

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

KLAUS FABIAN CÔCO

**CLASSIFICAÇÃO NEURAL DE DOENÇAS
CARDÍACAS BASEADA NA ENERGIA DOS
COEFICIENTES WAVELET**

VITÓRIA, 7 DE MARÇO DE 2003.

KLAUS FABIAN CÔCO

**CLASSIFICAÇÃO NEURAL DE DOENÇAS
CARDÍACAS BASEADA NA ENERGIA DOS
COEFICIENTES WAVELETS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Mestre em Engenharia Elétrica – Automação.

Orientador: Prof. PhD. Ailson Rosetti de Almeida.

Co-Orientador: Prof. Dr. Evandro Ottoni Teatini Salles

VITÓRIA, 7 DE MARÇO DE 2003.

KLAUS FABIAN CÔCO

**CLASSIFICAÇÃO NEURAL DE DOENÇAS
CARDÍACAS BASEADA NA ENERGIA DOS
COEFICIENTES WAVELETS**

COMISSÃO EXAMINADORA

Prof. Dr. Ailson Rosetti de Almeida
Orientador

Prof. Dr. Evandro Ottoni Teatini Salles
Co-Orientador

Prof. Dr. Edson Baptista
Examinador

Prof. Dr. Hans-Jorg Andreas Schneebeli
Examinador

Vitória, 7 de março de 2003.

A minha querida esposa, Ana Paula Cardoso Prata.

AGRADECIMENTOS

Agradeço principalmente à minha esposa pela ternura, amor, paciência, estímulo, confiança, alegria e serenidade, me incentivando por todos os lados no esforço de cumprimento de meus sonhos, que sempre se realizam em sua quase totalidade cada vez que a vejo sorrir.

Aos amigos que perfizeram intromissões que direta ou indiretamente contribuíram para elaboração deste trabalho. Seja por apenas um simples comentário, seja por delongas conversas travadas a respeito do assunto, deixo registrada minha enorme gratidão.

Não obstante, em especial, fico extremamente grato aos professores Ailson Rosetti de Almeida e Evandro Ottoni Teatini Salles pela paciência, atenção, dedicação e ausência de parcimônia em me ensinar muitos dos preceitos (mais que o necessário) para elaboração correta e adequada deste trabalho; e ao amigo Juliano Vescovi Damasceno, não apenas pela revisão dos textos da área médica, mas também por sua conduta honesta e diligente em corroborar interesse na explicação da dinâmica fisiológica despendida pelo coração no constante labor iniciado ao limiar da vida e que apenas termina com a inevitável morte.

Aos meus infindáveis amigos e colegas, que por jus à menção, mas que pela impossibilidade de listá-los devidamente omiti seus nomes, meus sinceros e respeitosos agradecimentos.

Aos meus pais, mencionados somente agora, porém não menos importantes, que com tremendas dificuldades e limitações deixaram de lado as possibilidades de conforto e de segurança para prover condições suficientes em que eu e meus irmãos pudéssemos estudar... Deveras tamanha gratidão pudesse aqui solevar, o faria.

“Esfalfamo-nos na Terra a fazer testes de inteligência para ganhar inteligência, e, sem dúvida, precisamos todos de agilidade mental para a destreza de raciocínio e firmeza de decisão.

Entretanto, quase sempre sabemos entesourar conhecimento intelectual, mas ignoramos ainda como utilizá-lo para evitar a guerra; inventar os mais variados processos de reconforto em benefício do corpo transitório, mas desconhecemos ainda como prover as necessidades de nossas almas eternas.

Em razão disso, muitas vezes damos na Terra espetáculos de genialidade e delinquência, cultura e degradação.

Estamos em condições de preparar o futuro para todas as garantias do plano físico, mas habitualmente descuidamo-nos de nossos interesses na imortalidade que é patrimônio inalienável de cada um.”

EMMANUEL

LISTA DE SIGLAS

AFIB	Fibrilação atrial
AFL	Flutter atrial
AV	Nódulo átrio-ventricular
CWT	Transformada Wavelet Contínua
DWT	Transformada Wavelet Discreta
ECG	Eletrocardiograma
ESV	Extra sístole ventricular
FIR	Resposta ao impulso finita
FT	Transformada de Fourier
HMM	Modelo Oculto de Markov
HP	Filtros passa alta
IA	Inteligência artificial
IIR	Resposta ao impulso infinita
LA	Derivação do braço esquerdo
LL	Derivação da perna esquerda
LNPCA	Análise não-linear de Componentes Principais
LP	Filtro passa baixa
LPC	Coeficientes de Predição Linear
LVQ	Quantização vetorial por aprendizagem
LVQ1	Algoritmo LVQ com a taxa de aprendizagem otimizada
MIT	<i>Massachusetts Institute of Technology</i>
MITDB	<i>Massachusetts Institute of Technology Data Base</i>
N	ECG normal
P	Onda resultante da excitação elétrica atrial no ECG normal
PCA	Análise de Componentes Principais
PE	Elemento de processamento (= neurônio)
PSD	Densidade Espectral de Potência
QRS	Onda resultante da excitação elétrica ventricular no ECG normal
RA	Derivação do braço direito
RBF	Função de base radial
RL	Derivação da perna direita
RNA	Rede Neural Artificial

SA	Nódulo sino-atrial
SOM	Mapa auto-organizável
STFT	Transformada de Fourier de Tempo Curto
T	Onda resultante do relaxamento muscular atrial e ventricular no ECG normal
U	Sinal anômalo que surge após a onda T no ECG anormal
V ₁ a V ₆	Derivações precordiais
VFL	Flutter Ventricular
VLSI	Integração em Larga Escala
VT	Taquicardia Ventricular
WT	Transformada Wavelet

LISTA DE SÍMBOLOS

C_m	É a capacitância da membrana celular
v^i	Potencial interno à membrana
v^o	Potencial externo à membrana
$\{\varphi(\ \mathbf{x} - \mathbf{x}_i\) \mid i = 1, 2, \dots, N\}$	Conjunto da N funções de base radial
$\{\mathbf{x}_i \in \mathbb{R}^{m_0} \mid i = 1, 2, \dots, N\}$	Centros das N funções de base radial
$\dot{\phi}_k(\cdot)$	Derivada da função de ativação do neurônio k
a	Escala horizontal da wavelet
F_a	Pseudofrequência correspondente a escala a .
\mathbb{R}	Conjunto dos números reais
b	Escala vertical da wavelet
$W_f(a, b, \tau)$	Transformada wavelet contínua de $f(t)$
$\psi_{a,b,\tau}$	Wavelet de base escalada e posicionada
\mathbb{Z}	Conjunto dos números inteiros
$\psi_k(t)$	Conjunto de expansão
$\tilde{\psi}_k(t)$	Conjunto de expansão dual
\mathcal{U}_0	Subespaço de Lebesgue
\mathcal{U}_j	Subespaços expandidos de Lebesgue
v_A e v_B	Tensões de entrada do amplificadores de instrumentação
μ	Posicionamento da base gaussiana na rede RBF
σ	Largura da base gaussiana na rede RBF
η	Taxa de aprendizado da RNA
α	Constante de momento
ω	Frequência
τ	Posição da wavelet
\oplus	Representa uma relação entre subespaços
\perp	Representa uma ortogonalidade entre subespaços
$\Psi(\omega)$	Transformada de Fourier da wavelet

$\delta(\cdot)$	Função delta de Kronecker
$\xi(n)$	Função de custo (ou índice de desempenho)
$\varphi(r)$	Função de base radial
$\psi(t)$	Wavelet de base
$\varphi(v)$	Função de ativação do neurônio
$\phi_A \phi_B \phi_{AB}$	Representam os potenciais em A , em B e entre A e B , no corpo humano
α_c	Constante de aprendizagem
Δf_s	Resolução em frequência da transformada wavelet discreta
μ_k	Amostra par da transformada <i>lifting</i> wavelet
γ_k	Amostra ímpar da transformada <i>lifting</i> wavelet
$\alpha_k \beta_k$	Coefficientes de Daubechies
$\delta_k(n)$	Gradiente local
$\xi_k(t)$	Função de escala
μ_m	Escalar usado no método de Levenberg-Marquardt
$\Delta w_{kj}(n)$	Ajuste aplicado ao peso sináptico $w_{kj}(n)$ do neurônio k da camada j da RNA no passo n
Δz	Comprimento linear da membrana celular
a_k	Coefficientes de expansão reais
a_n	Coefficientes de aproximação do nível n
b_k	Entrada de polarização do neurônio k da RNA
c	Índice do mais próximo vetor de Voronoi do vetor \mathbf{x}_i
C	Coefficiente de correlação
$c_{j,k}$	DWT
c_k	Coefficientes de expansão reais
Cl^-	Ânion Cloro
\mathbf{d}	Vetor de resposta desejada da rede RBF
d_k	Saída desejada do neurônio k
d_n	Coefficientes de detalhe do nível n
E	Potenciais da membrana celular
$e_k(n)$	Erro da saída no neurônio k
E_s	Média dos valores de cada subsequência da decomposição <i>lifting</i>
F	Espaço vetorial de Lebesgue
$f(t)$	Função pertencente ao espaço de Lebesgue
F_c	Frequência central de uma wavelet

f_s	Taxa de amostragem
g	Condutâncias da membrana celular
\mathbf{g}_j	Vetor gradiente
\mathbf{H}	Matriz Hessiana
$h(n)$	Coefficientes de expansão (filtro FIR LP)
$h_I(n)$	Coefficientes de recursão (filtro FIR HP)
i_m	É a corrente trans-membrana
\mathbf{J}	Matriz Jacobiana
K ou K^+	Cátion Potássio
L	Membrana lipoprotéica
$L^2(\mathbb{R})$	Espaço de Lebesgue
m_0	Dimensionalidade do espaço de entrada de uma rede RBF
m_k	Fator de normalização
n	Número de iterações no treinamento neural ou nível da decomposição wavelet
Na ou Na^+	Cátion Sódio
R_{AB}	É a resistência equivalente medida entre as tomadas A e B do corpo humano
r_i	Resistência do meio interno da célula
r_o	Resistência do meio externo da célula
R_{T1} e R_{T2}	Resistências inerentes ao eletrocardiógrafo
S	Espaço vetorial de Lebesgue
$s(\cdot)$	Função sinal
T_s	Período de amostragem
\mathbf{w}	Vetor de pesos lineares da rede RBF
W	Número de parâmetros da RNA
\mathbf{w}_c	Vetor de Voronoi
W_j	Complemento ortogonal de \mathcal{V}_j e \mathcal{V}_{j+1}
w_{kj}	Peso sináptico do neurônio artificial k da entrada j
$X(j\omega)$	Transformada de Fourier de $x(t)$
$x(t)$	Sinal contínuo variante no tempo
\mathbf{x}_i	i -ésimo vetor de entrada da RNA
x_m	Amostra da entrada “m” do neurônio
y_k	Saída do neurônio k da RNA
z	Ponto de referência sobre a membrana celular para tomada dos potenciais

Φ

Matriz de interpolação da rede RBF

LISTA DE FIGURAS

FIGURA 2.1 - Localização do coração no mediastino médio.....	..23
FIGURA 2.2 - Câmaras cardíacas.....	..24
FIGURA 2.3 - Fluxo sanguíneo pulmonar e sistêmico no corpo humano.....	..25
FIGURA 2.4 - Irrigação cardíaca mostrando as artérias coronárias.....	..26
FIGURA 2.5 - Sistema de condução do sinal elétrico no coração humano. (Veja as setas indicadoras do início “P” e fim “F” do percurso).....	..27
FIGURA 2.6 - Linhas de condução do sinal elétrico no coração humano.....	..28
FIGURA 2.7 - Esquema de condução do sinal elétrico no coração humano.....	..28
FIGURA 2.8 - Diagrama da inervação autônoma eferente do coração humano.....	..29
FIGURA 2.9 - Válvulas cardíacas humanas.....	..30
FIGURA 2.10 - Correlação entre sons, eventos mecânicos e elétricos do coração humano.....	..31
FIGURA 2.11 - (a) Distribuição das cargas em torno de uma fibra em condução. (b) Fluxo de corrente na mesma fibra.....	..32
FIGURA 2.12 - Circuito equivalente de uma fibra muscular esquelética.....	..33
FIGURA 2.13 - Equivalente elétrico do problema eletrocardiográfico. R_{T1} e R_{T2} representam as resistências inerentes ao equipamento de medição; R_{AB} é a resistência equivalente medida entre as tomadas A e B do corpo humano; e ϕ_A ϕ_B ϕ_{AB} representam os potenciais em A, em B e entre A e B, respectivamente.....	..34
FIGURA 2.14 - Atividade elétrica representativa de cada região do coração.....	..34
FIGURA 2.15 - Linha isócrona de ativação ventricular do coração humano.....	..35
FIGURA 2.16 - Eletrocardiógrafos. (a) Portátil para uso com microcomputador. (b) Modelo fixo para uso com microcomputador.....	..35
FIGURA 2.17 - Derivações do plano frontal e triângulo de Eindhoven.....	..36
FIGURA 2.18 - Modelo elétrico equivalente.....	..37
FIGURA 2.19 - Mapeamento do vetor cardíaco.....	..37
FIGURA 2.20 - Derivações precordiais.....	..38
FIGURA 2.21 - Amplificador ECG para uma derivação.....	..38
FIGURA 2.22 - Sinal do ECG com artefatos da rede elétrica.....	..39
FIGURA 2.23 - Taquicardia Ventricular.....	..41
FIGURA 2.24 - Extra Sístole Ventricular.....	..41
FIGURA 2.25 - Capturas e Fusões.....	..42
FIGURA 2.26 - Capturas e Fusões.....	..42
FIGURA 2.27 - Arritmia Supraventricular.....	..42
FIGURA 2.28 - Extra-sístole Auricular.....	..42
FIGURA 2.29 - Fibrilação Auricular.....	..43
FIGURA 2.30 - Fibrilação Ventricular. (a) Múltiplos Focos Ectóticos. (b) ECG caótico.....	..43
FIGURA 2.31 - Flutter Auricular.....	..44
FIGURA 2.32 - Flutter Ventricular. (a) Foco gerador. (b) Evolução para fibrilação.....	..44
FIGURA 2.33 - Escape Auricular.....	..45
FIGURA 2.34 - Escape Nodal.....	..45

FIGURA 2.35 - Escape Ventricular.....	..45
FIGURA 2.36 - Geminismos.....	..46
FIGURA 2.37 - Fenômeno de Wenckebach.....	..46
FIGURA 2.38 - Marca-passo Migratório.....	..47
FIGURA 2.39 - Alterações nos segmentos ST, QT e onda T. (a) Isquemia. (b) Sobrecarga. (c) Infarto.....	..47
FIGURA 2.40 - Alterações nos segmentos ST, QT e onda T por distúrbio químico. (a) Potássio. (b) Cálcio.....	..48
FIGURA 2.41 - Inflamações.....	..48
FIGURA 2.42 - Ondas Q Patológicas.....	..48
FIGURA 3.1 - Traçado do ECG com 1024 amostras da derivação <i>signal_I</i> para: (a) ECG Normal, (b) Taquicardia Ventricular, (c) Flutter Ventricular, (d) Flutter Auricular, (e) Fibrilação Auricular.....	..52
FIGURA 3.2 - Base wavelet, função de escala e coeficientes dos filtros. (a) daubechies 4 (b) symlet 4.....	..53
FIGURA 3.3 - Base wavelet, função de escala e coeficientes dos filtros Haar.....	..54
FIGURA 3.4 - Número de amostras em cada nível da decomposição wavelet. As amostras dos oito níveis foram geradas pela transformada discreta de primeira geração, aplicada em 1024 amostras, de cada derivação, coletadas simultaneamente de um paciente. As amostras com grifo são descartadas.....	..55
FIGURA 3.5 - Coeficientes da Decomposição Wavelet em 8 níveis do sinal do ECG Normal e as energias dos respectivos níveis. O sinal foi obtido da base de dados do MIT e processado no MATLAB.....	..56
FIGURA 3.6 - Gráficos de energias de quarto doenças e ECG normal tomados de duas derivações simultâneas. Os níveis estão concatenados, sendo que as energias de 1 a 7 correspondem à primeira derivação e as de 8 a 14 são relativas à segunda derivação. A wavelet utilizada foi a symlet4.....	..57
FIGURA 3.7 - Diagrama das fases do processo de classificação. As etapas tracejada e pontilhada, do esquema, ocorrem de forma mutuamente exclusivas e foram apresentadas dessa forma para vias de comparação.....	..60
FIGURA 4.1 - (a) Taquicardia ventricular. (b) Flutter ventricular.....	..64
FIGURA 4.2 - Amostras de três classes que se misturam.....	..68
FIGURA 5.1 - Interface com o usuário.....	..71
FIGURA 5.2 - Fluxograma do sistema de diagnóstico de doenças cardíacas.....	..72
FIGURA 5.3 - Sistema de avaliação do ECG implementado no emulador para PC.....	..74

LISTA DE TABELAS

TABELA 3.1 - Amostras coletadas.....	..51
TABELA 3.2 - Amostras coletadas.....	..51
TABELA 3.3 - Faixas de Frequência (Hz).....	..55
TABELA 4.1 - Vetores de Energia com Taquicardia Ventricular.....	..62
TABELA 4.2 - Rede Perceptron Multicamadas com Taquicardia Ventricular.....	..63
TABELA 4.3 - Vetores de Energia sem Taquicardia Ventricular.....	..64
TABELA 4.4 - Rede Perceptron Multicamadas com Taquicardia Ventricular.....	..65
TABELA 4.5 - Rede RBF considerando a Taquicardia Ventricular.....	..66
TABELA 4.6 - Rede RBF não considerando a Taquicardia Ventricular.....	..66
TABELA 4.7 - Rede LVQ considerando a Taquicardia Ventricular.....	..67
TABELA 4.8 - Rede LVQ não considerando a Taquicardia Ventricular.....	..67
TABELA 6.1 - Ordem de Melhor Classificação das Bases Wavelets.....	..77

SUMÁRIO

RESUMO.....	14
ABSTRACT.....	15
1 INTRODUÇÃO	16
1.1 ESTADO DA ARTE.....	17
1.2 ESTRUTURA DO TRABALHO.....	22
2 O CORAÇÃO	23
2.1 INTRODUÇÃO.....	23
2.2 NOÇÕES QUANTO À IRRIGAÇÃO DO CORAÇÃO	26
2.3 NOÇÕES QUANTO AO SISTEMA DE CONDUÇÃO.....	27
2.4 NOÇÕES QUANTO À INERVAÇÃO CARDÍACA.....	28
2.5 O CICLO CARDÍACO	29
2.6 ELETROCARDIOGRAFIA.....	31
2.6.1 BIOPOTENCIAIS.....	32
2.6.2 ELETROCARDIOGRAMA.....	35
2.6.2.1 Ruídos Associados aos Sinais Bioelétricos.....	39
2.6.3 DOENÇAS DETECTADAS PELA ANÁLISE DO ECG E DISPONÍVEIS NO MITDB	40
2.6.3.1 Taquicardia Ventricular	40
2.6.3.2 Arritmia Supraventricular.....	42
2.6.3.3 Fibrilação Atrial	42
2.6.3.4 Fibrilação Ventricular.....	43
2.6.3.5 Flutter Atrial.....	44
2.6.3.6 Flutter Ventricular.....	44
2.6.3.7 Batimentos de Escape	45
2.6.3.8 Geminismo	46
2.6.3.9 Bradicardia Sinusal.....	46
2.6.3.10 Fenômeno de Wenckebach.....	46
2.6.3.11 Marca-Passo Migratório	47
2.6.3.12 Episódios ST, QT e Onda T.....	47
3 METODOLOGIA.....	49
3.1 INTRODUÇÃO.....	49
3.2 ESTUDOS DESENVOLVIDOS	49
3.2.1 Organização do Banco de Dados	49
3.2.2 Transformada Wavelet.....	52
3.2.3 Rede Neural Artificial	58
4 EXPERIMENTOS E RESULTADOS.....	61
4.1 INTRODUÇÃO.....	61
4.2 PROCEDIMENTO.....	61
4.3 RESULTADOS	63
4.4 COMENTÁRIOS	68
5 IMPLEMENTAÇÃO NO PALMTOP.....	70
5.1 INTRODUÇÃO.....	70
5.2 DOCUMENTO CONCEITUAL.....	70
5.3 PROJETO.....	71
5.3.1 Análise do Sistema.....	71
5.4 IMPLEMENTAÇÃO.....	73
6 CONCLUSÕES	75
6.1 SUGESTÕES	79
REFERÊNCIAS	80

APÊNDICE A - WAVELETS	84
A.1 INTRODUÇÃO.....	84
A.2 SISTEMAS WAVELETS DE PRIMEIRA GERAÇÃO.....	86
A.2.1 Transformada Wavelet Contínua.....	87
A.2.2 Transformada Wavelet Discreta.....	92
A.3 SISTEMAS WAVELETS DE SEGUNDA GERAÇÃO: A LIFTING WAVELET	103
APÊNDICE B - REDES NEURAIS ARTIFICIAIS.....	111
B.1 INTRODUÇÃO.....	111
B.2 REPRESENTAÇÃO DO CONHECIMENTO	114
B.3 MODELO DE UM NEURÔNIO	118
B.4 MODELO DA REDE NEURAL ARTIFICIAL.....	120
B.4.1 Mapa Auto-Organizável.....	121
B.4.1.1 Quantização Vetorial por Aprendizagem	123
B.4.2 Redes Alimentadas Diretamente Multicamadas.....	125
B.4.2.1 Redes de Função de Base Radial	127
B.4.2.2 Redes Perceptron Multicamadas.....	132
B.5 O PROCESSO DE APRENDIZAGEM.....	134
B.5.1 Algoritmo de Retropropagação do Erro.....	135
B.5.2 Algoritmos de Correção de Erro	135
B.5.2.1 Método da Descida do Gradiente.....	136
B.5.2.2 Método de Levenberg-Marquardt.....	138
B.5.3 Critérios de Parada do Treinamento	142
APÊNDICE C - A BASE DE DADOS DO MIT.....	146
C.1 INTRODUÇÃO.....	146
C.2 DESCRIÇÃO DOS BANCOS DE DOENÇAS CARDÍACAS.....	146
C.2.1 The MIT-BIH Atrial Fibrillation Database	146
C.2.2 The MIT-BIH Malignant Ventricular Arrhythmia Database	147
C.2.3 MIT-BIH Arrhythmia Database.....	147
C.2.4 The QT Database	148
C.2.5 Ventricular Tachyarrhythmia (ou Taquicardia) Database.....	149
C.2.6 European ST-T Database	150
C.2.7 The PAF Prediction Challenge Database	155
C.2.8 The MIT-BIH Normal Sinus Rhythm Database.....	156
C.2.9 The MIT-BIH Supraventricular Arrhythmia Database	156
C.2.10 The MIT-BIH LT_ST Database	156
C.3 DESCRIÇÃO DOS ARQUIVOS.....	157
C.4 CONSIDERAÇÕES SOBRE O BANCO DE DADOS – MITDB.....	158
C.5 CONTEÚDO DO MITDB.....	159
C.5.1 Anotações Médicas	181
APÊNDICE D - GRÁFICOS DE ERROS.....	192
APÊNDICE E - MATRIZES DE CONFUSÃO	194

RESUMO

O espectro de energia, calculado dos coeficientes de cada nível da decomposição wavelet do sinal do ECG, constitui bom vetor de características para separação de um número específico de doenças do coração. Isso sugere a possibilidade de se poder diagnosticar essas diferentes classes de doenças de modo automático. Além da segregação das classes, há a necessidade de rapidez no diagnóstico, uma vez que, o que se propõe também seja a implementação em ambiente de processamento embutido (palmtop), permitindo a mobilidade do sistema. Nesse caso o uso de redes neurais artificiais e das transformadas wavelets apresentam-se como alternativas adequadas à implementação do modelo, resultando em um sistema com boa eficiência e portabilidade.

ABSTRACT

The energy spectrum computed from the coefficients of each level of the wavelet decomposition of ECG signals constitutes good characteristic vectors for the classification of a number of specific heart diseases. This suggests the possibility of sorting these different classes of diseases in an automatic way. In addition to the segregation of the classes, there is the need for fast diagnosis, once, what is also intended is the development of built-in processing capability (palmtop), allowing the mobility of the system. In that case the use of neural networks and wavelets transforms became adequate alternatives for the implementation of the model, resulting in a classification system with emphasis on efficiency and portability.

1 INTRODUÇÃO

A eletrocardiografia vem sendo amplamente utilizada pela medicina como uma maneira rápida, barata e não invasiva no diagnóstico de uma ampla variedade de doenças do coração. O eletrocardiograma (ECG) é um dos exames mais comuns de diagnóstico, realizado mais de 50 milhões de vezes por ano só nos Estados Unidos [24].

Boa parte das doenças cardíaca somente é detectada pela investigação do sinal elétrico obtido através do eletrocardiograma. Contudo, a sutileza de detalhes e a ampla variedade de moléstias acarretam o aumento na possibilidade de erros no diagnóstico médico. Estudos já demonstraram que de 2 a 8% dos pacientes que são examinados em prontos-socorros são equivocadamente liberados, e um quarto dessas pessoas morre ou sofre uma parada cardíaca completa [24].

