrhythmia Data base* CD-ROM.

Finalmente o botão *Grid PTL* ativa ou desativa a grade para as ondas do PTL.

Exemplos de sinais gerados – Na Figura G.5a é apresentado um batimento sintético conformado com as seguintes características: segmento TP sintético com nível zero, Onda P real (batimento 1) com um escalado de 2 e um nível de contínua de - 0,15 unidades, segmento PQ sintético com nível zero, Complexo QRS e segmento ST, reais (batimento 8), Onda T real (batimento 2) somada com um nível de contínua negativo de -0,10 unidades e ruído branco gaussiano com SNR de 60 dB.

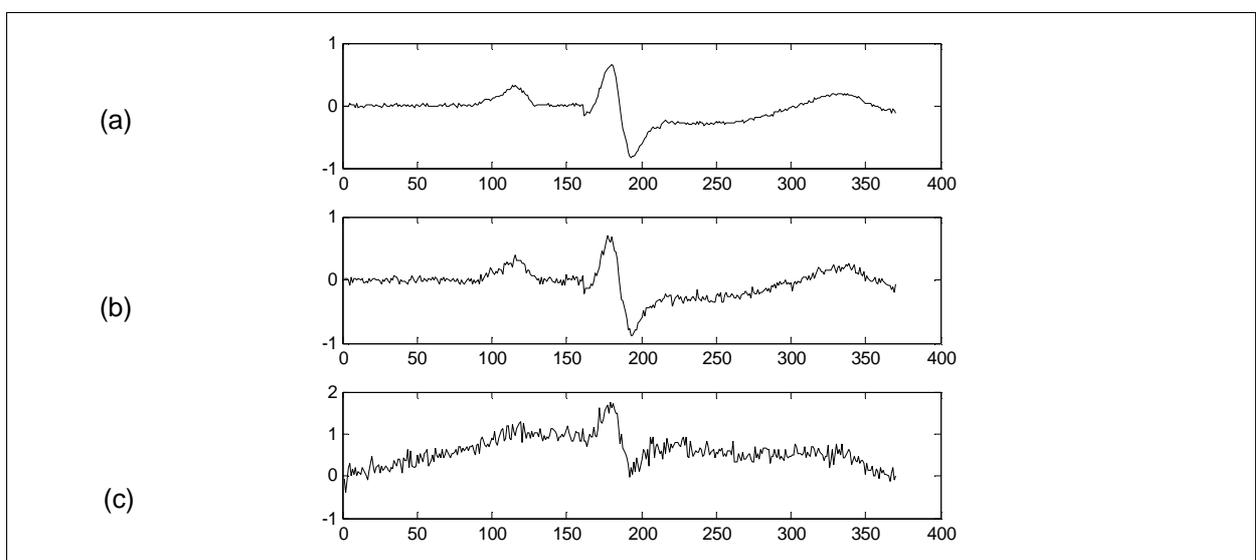


Figura G.5 - Exemplo de um batimento (superior) ao qual foi adicionados ruído (centro) e flutuações da linha base (inferior).

A Figura G.5b mostra o mesmo batimento ao qual foi adicionando ruído branco gaussiano com SNR de 40 dB. Finalmente na Figura G.5c, é mostrado o batimento anterior com um nível de AC sinusoidal unitário, que simula uma flutuação da linha base devido à respiração do paciente.

Vantagens e desvantagens

O novo método proposto permite gerar sinais quase-artificiais a partir de sinais reais sem necessidade de recorrer a modelos matemáticos de alto custo computacional (MCSHARRY, 2003A), (CLIFFORD, 2008), (SAEEDAH, 2008) E (SAYADI, 2010), os quais possuem limitações quanto à variabilidade morfológica obtida. Sua principal vantagem é que permite controlar a morfologia de forma sistemática e supervisionada pelo especialista. A combinação de segmentos de diversos sinais permite aumentar a variabilidade morfológica de forma fatorial, mostrando situações que não estão disponíveis nas bases de dados, mas que são possíveis de ocorrer.

A desvantagem do método proposto é que não leva em conta a dinâmica do ritmo cardíaco para a geração de batimentos, como ocorre em outros modelos mais sofisticados. Essa desvantagem não é significativa para a aplicação de reconhecimento morfológico de batimentos.