Sistemas que pudessem efetuar o diagnóstico a partir do traçados do eletrocardiograma (ECG) poderiam facilitar bastante a análise médica, permitindo uma diagnose segura, praticamente eliminando o risco de erro humano.

Um estudo apresentado por Gawande [24] mostra um sistema baseado em redes neurais para diagnóstico de infarto do miocárdio. O sistema foi treinado com o ECG de mais de dez mil pacientes e submetido a testes com um dos maiores especialistas em cardiologia da Suécia, que analisava em torno de dez mil eletrocardiogramas por ano. Foram selecionados 2240 ECGs sendo que 1120 apresentavam casos confirmados de ataque cardíaco. O médico interpretou corretamente 620 casos, enquanto o computador, 738. A máquina teve uma vantagem de 20 % sobre o homem.

O uso de sistemas computadorizados provê, além da segurança na identificação do problema, a eliminação do dispêndio de tempo para inspeção do traçado, com a informação correta sendo apresentada durante a medição do sinal. Isso permitiria a tomada de ações rápidas evitando, por exemplo, a progressão do infarto no instante em que o paciente estivesse sendo monitorado.

Todavia, sistemas que, além de diagnosticar, fossem manuseados e transportados com facilidade poderiam ser utilizados a qualquer tempo em diferentes lugares e situações. Por exemplo, médicos especialistas em outras áreas, que não a cardiologia, fariam uso

do equipamento como apoio no diagnóstico de doenças que, indiretamente, afetam temporariamente o traçado do ECG.

Ainda na mesma hipótese, a mobilidade desses sistemas seria bastante útil nas centrais de emergência, ou no monitoramento de pacientes com histórico de doenças cardíacas, informando o momento adequado de ingerir o medicamento quando da ocorrência de determinada patologia.

1.1 ESTADO DA ARTE

Com o intuito de melhorar a eficiência e a segurança das análises humanas sobre o sinal do ECG, várias pesquisas foram realizadas abordando diferentes técnicas de processamento de sinais e de reconhecimento de padrões [50].

Os parágrafos seguintes relatam uma série de trabalhos em torno da classificação de padrões para sinais eletrocardiográficos. Cada trabalho procura demonstrar maneiras de salientar características que sejam relevantes para determinadas inquirições patognomônicas, permitindo detectar doenças de forma mais robusta, rápida e eficiente.

Experimentos realizados em [11] apresentam uma comparação do desempenho de três classificadores (discriminante linear, discriminante logístico e rede neural artificial) nos conjuntos de características gerados por diferentes wavelets. O resultado obtido para classificação da hipertrofia ventricular, infarto do miocárdio e ECG normal foi de 71.6 a 74.2% de acerto.

Pesquisas vêm sendo realizadas utilizando a transformada wavelet para identificação de segmentos P-QRS-T [34][49][53] do sinal do ECG. Outros, mais específicos, para detecção apenas de um segmento particular, como a onda P [41], o complexo QRS [28] e o segmento ST [39].

Um estudo desenvolvido em [9] elabora um procedimento baseado na análise de limiar para a escolha da wavelet de base que apresente a melhor correlação com o traçado do ECG. O resultado mostra que para o sinal obtido de diferentes patologias e de diferentes derivações, há sempre uma wavelet de base que melhor representa a informação morfológica que ele carrega.

Inquirições a respeito dos métodos estatísticos como modelos de Markov, sistemas especialistas e métodos de agrupamentos (*clustering*) bem como comparações de desempenho entre os métodos de classificação do ECG por discriminantes lineares, discriminantes logísticos, redes neurais bayseanas, mapas auto-organizáveis e arquiteturas neuro-fuzzy foram elaboradas por Silipo [50] para hipertrofia ventricular e infarto do miocárdio. Os melhores resultados foram obtidos pela combinação de aproximações connexionistas e sistemas neuro-fuzzy, perfazendo em média 95% de acerto.

Os trabalhos apresentados em [12] e [40] efetivam a comparação entre parâmetros escalares [12], wavelets e a densidade espectral de potência (PSD – *Power Spectral Density*) para classificação entre infartos, hipertrofias ventriculares e ECG normal. Uma rede neural multicamadas foi usada para classificação do ECG através dos parâmetros discriminantes obtidos pelos métodos supracitados.

Os resultados obtidos em [12] mostram que as wavelets e a PSD são bons discriminantes entre ECG normal e anormal. O melhor resultado de classificação do ECG (84,4%) foi encontrado com o método de parâmetros escalares e o pior (76,6%) foi obtido com a PSD. Em [40] a classificação entre ECG normal e anormal teve sucesso em 75% dos casos.

A classificação de dez diferentes patologias cardíacas, pela submissão dos coeficientes da decomposição wavelet, e coeficientes discretos de Fourier à rede neural artificial, foi apresentada por Dokur [18], onde o desempenho de classificação obtido foi de 99,4% para wavelet e 92,2% para Fourier. No referido trabalho o autor fez uso de 5 exemplos de ECG contendo, cada exemplo, apenas um período (256 amostras) do sinal para cada patologia estudada.

Uma técnica para distinção entre arritmia ventricular maligna e outras arritmias usando wavelet foi apresentada em [48] na forma de um algoritmo rápido e de baixa complexidade computacional. Segundo o autor, os resultados obtidos foram melhores que aqueles apresentados pelos métodos por ele denominados de tradicionais.

A identificação do flutter atrial pela decomposição wavelet do sinal do ECG foi discutida em [6] obtendo um resultado satisfatório (99,2%), porém, a alta complexidade do algoritmo torna sua computação proibitiva em sistemas não equipados com co-processador.

A referência [3] afirma que o uso de modelos de predição linear (LPC – *Linear Prediction Coefficients*) é inadequado para identificação de características do sinal do ECG, uma vez que eles não discriminam formas de onda com diferentes morfologias, e propõe um modelo de funções ortonormais para isso.

A técnica de aproximação multifractal de tempo curto, associada a uma rede neural *fuzzy* baseada em mapa de Kohonen é usada para detecção de arritmias (fibrilação atrial, fibrilação ventricular e taquicardia ventricular) em [57]. O algoritmo de detecção é computacionalmente rápido perfazendo uma taxa de acerto acima de 97%.

Um exemplo de aplicação usando modelos ocultos de Markov (HMM – *Hidden Markov Model*) para classificação de arritmias foi proposto em [14] resultando na classificação de 93% dos exemplos de ECG normal, 65,55% para arritmia ventricular e 56,38% para taquicardia ventricular.

O uso de análise não linear de componentes principais (LNPCA – *Nonlinear Principal Component Analysis*) para extração de características do ECG foi abordado por [51] para classificação entre o sinal normal e o sinal com anomalias no segmento ST do ECG. O método foi satisfatório para detecção de 80% dos sinais normais e mais de 90% para sinais anormais de pacientes com isquemia.

Acertos de 99,1% para classificação do ECG normal, 98,3% para arritmia ventricular e 91,4% para batimentos de fusão foram obtidos no trabalho de Nadal e Bossan [42] usando os coeficientes da análise de componentes principais (PCA) como entradas para uma rede neural perceptron multicamadas.

Uma comparação entre as redes LVQ e RBF para identificação de bloqueios cardíacos foi apresentada em [36], onde, a modelagem, fez uso das técnicas de predição linear e de análise cepstral para preparação dos sinais cardíacos a serem inseridos na entrada das

redes neurais. Os resultados de classificação para o cepstrum foram, em média, bem superiores a 70%.

A maioria dos trabalhos mencionados nos parágrafos anteriores fez uso do banco de dados de sinais biomédicos do MIT (*Massachusetts Institute of Technology*) [45]. Dessa forma, o presente estudo utiliza a mesma base, obtida pela internet, e que será explicada em momento oportuno.

Objetivando uma contribuição efetiva nas pesquisas em torno da classificação de patologias cardíacas, o presente trabalho traz o estudo de uma técnica que permite diagnosticar de forma satisfatória algumas¹ doenças cardíacas², ou classes de doenças, e, ao mesmo tempo, ser rápido e compacto o suficiente para adaptação em um sistema portátil de processamento.

A técnica apresentada aqui possui vantagens, em relação aos trabalhos pesquisados, basicamente nos seguintes aspectos:

- a) Há boa relação entre “número de amostras do ECG” x “tamanho do conjunto de entrada da RNA”, perfazendo uma boa representação das informações em reduzido conjunto de características. Um menor conjunto de valores para classificação, e que represente bem as características discriminativas, favorece o bom desempenho da etapa de classificação.
- b) O ponto de tomada do trecho do sinal a ser usado na identificação, independe da posição do ciclo periódico (ondas P-QRS-T) descrito pelo ECG.
- c) São usados vários períodos consecutivos do ECG para geração de apenas um conjunto de características para uso na RNA. Isso faz com que a wavelet tome exemplos patológicos que se repetem a cada ciclo consecutivo, garantindo maior robustez da informação lida para identificação, e apresentando resultados de diagnóstico em tempo real.

¹ As que foram possíveis testar, dentro das limitações impostas e apresentadas no capítulo 3.

² Principalmente as arritmias, devido à ocorrência endêmica dessas patologias e à dificuldade de distinção relatada pelos agentes humanos.

- d) O método é adequado para classificação de doenças que apresentem características tempo-frequência díspares em relação às demais moléstias, e também para pré-classificação de doenças que possuem características tempo-frequência semelhantes.
- e) O algoritmo é simples, rápido, robusto e eficiente na identificação das doenças. Dependendo da wavelet usada a taxa de acerto é de 100%.
- f) A técnica efetua a geração dos coeficientes wavelets em valores inteiros, favorecendo o manuseio e ao armazenamento em memória.
- g) A transformação wavelet usada, permite a reconstrução perfeita do sinal do ECG a partir dos coeficientes wavelets inteiros.

As características apresentadas nos itens (b) e (d) representam um importante diferencial para a maioria das técnicas de classificação de padrões do ECG. No que se refere ao item (b), normalmente, o uso de procedimentos para classificação de sinais periódicos faz uso da informação repetitiva contida nos segmentos do sinal a cada ciclo. Sendo assim, ocorre a aplicação dos métodos sempre nos mesmos trechos do período do sinal, o que acarreta na necessidade de localização adequada dos pontos do ciclo cardíaco.

A necessidade de detectar e localizar, no ECG, os pontos que iniciam o ciclo elétrico do coração, introduz não só um aumento no tempo de processamento do sinal, mas também na probabilidade de erro pela aplicação subsequente da técnica de identificação, uma vez que há a possibilidade inerente de erro na técnica de detecção do ciclo cardíaco.

No que tange o item (d), as técnicas estudadas normalmente abordam maneiras de identificar uma única doença ou um conjunto restrito delas. O trabalho aqui proposto permite a classificação das doenças em sua individualidade, quando possível, ou em grupos distintos que apresentem características tempo-frequência semelhantes. Dessa forma, a técnica permite a classificação imediata da doença ou a identificação de um grupo em que ela pertença para, então, ser efetuado um pós-processamento que seja mais específico para a segmentação da patologia do grupo pré-classificado.

A necessidade de prover mobilidade ao sistema é um dos principais motivos do referido estudo. Mais especificamente, no que se refere ao ambiente portátil, optou-se pelo *palmtop* devido às facilidades quanto à: programação, operação pelo médico, aquisição do equipamento e do ambiente de desenvolvimento.

1.2 ESTRUTURA DO TRABALHO

O segundo capítulo dessa pesquisa introduz noções quanto à anatomia e fisiologia cardíaca e aborda a técnica de medição de sinais cardiolétricos na superfície torácica do paciente.

O terceiro capítulo apresenta a metodologia empregada em cada etapa do trabalho. E vem seguido pelo capítulo contendo os resultados dos experimentos e comentários.

O quinto capítulo trata do projeto de engenharia de software do protótipo implementado no palmtop seguido do capítulo de comentários e conclusões da pesquisa.

O APÊNDICE A possui uma introdução à teoria de wavelets e o APÊNDICE B aborda a teoria de redes neurais artificiais. O uso da Transformada Wavelet (WT) na preparação das classes e das Redes Neurais Artificiais (RNA) para classificação dos padrões formados será comentado nesses apêndices.

Um estudo do banco de dados MITDB (*Massachusetts Institute of Technology Data Base*), usado nesse trabalho, é apresentado no APÊNDICE C.

Os APÊNDICES D e E trazem gráficos de treinamento, dados da base MITDB, gráficos de erros e matrizes de confusão resultantes dos treinamentos.

2 O CORAÇÃO

2.1 INTRODUÇÃO

O coração é uma bomba hidrostática que está situada no mediastino médio do corpo humano (FIGURA 2.1).




FIGURA 2.1 – Localização do coração no mediastino médio.

Fonte: Netter, 1978.

O coração é dividido em duas metades, direita e esquerda, por um septo longitudinal orientado obliquamente. Cada metade consiste de uma câmara, chamada átrio, que

recebe o sangue das veias e de outra, chamada ventrículo, que impulsiona o sangue para o interior das artérias (FIGURA 2.2) [23].




FIGURA 2.2 – Câmaras cardíacas.
Fonte: NETTER, 1978.

Dentro do sistema cardiovascular, o átrio direito recebe o sangue venoso (pobre em oxigênio) do corpo humano através das veias cavas. A partir daí o sangue segue do átrio direito para o ventrículo direito e, deste, através do tronco pulmonar, para o pulmão.

No pulmão, o sangue venoso é oxigenado e passa a ser denominado de sangue arterial, que penetra nas veias pulmonares e segue para o átrio esquerdo. Desse átrio o sangue segue para o ventrículo esquerdo ganhando a circulação sistêmica através da artéria aorta.

A FIGURA 2.3 apresenta um esquema do percurso sangüíneo no corpo humano.




FIGURA 2.3 –Fluxo sangüíneo pulmonar e sistêmico no corpo humano.
Fonte: Webster, 1998.

O coração é constituído de fora para dentro pelos tecidos: epicárdio, miocárdio e endocárdio. O epicárdio é o pericárdio visceral que, com seu líquido, lubrifica as superfícies móveis do coração, mantendo-o em posição e evitando sua dilatação, constituindo assim um importante sistema hidrostático. O miocárdio é um conjunto de fibras musculares que se dispõem em camadas e feixes complexos. As camadas musculares atrial e ventricular são separadas e o sistema de condução é a única conexão

muscular. Também contém o esqueleto de tecido conjuntivo que sustenta a musculatura e lhe dá inserção [23].

A espessura da camada miocárdica é proporcional à quantidade de trabalho que executa, dessa forma, os ventrículos possuem paredes mais espessas que os átrios e, mais especificamente, o ventrículo esquerdo é mais de duas vezes mais espesso que o direito devido à pressão na artéria aorta ser maior que no tronco pulmonar. O endocárdio é o revestimento interno endotelial liso [23].

2.2 NOÇÕES QUANTO À IRRIGAÇÃO DO CORAÇÃO

A irrigação cardíaca é feita por duas artérias, ramos da artéria aorta: artéria coronária direita e artéria coronária esquerda. A primeira sai à direita da artéria aorta indo irrigar o átrio e o ventrículo direito e a parte posterior do ventrículo esquerdo. A segunda divide-se em dois grandes ramos: a artéria interventricular anterior e a artéria circunflexa. Essas artérias irrigam o átrio e o ventrículo esquerdo e uma porção considerável da parede anterior do ventrículo direito (FIGURA 2.4).




FIGURA 2.4 – Irrigação cardíaca mostrando as artérias coronárias.
Fonte: NETTER, 1978.

2.3 NOÇÕES QUANTO AO SISTEMA DE CONDUÇÃO

O sistema de condução consiste de fibras musculares, especializadas em conduzir impulsos elétricos, que unem certas regiões de “marcapasso” do coração com as fibras musculares cardíacas (FIGURA 2.6). As contrações rítmicas intrínsecas dessas fibras são reguladas pelos “marcapassos” que, por sua vez, são regulados por impulsos nervosos dos centros vasomotores do tronco encefálico [23].

O sistema de condução do coração adulto (FIGURA 2.5) compreende o nó sino-atrial³ (ou sinusal), o nó átrioventricular e o feixe átrioventricular (ou feixe de Hiss) com seus dois ramos (direito e esquerdo) e os plexos subendocárdicos de fibras de Purkinje [22].




FIGURA 2.5 – Sistema de condução do sinal elétrico no coração humano. (Veja as setas indicadoras do início “I” e fim “F” do percurso).

Fonte: Ganong, 1977.

Em uma situação normal o impulso mioelétrico começa no nó sino-atrial, ativa a musculatura do átrio e é daí conduzido para o nó átrioventricular que propaga o estímulo para o feixe de Hiss, passando pela rede de Purkinje e chegando ao miocárdio ventricular (FIGURA 2.7) [23].

³ É efetivamente o “marcapasso” do coração. No entanto em situações anormais podem surgir focos ectópicos que atuam como “marcapasso” [19].




FIGURA 2.6 – Linhas de condução do sinal elétrico no coração humano.
 Fonte: CCS, 2002.




FIGURA 2.7 – Esquema de condução do sinal elétrico no coração humano.

2.4 NOÇÕES QUANTO À INERVAÇÃO CARDÍACA

O coração é innervado por fibras nervosas autônomas e fibras sensitivas dos nervos vagos e dos troncos simpáticos (FIGURA 2.8). Muitas células ganglionares estão presentes nos átrios, principalmente próximas aos nós e nas vizinhanças das veias e algumas nos ventrículos. Essas células nervosas, principalmente parasimpáticas, ocorrem tanto no epicárdio quanto no miocárdio. Terminações nervosas sensitivas complexas são encontradas especialmente nos átrios próximo aos óstios das veias e nas paredes das grandes veias [23].




FIGURA 2.8 – Diagrama da inervação autônoma eferente do coração humano.
Fonte: Hurst, 1977.

2.5 O CICLO CARDÍACO

A contração do coração é denominada sístole e o seu relaxamento, diástole. Quando os ventrículos estão cheios, eles começam a contrair-se, aumentando a pressão intraventricular, causando o fechamento das válvulas atrioventriculares — as vibrações resultantes desse fechamento são a principal causa da primeira “bulha cardíaca” (FIGURA 2.10) — e fazendo abrir as valvas da aorta e do tronco pulmonar. A mais alta pressão atingida durante essa fase representa a pressão sanguínea sistólica [23].

No final da contração ventricular, e após o fechamento das valvas aórtica e pulmonar — as vibrações resultantes desse fechamento são a principal causa da segunda “bulha cardíaca” —, a musculatura ventricular relaxa-se e a pressão cai a um nível inferior à dos átrios. Abrem-se, então, as valvas atrioventriculares e o sangue flui dos átrios para os ventrículos fazendo com que estes se dilatem à medida que enchem de sangue

(diástole ventricular). Durante esse intervalo os átrios se contraem (sístole atrial) e a pressão nas artérias atinge seu nível mais baixo — pressão arterial diastólica [23].

O ciclo é reiniciado com a contração dos ventrículos. O fluxo sanguíneo segue um percurso em sentido único pelas cavidades cardíacas (FIGURA 2.3) garantido por esse sistema de válvulas presente nessas câmaras (FIGURA 2.9) e que atuam de forma síncrona com os movimentos do coração [23].

As valvas atrioventriculares impedem o refluxo de sangue do ventrículo para o átrio durante a sístole ventricular. A valva tricúspide separa o átrio direito do ventrículo direito, enquanto a valva bicúspide divide o átrio esquerdo do ventrículo esquerdo.

As valvas sigmóides impedem o refluxo de sangue das artérias para o ventrículo durante a diástole ventricular. A valva pulmonar separa o tronco pulmonar do ventrículo direito, enquanto a valva aórtica separa a artéria aorta do ventrículo esquerdo.




FIGURA 2.9 – Válvulas cardíacas humanas.

Fonte: Hurst, 1977.

A FIGURA 2.10 apresenta a correlação entre os quatro sons cardíacos (fechamento e abertura das válvulas) com os eventos mecânicos (pressão e movimento das válvulas) e elétricos (ECG) do coração durante o ciclo cardíaco [59].




FIGURA 2.10 – Correlação entre sons, eventos mecânicos e elétricos do coração humano.
Fonte: Webster, 1998.

2.6 ELETROCARDIOGRAFIA

As atividades elétricas periféricas do corpo humano têm sua origem basicamente nos fenômenos bioelétricos de origem celular. Esses fenômenos são produzidos como resultado das atividades eletroquímicas de certas classes de células, conhecidas como células excitáveis, que são as que compõem os nervos, músculos e o tecido glandular.

A eletrocardiografia trata da tarefa de coletar e exibir graficamente os fenômenos bioelétricos gerados pelas células do coração humano.

2.6.1 BIOPOTENCIAIS

Eletricamente essas células exibem um potencial de repouso e, quando apropriadamente estimuladas, um potencial de ação. Esse potencial é medido entre os ambientes interno e externo da célula e varia, quando em repouso, de -50 mV a -100 mV em relação à média no ambiente externo [59].

A membrana celular é constituída de um complexo lipoprotéico que é essencialmente impermeável para uma série de compostos químicos e é apenas ligeiramente permeável para Na^+ e bastante permeável para K^+ e Cl^- . Assim, a força de difusão osmótica atua sobre a membrana de maneira oposta à força elétrica mantendo um estado de equilíbrio. A diferença de concentração desses íons em torno da membrana celular faz com que a membrana funcione como um capacitor mal vedado [59], e a diferença de potencial elétrico medida nessa situação é denominada de potencial de equilíbrio.

Uma propriedade importante das células excitáveis é a habilidade de conduzir um potencial de ação sobre estímulo adequado. Quando a célula está em estado de repouso, dizemos que sua membrana está polarizada. Uma célula polarizada pode sofrer um estímulo adequado capaz de romper o limiar de polarização e produzir um potencial de ação que se propaga para as células vizinhas. A célula, nessa situação, é dita estar despolarizada e o comportamento descrito define a lei do tudo-ou-nada amplamente citada no estudo neurológico.




FIGURA 2.11 – (a) Distribuição das cargas em torno de uma fibra em condução. (b) Fluxo de corrente na mesma fibra.

Fonte: Webster, 1998.

A FIGURA 2.11 apresenta a distribuição das cargas elétricas na vizinhança da região ativa em uma fibra muscular conduzindo um impulso elétrico de ação [59].

Após a propagação do potencial de ação, a célula se repolariza estabelecendo novamente o potencial de equilíbrio. A FIGURA 2.12 apresenta o modelo elétrico equivalente de uma fibra muscular, onde: C_m é a capacitância da membrana; g e E são as condutâncias e potenciais da membrana, respectivamente; r_i e r_o são as resistências dos meios interno e externo respectivamente; i_m é a corrente trans-membrana; v^i e v^o são os potenciais interno e externo no ponto z , respectivamente; Na, K e L são íons sódio e potássio e a camada lipoprotéica, respectivamente; e, por fim, Δz é o comprimento linear em torno do ponto z [59].




FIGURA 2.12 – Circuito equivalente de uma fibra muscular esquelética.
Fonte: Webster, 1998.

O problema fundamental em eletrofisiologia é o do modelamento dos campos condutores de volume, e consiste em duas partes: (1) o da fonte bioelétrica (2) e sua carga elétrica [59].

A fonte bioelétrica é a própria atividade celular, que é modelada eletricamente por uma fonte de corrente aproximadamente constante, entregando elétrons a uma grande variedade de condições de carga [59].

No caso da eletrocardiografia, o coração é visto como um gerador elétrico equivalente e, a região torácica média, pode ser considerada a carga resistiva desse gerador equivalente (FIGURA 2.13).




FIGURA 2.13 – Equivalente elétrico do problema eletrocardiográfico. R_{T1} e R_{T2} representam as resistências inerentes ao equipamento de medição; R_{AB} é a resistência equivalente medida entre as tomadas A e B do corpo humano; e Φ_A , Φ_B , Φ_{AB} representam os potenciais em A, em B e entre A e B, respectivamente.

Fonte: Webster, 1998.

O coração é composto por uma variedade de tecidos contendo células eletricamente excitáveis que diferem consideravelmente quanto à forma com que apresentam o potencial de ação (FIGURA 2.14).




FIGURA 2.14 – Atividade elétrica representativa de cada região do coração.

Fonte: Webster, 1998.

A excitação elétrica produz potenciais de ação que se propagam ao longo da estrutura do coração na forma de superfícies isócronas (excitadas de forma síncrona – FIGURA 2.15) da região do miocárdio (externa) para o endocárdio (interna) [59]. Isso ocorre devido ao alto grau de interação elétrica entre as células da estrutura eletromotiva.




FIGURA 2.15 – Linha isócrona de ativação ventricular do coração humano.

Fonte: Webster, 1998.

2.6.2 ELETROCARDIOGRAFO

O eletrocardiógrafo (FIGURA 2.16) é o equipamento responsável pela captura, tratamento e registro, no eletrocardiograma, do sinal elétrico medido na superfície do corpo humano.




FIGURA 2.16 - Eletrocardiógrafos. (a) Portátil para uso com microcomputador. (b) Modelo fixo para uso com microcomputador.

Fonte: TEB, 2002.

A captação dos sinais bioelétricos é feita através de eletrodos de metal acoplados à pele por um gel condutor. Os eletrodos enviam o sinal bio-elétrico ao longo de fios até a entrada dos amplificadores isoladores que farão a amplificação do sinal, além de também garantir o isolamento de proteção do paciente.

Os eletrocardiogramas utilizam um modelo simples para representar a atividade elétrica no coração. Esse modelo consiste em um dipolo elétrico, localizado no tórax, que informa a atividade elétrica em um determinado instante. No entanto, é necessário conhecer o local onde os sinais são detectados, suas amplitudes e dependências no tempo.

As posições do corpo onde são tomados os sinais são conhecidas como derivações. Elas podem ser subdivididas em três grupos: derivações clássicas (ou bipolares ou de Einthoven), derivações unipolares dos membros (ou de Goldberger) e derivações precordiais de Wilson.

No modelo vetorial, que representa a propagação do estímulo elétrico no coração, o momento dipolo é conhecido como vetor cardíaco (M) e as derivações normalmente usadas estabelecem a avaliação elétrica do plano frontal do tórax, conhecido como triângulo de Einthoven [59]. A FIGURA 2.17 mostra onde são tomados os sinais para compor o ECG.

A derivação de Einthoven é bipolar, pois o que se mede é a diferença de potencial entre cada duas derivações [33].

A lei de Einthoven estabelece que a soma vetorial de um acidente eletrocardiográfico em I e III é igual a II. Essa lei é uma modificação da lei de Kirchhoff para circuitos elétricos [33].




FIGURA 2.17 – Derivações do plano frontal e triângulo de Einthoven.
Fonte: Webster, 1998.

A derivação RL (*Right Leg*) é normalmente aterrada ou conectada a um circuito especial (FIGURA 2.18). As derivações LL (*Left Leg*), RA (*Right Arm*) e LA (*Left Arm*) são conectadas aos eletrodos que levam o sinal elétrico aos amplificadores isoladores.

Nas derivações unipolares, a queda de tensão medida em cada derivação ao longo do tempo, tomado em relação ao terminal central Wilson, é usada para calcular a direção e o módulo do dipolo em cada instante (FIGURA 2.19) [59].




FIGURA 2.18 – Modelo elétrico equivalente.
Fonte: Webster, 1998.




FIGURA 2.19 – Mapeamento do vetor cardíaco.
Fonte: Webster, 1998.

As derivações precordiais (V_1 a V_6) permitem o mapeamento elétrico no plano transverso. O dipolo é calculado a partir das tensões medidas entre as derivações e o terminal central Wilson (FIGURA 2.20).




FIGURA 2.20 – Derivações precordiais.

Fonte: Webster, 1998.

A FIGURA 2.21 apresenta o circuito de um amplificador eletrocardiográfico para cada derivação. Observa-se na entrada um amplificador de instrumentação com alta impedância de entrada e alta rejeição de modo comum [59].

As entradas são v_A e v_B que são conectadas conforme os tipos de derivações utilizadas. Por exemplo, em derivações unipolares, v_B pode ser conectado ao terminal central Wilson e v_A a um dos pontos RA, LA ou LL como mostrado na FIGURA 2.18.




FIGURA 2.21 – Amplificador ECG para uma derivação.

Fonte: Webster, 1998.

Os amplificadores de biopotenciais devem possuir certos requerimentos considerados básicos [59]:

- Circuitos de proteção ao paciente.
- Alta impedância de entrada ($\geq 10 \text{ M}\Omega$).
- Baixa impedância de saída.
- Alto ganho (≥ 1000).
- Rápida calibração.
- Operação apenas na porção do espectro de frequência em que o biopotencial reside.
- Circuito de entrada baseado em amplificadores diferenciais.

2.6.2.1 Ruídos Associados aos Sinais Bioelétricos

Durante a captação dos sinais bioelétricos pelo eletrocardiógrafo pode ocorrer o aparecimento de sinais indesejados, denominados de ruídos ou artefatos, provenientes de diversas situações. Dentre as quais pode-se destacar:

INTERFERÊNCIA DA REDE ELÉTRICA

Consiste em um sinal senoidal com frequência em torno de 60 Hz ou 50 Hz, dependendo da fonte geradora, e é causado pela indução eletromagnética do condutor, ou por efeito eletrostático (FIGURA 2.22).




FIGURA 2.22 – Sinal do ECG com artefatos da rede elétrica.

Fonte: Widrow, 1975.

ARTEFATOS DE MOVIMENTO

São causados por vibrações ou mudanças na interface eletrodo-pele devido ao movimento do paciente. No ECG isso acarreta mudanças de transiente na linha de base do sinal. Tanto a amplitude quanto a duração dos artefatos são variáveis.

RUIDO DE CONTATO DO ELETRODO

A perda de contato do eletrodo com a pele pode se dar de maneira permanente ou intermitente. Essa ação de chaveamento na entrada do sistema pode resultar em grandes artefatos, uma vez que o sinal do ECG normalmente é acoplado capacitivamente ao sistema. Assim, com a entrada do amplificador desconectada, a interferência de 60 Hz pode se tornar significativa [5].

RUIDO INERENTE DE EQUIPAMENTOS NO CORPO DO PACIENTE

Equipamentos em contato com o corpo do paciente podem introduzir sinais indesejáveis na leitura do eletrocardiógrafo. O bisturi elétrico é capaz de destruir completamente o sinal do ECG [5].

RUÍDO ELETROMIOGRÁFICO

São aqueles causados pelas contrações musculares do paciente, geralmente são artefatos da ordem de milivolts [5].

2.6.3 DOENÇAS DETECTADAS PELA ANÁLISE DO ECG E DISPONÍVEIS NO MITDB

As doenças detectáveis pela análise do ECG são aquelas que ocasionam alterações na eletrofisiologia cardíaca. Logo, o predomínio da perturbação gerada no sinal elétrico irá influenciar, de alguma forma, a morfologia do sinal medido pelo eletrocardiograma.

2.6.3.1 Taquicardia Ventricular

A taquicardia ventricular (FIGURA 2.23) é uma arritmia originada pela salva de mais de quatro ESV (Extra-sístole Ventricular). A ESV (FIGURA 2.24) se origina de um ou mais focos ectópicos nos ventrículos que provocam uma contração ventricular

prematura geralmente antes do momento em que se espera uma onda P. Essa contração introduz uma frequência ventricular de 150 a 250 batimentos por minuto e embora as aurículas ainda despolarizem regularmente com frequência própria, geralmente não se observam ondas P distintas.




FIGURA 2.23 – Taquicardia Ventricular.
Fonte: Physionet, 2002.




FIGURA 2.24 – Extra Sístole Ventricular.
Fonte: Dubin, 1996.

Quando uma despolarização auricular, de origem superior (nódulo SA) estimula o nódulo AV durante uma taquicardia ventricular – o que ocorre muito pouco – o impulso começa a seguir a via normal do Tronco e dos ramos do Feixe de Hiss. Isso resulta num complexo QRS de aparência quase normal – ou pelo menos no começo de um QRS.

Essa porção do QRS se funde com um complexo do tipo ESV proveniente do foco ectópico criando um “batimento de fusão”. Vez por outra um impulso de origem superior caminha até o fim para captar um QRS, criando um “batimento de captura” (FIGURAS 2.25 e 2.26). A presença de “capturas” e “fusões” confirma o diagnóstico de Taquicardia Ventricular.




FIGURA 2.25 – Capturas e Fusões.
Fonte: Dubin, 1996.




FIGURA 2.26 – Capturas e Fusões.
Fonte: Physionet, 2002.

2.6.3.2 Arritmia Supraventricular

As arritmias supraventriculares (FIGURAS 2.27 e 2.28) englobam a classe de arritmias cuja origem procede das regiões acima dos ventrículos. Nessa categoria classificam-se: Fenômeno de Wenckebach, Arritmias Auriculares (Extra-sístole, Escape, Fibrilação, Flutter, Taquicardia...), Marca-passo Migratório, etc.




FIGURA 2.27 – Arritmia Supraventricular.
Fonte: Physionet, 2002.




FIGURA 2.28 – Extra-sístole Auricular.
Fonte: Physionet, 2002.

2.6.3.3 Fibrilação Atrial

É causada pela descarga de focos auriculares múltiplos (FIGURA 2.29). Não há impulso único que despolarize as aurículas de maneira completa e, somente de forma aleatória, um impulso estimula o nódulo AV iniciando um complexo QRS. Não é possível

encontrar ondas P “verdadeiras” e as respostas ventriculares irregulares podem gerar um ritmo rápido ou lento.




FIGURA 2.29 – Fibrilação Auricular.
Fonte: Dubin, 1996.

2.6.3.4 Fibrilação Ventricular

É um tipo de parada cardíaca produzida por estímulos de muitos focos ventriculares ectópicos (FIGURA 2.30(a)) causando uma contração aleatória e irregular dos ventrículos. Não há bombeamento cardíaco efetivo.

Identifica-se facilmente a fibrilação ventricular no traçado do ECG (FIGURA 2.30(b)) pelo seu aspecto totalmente irregular, que é normalmente denominado de “movimento vermicular”. Não há padrão característico dessa fibrilação e ela assume formas diferentes a cada momento.

Havendo alguma repetição de padrão ou regularidade das deflexões (periodicidade), provavelmente não se trata da fibrilação ventricular.




FIGURA 2.30 – Fibrilação Ventricular. (a) Múltiplos Focos Ectóticos. (b) ECG caótico.
Fonte: Dubin, 1996.

2.6.3.5 *Flutter Atrial*

O “flutter” auricular (FIGURA 2.31) se origina de um único foco auricular ectópico disparando a uma frequência de 250 a 350 batimentos por minuto. As ondas P ocorrem em sucessão rápida, uma após a outra, e são todas idênticas. A linha de base se assemelha a um “dente de serra”. Um estímulo auricular ocasional sensibiliza o nóculo AV iniciando um complexo QRS.




FIGURA 2.31 – Flutter Auricular.
Fonte: Dubin, 1996.

2.6.3.6 *Flutter Ventricular*

O “flutter” ventricular é produzido por um único foco ventricular ectópico (FIGURA 2.32(a)) disparando a uma frequência de 200 a 300 batimentos por minuto (3.3 a 5 Hz) e que evolui invariavelmente para fibrilação ventricular (FIGURA 2.32(b)).

No ECG observa-se o aspecto sinusóide uniforme do sinal.




FIGURA 2.32 – Flutter Ventricular. (a) Foco gerador. (b) Evolução para fibrilação.
Fonte: Dubin, 1996.

2.6.3.7 Batimentos de Escape

Os batimentos de escape surgem quando o marca-passo normal (Nódulo SA) não consegue produzir estímulo durante um ou mais ciclos – pausa de silêncio elétrico –, logo, ocorre a descarga de um foco ectópico “impaciente”.

Quando um foco auricular ectópico descarrega após uma pausa de silêncio elétrico é, então, chamado de escape auricular (FIGURA 2.33) e a onda P originada é diferente das demais.




FIGURA 2.33 – Escape Auricular
Fonte: Dubin, 1996.

Quando o batimento de escape se origina do nódulo AV, ele é denominado escape nodal (FIGURA 2.34) e observa-se a ausência da onda P.




FIGURA 2.34 – Escape Nodal.
Fonte: Dubin, 1996.

Os batimentos de escape ventricular (FIGURA 2.35) se originam num foco ventricular ectópico e a resposta observada no sinal do ECG é do tipo ESV (Extra-sístole Ventricular), após uma pausa no ritmo.




FIGURA 2.35 – Escape Ventricular
Fonte: Dubin, 1996.

2.6.3.8 Geminismo

É a denominação que se dá ao traçado do ECG quando as ESV (Extra-sístoles Ventriculares) coincidem com um (bigeminismo) ou mais batimentos normais (FIGURA 2.36).




FIGURA 2.36 – Geminismos
Fonte: Dubin, 1996.

2.6.3.9 Bradicardia Sinusal

A bradicardia sinusal é a ocorrência de frequência cardíaca inferior a 60 batimentos por minuto originada no nódulo SA com ritmo normal. As ondas dos complexos P-QRS-T permanecem bem próximas, havendo o distanciamento apenas entre as ocorrências desse complexo.

2.6.3.10 Fenômeno de Wenckebach

O fenômeno de Wenckebach (FIGURA 2.37) ocorre quando o intervalo P-R se torna progressivamente maior até que o nódulo AV não seja mais estimulado. A onda P e o complexo QRS se alongam cada vez mais nos ciclos sucessivos até que a última onda P fica sozinha não ocorrendo o complexo QRS.




FIGURA 2.37 – Fenômeno de Wenckebach.
Fonte: Dubin, 1996.

2.6.3.11 Marca-Passo Migratório

O marca-passo migratório (FIGURA 2.38) é um ritmo variável causado pela mudança de posição do comando entre vários focos ectópicos caracterizando ondas P de forma variável.




FIGURA 2.38 – Marca-passo Migratório.
Fonte: Dubin, 1996.

2.6.3.12 Episódios ST, QT e Onda T

As alterações de forma nos segmentos ST, QT e na onda T (FIGURAS 2.39 A 2.42) caracterizam diversos fatores patológicos como: isquemia, infarto, sobrecarga ventricular, distúrbios químicos, inflamações...

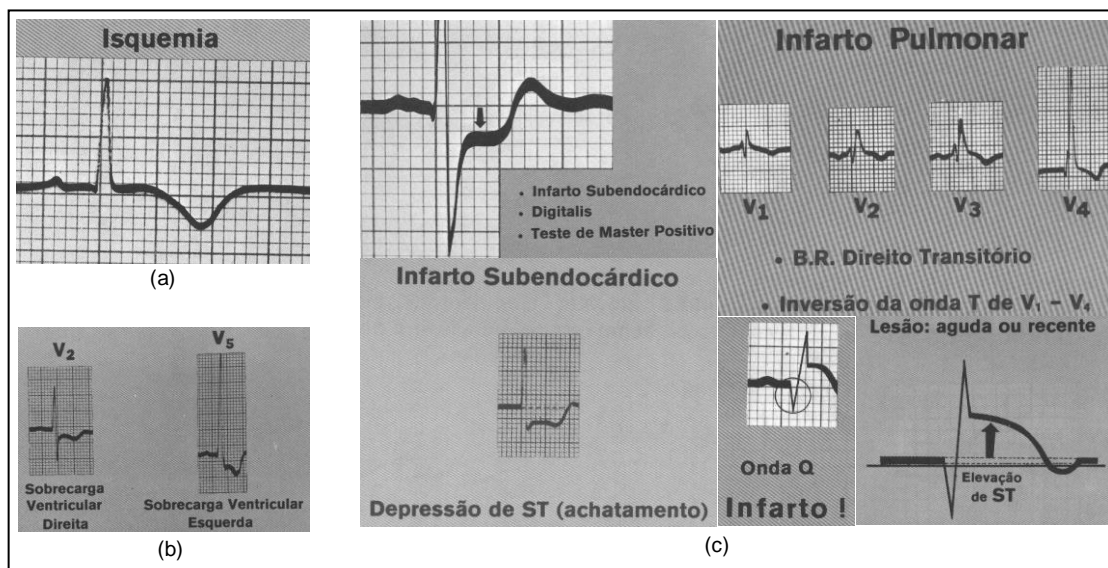


FIGURA 2.39 – Alterações nos segmentos ST, QT e onda T. (a) Isquemia. (b) Sobrecarga. (c) Infarto.
Fonte: Dubin, 1996.

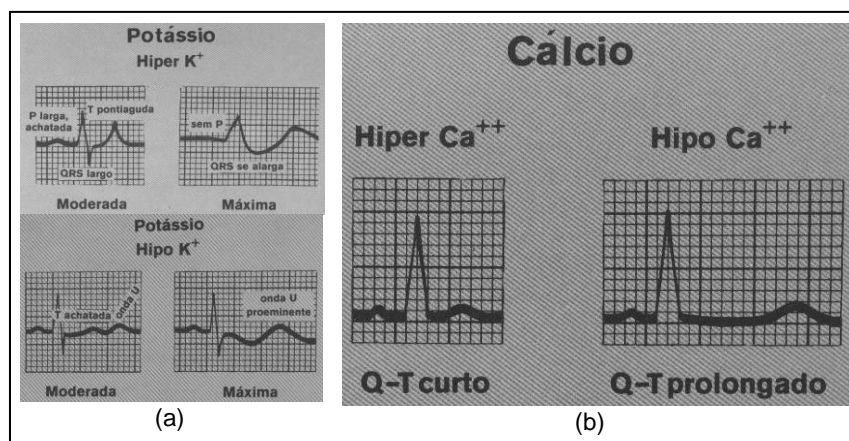


FIGURA 2.40 – Alterações nos segmentos ST, QT e onda T por distúrbio químico. (a) Potássio. (b) Cálcio.
Fonte: Dubin, 1996.




FIGURA 2.41 – Inflamações.
Fonte: Dubin, 1996.




FIGURA 2.42 – Ondas Q Patológicas.
Fonte: Dubin, 1996.

3 METODOLOGIA

3.1 INTRODUÇÃO

Diagnóstico é definido como o conhecimento ou a determinação de uma doença pelos sintomas, sinais e/ou mediante exames diversos. No presente contexto, a diagnose refere-se essencialmente à determinação de doenças mediante análise de sinais, especificamente, do eletrocardiograma (ECG).

O problema consiste no desenvolvimento de um sistema em software para classificação de algumas doenças cardíacas, ou grupos de doenças, a partir da análise do sinal do ECG. Não obstante, a classificação deve se proceder de forma rápida, robusta, de fácil manuseio e boa mobilidade.

3.2 ESTUDOS DESENVOLVIDOS

Na apresentação desta dissertação foram mencionadas diversas pesquisas que vêm sendo desenvolvidas com intuito de melhorar a eficiência e a segurança das análises humanas sobre o sinal do ECG. Cada trabalho procura demonstrar maneiras de salientar características que sejam relevantes para determinadas inquirições patognomônicas, permitindo detectar doenças de forma mais robusta, rápida e eficiente.

Objetivando uma contribuição efetiva nas pesquisas em torno desse tema, o presente trabalho traz o estudo de uma técnica que permite diagnosticar, de forma satisfatória, algumas doenças cardíacas e, ao mesmo tempo, ser rápido e compacto o suficiente para adaptação em um sistema portátil de processamento.

3.2.1 Organização do Banco de Dados

O APÊNDICE C traz a descrição dos arquivos de doenças cardíacas obtidas do banco de dados do MIT (MITDB) [45], enquanto o capítulo 2 apresenta o comportamento do ECG para diferentes doenças encontradas no banco de dados.

As limitações observadas na análise dos arquivos de sinais do MITDB permitiram a segregação de algumas doenças para aplicação da técnica estudada. As restrições fundamentam-se na escolha de arquivos de sinais que:

- Possuam amostras obtidas nas mesmas posições (derivações) do corpo humano em diferentes pacientes.
- Possuam anotações médicas indicadoras das amostras de início e fim da ocorrência de determinada doença.
- Possuam duas derivações simultâneas do mesmo paciente.
- Tenham interesse médico proeminente observando-se a endemia existente e a sutileza da detecção.

As doenças definidas como: taquicardia ventricular (VT), flutter ventricular (VFL), fibrilação auricular (AFIB) e flutter auricular (AFL), além do ECG normal, satisfazem todos os requisitos apontados nos itens acima.

Conjuntos de amostras foram formados, para cada doença e ECG normal, a partir de diferentes pacientes. Cada conjunto contendo blocos de 1024 amostras normalizadas obtidas a uma taxa de 250 amostras por segundo. O capítulo 4 apresenta detalhadamente esses conjuntos.

As TABELAS 3.1 e 3.2 apresentam os arquivos e as respectivas posições de onde foram retiradas as amostras das doenças citadas acima.

A FIGURA 3.1 mostra o traçado do ECG para cada doença selecionada e ECG normal, tomados na derivação “*signal_I*”, definida pelo MITDB. Observa-se a necessidade de extração, em múltiplas escalas, das informações em frequência contidas em diferentes intervalos de tempo do sinal.

A escolha do tamanho do bloco se justifica pela utilização do algoritmo de análise tempo-frequência, no caso wavelets, selecionada pela inspeção da morfologia do ECG (FIGURA 3.1).

TABELA 3.1 - MALIGNANT_VA – $f_s = 250$ Hz								
ARQUIVO	VT		AFIB		AFL		VFL	
	INICIO	TAM	INICIO	TAM	INICIO	TAM	INICIO	TAM
418							99624	1875
							133092	946
							135775	853
							153057	1058
							154942	1349
							159442	1074
							169192	615
							173054	619
							174788	615
							176259	1609
							190080	1169
							191807	888
							195631	1163
							200211	423
							216788	2250
							219961	4058
							225355	702
							227211	2058
419							10201	1125
							144330	18458
							229923	8865
							345211	9615
							423830	1112
							487737	1224
420	357538	40154						
	398673	3442						
	404653	26923						
423			376557	1866				
			387442	1077				
609			25	255250				
615	81711	1000	38	81673				
	126961	1250	82711	44250				
	151346	4250	128211	23135				
	278538	981	155596	122942				
	503384	1250	279519	223865				

TABELA 3.2 - The MIT-BIH Atrial Fibrillation Database – $f_s = 250$ Hz								
ARQUIVO	VT		AFIB		AFL		VFL	
	INICIO	TAM	INICIO	TAM	INICIO	TAM	INICIO	TAM
04043					7669199	3225		
04908					3562785	2517		
					3619440	55500		

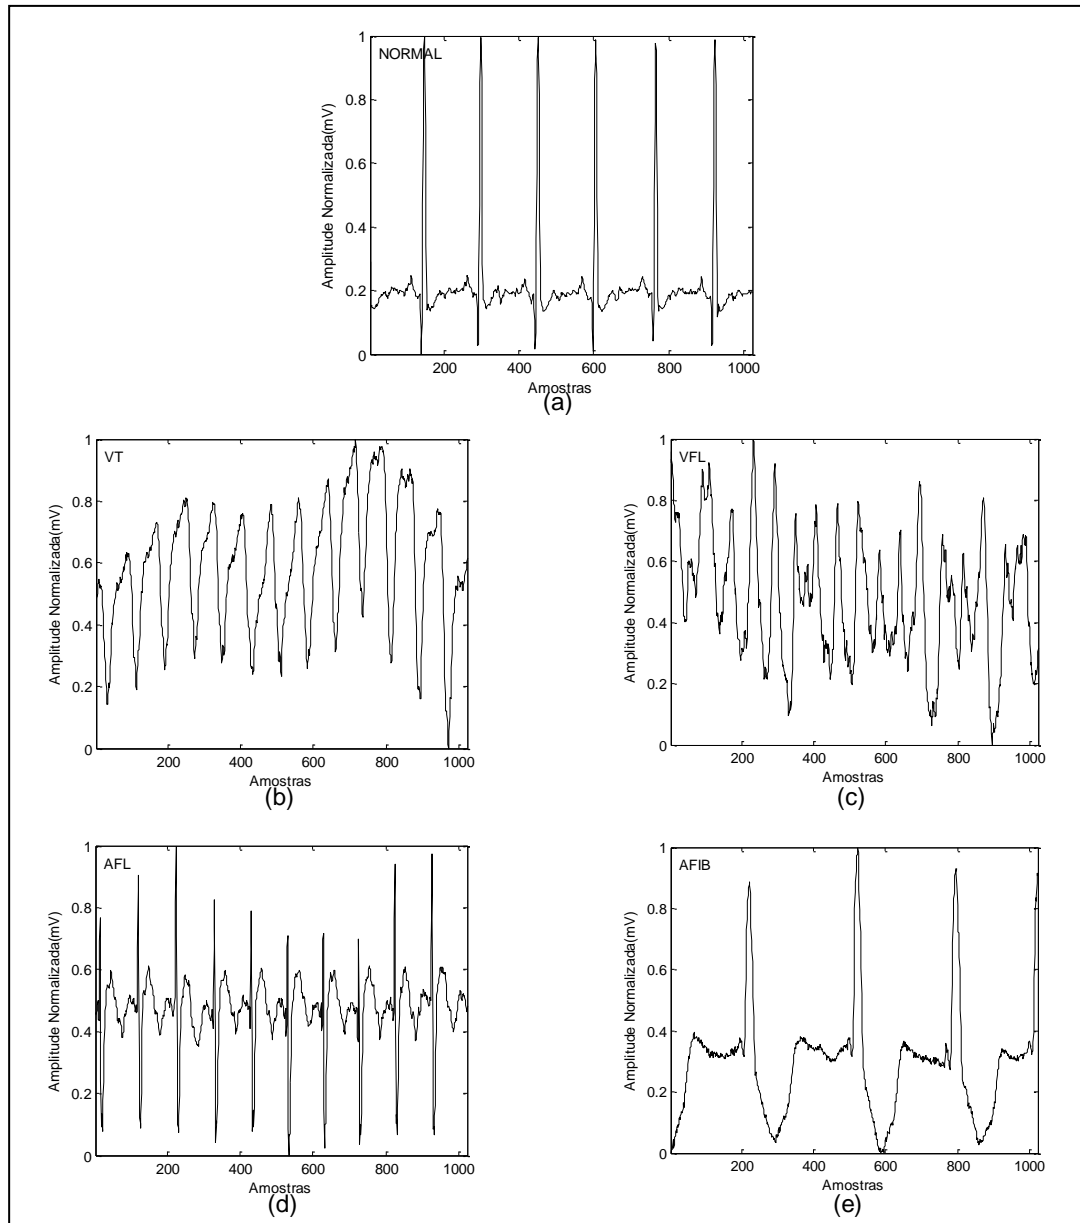


FIGURA 3.1 – Traçado do ECG com 1024 amostras da derivação *signal_I* para: (a) ECG Normal, (b) Taquicardia Ventricular, (c) Flutter Ventricular, (d) Flutter Auricular, (e) Fibrilação Auricular

3.2.2 Transformada Wavelet

Para a decomposição wavelet de primeira geração foram escolhidas duas bases: a symlet 4 (FIGURA 3.2-b) e a Daubechies 4 (FIGURA 3.2-a). A primeira em função dos estudos desenvolvidos por [9] utilizando wavelet mãe ótima para ECG normal. A segunda para vias de comparação com a transformada wavelet de segunda geração (*lifting*), também implementada usando o filtro de Daubechies 4.

Observa-se, no entanto, que a escolha da base Daubechies 4 se deve basicamente a dois fatores: semelhança morfológica com a symlet 4 e ampla utilização e discussão nas wavelets de segunda geração.

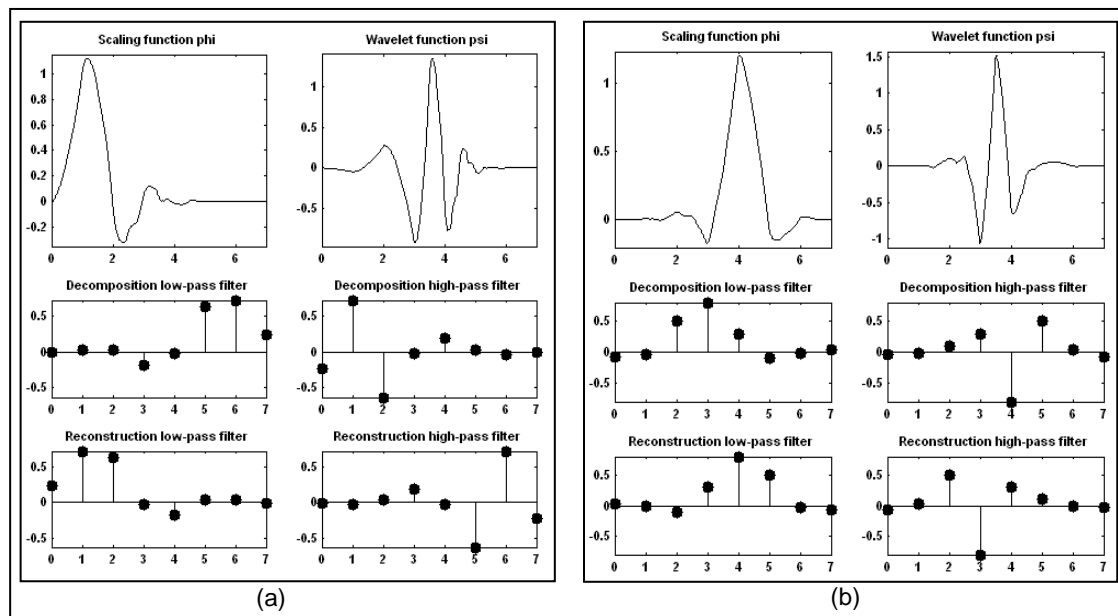


FIGURA 3.2 – Base wavelet, função de escala e coeficientes dos filtros. (a) daubechies 4 (b) symlet 4
Fonte: MathWorks, 2000.

A escolha da wavelet mãe ótima usa como referência o ECG de pacientes normais [9]. Sinais patológicos apresentam-se morfológicamente distintos quando confrontados com a forma do ECG normal e com a forma das demais doenças detectadas pelo ECG. A disparidade entre um sinal qualquer do ECG em relação ao sinal normal já caracteriza a ocorrência de anomalia a ser determinada.

Pode-se questionar então que, mesmo sendo a symlet 4 (FIGURA 3.2-b) uma base ótima [9] para uso na classificação entre ECG normal (FIGURA 3.1-a) e ECG anormal (FIGURA 3.1-b,c,d,e), a base não seria ótima para uso entre doenças ou classes de doenças. De fato, cada patologia observada terá uma base ótima que poderá ser a mesma, entre duas ou mais doenças, mas que certamente não será para todas [9]. Contudo, o que se espera é que, mesmo não sendo a base ótima para uso na classificação das doenças pesquisadas, a mesma seja adequada para representar de forma eficiente cada doença ou classe de doença abordada neste trabalho.

Para a decomposição wavelet de segunda geração foram escolhidas as bases de Haar (FIGURA 3.3) e Daubechies 4. A primeira para verificação da eficiência da classificação, uma vez que um dos méritos da *lifting* é a simplicidade e, portanto, a base de Haar é a mais simples das implementações dessa transformada de segunda geração. A segunda base foi escolhida para comparação com a Daubechies 4 de primeira geração, conforme comentado em parágrafos anteriores.

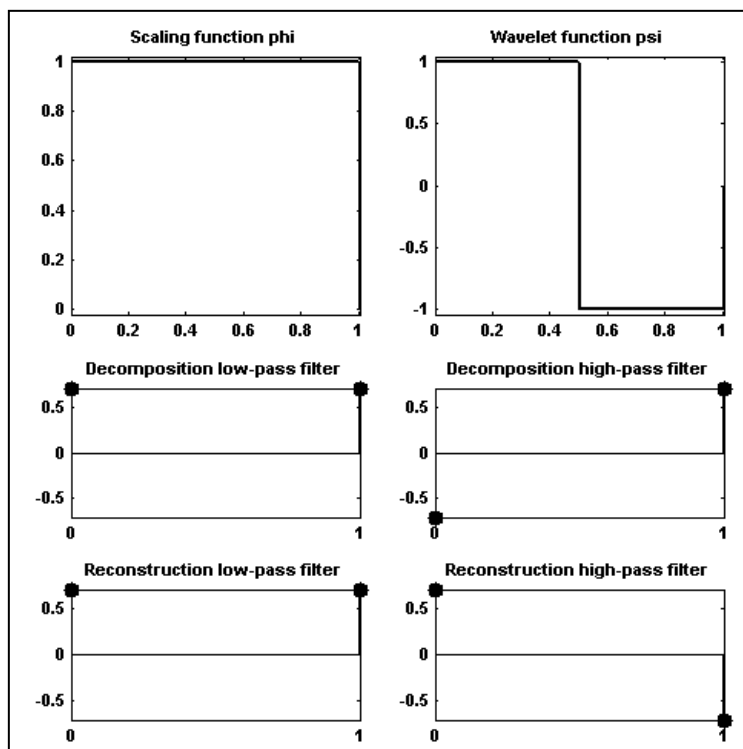


FIGURA 3.3 – Base wavelet, função de escala e coeficientes dos filtros Haar.

Fonte: MathWorks, 2000.

No experimento utilizando as wavelet de primeira geração, cada bloco de 1024 amostras foi decomposto em oito níveis de escala (FIGURA 3.4). Cada nível apresentando resolução em frequência dada pela equação (A.8) conforme TABELA 3.3. As colunas **A** e **D** representam os coeficientes de aproximação e de detalhe de cada nível **n** respectivamente.

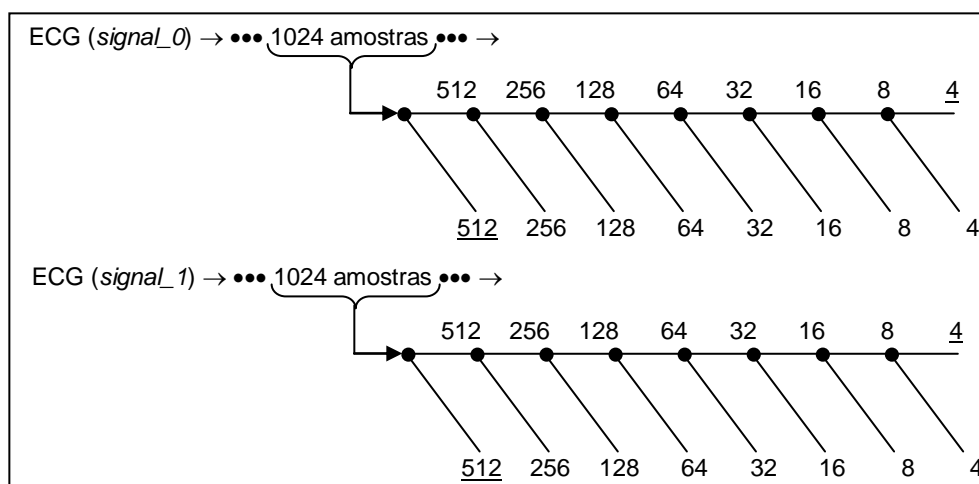


FIGURA 3.4 – Número de amostras em cada nível da decomposição wavelet. As amostras dos oito níveis foram geradas pela transformada discreta de primeira geração, aplicada em 1024 amostras, de cada derivação, coletadas simultaneamente de um paciente. As amostras com grifo são descartadas.

TABELA 3.3 – Faixas de Frequência (Hz)		
NÍVEL (n)	A(n)	D(n)
1	≤ 62.5	$> \underline{62.5}$
2	≤ 31.25	(31.25, 62.5]
3	≤ 15.63	(15.63, 31.25]
4	≤ 7.82	(7.82, 15.63]
5	≤ 3.91	(3.91, 7.82]
6	≤ 1.95	(1.95, 3.91]
7	≤ 0.98	(0.98, 1.95]
8	$\leq \underline{0.49}$	(0.49, 0.98]

Observando-se a TABELA 3.3, a decomposição em oito níveis se faz procedente uma vez que as informações patológicas, contidas no ECG, apresentam-se na faixa de 0.5 Hz a 40 Hz [12]. Conseqüentemente, os coeficientes de detalhe do primeiro nível e os coeficientes de aproximação do oitavo nível podem ser descartados por não possuírem informações concernentes. Testes preliminares constataram que, de fato, a informação desses níveis é irrelevante para a classificação das doenças.

No experimento utilizando as wavelets de segunda geração a decomposição é processada concomitantemente, amostra por amostra, até o oitavo nível. Os coeficientes indesejados são descartados da mesma forma, no primeiro e no oitavo nível.

O esquema da transformada *lifting* é semelhante ao apresentado na FIGURA 3.4, diferindo apenas no momento em que ocorre a transformação: nas wavelets de primeira

geração, ao totalizar 1024 amostras no *buffer*, a transformada é efetuada; nas wavelets de segunda geração, a transformação é efetuada a cada amostra. Um contador informa quando 1024 amostras foram processadas, indicando o momento de preparar os coeficientes para submissão à RNA.

No intuito de reduzir o conjunto de amostras representativas da informação patognomônica, simplificando o processo de classificação, sem ao menos distorcer significativamente os dados, optou-se pela caracterização dos níveis através da energia dos coeficientes da decomposição wavelet — aqui referida simplesmente como a energia —, contida nos respectivos níveis de transformação, para compor os vetores de características (FIGURA 3.5).




FIGURA 3.5 – Coeficientes da Decomposição Wavelet em 8 níveis do sinal do ECG Normal e as energias dos respectivos níveis. O sinal foi obtido da base de dados do MIT e processado no MATLAB.

A obtenção dos vetores de energia se processa pela aplicação da seguinte equação (3.1):

$$E_i = \frac{\sqrt{\sum_{k=1}^{N_i} c_k^2}}{N_i} \quad (3.1)$$

onde, c_k é o coeficiente da posição k do vetor de coeficientes do nível i , da decomposição wavelet, contendo N_i elementos. E_i é o valor da energia no nível i correspondente (FIGURA 3.5).

A observação das energias, em diferentes níveis de decomposição nas diferentes doenças analisadas, mostra como tal representação conserva o caráter discriminatório dos dados, permitindo a classificação das doenças apenas pela análise dos vetores de energia formados (FIGURA 3.6).

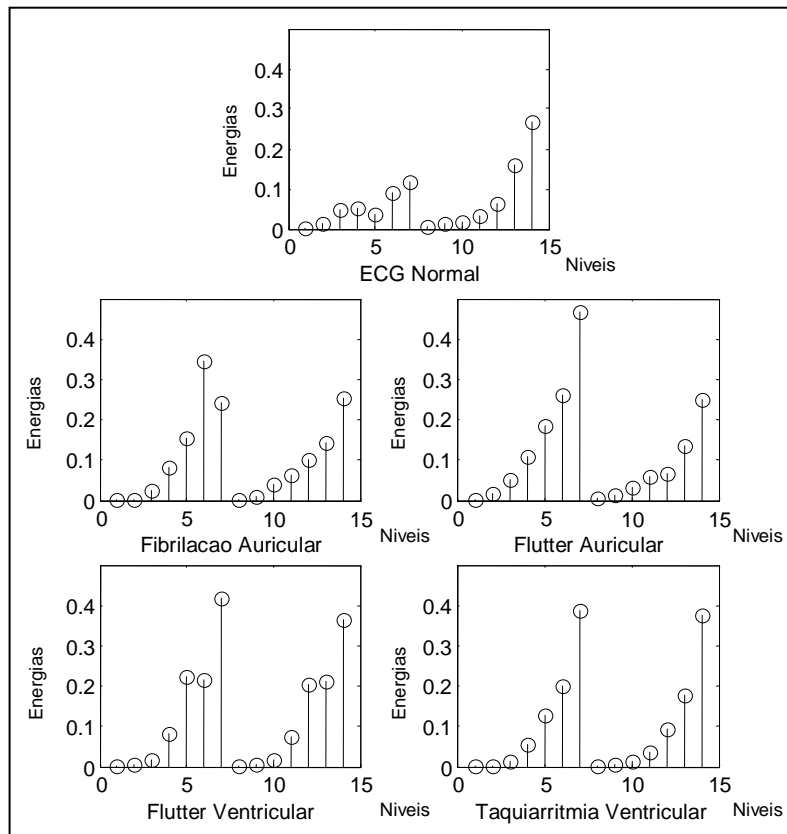


FIGURA 3.6 – Gráficos de energias de quatro doenças e ECG normal tomados de duas derivações simultâneas. Os níveis estão concatenados, sendo que as energias de 1 a 7 correspondem à primeira derivação e as de 8 a 14 são relativas à segunda derivação. A wavelet utilizada foi a symlet4.

Dessa forma os vetores de energia, de cada derivação, concatenados, vão compor as amostras de entrada da rede neural usada para classificação das doenças selecionadas.

3.2.3 Rede Neural Artificial

A utilização de redes neurais artificiais como máquinas cognitivas para classificação de padrões foi discutido no APÊNDICE B. A opção por redes neurais baseia-se em premissas que se sustentam pela larga utilização em ambientes industriais. Isto se deve à facilidade de utilização e implementação em hardware e a larga escala de aplicações nos mais variados problemas, proporcionando uma alta taxa de acerto, apesar de a RNA não prover uma explicação direta de como chegar à conclusão quanto ao aprendizado cognitivo.

Outros métodos de classificação (veja [20]) poderiam ser utilizados, contudo, as redes neurais permitem, integrar mais facilmente, abordagens que aliam capacidades explanativas de forma a compor um híbrido com técnicas de inteligência artificial. Detalhes desta composição foram abordados no APÊNDICE B onde se demonstra a capacidade de uso de RNAs para sistemas confiáveis.

Além do proposto, as RNAs possuem a capacidade de agrupar em um só sistema um conjunto de características úteis como: capacidade de generalizar resultados, modelagem de sistemas não-lineares, adaptabilidade a diferentes ambientes e situações, responder a evidências, tolerância à falhas, universais como processadoras de informações e por fim adequadas para implementação em tecnologia de integração em larga escala.

Se ainda não bastasse, os estudos apresentados em [50] [3] e [42] fortalecem o sentimento de uso das redes neurais artificiais em detrimento aos métodos tradicionais de classificação de padrões, como: PCA, LPC, discriminante linear, discriminante logístico e métodos estatísticos.

O uso das redes LVQ, RBF e perceptron multicamadas, no presente estudo, se faz pelos seguintes motivos:

- Verificação do comportamento classificatório de um método semi-parametrizado (rede LVQ) para segregação das classes de doenças. Dessa forma, procura-se observar a característica inerente ao método de efetuar uma generalização não-linear da técnica de análise de componentes principais.
- Verificação do comportamento classificatório de um método parametrizado (rede RBF) para segregação das classes de doenças. Dessa forma, procura-se observar a característica inerente ao método de efetuar o melhor ajuste, no sentido estatístico, para os dados de treinamento, na forma de superfícies de separação no espaço multidimensional.
- Verificação do comportamento classificatório de um método que permite a geração de superfícies complexas (rede perceptron). Dessa maneira, tendo muito mais liberdade nas possíveis formas das funções discriminantes.

Testes foram efetuados com uma rede RBF na tentativa de estabelecer uma parametrização dos dados de classificação pela composição de gaussianas. Outra rede, uma LVQ, foi utilizada no intuito de estabelecer uma classificação competitiva supondo um modelo de entrada não-parametrizado. Por fim, uma rede perceptron multicamadas, com uma camada oculta, foi utilizada de forma a contextualizar uma classificação com superfícies compondo funções discriminantes sem impor aproximações por modelos estatísticos e sem intuir espaços auto-organizados.

Os vetores de energia, obtidos da decomposição wavelet do sinal do ECG, de algumas doenças e do ECG normal foram utilizados para o treinamento da rede neural. A FIGURA 3.7 mostra um diagrama de blocos representando as fases do processo de classificação utilizadas nesse trabalho.

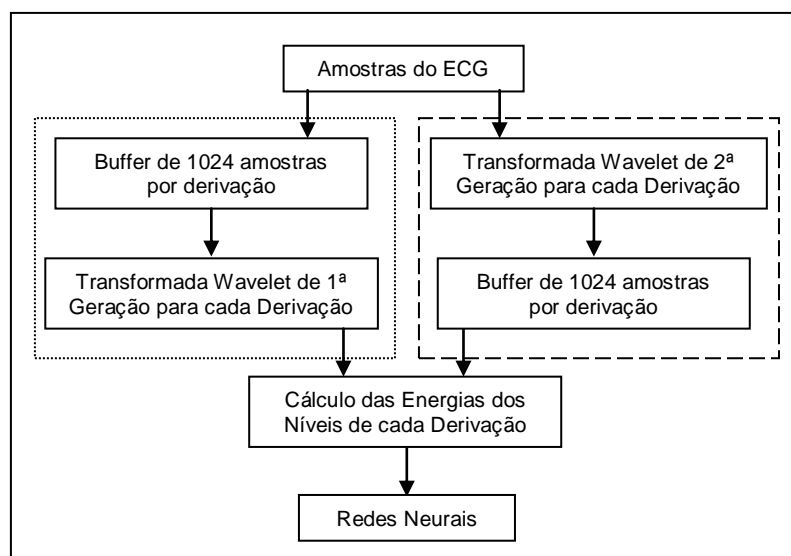


FIGURA 3.7 – Diagrama das fases do processo de classificação. As etapas tracejada e pontilhada, do esquema, ocorrem de forma mutuamente exclusivas e foram apresentadas dessa maneira para vias de comparação.

Observa-se, no entanto, que apesar de não constar no esquema acima, a transformada *lifting* não necessita de memória extra para processamento da transformação, enquanto a outra necessita de área de memória além do *buffer* representado no esquema.

4 EXPERIMENTOS E RESULTADOS

4.1 INTRODUÇÃO

Os experimentos foram realizados no MATLAB[®], utilizando implementações próprias das funções wavelets, de forma a possibilitar o uso dessas na transcrição dos códigos para o ambiente do palmtop.

Para o caso da rede neural, manteve-se a utilização do *toolbox* do MATLAB[®], uma vez que, no palmtop, serão utilizados apenas os pesos sinápticos obtidos do treinamento da RNA.

4.2 PROCEDIMENTO

Os sinais do ECG para arritmia auricular, flutter auricular, taquicardia ventricular, flutter ventricular e ECG normal foram obtidos (ANEXO E) a uma taxa de 250 amostras por segundo em dois canais (derivações) simultâneos definidos no MITDB como *signal_0* e *signal_1*.

Foram coletados 500 blocos de 1024 amostras cada, entre 10 pacientes. Cada sinal coletado para análise compunha 2 blocos de 1024 amostras, obtidas simultaneamente do paciente, perfazendo um total de 2048. Para cada doença foram coletados 50 conjuntos de 2 blocos de amostras e, para o ECG normal, também 50 conjuntos de 2 blocos de amostras.

Os blocos foram extraídos nos trechos do ECG contendo as devidas anotações médicas, evidenciando a ocorrência isolada de cada doença abordada e do ECG normal.

Cada conjunto contendo os dois blocos de amostras simultâneas passou pela decomposição wavelet de primeira geração em até 8 níveis, em cada bloco, utilizando as wavelets mãe de Daubechies 4 e symlet 4. Os coeficientes de aproximação do oitavo nível e os de detalhe do primeiro nível de cada bloco foram extraídos do resultado.

As energias de cada nível da decomposição, em cada bloco, foram calculadas e concatenadas entre os blocos do conjunto formando um vetor de 14 posições. Dessa forma, foram gerados 50 vetores de energia para cada doença e 50 para o ECG normal,

totalizando 250 vetores de energia dos sinais para cada base wavelet (Daubechies e symlet).

Aos vetores de energia foram associados a vetores indicadores da respectiva doença para compor a codificação “1-de-5” a ser usada no treinamento neural. Conjuntos para treinamento neural, teste e validação de aprendizagem foram separados simetricamente na proporção 7:2:1, respectivamente (veja TABELA 4.1). Os vetores de energia, devidamente identificados, foram agrupados e misturados em cada conjunto separadamente (treino, teste, validação).

Foram efetuados três revezamentos dos vetores de energia (C1, C2 e C3) entre os grupos de treino, teste e validação. Os revezamentos foram elaborados de forma que aqueles vetores de energia que ora estavam no conjunto de validação também fizeram parte do conjunto de treino e de teste; os que estavam no conjunto de treino passam a compor os conjuntos de validação e teste; e assim sucessivamente.

O procedimento acima foi repetido para a *lifting* wavelet nas bases de Haar e Daubechies 4 (TABELA 4.1). Duas variações adicionais, além da Haar convencional (Haar I), foram implementadas. Ambas com transformações de inteiro para inteiro [8]: uma com procedimento de cálculo em ponto fixo e exibição de valores inteiros para a energia (Haar II), e outra análoga, porém, com procedimento de cálculo e valores finais não inteiros para a energia (Haar III).

TABELA 4.1 – Vetores de Energia com Taquicardia Ventricular				
GERAÇÃO	WAVELET MÃE	TREINO	TESTE	VALIDAÇÃO
1ª	symlet 4	175	50	25
	daubechies 4	175	50	25
2ª	haar I	175	50	25
	haar II	175	50	25
	haar III	175	50	25
	daubechies 4	175	50	25

Foram treinadas dezoito redes neurais perceptron multicamadas com algoritmo de retropropagação usando o método de Levenberg-Marquardt. Cada rede foi estruturada com quatorze entradas, uma camada oculta e uma camada de saída com cinco neurônios (TABELA 4.2). A função de ativação utilizada nos neurônios ocultos foi a *tansig* e nos neurônios de saída a *logsig*.

4.3 RESULTADOS

Todo o procedimento acima, desde a decomposição wavelet até o treinamento e teste da rede neural, foi implementado em MATLAB®. Os resultados de classificação estão na TABELA⁴ 4.2.

TABELA 4.2 – Rede Perceptron Multicamadas considerando a Taquicardia Ventricular										
GERAÇÃO	WAVELET MÃE	SEM NÍVEIS	NEURÔNIOS OCULTOS	ÉPOCAS DE TREINO			META DE ERRO MÁXIMO			% DE ACERTO
				C1	C2	C3	C1	C2	C3	
1ª	symlet 4	-	12	19	15	16	0,0001	0,001	0,001	90,67
		2D	12	15	14	11	0,001	0,001	0,01	84,67
		2D 3D	8	21	19	27	0,005	0,001	0,001	87,33
	Daubechies 4	-	10	12	18	15	0,0001	0,0001	0,0001	80
		2D	9	17	23	10	0,0001	0,0001	0,01	88
		2D 3D	7	19	25	15	0,0001	0,001	0,01	82
2ª	Haar I	-	12	10	20	18	0,001	0,001	0,001	88
		2D	12	60	15	17	0,001	0,001	0,001	87,33
		2D 3D	10	15	15	28	0,001	0,001	0,001	83,33
	Haar II	-	12	24	8	15	0,01	0,04	0,04	71,33
		2D	10	17	9	10	0,01	0,04	0,04	70
		2D 3D	8	29	14	15	0,01	0,02	0,02	75,33
	Haar III	-	12	12	14	16	0,02	0,02	0,02	72
		2D	12	15	12	12	0,01	0,02	0,02	74
		2D 3D	12	18	17	14	0,02	0,02	0,02	78,67
	Daubechies 4	-	8	18	23	18	0,008	0,008	0,008	84,67
		2D	8	22	20	14	0,008	0,008	0,008	84
		2D 3D	6	57	33	30	0,008	0,01	0,008	78,67

O número de neurônios ocultos foi obtido através de tentativas de treinamento, respeitando-se os requisitos de erro, algoritmo de treinamento e validação, tendendo, portanto, ao número mínimo de neurônios capaz de efetuar a classificação dos sinais.

Na análise dos erros de classificação verificou-se que quase todos ocorreram entre o flutter ventricular e a taquicardia ventricular, como mostram as matrizes de confusão nos ANEXOS F, G e H. A observação do mecanismo de ação mostra que a origem do sinal anômalo é a mesma nas duas doenças, — o foco ectópico ventricular (FIGURA 4.1).

⁴ Os níveis 2D e 3D representam, respectivamente, o segundo e o terceiro nível de detalhe da decomposição wavelet.

A diferença entre os dois sinais está na existência do estímulo elétrico normal gerado pelo marca-passo do coração, na taquicardia ventricular, e a ausência do mesmo no flutter ventricular. Normalmente o flutter ventricular evolui para a taquicardia ventricular o que demonstra a similaridade dos mecanismos de ação.

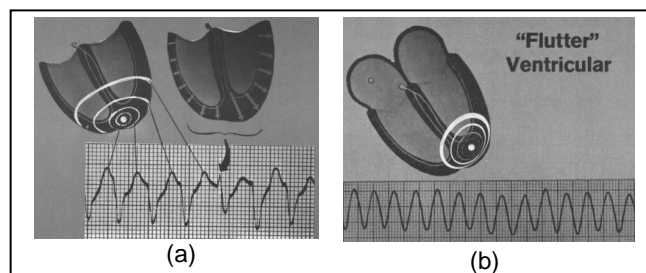


FIGURA 4.1 – (a) Taquicardia ventricular. (b) Flutter ventricular.

Fonte: Dubin, 1996.

A diferenciação médica dos dois sinais ocorre pela observação dos batimentos de fusão e batimentos de captura (veja seção 2.6.3).

Retirando-se as amostras de taquicardia ventricular e após as adequações na arquitetura da rede neural, obteve-se o seguinte:

TABELA 4.3 – Vetores de Energia sem Taquicardia Ventricular				
GERAÇÃO	WAVELET MÃE	TREINO	TESTE	VALIDAÇÃO
1ª	symlet 4	140	40	20
	daubechies 4	140	40	20
2ª	haar I	140	40	20
	haar II	140	40	20
	haar III	140	40	20
	daubechies 4	140	40	20

TABELA 4.4 – Rede Perceptron Multicamadas não considerando a Taquicardia Ventricular										
GERAÇÃO	WAVELET MÃE	SEM NÍVEIS	NEURÔNIOS OCULTOS	ÉPOCAS DE TREINO			META DE ERRO MÁXIMO NO TREINAMENTO			% DE ACERTO
				C1	C2	C3	C1	C2	C3	
1ª	symlet 4	-	5	14	21	9	0,0001	0,0001	0,0001	100
		2D	5	17	25	6	0,0001	0,0001	0,0001	98,33
		2D 3D	3	31	27	27	0,0001	0,0001	0,0001	100
	Daubechies 4	-	5	13	22	7	0,0001	0,0001	0,0001	100
		2D	5	51	27	17	0,0001	0,0001	0,0001	98,33
		2D 3D	3	22	16	24	0,0001	0,0001	0,0001	100
2ª	Haar I	-	2	31	25	12	0,0001	0,0001	0,0001	100
		2D	2	36	35	14	0,0001	0,0001	0,0001	100
		2D 3D	2	49	13	11	0,0001	0,002	0,001	100
	Haar II	-	10	16	15	15	0,01	0,01	0,01	85,83
		2D	8	16	13	13	0,01	0,01	0,01	88,33
		2D 3D	7	10	13	6	0,01	0,01	0,01	89,16
	Haar III	-	12	20	20	7	0,02	0,02	0,02	90
		2D	12	22	23	25	0,01	0,01	0,01	87,5
		2D 3D	12	11	17	18	0,01	0,01	0,01	88,33
	Daubechies 4	-	6	15	15	18	0,0001	0,0001	0,0001	96,67
		2D	6	14	11	16	0,008	0,008	0,008	95,83
		2D 3D	4	24	13	13	0,008	0,008	0,008	96,67

As TABELAS 4.5 a 4.8 apresentam os resultados do treinamento das redes RBF e LVQ.

Tanto a rede RBF quanto a LVQ não conseguiram efetuar o treinamento nas bases Haar II e Haar III, tendo traços completando os campos de dados. A supressão de informações resultante da obtenção dos coeficientes inteiros provocou um aumento da complexidade das funções discriminantes entre as classes de patologias, e será comentado mais a diante.

O APÊNDICE E possui os gráficos de treinamento e as matrizes de confusão que originaram os dados das TABELAS 4.2, 4.4, 4.5, 4.6, 4.7 e 4.8 para as rede perceptron multicamadas, RBF e LVQ.

O APÊNDICE D possui os gráficos de erros de classificação baseados nas tabelas supracitadas.

Efetutando-se o procedimento análogo para as redes RBF e LVQ, com os mesmos conjuntos de vetores de energia (TABELAS 4.1 e 4.3), obteve-se:

TABELA 4.5 – Rede RBF considerando a Taquicardia Ventricular									
GERAÇÃO	WAVELET MÃE	SEM NÍVEIS	NEURÔNIOS OCULTOS			META DE ERRO MÁXIMO NO TREINAMENTO			% DE ACERTO
			C1	C2	C3	C1	C2	C3	
1ª	symlet 4	-	150	150	149	0,13	0,13	0,13	81,33
		2D	153	154	150	0,12	0,12	0,12	78
		2D 3D	152	149	152	0,12	0,12	0,12	74,67
	Daubechies 4	-	148	153	143	0,12	0,12	0,12	78
		2D	145	150	145	0,12	0,12	0,12	79,33
		2D 3D	145	146	144	0,12	0,12	0,12	77,33
2ª	Haar I	-	146	150	147	0,12	0,12	0,12	81,33
		2D	145	148	148	0,12	0,12	0,12	78,67
		2D 3D	144	148	148	0,12	0,12	0,12	77,33
	Haar II	-	-	-	-	-	-	-	-
		2D	-	-	-	-	-	-	-
		2D 3D	-	-	-	-	-	-	-
	Haar III	-	-	-	-	-	-	-	-
		2D	-	-	-	-	-	-	-
		2D 3D	-	-	-	-	-	-	-
	Daubechies 4	-	166	168	166	0,13	0,13	0,13	83,33
		2D	166	167	167	0,12	0,12	0,12	73,33
		2D 3D	174	174	174	0,12	0,12	0,5	50,67

TABELA 4.6 – Rede RBF não considerando Taquicardia Ventricular									
GERAÇÃO	WAVELET MÃE	SEM NÍVEIS	NEURÔNIOS OCULTOS			META DE ERRO MÁXIMO NO TREINAMENTO			% DE ACERTO
			C1	C2	C3	C1	C2	C3	
1ª	symlet 4	-	123	122	122	0,01	0,01	0,01	95,83
		2D	125	120	122	0,01	0,01	0,01	95
		2D 3D	124	121	121	0,01	0,01	0,01	94,17
	Daubechies 4	-	114	114	107	0,04	0,04	0,04	94,17
		2D	112	112	105	0,04	0,04	0,04	94,17
		2D 3D	114	110	108	0,04	0,04	0,04	95
2ª	Haar I	-	128	129	122	0,01	0,01	0,01	90
		2D	126	125	124	0,01	0,01	0,01	89,17
		2D 3D	126	124	125	0,01	0,01	0,01	85,83
	Haar II	-	-	-	-	-	-	-	-
		2D	-	-	-	-	-	-	-
		2D 3D	-	-	-	-	-	-	-
	Haar III	-	-	-	-	-	-	-	-
		2D	-	-	-	-	-	-	-
		2D 3D	-	-	-	-	-	-	-
	Daubechies 4	-	132	130	129	0,04	0,04	0,04	92,5
		2D	132	130	131	0,04	0,04	0,04	95
		2D 3D	139	138	135	0,04	0,04	0,04	90

TABELA 4.7 – Rede LVQ considerando Taquicardia Ventricular										
GERAÇÃO	WAVELET MÃE	SEM NÍVEIS	NEURÔNIOS OCULTOS	ÉPOCAS DE TREINO			META DE ERRO MÁXIMO NO TREINAMENTO			% DE ACERTO
				C1	C2	C3	C1	C2	C3	
1ª	symlet 4	-	10	23	92	31	0,06	0,06	0,06	81,33
		2D	10	24	40	20	0,06	0,06	0,06	81,33
		2D 3D	8	24	35	21	0,06	0,06	0,06	80
	Daubechies 4	-	10	66	40	13	0,06	0,07	0,06	81,33
		2D	9	54	16	14	0,06	0,092	0,06	81,33
		2D 3D	9	15	60	13	0,06	0,09	0,06	80
2ª	Haar I	-	9	58	23	25	0,12	0,13	0,13	56,67
		2D	8	47	23	45	0,12	0,13	0,12	58,67
		2D 3D	7	77	25	64	0,13	0,137	0,13	54,67
	Haar II	-	-	-	-	-	-	-	-	-
		2D	-	-	-	-	-	-	-	-
		2D 3D	-	-	-	-	-	-	-	-
	Haar III	-	-	-	-	-	-	-	-	-
		2D	-	-	-	-	-	-	-	-
		2D 3D	-	-	-	-	-	-	-	-
	Daubechies 4	-	9	23	49	23	0,05	0,05	0,05	84
		2D	8	46	60	43	0,05	0,05	0,055	81,33
		2D 3D	7	57	21	82	0,06	0,06	0,065	83,33

TABELA 4.8 – Rede LVQ não considerando a Taquicardia Ventricular										
GERAÇÃO	WAVELET MÃE	SEM NÍVEIS	NEURÔNIOS OCULTOS	ÉPOCAS DE TREINO			META DE ERRO MÁXIMO NO TREINAMENTO			% DE ACERTO
				C1	C2	C3	C1	C2	C3	
1ª	symlet 4	-	5	14	12	8	0,04	0,04	0,04	97,5
		2D	7	57	70	31	0,033	0,033	0,033	96,67
		2D 3D	7	59	57	28	0,033	0,033	0,033	96,67
	Daubechies 4	-	4	33	75	21	0,04	0,05	0,03	96,67
		2D	4	22	21	19	0,05	0,05	0,03	97,5
		2D 3D	4	36	84	19	0,04	0,05	0,03	96,67
2ª	Haar I	-	5	51	88	32	0,137	0,13	0,13	75,83
		2D	5	34	82	33	0,136	0,13	0,13	75,83
		2D 3D	5	60	87	29	0,136	0,13	0,13	75,83
	Haar II	-	-	-	-	-	-	-	-	-
		2D	-	-	-	-	-	-	-	-
		2D 3D	-	-	-	-	-	-	-	-
	Haar III	-	-	-	-	-	-	-	-	-
		2D	-	-	-	-	-	-	-	-
		2D 3D	-	-	-	-	-	-	-	-
	Daubechies 4	-	4	30	18	15	0,036	0,06	0,06	95,83
		2D	4	21	15	20	0,05	0,05	0,05	94,17
		2D 3D	4	21	25	15	0,043	0,04	0,05	95

4.4 COMENTÁRIOS

Uma vez que a RBF e a LVQ são redes baseadas na técnica de agrupamentos (*clustering*), entende-se facilmente a dificuldade desses modelos em adequar corretamente as superfícies multidimensionais entre amostras que se misturam nessas superfícies. A FIGURA 4.2 apresenta um modelo em duas dimensões, com mistura de três classes, que exemplificam o que foi dito.




FIGURA 4.2 – Amostras de três classes que se misturam.

Observe que as amostras definidas como bolas pretas se inserem entre as amostras quadradas e as linhas, determinando duas superfícies discriminantes complexas, representadas pelas linhas tracejadas. Contudo, a classe de bolas pretas necessita de uma superfície discriminante que possua contorno altamente complexo para segregação de suas amostras.

A rede LVQ tem dificuldades para representar modelos dessa natureza, pois a representação neural baseia-se no agrupamento de neurônios vizinhos (distância vetorial) em torno do neurônio vencedor de cada classe [25]. Dessa forma, no treinamento, os neurônios vizinhos a um grupamento também o são para o grupamento de amostras que se misturam impossibilitando a separação adequada dos neurônios que ficam, por assim dizer, “indecisos”. Por outro lado, havendo o treinamento, as amostras que se inserem entre as de outras classes contribuem efetivamente no aumento da taxa do erro de classificação.

A rede RBF, por sua vez, procura parâmetros que possibilitem adequar suas funções estatísticas (no presente caso, as gaussianas) nos espaços multidimensionais de forma a não haver sobreposição de funções que representem classes distintas.

Havendo dificuldade de segregação, a rede RBF cresce a primeira camada em neurônios até o limite de um neurônio para cada amostra de entrada. Isso mostra porque as redes RBF são adequadas à aproximação de funções, chegando ao limite de disponibilizar um neurônio para representar cada amostra. Entretanto, apesar desse fato, a camada de saída não consegue estabelecer as superfícies para separação quando as amostras são reentrantes.

A menos que amostras de mesmo valor compunham duas classes distintas — nesse caso o problema está na adequação dos dados e não na rede neural — as redes RBF ponderam os parâmetros de forma a evitar a sobreposição completa de funções.

O parágrafo anterior suscita a informação de poder haver amostras de mesmo valor pertencendo a classes distintas. Tal informação é verdadeira, no que se refere à transformada wavelet de inteiro para inteiro (seção A.3), uma vez que observa-se o truncamento dos coeficientes transformados.

5 IMPLEMENTAÇÃO NO PALMTOP

5.1 INTRODUÇÃO

A praticidade associada à possibilidade de mobilidade do sistema motivaram a implementação da técnica em ambiente portátil. Optou-se pelo *palmtop* devido às facilidades quanto à: programação, operação pelo médico, aquisição do equipamento e do ambiente de desenvolvimento.

Utilizou-se o pacote de desenvolvimento *Microsoft Embedded Tools* com o *Embedded Visual Basic* para programação em ambiente *PocketPC* utilizando um emulador para computadores pessoais (PC). Todas as ferramentas são disponibilizadas gratuitamente pela *Microsoft* e podem ser obtidas pela *Internet*.

O programa implementado no *palmtop* usou a transformada *lifting* Haar e a rede perceptron multicamadas. O diagrama de blocos da FIGURA 3.7 mostra todas as etapas efetuadas na implementação da técnica.

5.2 DOCUMENTO CONCEITUAL


É proposto que se elabore um sistema para monitoramento de doenças cardíacas através da interpretação dos sinais elétricos do coração. O software a ser desenvolvido deve possuir as seguintes características:

- Ser implementado em ambiente portátil de fácil manuseio e transporte;
- Possuir interface com o usuário amigável de fácil interpretação e operação;
- Apresentar ao operador os gráficos de duas derivações simultâneas do coração;
- Permitir a visualização dos valores ponderados de aproximação do diagnóstico obtido;
- A análise deve ser rápida e robusta.

5.3 PROJETO

A partir dos quesitos relacionados no documento conceitual efetuou-se a opção pelo uso de ambientes *palmtop* e do modelo *pocketPC* com ambiente de desenvolvimento *Embedded Visual Basic 3.0* de distribuição gratuita pela Microsoft.

A estrutura da interface com o usuário proposta encontra-se na FIGURA 5.1.



A partir da teoria desenvolvida em torno do método de diagnóstico e dos experimentos apresentados, optou-se pela implementação da transformada *lifting Haar* e da rede perceptron multicamadas.

5.3.1 Análise do Sistema

Os sinais do ECG das duas derivações são valores inteiros que são processados amostra por amostra em cada canal paralelamente. Os coeficientes da transformação wavelet são utilizados para o cálculo das energias e em seguida são submetidos à rede neural treinada.

O diagrama de fluxo abaixo (FIGURA 5.2) representa a trajetória dos valores processados pelo algoritmo de processamento.

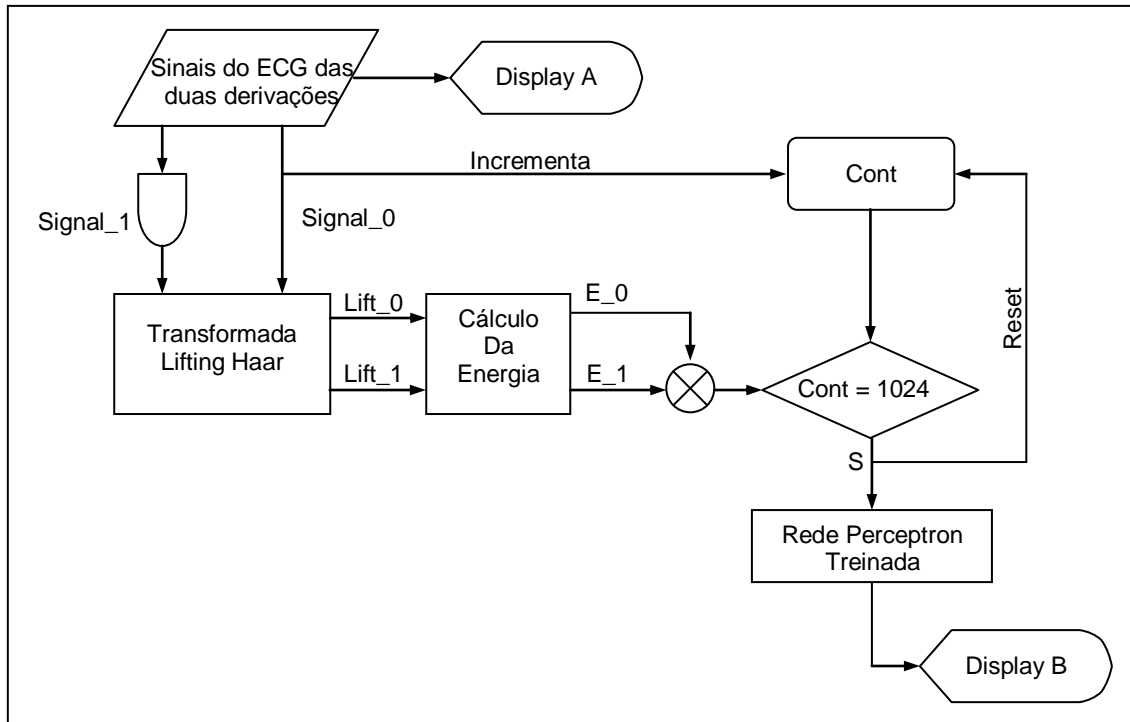


FIGURA 5.2 – Fluxograma do sistema de diagnóstico de doenças cardíacas.

MÓDULO DA TRANSFORMADA LIFTING HAAR

A transformada é obtida pela aplicação das equações 5.1 (veja eq. A.42) em cada derivação independentemente à medida em que as amostras são fornecidas ao sistema.

$$\mu_k = \frac{a_k + b_k}{2}$$

$$\gamma_k = \mu_k - b_k = \frac{a_k - b_k}{2}$$
(5.1)

MÓDULO DO CÁLCULO DA ENERGIA

A cada 1024 amostras processadas por cada derivação, é efetuado o cálculo das energias de cada nível da decomposição wavelet através da equação 5.2 (veja eq. 3.1).

$$E_i = \frac{\sqrt{\sum_{k=1}^{N_i} c_k^2}}{N_i}$$
(5.2)

MÓDULO DA REDE NEURAL

A rede neural perceptron, já treinada no MATLAB[®], recebe as amostras de energia das duas derivações concatenadas e processa a identificação da patologia em questão.

MÓDULO DISPLAY A

Apresenta os sinais do ECG das duas derivações simultaneamente no display do palmtop à medida em que as amostras são obtidas dos sensores.

MÓDULO DISPLAY B

Apresenta o resultado da classificação neural no display do palmtop, reinicializa o DISPLAY A, e atualiza os demais dados de controle no *display* do palmtop.

5.4 IMPLEMENTAÇÃO

Os códigos do programa desenvolvido no *Embedded Visual Basic 3.0* encontram-se no CD-ROM que acompanha esta dissertação.

A utilização de ambiente de emulação para *pocketPC* fornecido gratuitamente pela Microsoft permite a avaliação e teste de funcionamento do sistema.

A FIGURA 5.3 mostra a interface implementada no emulador. Observam-se os sinais simultâneos de duas derivações: a primeira (*signal_0*) e a segunda (*signal_1*); a doença detectada e as demais doenças com seus respectivos percentuais de aproximação; e informações de controle operacional do sistema.

Os pesos de aproximação informam o quanto o sinal analisado se aproxima do sinal característico de cada doença, sendo comparado, indiretamente, com os sinais usados no treinamento neural.




FIGURA 5.3 – Sistema de avaliação do ECG implementado no palmtop. Programa sendo emulado no PC.

A utilização das amostras do MITDB para teste, treinamento e validação dos resultados impõe a necessidade de efetuar uma simulação para entrada dos dados para processamento no sistema. Dessa forma, elaborou-se um vetor contendo amostras de diferentes patologias para submissão ao sistema de avaliação proposto.

Tal conjunto supre a necessidade de verificar o correto funcionamento do sistema nas diferentes doenças relacionadas, não dependendo, a pesquisa, de encontrar pacientes que apresentem as devidas anomalias cardíacas.

6 CONCLUSÕES

Primeiramente, pode-se enfatizar a característica pré-classificadora do método, em relação à taquicardia ventricular e ao flutter ventricular. O uso da energia dos coeficientes permite a classificação de categorias de doenças, uma vez que elas apresentem semelhanças consideráveis na escala tempo-frequência. Ao mesmo tempo, doenças morfologicamente díspares, nessa escala, são classificadas isoladamente.

Outrora, por hipótese, a classificação fosse aplicada diretamente sobre o sinal do ECG. Isso notadamente se apresentaria inviável tendo em vista, primeiramente, a variação da frequência cardíaca e as flutuações do sinal, originadas pelo movimento do paciente, tanto em função dos sinais mioelétricos, quanto ao contato dos sensores na pele. Essas componentes indesejáveis do sinal do ECG têm sua influência eliminada, ou apenas minimizada pela supressão dos coeficientes de aproximação do oitavo nível da decomposição wavelet.

Ainda, nessa hipótese, 2048 entradas na RNA teria, conseqüentemente, maior complexidade no treinamento, envolvendo necessariamente mais neurônios, e mais tempo de processamento que em uma RNA com quatorze entradas. Da mesma forma, o uso dos coeficientes da decomposição wavelet diretamente na entrada da RNA, para classificação, abarcaria a mesma explicação acima, uma vez que seriam aproximadamente mil entradas na rede em contrapartida às quatorze entradas do vetor de energia.

Alguns autores, em artigos como [18], utilizam os coeficientes da decomposição wavelet diretamente na entrada da rede neural. Contudo, observa-se, que nesses casos, o método faz uso de coeficientes obtidos da decomposição de apenas um período do ECG. Como, normalmente, os eletrocardiógrafos amostram a uma taxa de 250 amostras por segundo e o ciclo cardíaco normal se repete por volta de pouco menos de um segundo, o número de amostras consideradas para decomposição wavelet fica em torno de 200 amostras.

Nesse estudo foram utilizadas 2048 amostras (dez vezes mais) obtidas a uma taxa de 250 amostras por segundo totalizando, aproximadamente, 10 períodos de ECG para

cada conjunto de análise. Em todo o conjunto de dados há por volta de 2500 ciclos cardíacos sendo considerados nos experimentos.

O uso de mais ciclos consecutivos do ECG, contendo informações repetidas (em cada ciclo), no montante para análise leva ao acréscimo na robustez da classificação, quando comparado aos métodos que baseiam-se apenas em períodos isolados. Tal acréscimo é dado pela confirmação da informação patológica contida nos ciclos subsequentes e pela informação quanto à evolução da doença, registrada nos períodos imediatamente anteriores ao seu aparecimento, quando é o caso.

Não bastassem as observações supra mencionadas, a característica pré-qualificadora do método, pelo uso da energia, poderia não se confirmar com o uso direto das amostras ou dos coeficientes da transformada wavelet na entrada da RNA. Isso se verifica comparando os vetores de energia entre VT e VFL (FIGURA 3.6) e as amostras do ECG entre essas duas doenças (FIGURA 3.1). Observam-se diferenças morfológicas na disposição das amostras, porém a energia dos sinais é bem parecida. Isso não necessariamente significa que o não uso da energia permitiria a classificação entre VT e VFL utilizando a técnica referida neste parágrafo.

Em relação à classificação pelas bases de Daubechies das wavelets de 1ª e 2ª geração, observa-se que, de modo geral, para as três redes neurais as duas bases obtiveram resultados de classificação muito próximos com uma discreta liderança da wavelet de Daubechies de 1ª geração.

A TABELA 6.1 mostra as bases wavelets ordenadas de maneira decrescente quanto ao melhor resultado de classificação. De modo a facilitar a representação em tabela, as bases de Daubechies 4 de primeira e de segunda geração foram abreviadas para a notação Db I e Db II, respectivamente.

TABELA 6.1 – Ordem de Melhor Classificação das Bases Wavelets						
ORDEM	PERCEPTRON		RBF		LVQ	
	VT	SVT	VT	SVT	VT	SVT
1ª	Symlet	Haar I	Haar I	Symlet	Db II	Symlet / Db I
2ª	Haar I	Symlet / Db I	Symlet	Db I	Symlet / Db I	Db II
3ª	Db I	Db II	Db I	Db II	Haar I	Haar I
4ª	Db II	Haar III	Db II	Haar I	-	-
5ª	Haar III	Haar II	-	-	-	-
6ª	Haar II	-	-	-	-	-

O uso da rede perceptron multicamadas e da transformada lifting Haar I se mostram adequados ao que se propõe em relação à resposta rápida, eficiente e robusta de um sistema embutido para detecção de doenças cardíacas. A rapidez está vinculada à simplicidade da transformada wavelet e da implementação da rede neural perceptron multicamadas. A eficiência e robustez permeiam a natureza funcional da análise tempo-frequência da wavelet — uma vez que a transformada por si já constitui uma maneira de representar as características de interesse — e à essência cognitiva da RNA.

De maneira um tanto intuitiva e filosófica, Vaidyanathan [56], exprime a relação das wavelets ao conhecimento como:

“Qualquer tipo de “aprendizado” ou “entendimento” na vida ocorre em vários níveis de resolução, que se apuram em finos ajustes à medida em que vamos nos especializando.”

(Vaidyanathan, 1993. pp 258 – tradução nossa)

A citação exprime os diversos níveis da decomposição wavelet como etapas de informações daquilo que se deseja conhecer. Os níveis de aproximação carregam informações substanciais, básicas e grosseiras sem a devida exatidão daquilo que ela representa. A medida em que os níveis de detalhe são acrescentados, a exatidão aumenta a cerca do conhecimento daquilo que se deseja conhecer, ou representar.

Tal observação presta-se para explicitar a importância das wavelets em matéria de reconhecimento de padrões, como referido nesse trabalho. A identificação dos sinais permeia a análise do conhecimento embutido em cada nível da decomposição wavelet. Cabe à rede neural, a identificação das informações segregativas, quanto à doença que se quer representar, em cada nível de “conhecimento” da transformada.

Não obstante, a rede perceptron possui ainda a característica de poder modelar superfícies discriminantes complexas, necessárias nesse contexto, o que a torna a melhor opção em relação às redes RBF e LVQ.

As qualidades relativas à *lifting* wavelet para classificação de padrões, associadas ao uso de coeficientes inteiros, após a classificação, para armazenamento e posterior reconstrução do sinal, podem ser elaboradas no presente sistema sem perda de desempenho.

No mais, pode-se frisar que o uso da energia dos níveis da decomposição wavelet implica em:

- Não requerer a detecção do complexo QRS [12].
- Não haver a necessidade de que os blocos de amostras iniciem sempre na mesma posição relativa ao ciclo cardíaco.
- Não ser necessário que o bloco de amostras possua tamanho limitado a um múltiplo do tamanho do ciclo cardíaco completo (período completo). Indirectamente proporcionando maior robustez.

A comparação da *lifting* com a transformada wavelet de primeira geração destaca-se em:

- A transformação *lifting* é efetuada continuamente amostra por amostra.
- A transformação *lifting* é linear.
- O algoritmo da *lifting* é simples e de reconstrução perfeita (ideal para compactação de sinais biomédicos [31]).
- A transformação *lifting* permite a geração de coeficientes inteiros (ideal para armazenamento).

A taxa de acerto elevada associada a uma técnica simples e rápida justifica o uso em aplicações médicas de emergência, onde se requer sistemas embutidos portáteis e de diagnóstico rápido.

6.1 SUGESTÕES

Com o intuito de prover melhorias para a detecção de doenças pelo uso da energia dos coeficientes wavelets, sugere-se:

- O uso de wavelets diferentes para cada canal do ECG, de forma a constituir derivações com as bases wavelets que melhor representem o sinal nesses pontos.
- O uso de fusão de técnicas, tendo o critério da energia como pré-classificador de doenças.
- Estender a análise utilizando wavelet packet.

REFERÊNCIAS

- [1] AGUIRRE A. **Introdução à identificação de sistemas – técnicas lineares e não-lineares aplicadas a sistemas reais**. Belo Horizonte. Ed. UFMG, 2000.
- [2] AZEVEDO, F. M.; BRASIL, L. M.; OLIVEIRA, R. C. L. **Redes neurais: com aplicações em controle e em sistemas especialistas**. Florianópolis: Bookstore, 2000.
- [3] BENDEZÚ, L. G. H.; DENYS, B. G. **Feature identification of ecg waveform via orthonormal functions**. Computers in Cardiology 1990. Proceedings. , p. 641–644, 23-26 Sep 1990.
- [4] BISHOP, C. M. **Neural networks for pattern recognition**. New York: Oxford University Press, 1997.
- [5] BORN, R. S. **Filtros adaptativos aplicados a sinais biomédicos**. Monografia de Bacharelado da Universidade Federal de Pelotas, Pelotas, RS, 2000.
- [6] BROHET, C.; DERWAELE, C.; FESLER, R. **Automated ecg diagnosis of atrial flutter by means of wavelet transform**. IEEE Computers in Cardiology, p. 773-776, 1994.
- [7] BURRUS, C. Sidney; GOPINATH, Ramesh A.; GUO, Haitao. **Introduction to wavelets and wavelet transform a primer**. New Jersey: Prentice Hall, 1998.
- [8] CALDERBANK, A. R.; DAUBECHIES, Ingrid; SWELDENS, Win. **Wavelet transform that map integers to integers**. Technical report, Department of Mathematics, Princeton University, 1996.
- [9] CASTRO, B.; KOGAN, D.; GEVA, A. B. **Ecg feature extration using optimal mother wavelet**. Electrical and Electronic Engineers in Israel, 2000. The 21st IEEE Convention of the , p. 346 –350, 2000.
- [10] CENTRO DE CIÊNCIAS DA SAÚDE (CCS). **Curso de eletrocardiografia básica**. Universidade Estadual de Londrina (UEL), <http://www.ccs.uel.br/pbl/cardio/capitulo1.asp>, 17/12/2002.
- [11] CHAZAL, P. de; CELLER, B. G.; REILLY, R. B. **Using wavelet coefficients for the classification of the electrocardiogram**. Proceedings of the 22nd Annual EMBS International Conference – Chicago IL, p. 64-67, July, 2000.
- [12] _____; _____. *Selection of parameters from power spectral density, wavelet transform and other methods for the automated interpretation of the ecg*. IEEE Digital Signal Processing, p. 71-74, 1997.
- [13] _____ et al. **Classification of the electrocardiogram using selected wavelet coefficients and linear discriminants**. Acoustics, Speech, and Signal Processing, 2000. ICASSP '00. Proceedings. 2000 IEEE International Conference on , v. 6 , p. 3590-3593, 2000.

- [14] CHENG, W. T.; CHAN, K. L. **Classification of electrocardiogram using hidden Markov models**. Proceedings of the 20nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society, v. 20, n. 1, p. 143-146, 1998.
- [15] COHEN, A.; KOVACEVIC, J. **Wavelets: the mathematical background**. Proceedings of the IEEE, p. 514-522, v. 84, n. 4, april, 1996.
- [16] DAUBECHIES, Ingrid. **Ten lectures on wavelets**. SIAM, 1992.
- [17] DEMUTH, H.; BEALE, M. **Neural Network Toolbox User's Guide**. The MathWorks Inc. Natick, 2002.
- [18] DOKUR, Z.; ÖLMEZ, Tamer; YAZGAN, E. **Ecg waveform classification using the neural network and wavelet transform**. Engineering in Medicine and Biology, 1999. 21st Annual Conf. and the 1999 Annual Fall Meeting of the Biomedical Engineering Soc. BMES/EMBS Conference, 1999. Proceedings of the First Joint , v. 1, p. 273, 1999.
- [19] DUBIN, Dale. **Interpretação Rápida do ECG: um curso programado**. 3 ed., 8. reimp. Rio de Janeiro: Editora de Publicações Científicas LTDA, 1996.
- [20] DUDA, O. Richard; HART, E. Peter; STORK, G. David. **Pattern classification**. 2 ed. New York: John Wiley & Sons Inc, 2001.
- [21] FLIEGE, N. J. **Multirate digital signal processing: multirate systems, filter banks, wavelets**. Chichester: John Wiley & Sons Ltd, 2000.
- [22] GANONG, W. F. **Fisiologia Médica**. 3 ed. São Paulo: Editora Atheneu, 1977.
- [23] GARDNER, E.; GRAY, D. J.; RAHILLY, R. O. **Anatomia: estudo regional do corpo humano**. 4 ed. Rio de Janeiro: Guanabara Koogan, 1975.
- [24] GAWANDE, Atul. **Complicações: dilemas de um cirurgião diante de uma ciência imperfeita**. Rio de Janeiro: Objetiva, 2002.
- [25] HAYKIN, Simon. **Redes neurais: princípios e prática**. 2 ed. Porto Alegre: Bookman, 2001.
- [26] HURST, J. W. et al. **O coração: artérias e veias**. 3 ed. Rio de Janeiro: Guanabara Koogan, 1977.
- [27] JENSEN, A.; LA COUR-HARBO, A. **Ripples in mathematics: the discrete wavelet transform**. Germany: Springer, 2001.
- [28] KADAMBE, S.; MURRAY, R.; BARTELS, G. F. B. **The dyadic wavelet transform based qrs detector**. Signals, Systems and Computers, 1992. 1992 Conference Record of The Twenty-Sixth Asilomar Conference on , 26-28 Oct 1992.
- [29] KAISER, Gerald. **A friendly guide to wavelets**. New York: Birkhäuser, 1999.
- [30] KOHONEN, T. **Self-organizing maps**. Springer-Verlag. Berlin, 1995.
- [31] KRZYSZTOF, Duda; PAWEL, Turcza; TOMASZ, P. Zielinsk. **Lossles ECG compression with lifting wavelet transform**. IEEE Instrumentation and Meassurement Techinology Conference, Hungary, may 21-23, 2001.

- [32] KULKARNI, A. D. **Computer vision and fuzzy-neural systems**. New Jersey: Prentice Hall, 2001.
- [33] LENGYEL, Ladislau. **Eletrocardiografia clínica**. São Paulo: SARVIER, 1974.
- [34] LI, C.; ZHENG, C.; TAI, C. **Detection of ecg characteristic point using wavelet transform**. IEEE Transactions on Biomedical Engineering, v. 42, n.1, Jan. 1995.
- [35] MAASS, W.; BISHOP, C. M. **Pulsed neural networks**. Cambridge: The MIT Press, 1999.
- [36] MACHADO, V. B. **Identificação de bloqueios cardíacos**. Dissertação de Mestrado do PPGE – UFES, Vitória, Dez., 1995.
- [37] MALLAT, S. G. **A theory for multiresolution signal decomposition: the wavelet representation**. IEEE Transaction on Pattern Recognition and Machine Intelligence. p. 674-693, July, 1989.
- [38] _____. **Multiresolution frequency channel decomposition of images and wavelet models**. IEEE Trans. On Acoust, Speech Signal Processing, v. 12, p. 2091-2110, 1989.
- [39] MARTINEZ, J. P.; OLMOS, S.; LAGUNA, P. **Evaluation of a wavelet-based ecg waveform detector on the qt database**. IEEE Computers in Cardiology, v. 27, p. 81-84, 2000.
- [40] MCDARBY, G.; CELLER, B. G.; LOVELL, N. H. **Characterising discrete wavelet transform of an ecg signal with simple parameters for use in automated diagnosis**. The 2nd International Conference on Bioelectromagnetism, Melbourne Australia, Feb. 1998.
- [41] MICHAELIS, M. et al. **Detection and classification of p waves using gabor wavelets**. IEEE Computers in Cardiology 1993. Proceedings. , 5-8 Sep 1993, Page(s): 531 – 534.
- [42] NADAL, J; BOSSAN, M. C. **Classification of cardiac arrhythmias based on principal component analysis and feedforward neural networks**. Computers in Cardiology 1993. Proceedings. P. 341-343, 5-8 Sep 1993.
- [43] NETTER, Frank H. **The ciba collection of medical illustrations: heart**. V. 5. Ciba Pharmaceutical Company, New York, 1978.
- [44] OPPENHEIM, G. et al. **Wavelet Toolbox User's Guide**. The MathWorks Inc. Natick, 2002.
- [45] PHYSIONET. **MITDB**. <http://www.physionet.org>. 01.2001 a 06.2002.
- [46] PRINCIPE, J. C.; EULIANO, N. R. LEFEBVRE, W. C. **Neural and adaptative systems: fundamentals through simulation**. New York: John Wiley & Sons, 2000.
- [47] RIOUL, O.; VETTERLI, M. **Wavelet and signal processing**. IEEE Signal Processing Magazine, p. 14-38, 10.1991.
- [48] ROIG, M. J. et al. **Study of frequency and time domain parameters extracted by means of wavelet transform applied to ecg to distinguish between vf and other arrhythmias**. IEEE Computers in Cardiology, v. 25, p. 17-20, 1998.

- [49] SAHAMBI, J. S.; TANDON, S. N.; BHATT, R. K. P. **Using wavelet transform for ecg characterization.** IEEE Engineering in medicine and biology, p. 77-83, 01.1997.
- [50] SILIPO, Rosaria; BORTOLAN, Giovanni. **Neural and traditional techniques in diagnostic ecg classification.** Acoustics, Speech, and Signal Processing, 1997. ICASSP-97., 1997 IEEE International Conference on , v. 1, p. 123-126 , 21-24 Apr 1997.
- [51] STAMKOPOULOS, T. et al. **Ecg analysis using nonlinear pca neural networks for ischemia detection.** IEEE Transactions on Signal Processing, v. 46, n. 11, p. 3058-3067, Nov., 1998.
- [52] SWELDENS, Win. **Wavelet and the lifting scheme: a 5 min tour.** Technical report, Department of Mathematics, Princeton University, 1996.
- [53] SZILAGYI, S. M.; SZILAGYI, L.; DAVID, L. **Comparison between neural-network-based adaptive filtering and wavelet transform for ecg characteristic point detection.** The 1997 Annual Fall Meeting of the Biomedical Engineering Soc. EMBS Conference, 1997. Proceedings of the First Joint , p. 272-274, Oct. 1997.
- [54] TECNOLOGIA ELETRÔNICA BRASILEIRA (TEB). **Catálogo Virtual de Produtos**, <http://www.teb.com.br/eletrocardiografos/eletrocardiografos.htm>, 17/12/2002.
- [55] TIKKANEN, P. E.; PALMGREN, J. E.; SELLIN, L.C. **Wavelet analysis of ecg map signals.** Engineering in Medicine and Biology society, 1997. Proceedings of the 19th Annual International Conference of the IEEE , v. 1, p. 317-320, 30 Oct-2 Nov 1997.
- [56] VAIDYANATHAN, P. P. **Multirate systems and filter banks.** New Jersey: Prentice Hall, 1993.
- [57] WANG, Y. et al. **A short-time multifractal approach for arrhythmia detection based on fuzzy neural network.** IEEE Transactions on Biomedical Engineering, v. 48, n. 9, p. 989-995, Sep., 2001.
- [58] WATSON, Jamie et al. **Evaluating arrhythmias in ecg signal using wavelet transform.** IEEE Engineering in Medicine and Biology, p. 104-109, 10.2000.
- [59] WEBSTER, J. G. et al. **Medical instrumentation: application and design.** 3 ed. New York: John Wiley & Sons, 1998.
- [60] WIDROW, B. et al. **Adaptive noise canceling: principles and applications.** Proceedings of IEEE. v. 63, n.12, pg. 1692-1716, Dez. 1975.

APÊNDICE A - WAVELETS

A.1 INTRODUÇÃO

É comum definir uma onda (*wave*) como uma função oscilatória no espaço ao longo do tempo [7]. Vários fenômenos, existentes na natureza ou criados pelo homem, apresentam um comportamento ondulatório. A correlação desses fenômenos à morfologia dos sinais ondulatórios relacionados possibilita a extração de informações que facilitam o entendimento e modelagem desses sistemas.

Há várias técnicas desenvolvidas para análise de sinais ondulatórios. A transformada de Fourier (FT – *Fourier Transform*), a transformada de Fourier em janela (STFT - *Short Time Fourier Transform*) e a transformada Wavelet (WT – *Wavelet Transform*) são alguns exemplos.

A análise de Fourier provê uma transformação matemática do sinal no domínio do tempo para o domínio da frequência (FIGURA A.1) através da equação A.1:

$$X(j\omega) = \int_{-\infty}^{\infty} x(t)e^{-j\omega t} dt \quad (\text{A.3})$$



FIGURA A.1 – Transformada de Fourier.
Fonte: MathWorks, 2000.

onde, $x(t)$ é um sinal variante no tempo; ω é a frequência do novo domínio; j representa a parte imaginária de um número complexo e $X(j\omega)$ é a transformada de Fourier de $x(t)$.

Entretanto, essa transformação implica na perda da localização dos eventos temporais, tornando impossível a localização de um determinado evento no instante em que ele ocorre.

A análise de Fourier é especialmente utilizada para fenômenos com componentes periódicos invariantes no tempo, ou estacionários, e baseia-se na representação do sinal em senóides de mesma amplitude e diferentes frequências no intervalo de $-\infty \leq t \leq \infty$.

A STFT utiliza uma técnica (*windowing*) para mapear o sinal no tempo em uma função bidimensional de tempo e frequência (FIGURA A.2). A posição da janela permite a localização no tempo, contudo, a precisão da transformada é limitada, como exposto a seguir.



FIGURA A.2 – Transformada de Fourier em janela.

Fonte: MathWorks, 2000.

A precisão da transformada, como citada anteriormente, refere-se à exatidão da informação em frequência, nos intervalos de tempo definidos pelas janelas, em relação à informação real contida no sinal. A limitação dessa precisão ocorre basicamente devido a duas características do método:

- A janela influencia no trecho do sinal onde ela se posiciona, introduzindo componentes em frequência que se misturam à informação em frequência do sinal, mascarando a existência dessas componentes no sinal analisado.
- O tamanho fixo da janela impõe a mesma resolução tempo-frequência para toda a extensão do sinal, o que ocasiona a perda de informações relevantes nos trechos que necessitam de melhor definição em tempo e/ou em frequência.

A partição do espaço tempo x frequência (ladrilho) observado no gráfico *Time x Frequency* da FIGURA A.2 representa escalas de tempo fixas, no eixo horizontal, definidas pelo posicionamento das janelas ao longo do sinal e escalas em frequência fixas, no eixo vertical, devido à uniformidade da transformada de Fourier.

A WT representa a próxima etapa na técnica de *windowing*, com janelas de tamanho variável (FIGURA A.3).



FIGURA A.3 – Transformada Wavelet .

Fonte: MathWorks, 2000.

A análise wavelet não usa regiões de tempo-frequência, mas regiões de tempo-escala. A relação escala-frequência é representada pela equação A.2:

$$F_a = \frac{F_c}{a \cdot T_s} \quad (\text{A.4})$$

onde: a é a escala; T_s é o período de amostragem; F_c é a frequência central de uma wavelet (Hz) e F_a é a pseudofrequência correspondente a escala a .

A idéia fundamenta-se em associar a uma dada wavelet um sinal puramente periódico de frequência F_c . Dessa forma, a aproximação na pseudofrequência captura as principais oscilações wavelets, logo, sendo uma caracterização simples e conveniente da frequência dominante da wavelet [44].

O o gráfico *Time x Scale* da FIGURA A.3 mostra diferentes tamanhos de janelas de tempo, no eixo horizontal, associados a diferentes escalas da função de base (wavelet), no eixo vertical. Essa disposição tempo-escala permite realçar informações de maneira adequada nas diferentes dimensões de tempo e/ou frequência. Nas seções subseqüentes serão abordados os aspectos relativos à WT.

A.2 SISTEMAS WAVELETS DE PRIMEIRA GERAÇÃO

Um espaço que é particularmente importante em processamento de sinais é chamado de espaço de *Lebesgue* e possui a notação $L^2(\mathbb{R})$ que representa o espaço de todas as funções com convergência quadrática. Nesse espaço, $\psi(t)$ é uma função com integral bem definida do quadrado do módulo dela mesma. L significa a *integral de Lebesgue*, 2 denota a integral do quadrado do módulo da função e \mathbb{R} indica que a variável independente de integração, t , é um número real.

Nas próximas seções serão apresentadas as transformadas wavelets contínua (CWT – *Continuous Wavelet Transform*) e discreta (DWT – *Discrete Wavelet Transform*).

A.2.1 Transformada Wavelet Contínua

Antes de abordar diretamente a CWT serão apresentados alguns conceitos impreteríveis ao entendimento da transformada em si. A definição de wavelet aqui está embasada no método de Fourier, como apresentado abaixo.

Seja $\psi(t)$ uma função (real ou complexa) no $L^2(\mathbb{R})$. A função $\psi(t)$ é uma wavelet se e somente se sua transformada de Fourier $\Psi(\omega)$ satisfaz a condição de admissibilidade (A.3) [15] :

$$\int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega = C_{\psi} < \infty \quad (\text{A.5})$$

Essa condição implica que (A.4) [7]:

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (\text{A.6})$$

o que mostra que $\psi(t)$ possui média zero⁵, ou seja, é oscilatória.

Dessa forma, pode-se simplificar a definição de wavelet da seguinte maneira:

“Uma wavelet é definida como uma onda de duração efetivamente limitada e que possui média zero.”
(Cohen, 1996 – Tradução Nossa)

Existem diversas wavelets intituladas *básicas* ou *mães* (FIGURA A.4), que apresentam particularidades matemáticas, possibilitando realçar características importantes na análise de diferentes sinais.

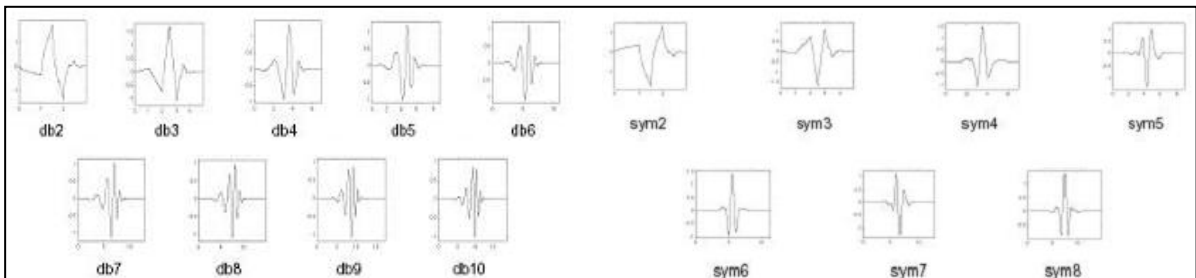


FIGURA A.4 – Wavelets Básicas: Daubechies (db) e Symlets (sym).
Fonte: MathWorks, 2000.

⁵Como a wavelet, por definição, possui média zero, a transformada wavelet, que será vista mais adiante, remove a média do sinal do espaço de transformada [57].

A CWT é uma operação linear que decompõe um sinal em componentes que aparecem em diferentes escalas (ou resoluções) [7], [38], [47].

A função $\psi(t)$ para diferentes escalas (a, b) e posições (τ) é expressa como (A.5):

$$\psi_{a,b,\tau}(t) = |a|^{-b} \psi\left(\frac{t-\tau}{a}\right) \quad (\text{A.7})$$

onde a é o fator de escala horizontal ($a > 0$), b é o fator de escala vertical, $|\cdot|$ denota o valor absoluto e $|a|^{-b}$ é usado para normalização da energia.

A CWT efetuada sobre uma determinada função $f(t) \in L^2(\mathbb{R})$, nas escalas a, b e posição τ é dada por (A.6):

$$W_f(a, b, \tau) = \left\langle f(t), \psi_{a,b,\tau}(t) \right\rangle = \int_{-\infty}^{\infty} f(t) \psi_{a,b,\tau}^*(t) dt \quad (\text{A.8})$$

onde: $\langle \cdot \rangle$ denota o produto interno; $*$ representa o conjugado complexo.

Substituindo (A.5) em (A.6) tem-se (A.7):

$$W_f(a, b, \tau) = \int_{-\infty}^{\infty} f(t) |a|^{-b} \psi\left(\frac{t-\tau}{a}\right) dt \quad (\text{A.9})$$

Esse tipo de transformação satisfaz o critério de conservação da energia, e o sinal original pode ser reconstruído a partir da CWT pela aplicação da CWT inversa.

O fator de escala b não interfere na relação entre os coeficientes de correlação da CWT por ser constante ao longo de toda a transformação. Usualmente adota-se $b = \frac{1}{2}$.

A TABELA A.1 apresenta o comportamento da wavelet para diferentes valores de escalas [29] e a FIGURA A.5 apresenta graficamente o comportamento da wavelet em diferentes escalas.

TABELA A.1 – Comportamento da wavelet para diferentes valores de escala		
a	b	$\psi_{a,b,\tau}$
< -1	< 0	Reflexão e Expansão
	≥ 0	Reflexão e Compressão
-1	\forall	Reflexão
$(-1,0)$	< 0	Reflexão e Compressão
	≥ 0	Reflexão e Expansão
0	\forall	Não Existe
$(0,1)$	< 0	Compressão
	≥ 0	Expansão
1	\forall	Sem Alteração
> 1	< 0	Expansão
	≥ 0	Compressão




FIGURA A.5 – Wavelet Escalada.
Fonte: MathWorks, 2000.

A diminuição de a (equivalente, por analogia, a uma aproximação microscópica em frequência do sinal) torna a wavelet mais sensível aos componentes de alta frequência, enquanto o aumento de a (equivalente ao afastamento microscópico em frequência) enfatiza os componentes que variam lentamente. Dessa forma, para a transformada wavelet, o *princípio da incerteza de Heisenberg* impõe um limite para a relação tempo-frequência estabelecendo um acordo entre as resoluções no tempo e na frequência (quando uma aumenta, a outra diminui, e vice-versa), o que não ocorre na STFT[55]. Ou ainda, a transformada wavelet possui melhor resolução de tempo para altas frequências enquanto a transformada de Fourier apresenta a mesma resolução no tempo para todas as frequências [55].

A resolução em frequência na transformada wavelet pode ser expressa como (A.8) [58]:

$$\Delta f_n = \frac{f_s}{2^{n+1}} \quad (\text{A.10})$$

onde: f_s é a taxa de amostragem e n é o nível da decomposição wavelet.

O procedimento para aplicação da transformada é descrito abaixo:

1. Efetua-se o produto interno entre a wavelet escalada e cada trecho do sinal obtendo o coeficiente de correlação C , que representa o grau de similaridade entre a wavelet escalada e a parte do sinal comparada (FIGURA A.6-a).
2. Desloca-se a wavelet para a direita e repete-se o passo anterior. Essa etapa continua enquanto existir amostras do sinal (FIGURA A.6-b).




FIGURA A.6 – (a) Etapa 1 (b) Etapa 2 (c) Repete a etapa 2 ao longo de todo o sinal.
Fonte: MathWorks, 2000.

3. Escala-se a wavelet e repete-se os passos anteriores (FIGURA A.7).




FIGURA A.7 – Etapa 3.
Fonte: MathWorks, 2000.

Cada nível da decomposição representa uma escala diferente da wavelet básica. A FIGURA A.8 apresenta a aplicação da transformada wavelet em oito escalas distintas sobre um sinal de eletrocardiograma normal.

Os rótulos a_n e d_n representam os coeficientes de aproximação e de detalhe, respectivamente, de cada nível n e serão discutidos a seguir.




FIGURA A.8 – Resultado da decomposição wavelet em 8 níveis de um ECG normal.

(a) Coeficientes em cada nível. (b) Árvore da decomposição.

Fonte: MathWorks, 2000.

A transformada wavelet inversa é obtida pela aplicação da equação A.9:

$$f(t) = K^{-1} \iint \frac{\psi_{a,b,\tau}(t) \cdot W_f(a,b,\tau)}{a^2} da d\tau \quad (\text{A.11})$$

onde, ω representa a frequência, $f(t)$ o sinal obtido pela transformação inversa e K é dado por (A.10):

$$K = \int \frac{|\mathfrak{F}\{\psi(t)\}|^2}{|\omega|} d\omega < \infty \quad (\text{A.12})$$

A.2.2 Transformada Wavelet Discreta

Um sinal ou função $f(t)$ pertencente a um espaço vetorial S pode ser melhor analisado, descrito ou processado se for expresso como uma decomposição linear (A.11):

$$f(t) = \sum_k c_k \psi_k(t) \quad (\text{A.13})$$

onde k é inteiro, c_k são os coeficientes de expansão reais e $\psi_k(t)$ é um conjunto de expansão de S .

Se a representação é única, ou seja, se existe apenas um conjunto c_k que gera $f(t)$, então o conjunto $\psi_k(t)$ é uma base para o espaço vetorial S [7].

Se a base é ortogonal (A.12), ou seja,

$$\langle \psi_k(t), \psi_l(t) \rangle = 0 \quad \forall k \neq l \quad k, l \in Z \quad (\text{A.14})$$

então os coeficientes podem ser calculados pelo produto interno (A.13):

$$c_k = \langle f(t), \psi_k(t) \rangle \quad (\text{A.15})$$

Se a base for não ortogonal então uma *base dual* $\tilde{\psi}_k(t)$ existe tal que (A.14):

$$c_k = \langle f(t), \tilde{\psi}_k(t) \rangle \quad (\text{A.16})$$

A base dual pode ser construída com as linhas de $\psi_k^{-1}(t)$.

Uma base $\psi_k(t)$ é biortogonal se cada elemento da base for ortonormal ao seu correspondente elemento do conjunto de expansão $\tilde{\psi}_k(t)$.

Uma base é ortonormal se (A.15):

$$\langle \psi_k(t), \psi_l(t) \rangle = \delta(k - l) \quad (\text{A.17})$$

onde, $\delta(\cdot)$ é a função delta de Kronecker.

Outras considerações podem ser feitas a respeito das bases wavelets. A definição de base condicional e incondicional é uma propriedade importante uma vez que mostra porque um sistema de bases é melhor para uma classe particular de sinais e porque um sistema wavelet é bom para uma grande variedade de classes de sinais [7].

Seja $\psi_k(t)$ o conjunto base de F . Se cada função $f(t) \in F$ possui uma única representação dada por (A.16):

$$f(t) = \sum_k m_k c_k \psi_k(t) \quad (\text{A.18})$$

onde m_k é o fator de normalização, e se $\forall f(t) \in F$ o somatório com $k \rightarrow \infty$ para $|m_k| \leq 1$ converge, então a base $\psi_k(t)$ é dita incondicional. Porém, se a convergência depende de $m_k = 1$ para algum $f(t)$, então a base é dita condicional.

Bases incondicionais, em processamento de sinais, têm a propriedade de serem quase ótimas para aproximação de funções, bem como provêem condições para eficiente e efetiva compressão, detecção e eliminação de ruídos na transformada wavelet [7]. É a melhor escolha a se fazer quando se conhece muito pouco sobre um sinal [7].

Para a expansão wavelet, um sistema de dois parâmetros, um para escala (selecionado por j) e outro para a posição (selecionado por k), é construído a partir de (A.11), formando (A.17):

$$f(t) = \sum_k \sum_j c_{j,k} \psi_{j,k}(t) \quad (\text{A.19})$$

onde $\psi_{j,k}(t)$ são as funções de expansão wavelet que usualmente formam uma base ortogonal. O conjunto de coeficientes $c_{j,k}$ é chamado de transformada wavelet discreta (DWT) de $f(t)$ e (A.17) é a transformada inversa.

Observe que $\psi_{j,k}(t)$ é dada pela equação (A.5) para $b = 1/2$, $a = 2^{-j}$ e $\tau = \frac{k}{a}$, logo (A.18):

$$\psi_{j,k}(t) = 2^{j/2} \psi(2^j t - k) \quad j, k \in Z \quad (\text{A.20})$$

Utilizando a idéia de multiresolução (A.17) é necessário definir uma função de escalamento (ξ) que vá possibilitar, mais adiante, a elaboração da definição da transformada wavelet em termos de coeficientes de aproximação e de detalhe.

Como exemplo, a FIGURA A.9 apresenta a função de escalamento Haar, a mais simples, consistindo apenas de um pulso de largura e amplitude unitária.




FIGURA A.9 – A função de escala Haar.

O conjunto de funções de escalamento é definido em termos de translações inteiras da função de escala básica (A.19). Assim:

$$\xi_k(t) = \xi(t - k) \quad k \in \mathbb{Z}, \xi \in L^2 \quad (\text{A.21})$$

Antes de prosseguir é necessário conhecer as seguintes definições:

Seja o espaço vetorial S que representa o conjunto de todas as funções $f(\cdot)$ que podem ser escritas na forma (A.20):

$$f(t) = \sum_k a_k \xi_k(t) \quad (\text{A.22})$$

onde, $\xi_k(t)$ é uma base de expansão do espaço vetorial S e a_k são os coeficientes de expansão reais, então, S é referido como o conjunto expansão (*span*) do conjunto base $\xi_k(t)$.

Em alguns casos o espaço de sinais necessário é aquele que promove o fechamento do espaço expandido pelo conjunto base, ou seja, delimita a fronteira (limite) desse espaço [7]. Desse modo, o espaço contém não apenas todos os sinais que podem ser expressos por uma combinação linear das funções de base, mas também os sinais que são o limite dessa expansão infinita [7]. O fechamento do espaço é, geralmente, representado por uma barra sobre o conjunto de expansão. Assim, o subespaço de $L^2(\mathbb{R})$, v_0 , expandido pela função de escalamento, é definido como (A.21):

$$v_0 = \overline{\text{Span}_k \{\xi_k^\zeta(t)\}} \quad k \in Z \quad (\text{A.23})$$

Isso significa que $f(t)$ é uma combinação linear da base de expansão (A.22):

$$f(t) = \sum_k a_k \xi_k^\zeta(t) \quad \forall f(t) \in v_0 \quad (\text{A.24})$$

O tamanho do espaço expandido é alterado pela mudança da escala de tempo da função de escalamento (A.23):

$$\xi_{j,k}^\zeta(t) = 2^{j/2} \xi(2^j t - k) \quad j, k \in Z \quad (\text{A.25})$$

Dessa maneira, os espaços expandidos v_j podem ser expressos como (A.24):

$$v_j = \overline{\text{Span}_k \{\xi_{j,k}^\zeta(t)\}} \quad k \in Z \quad (\text{A.26})$$

Para $j > 0$, a expansão pode ser maior desde que $\xi_{j,k}(t)$ seja mais estreito e esteja transladado em pequenos passos, o que pode representar os detalhes mais finos. Para $j < 0$, $\xi_{j,k}(t)$ está mais largo e é transladado em passos longos [7].

As funções de escalamento com conjunto suporte maior (mais largas) podem representar apenas as informações grosseiras e o espaço de expansão é pequeno [7].

Baseado nas idéias citadas acima, é possível formular os princípios da análise em multiresolução (FIGURA A.10). Que são:

$$1^\circ \text{ Princípio (A.25):} \quad \begin{cases} v_j \subset v_{j+1} & \forall j \in Z \\ v_{-\infty} = \{0\} & v_\infty = L^2 \end{cases} \quad (\text{A.27})$$




FIGURA A.10 – Espaço vetorial expandido pela função de escalamento.

2º Princípio: O espaço que contém sinais de alta resolução também conterá os sinais de baixa resolução (A.26):

$$f(t) \in v_j \quad \Leftrightarrow \quad f(2t) \in v_{j+1} \quad (\text{A.28})$$

Dessa forma, $\xi(t)$ está em v_0 e em v_1 , e $\xi(2t)$ está em v_1 , mas não em v_0 conforme (A.26). Isso significa que $\xi(t)$ pode ser expresso como (A.27):

$$\xi(t) = \sum_n h(n) \sqrt{2} \xi(2t - n) \quad n \in \mathbb{Z} \quad (\text{A.29})$$

onde os coeficientes $h(n)$ são uma seqüência de números reais ou complexos chamados de coeficientes da função de escalamento⁶ e $\sqrt{2}$ mantém a norma da função de escalamento com a escala de dois [7].

A equação (A.27) é fundamental para a teoria das funções de escalamento e é, de algum modo, análoga a uma equação diferencial com coeficientes $h(n)$ e solução $\xi(t)$, que pode ou não existir e ser única [7].

A equação (A.27) é denominada de várias formas: equação de refinamento, equação de análise multiresolução, equação de dilatação ou equação de escala de dois.

Há vantagens em ter as funções de escalamento ortogonais às wavelets, como a simplicidade no cálculo dos coeficientes de expansão e a divisão da energia do sinal no domínio da transformada wavelet (teorema de Parseval) [7].

Definindo W_j como o complemento ortogonal de v_j e v_{j+1} é possível definir o subespaço expandido wavelet (FIGURA A.11) como (A.28):

$$v_j = v_0 \oplus W_0 \oplus W_1 \oplus L \oplus W_{j-1} \quad (\text{A.30})$$

uma vez que (A.29):

$$v_0 \perp W_0 \perp W_1 \perp L \perp W_j \quad (\text{A.31})$$

⁶ Ou filtro de escalamento, ou vetor de escalamento.

O termo \oplus representa uma relação entre subespaços e o termo \perp denota a ortogonalidade entre eles.




FIGURA A.11 – Funções de escalamento e espaços vetoriais wavelet.

Dessa forma, o espaço L^2 pode ser descrito como (A.30):

$$L^2 = \dots \oplus W_{-2} \oplus W_{-1} \oplus W_0 \oplus W_1 \oplus W_2 \oplus \dots \quad (\text{A.32})$$

Conforme (A.25), daí (A.31):

$$W_{-\infty} \oplus \dots \oplus W_{-1} = v_0 \quad (\text{A.33})$$

Substituindo (A.31) em (A.30) tem-se (A.32) e (A.33)

$$L^2 = v_0 \oplus W_0 \oplus W_1 \dots \quad (\text{A.34})$$

e

$$L^2 = v_j \oplus W_j \oplus W_{j+1} \dots \quad (\text{A.35})$$

isso demonstra que a escala do espaço de escalamento (v_j) além de poder ser escolhida arbitrariamente ela representa os detalhes mais grosseiros (informações de baixa frequência) de interesse em um sinal [7]. Na prática é usual escolher a escala que melhor represente os detalhes de interesse do sinal.

A relação estabelecida pela equação (A.32) pode ser representada convenientemente por um banco de filtros FIR (*Finite Impulse Response*) como mostra a FIGURA A.12. Isso foi provado nos estudos desenvolvidos por Mallat [37] e Daubechies [16].




FIGURA A.12 – Bandas de frequência do banco de filtros usado para decomposição wavelet nos espaços definidos pela equação A.32

Assim, desde que as wavelets residem no espaço expandido (v_j) pelas funções de escala, ou seja ($W_j \subset v_{j+1}$), é possível representá-las por uma soma balanceada de funções de escala deslocadas (A.34), conforme (A.26) e (A.27):

$$\psi(t) = \sum_n h_l(n) \sqrt{2} \xi(2t - n) \quad n \in Z \quad (\text{A.36})$$

para algum conjunto de coeficientes $h_l(n)$.

Uma vez entendida a relação definida pela equação (A.33) é possível construir um conjunto de funções $\xi(t)$ e $\psi_{j,k}(t)$ expansível para todo $L^2(\mathbb{R})$ a partir de (A.17).

Assim, qualquer função $f(t) \in L^2(\mathbb{R})$ pode ser escrita como uma série de expansão em termos da função de escalamento e das wavelets (A.35).

$$f(t) = \sum_{j=0}^{\infty} \sum_{k=-\infty}^{\infty} a_j(k) \xi_{j,k}(t) + \sum_{j=0}^{\infty} \sum_{k=-\infty}^{\infty} d_j(k) \psi_{j,k}(t) \quad (\text{A.37})$$

Os coeficientes a_j (aproximação) e d_j (detalhe) na expansão wavelet (A.35) são denominados de coeficientes da transformada wavelet discreta do sinal $f(t)$ e são obtidos por (A.36):

$$\begin{aligned} a_j(k) &= \langle f(t), \xi_{j,k}(t) \rangle \\ d_j(k) &= \langle f(t), \psi_{j,k}(t) \rangle \end{aligned} \quad (\text{A.38})$$

A partir da equação (A.27) para $\xi(2^j t - k)$ e $m = 2k + n$ temos (A.37):

$$\xi(2^j t - k) = \sum_m h(m - 2k) \sqrt{2} \xi(2^{j+1} t - m) \quad (\text{A.39})$$

Considerando (A.25), (A.26), (A.35) e (A.36) chega-se a (A.38) e (A.39):

$$a_j(k) = \sum_m h(m - 2k) a_{j+1}(m) \quad (\text{A.40})$$

$$d_j(k) = \sum_m h_1(m - 2k) a_{j+1}(m) \quad (\text{A.41})$$

As equações (A.38) e (A.39) mostram que o escalamento e os coeficientes wavelets em diferentes níveis de escala podem ser obtidos pela convolução dos coeficientes de expansão na escala j e pelos coeficientes de recursão revertidos no tempo, $h(-n)$ e $h_1(-n)$, (coeficientes do filtro FIR) seguido da decimação de dois, para gerar os coeficientes de expansão do próximo nível $(j - 1)$ [7].

A estrutura descrita no parágrafo anterior, e representada na FIGURA A.13, é usada para implementar o algoritmo de Mallat [37].




FIGURA A.13 – Banco de análise de duas bandas.

A FIGURA A.14 apresenta graficamente a transformação descrita na FIGURA A.13.

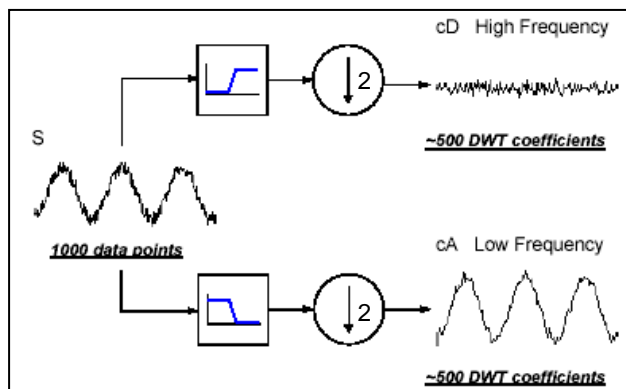


FIGURA A.14 – Exemplo de comportamento do sinal após passar por um estágio da transformação wavelet.

Fonte: MathWorks, 2000.

A decimação é definida como um processo de eliminação das amostras de um sinal com o objetivo imediato de redução da taxa de amostragem [21]. Normalmente o processo de decimação é precedido por uma filtragem para redução da largura de banda do sinal [21].

A filtragem, aplicada às amostras do sinal na transformação wavelet, promove a redução da largura de banda, o que permite o uso da decimação para eliminação das amostras desnecessárias, reduzindo a taxa de Nyquist e mantendo a ortogonalidade da base [7], [56] e [21].

A FIGURA A.15 mostra a aplicação das equações (A.38) e (A.39) em três estágios juntamente com os respectivos espaços de expansão. As bandas de frequência para a árvore de análise se encontram na FIGURA A.12.

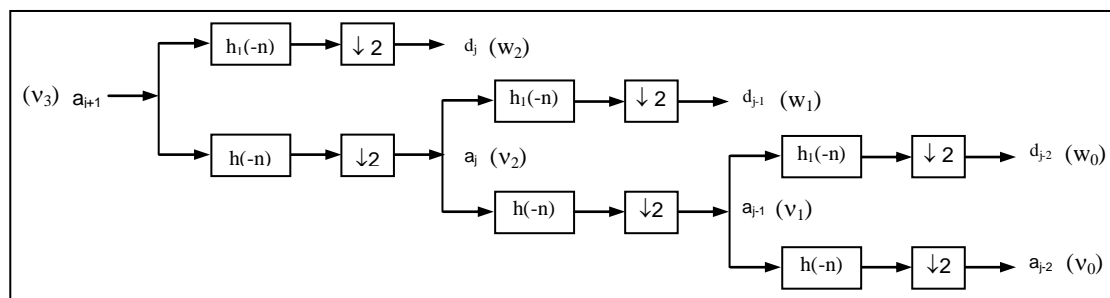


FIGURA A.15 – Árvore de análise de duas bandas e três estágios.
Fonte: Burrus, 1998 (adaptado).

A FIGURA A.16 apresenta, de forma ilustrativa a transformação descrita na FIGURA A.15.

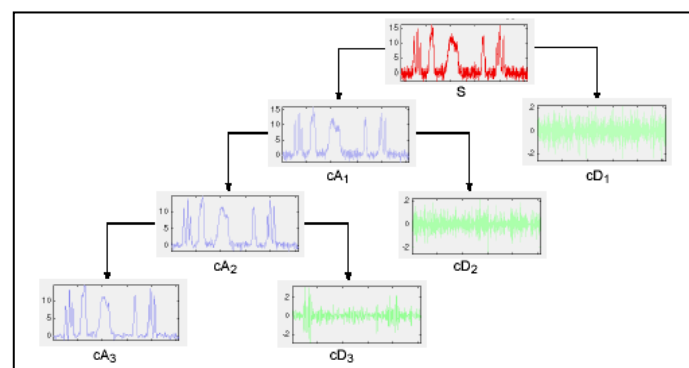


FIGURA A.16 – Visualização dos coeficientes de aproximação (cA_n) e detalhe (cD_n) em três níveis de decomposição.
Fonte: MathWorks, 2000.

Assim, de acordo com a FIGURA A.15 e pelas equações (A.38) e (A.39) obtém-se (A.40):

$$a_{j+1}(k) = \sum_m a_j(m)h(k - 2m) + \sum_m d_j(m)h_l(k - 2m) \quad (\text{A.42})$$

A relação entre h (coeficientes do filtro FIR passa baixa) e h_l (coeficientes do filtro FIR passa alta) das equações (A.27), (A.34), (A.37), (A.38) e (A.39) para um conjunto de amostras finito (N) e par é dada por (A.41):

$$h_l(n) = (-1)^n h(N - 1 - n) \quad (\text{A.43})$$

A dedução detalhada da equação (A.41) é complexa e bastante extensa e foi omitida desse trabalho, contudo uma abordagem completa se encontra no apêndice da referência [7].

Observe que a expansão, ao longo da árvore (FIGURA A.15), ocorre apenas nos vetores dos coeficientes de aproximação, no entanto, existe uma outra abordagem, definida como *wavelet packet*, em que a decomposição do sinal se processa nos dois vetores de coeficientes (FIGURA A.17).

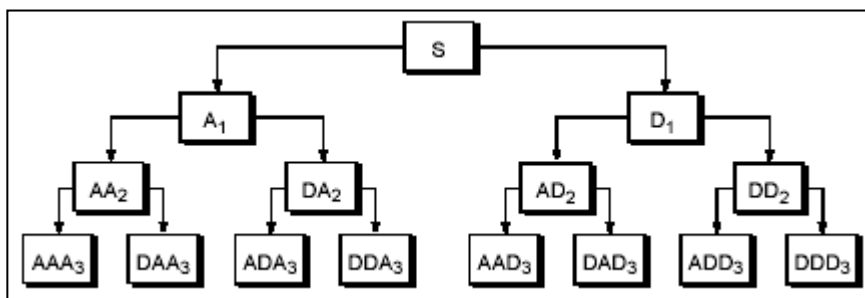


FIGURA A.17 – Decomposição wavelet packet em três níveis.
Fonte: MathWorks, 2000.

A reconstrução de um sinal a partir de seus coeficientes wavelet ocorre pela aplicação de filtros de reconstrução que são intrinsecamente relacionados aos filtros de decomposição utilizados (FIGURA A.19).

No processo de reconstrução, a operação inversa a decimação, conhecida como superamostragem (*upsample*), ocorre com a inserção de zeros entre cada par⁷ de coeficientes de cada nível (FIGURA A.18).




FIGURA A.18 – Superamostragem de um sinal por um fator de 2.

Fonte: MathWorks, 2000.

O presente trabalho trata de um sistema para reconhecimento de padrões, não se preocupando com o aspecto da reconstrução do sinal decomposto, uma vez que esse procedimento se faz desnecessário. Portanto, o desenvolvimento teórico relativo à reconstrução não será abordado aqui.




FIGURA A.19 – Análise (decomposição) e síntese (reconstrução) de um sinal (S) com 1000 amostras. As setas para baixo representam a decimação diádica e as setas para cima a superamostragem diádica.

Fonte: MathWorks, 2000.

Uma outra maneira de se calcular a transformada wavelet discreta é através das operações de *lifting*. A *lifting* não utiliza o método de Fourier (eq. A.3), logo, não necessariamente translada ou dilata uma função, além de poder ser aplicada a problemas mais gerais, como por exemplo, quando a amostragem não é uniforme [7].

⁷ Utiliza-se o par de amostras uma vez que se utiliza, normalmente, a decomposição em duas partes (coeficientes de detalhe e de aproximação).

A.3 SISTEMAS WAVELETS DE SEGUNDA GERAÇÃO: A *LIFTING* WAVELET

O esquema *lifting* é um método para construção de wavelets biortogonais [52]. A principal diferença em relação à construção clássica é a definição independente do método de Fourier [52].

A *lifting* wavelet possui as seguintes vantagens com relação às wavelets de primeira geração [52]:

- Rápida implementação da transformada, uma vez que o esquema *lifting* proporciona um ótimo uso das similaridades entre os filtros passa baixa e passa alta, aumentando a velocidade do cálculo.
- Não necessita de memória auxiliar (por isso a *lifting* é dita *in place*). As operações são efetuadas e armazenadas diretamente no vetor de amostras do sinal.
- A transformada inversa pode ser imediatamente obtida simplesmente desfazendo as operações da transformação direta.
- É um modo natural de introduzir os conceitos de wavelets para alunos.
- O esquema *lifting* pode ser usado em situações onde a transformada de Fourier é indisponível, ou inadequada.

Com referência ao último tópico, pode-se relacionar alguns exemplos onde a transformada de Fourier é inadequada [51]:

- Análise de intervalos do sinal sem introdução de artefatos de contorno.
- Análise de dados intrinsecamente inseridos em curvas ou superfícies sem necessidade de parametrização.
- Diagonalização de operadores diferenciais e aproximações balanceadas necessitam de uma base adaptada às medidas de balanceamento.

- Problemas que possuem amostragem irregular.

Uma operação *lifting* é definida como uma transformação, efetuada sobre uma sequência de números, que utiliza o cálculo de médias e de diferenças entre cada par de amostras consecutivas dessa sequência.

Seja s um conjunto contendo amostras sequenciais de um sinal:

$$s = \{a_1 \ b_1 \ a_2 \ b_2 \ ... \ a_n \ b_n\} \quad \text{onde: } n = 2^{j-1}; j = 1, 2, 3...$$

Os cálculos das médias e das diferenças são efetuados para cada par $(a_k \ b_k)$ de s (A.42):

$$\begin{aligned} \mu_k &= \frac{a_k + b_k}{2} \\ \gamma_k &= \mu_k - b_k = \frac{a_k - b_k}{2} \end{aligned} \quad (\text{A.44})$$

caracterizando a operação de *lifting*.

As operações de *lifting* podem ser repetidas nos resultados $(\mu_k \ \gamma_k)$ determinando um conjunto de níveis de operações que caracterizam a transformada *lifting* do sinal s .

A *lazy wavelet* é uma função muito simples, mas que possui as propriedades formais das wavelets de segunda geração (FIGURA A.20).

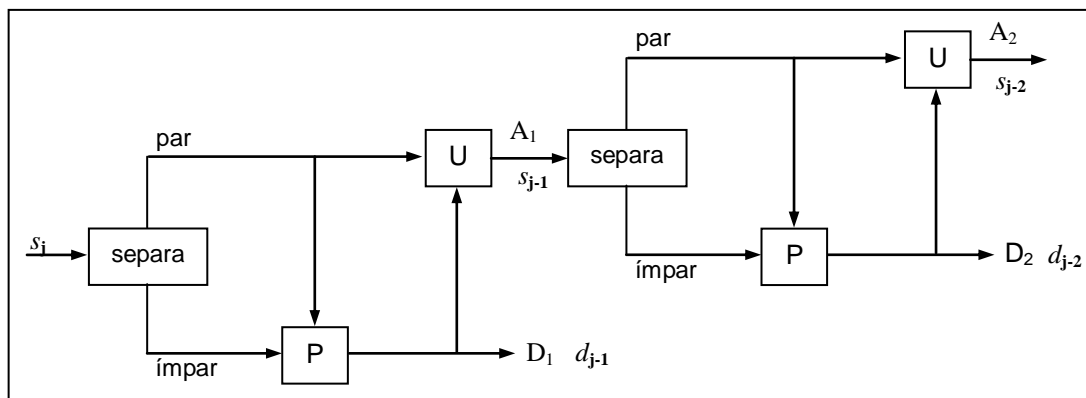


FIGURA A.20 – Decomposição Lazy Wavelet.

No esquema apresentado, há a separação das amostras pares das ímpares, seguida das etapas de predição (P) e atualização (U), onde ocorrem as seguintes operações (A.43):

$$\begin{aligned}
 P : \quad impar_{j-1} &= \frac{(impar_j + par_j)}{2} \\
 U : \quad par_{j-1} &= impar_{j-1} - par_j = \frac{(impar_j - par_j)}{2}
 \end{aligned}
 \tag{A.45}$$

Observe que (A.43) efetua exatamente as mesmas operações de (A.42) e j informa qual o nível da decomposição wavelet, conforme a FIGURA A.20.

Exemplo: Seja $s = \{56 \ 40 \ 8 \ 24 \ 48 \ 48 \ 40 \ 16\}$. O cálculo da transformada *lazy* de s pela aplicação sucessiva das operações *lifting* (A.42) se encontra na FIGURA A.21, onde: A_m representa o vetor com as amostras de aproximação do nível m e D_m representa o vetor com as amostras de detalhe do nível m .

s	<table> <tr> <td>56</td> <td>40</td> <td>8</td> <td>24</td> <td>48</td> <td>48</td> <td>40</td> <td>16</td> </tr> </table>								56	40	8	24	48	48	40	16
56	40	8	24	48	48	40	16									
	A_1				D_1											
nível 1	<table> <tr> <td>48</td> <td>16</td> <td>48</td> <td>28</td> <td>8</td> <td>-8</td> <td>0</td> <td>12</td> </tr> </table>								48	16	48	28	8	-8	0	12
48	16	48	28	8	-8	0	12									
	A_2				D_2											
nível 2	<table> <tr> <td>32</td> <td>38</td> <td>16</td> <td>10</td> </tr> </table>								32	38	16	10				
32	38	16	10													
	A_3				D_3											
nível 3	<table> <tr> <td>35</td> <td>-3</td> </tr> </table>								35	-3						
35	-3															
$a_1 = 56; b_1 = 40 \Rightarrow \mu_1 = 48; \gamma_1 = 8$ $a_2 = 8; b_2 = 24 \Rightarrow \mu_2 = 16; \gamma_2 = -8$																

FIGURA A.21 – Cálculo da Transformada *Lifting*.

A transformada *lifting* inversa é efetuada pelas operações aplicadas ao vetor de amostras formado da concatenação dos vetores $\{A_3 \ D_3 \ D_2 \ D_1\}$ (A.44).

$$\begin{aligned}
 a_k &= \mu_k + \gamma_k \\
 b_k &= \mu_k - \gamma_k
 \end{aligned}
 \tag{A.46}$$

Analogamente, tem-se (A.45):

$$\begin{aligned}
 U : \quad impar_j &= impar_{j-1} + par_{j-1} \\
 P : \quad par_j &= impar_{j-1} - par_{j-1} = impar_j - 2 \times par_{j-1}
 \end{aligned}
 \tag{A.47}$$

A FIGURA A.22 apresenta o diagrama esquemático da transformada *lazy wavelet* inversa.

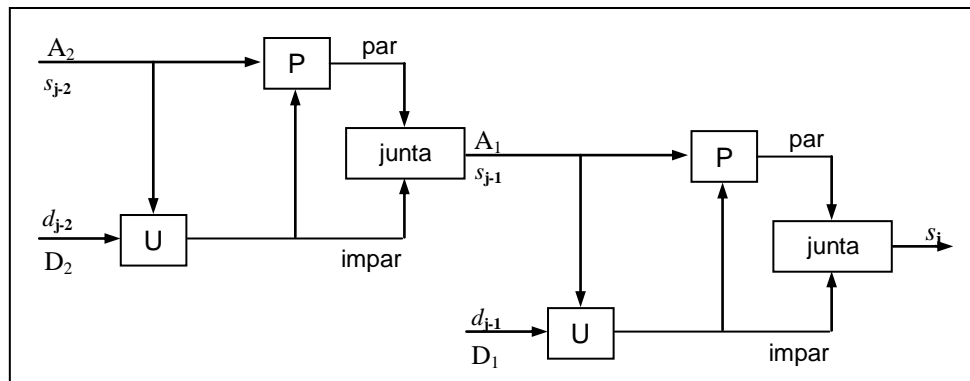


FIGURA A.22 – Composição *Lazy wavelet* inversa.

Exemplo: Seja $Ts = \{35 \ -3 \ 16 \ 10 \ 8 \ -8 \ 0 \ 12\}$. O cálculo da transformada *lifting* inversa de Ts pela aplicação sucessiva das operações *lifting* inversas (A.44) se encontra na FIGURA A.23. O estágio denominado “alterna” foi incluído no esquema apenas para facilitar o entendimento das operações no modelo, alternando as amostras pares das ímpares.

	A_3	D_3	
nível 3	35	-3	
	A_2	D_2	
nível 2	32	38	16 10
	alterna		
	32	16	38 10
	A_1	D_1	
nível 1	48	16	48 28 8 -8 0 12
	alterna		
	48	8	16 -8 48 0 28 12
s	56	40	8 24 48 48 40 16
	$\mu_2 = 32; \gamma_2 = 16 \Rightarrow a_2 = 48; b_2 = 16$ $\mu_3 = 38; \gamma_3 = 10 \Rightarrow a_3 = 48; b_3 = 28$		

FIGURA A.23 – Cálculo da Transformada *Lazy* Inversa.

A transformada *lifting* inversa também é *in place* [27].

Existem várias formas de se efetuar a predição de amostras na transformada *lifting*. Até agora, a explanação teve em vista a introdução dos conceitos e características dessa transformação e a utilização de um método simples para predição se faz mais conveniente.

Na *lifting* Haar (*Lazy*) a predição foi baseada na interpolação linear das amostras vizinhas ao ponto de transformada (FIGURA A.24) o que torna crucial a correção da diferença entre o sinal predito e o real (A.46).

$$d_{j-1}[n] = s_j[2n+1] - \frac{1}{2}(s_j[2n] + s_j[2n+2]) \quad (\text{A.48})$$

De acordo com Jensen [27], a não causalidade observada na equação acima é compensada substituindo-se por zeros as amostras inexistentes, ou efetuando-se um atraso nas amostras de entrada, armazenando-as em um *buffer*.

A não causalidade existente nas equações subseqüentes incorrerão ao mesmo mecanismo apresentado no parágrafo anterior.




FIGURA 3.24 – Predição linear.

Existem várias formas de se efetuar a predição na transformada *lifting*, uma delas é proposta por [27] e consiste em considerar dois valores consecutivos de correção das diferenças obtidas (A.47):

$$s_{j-1}[n] = s_j[2n] + A(d_{j-1}[n-1] + d_{j-1}[n]) \quad (\text{A.49})$$

onde A é uma constante a ser calculada.

Antes de continuar é necessário conhecer uma importante propriedade da transformada *lifting*: para qualquer seqüência s de tamanho 2^j a média dos valores de cada subseqüência da decomposição wavelet é a mesma e é dada pela equação A.48:

$$E_s = 2^j \sum_{n=0}^{2^j-1} s_j[n] \quad (\text{A.50})$$

Assim, utilizando (A.49):

$$s_{j-1}[n] = \frac{1}{2} (s_j[2n] + s_j[2n+1]) \quad (\text{A.51})$$

tem-se (A.50)

$$\sum_{n=0}^{2^{j-1}-1} s_{j-1}[n] = \frac{1}{2} \sum_{n=0}^{2^{j-1}-1} (s_j[2n] + s_j[2n+1]) = \frac{1}{2} \sum_{n=0}^{2^j-1} s_j[n] \quad (\text{A.52})$$

que pode ser generalizada para (A.51):

$$\sum_n n s_{j-1}[n] = \frac{1}{2} \sum_n n s_j[n] \quad (\text{A.53})$$

Retomando o desenvolvimento para o cálculo de A, a substituição da equação (A.46) na (A.47) resulta em (A.52) [27]

$$\sum_n s_{j-1}[n] = (1 - 2A) \sum_n s_j[2n] + 2A \sum_n s_j[2n+1] \quad (\text{A.54})$$

que para satisfazer (A.51) deve possuir $A = 1/4$.

Pode-se dizer que a transformação preserva o primeiro momento⁸ da sequência [27].

A notação simplificada considera um sinal infinito, entretanto, o uso de sinais finitos é perfeitamente aplicável com o complemento de zeros no início e fim das amostras do sinal, como citado anteriormente.

Adequando-se a notação, podem-se considerar amostras finitas sem perda dos preceitos estabelecidos no desenvolvimento matemático.

Uma importante transformada *lifting* é a baseada no filtro interpolador *Daubechies* de quarta ordem (A.53) e (A.54):

$$d_{j-1}[n] = \sum_{k=0}^3 \beta_k s_j[2n+1-k] \quad (\text{A.55})$$

$$s_{j-1}[n] = \sum_{k=0}^3 \alpha_k s_j[2n+k] \quad (\text{A.56})$$

⁸ A média é chamada de *momento zero* da sequência.

onde α são os coeficientes de escalamento de Daubechies de fase mínima já normalizados [16]. Os coeficientes β são obtidos pela inversão dos sinais e da ordem do vetor de coeficientes α .

A transformada *lifting* inversa é obtida pelas operações (A.55) e (A.56):

$$s_j[2n] = 4\alpha_0 s_{j-1}[n] + \frac{\alpha_2}{\alpha_3} s_j[2n+1] + 4\alpha_2 d_{j-1}[n+1] \quad (\text{A.57})$$

$$s_j[2n+1] = \sum_{k=0}^l \alpha_k d_{j-1}[n+k] + \alpha_{k+l} s_{j-1}[n-k] \quad (\text{A.58})$$

Outra transformada muito utilizada e conhecida como transformada de Haar (ou *Lazy wavelet*), tem em sua forma direta as seguintes operações (A.57) e (A.58):

$$d_{j-1}[n] = \frac{\sqrt{2}}{2} (s_j[2n+1] - s_j[2n]) \quad (\text{A.59})$$

$$s_{j-1}[n] = \frac{\sqrt{2}}{2} (s_j[2n+1] + s_j[2n]) \quad (\text{A.60})$$

e inversa (A.59) e (A.60):

$$s_j[2n] = \frac{\sqrt{2}}{2} (s_{j-1}[n] - d_{j-1}[n]) \quad (\text{A.61})$$

$$s_j[2n+1] = \frac{\sqrt{2}}{2} (s_{j-1}[n] + d_{j-1}[n]) \quad (\text{A.62})$$

A transformada *lifting* de Haar é a única que não precisa de complemento de zeros para um sinal contendo 2^j amostras [27].

Uma variação importante da transformada *lifting* é o mapeamento de inteiro para inteiro [8] e que consiste efetivamente na obtenção de coeficientes inteiros, resultantes da transformação wavelet, a partir de valores de entrada inteiros. Como exemplo, a transformada Haar de inteiro para inteiro é obtida por (A.61) e (A.62):

$$d_{j-1}[n] = s_j[2n+1] - s_j[2n] \quad (\text{A.63})$$

$$s_{j-1}[n] = s_j[2n] + \lfloor d_{j-1}[n] \rfloor \quad (\text{A.64})$$

onde $\lfloor \cdot \rfloor$ representa o arredondamento do valor numérico para o inteiro inferior mais próximo.

A inversa dessa transformação é (A.63) e (A.64):

$$s_j[2n] = s_{j-1}[n] - \left\lfloor \frac{d_{j-1}[n]}{2} \right\rfloor \quad (\text{A.65})$$

$$s_j[2n+1] = s_{j-1}[n] + d_{j-1}[n] \quad (\text{A.66})$$

APÊNDICE B - REDES NEURAIS ARTIFICIAIS

B.1 INTRODUÇÃO

A aplicabilidade de redes neurais em engenharia é extensa, sobretudo conjugada a modelos *fuzzy* [2][32], sistemas especialistas [2], visão computacional [32], reconhecimento de padrões [4] e inteligência artificial [25][2]. Existem, também, diversas ferramentas neurais baseadas em software para simulação de modelos e ambientes neurais [46][17].

O estudo em redes neurais artificiais (RNA) tem sido motivado pelo reconhecimento de como o cérebro humano processa informações. O cérebro é análogo a um computador altamente complexo, não-linear e paralelo que possui a capacidade de organizar seus constituintes estruturais, denominados de neurônios, de forma a realizar rapidamente e efetivamente diversas atividades aparentemente fáceis (como: reconhecimento, percepção e controle motor), mas que ainda não foram possíveis de se reproduzir (ou a reprodução é pouco satisfatória) em sistemas artificiais.

Para entender melhor a concepção dos modelos neuronais artificiais é necessário observar as características dos modelos biológicos reais. Os neurônios, como constituintes estruturais do cérebro, são de cinco a seis vezes mais lentos que as portas lógicas em silício, no entanto, o cérebro compensa a operação lenta das fibras nervosas pelo volume de conexões estabelecidas entre elas.

Essas conexões, denominadas de sinapses, são unidades estruturais e funcionais responsáveis pela propagação do sinal elétrico entre dois neurônios. O tipo mais comum de sinapse é a química, que opera liberando uma substância neurotransmissora devido a um estímulo elétrico. Essa substância atravessa a sinapse excitando outro neurônio e induzindo-lhe o estímulo elétrico.

As sinapses ocorrem entre as estruturas denominadas de dendritos e axônios do corpo neuronal (FIGURA B.1), sendo que a propagação do estímulo elétrico ocorre sempre no sentido do dendrito para o axônio.

A codificação de saída da maioria dos neurônios ocorre como uma série de pulsos breves de tensão que são denominados de potenciais de ação ou simplesmente impulsos (FIGURA B.1). Os impulsos se originam no corpo celular ou perto dele e se propagam para o axônio se distribuindo aos outros neurônios através das sinapses nervosas.




FIGURA B.1 – Neurônio biológico e o potencial de ação.
Fonte: Maass, 1999.

O impulso pode prosseguir ou não pelo neurônio ligado ao axônio. Isso ocorre porque o corpo celular contabiliza a contribuição de cada dendrito para geração do potencial de ação, ou seja, um impulso será gerado pelo corpo celular apenas se as contribuições de cada dendrito, quando somadas, ultrapassarem um determinado limiar de ação. Essa regra é conhecida como lei do tudo-ou-nada da neurobiologia.

As redes neurais artificiais são constituídas de neurônios artificiais interligados maciçamente e definidas como máquinas adaptativas [25]:

Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torna-lo disponível para uso.

(Haykin, 2001, p. 28).

As semelhanças entre RNAs e o cérebro humano entremeia dois aspectos básicos [25]:

- O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.

- Forças de coesão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Embora os neurônios biológicos codifiquem suas saídas de maneira pulsada, os neurônios artificiais não o fazem. Isso porque muitos dos problemas que utilizam RNAs não necessitam da informação codificada em pulsos para resolvê-los. No entanto, estudos dessa natureza vêm sendo desenvolvidos [35] para modelar aplicações com soluções cada vez mais próximas ao comportamento biológico.

O uso de redes neurais oferece um conjunto de características úteis:

- *Generalização*. Refere-se ao fato de a RNA produzir saídas adequadas para entradas que não estavam presentes durante o treinamento.
- *Não Linearidade*. Permite a modelagem, por uma RNA, de um sistema físico não linear.
- *Mapeamento de Entrada-Saída*. A RNA aprende dos exemplos, contendo dados de entrada e seus respectivos dados de saída, construindo um mapeamento de entrada e saída.
- *Adaptabilidade*. As RNAs possuem a capacidade inata de adaptar seus pesos sinápticos a modificações do meio ambiente.
- *Resposta a Evidências*. No contexto de classificação de padrões, uma RNA pode ser projetada não apenas para selecionar, mas também para prover confiança na decisão tomada.
- *Informação Contextual*. O conhecimento é representado pela própria estrutura e estado de ativação de uma rede neural. Cada neurônio da rede é potencialmente afetado pela atividade de todos os outros neurônios da rede.
- *Tolerância a Falhas*. Uma RNA é capaz de efetuar computação robusta, ou seja, se um neurônio falhar (por degradação natural de um sistema físico) a recuperação de um padrão armazenado é prejudicado apenas na qualidade.

- *Implementação em VLSI.* A natureza paralela da RNA a torna adequada para implementação em tecnologia de integração em larga escala.
- *Uniformidade de Análise e Projeto.* As RNAs são universais como processadoras de informações.
- *Analogia Neurobiológica.* O cérebro é a prova física do que as RNAs podem se tornar.

B.2 REPRESENTAÇÃO DO CONHECIMENTO

Do ponto de vista filosófico, o conhecimento pode ser entendido como a apropriação do objeto pelo pensamento, como quer que se conceba essa apropriação: apreensão completa, definição, percepção clara, análise, etc.

De forma genérica, aplicável às redes neurais artificiais, o conhecimento se refere à informação armazenada ou a modelos utilizados por uma máquina para interpretar, prever e responder apropriadamente ao mundo exterior. São duas as principais características da representação do conhecimento [25]:

1. Saber se a informação está realmente explícita.
2. Como a informação é codificada fisicamente para o uso subsequente.

Uma tarefa importante para a rede neural é tomar posse do conhecimento de um modelo do ambiente, no qual ela está inserida, e manter esse modelo suficientemente consistente com o contexto real de forma a atingir os objetivos delineados pela aplicação em foco. O conhecimento do ambiente consiste em duas informações:

1. O estado conhecido do meio, representado pelos fatos sobre o que é e o que era conhecido (informação prévia).
2. A observação do meio obtida através de medidas (exemplos).

Um conjunto de pares contendo um sinal de entrada e a saída correspondente é referida como um conjunto de dados de treinamento. A representação do conhecimento do meio ambiente no interior de uma RNA, utilizando para aprendizado um conjunto de dados

de treinamento, é definida pelos valores assumidos pelos parâmetros livres da rede (i.e. pesos sinápticos). Os pesos são ajustados diretamente dos dados de treinamento sem qualquer conhecimento prévio da distribuição estatística desses dados.

O processo de aprendizagem, que permite o ajuste dos parâmetros livres, permite que a rede neural não somente forneça o modelo implícito do ambiente no qual ela está inserida, mas também faz com que ela realize a função de processamento das informações de interesse.

Isso permite inferir como o tema da representação do conhecimento no interior de uma RNA é complexo. Entretanto, existem quatro regras de senso comum, utilizadas para dar forma à representação do conhecimento [25]:

Regra 1. Entradas similares de classes similares normalmente devem produzir representações similares no interior da rede e, portanto, devem ser classificadas como pertencentes à mesma categoria.

Regra 2. Devem ser atribuídas representações bem diferentes na rede a itens que são categorizados como classes separadas.

Regra 3. Se uma característica particular é importante, então deve haver um grande número de neurônios envolvidos na representação daquele item na rede.

Regra 4. Informações prévias e invariâncias devem ser incorporadas no projeto de uma rede neural, simplificando com isso o projeto pela não necessidade da RNA ter que aprende-las.

Independentemente do modo como o projeto é realizado, o conhecimento sobre o domínio do problema de interesse é adquirido pela rede de forma aparentemente simples e direta através do treinamento. Embora essa forma de representação permita a adaptação e a generalização da rede, ainda não há como se explicar, de forma abrangente, o processo computacional através do qual a rede toma uma decisão ou apresenta suas saídas. Isso pode ser uma limitação séria em aplicações onde a segurança é a principal preocupação, como em controle de tráfego aéreo ou em diagnóstico médico, por exemplo.

Nas aplicações dessa natureza é essencial que à rede seja incorporado alguma forma de capacidade explanativa. Portanto, a integração das redes neurais à inteligência artificial compondo um sistema híbrido, é o desejável no incorrer de aplicações de tamanha significância.

O objetivo da inteligência artificial (IA) é o desenvolvimento de paradigmas ou algoritmos que requeiram máquinas para realizar tarefas cognitivas, para as quais os humanos são atualmente melhores [25]. Um sistema de IA deve ser capaz de fazer três coisas:

- Armazenar conhecimento.
- Aplicar o conhecimento armazenado para resolver problemas.
- Adquirir novo conhecimento através da experiência.

Ainda, um sistema de IA possui três componentes principais:

1. Representação. Linguagens ou estruturas simbólicas representam tanto o conhecimento genérico sobre um domínio do problema de interesse, quanto o conhecimento específico sobre a solução do problema. O conhecimento pode ser representado como uma coleção estática de fatos ou como parte de um programa que representa o significado do conhecimento.
2. Raciocínio. É a habilidade de resolver problemas. Para isso o sistema deve satisfazer certas condições:
 - Ser capaz de expressar e resolver uma vasta gama de problemas e tipos de problemas.
 - Ser capaz de tornar conhecidas para ele tanto a informação implícita quanto a explícita.
 - Ter mecanismos de controle que determinem quais operações devam ser aplicadas para um problema particular, quando uma

solução é obtida e quando deve ser encerrado o tratamento desse problema.

3. Aprendizagem. Quando o ambiente fornece algum tipo de informação para um elemento de aprendizagem, este utiliza essa informação para aperfeiçoar sua base de conhecimento. Finalmente, o elemento de desempenho utiliza a base de conhecimento para executar sua tarefa.

A importância de conhecer os conceitos de IA supracitados permite comparações com a teoria de RNAs. Mostrar-se-á, então, que as redes neurais em grande parte por si somente compõem um sistema híbrido que satisfaz a maioria dos preceitos circunscritos pela IA para as aplicações de grande relevância.

Para a comparação, existem três subdivisões [25]:

1. Nível de Explicação. Do ponto de vista da cognição, a IA assume a existência de representações mentais e modela a cognição pelo processamento sequencial de representações simbólicas. As RNAs, por outro lado, dão grande relevo à explicação biológica dos fenômenos cognitivos e enfatizam o desenvolvimento de modelos de processamento distribuído. Esses modelos assumem que o processamento da informação simbólica acontece através da interação de um grande número de neurônios, onde cada neurônio envia sinais excitadores e inibitórios para outros neurônios da rede.
2. Estilo de Processamento. Na IA clássica, o processamento é sequencial. Mesmo quando não há uma ordenação predeterminada, as operações são executadas passo a passo. Um erro na base de conhecimento pode impedir uma conclusão adequada acerca de um problema. O paralelismo das RNAs permite flexibilidade e robustez na solução de problemas. Como a computação está distribuída entre muitos neurônios, não importa muito se houver algum desvio do valor esperado dos estados de alguns neurônios. Além de que entradas ruidosas ou incompletas podem ainda ser reconhecidas, como também não há necessidade de que a aprendizagem seja perfeita.

3. Estrutura Representativa. As representações simbólicas em IA possuem uma estrutura quase lingüística. Dado um repertório limitado de símbolos, novas expressões significativas podem ser compostas em virtude da capacidade de composição das expressões simbólicas e da analogia entre a estrutura sintática e a semântica. Isso permite estruturar a natureza das representações mentais, que no entanto não é expresso pelas RNAs. Dessa maneira a integração das capacidades de representação, inferência e universalidade, inerentes à IA, com a adaptabilidade, robustez e uniformidade implícitas da abordagem conexionista das RNAs podem ser colimadas com a extração de regras a partir das redes neurais treinadas.

A extração de regras, de redes neurais treinadas, completa a motivação do uso das RNAs em sistemas biomédicos. Essa extração possui algumas razões:

- Melhorar o desempenho de generalização das redes neurais, identificando regiões do espaço de entrada onde os dados de treinamento não estão adequadamente representados.
- Mineração de dados (descobrimento de características marcantes dos dados para exploração de sua representatividade).
- Satisfazer a crítica necessidade de segurança em uma classe especial de sistemas.

B.3 MODELO DE UM NEURÔNIO

O neurônio artificial (ou elemento de processamento) é a unidade de processamento de informação da rede neural artificial. No diagrama da FIGURA B.2 identificam-se três elementos básicos do modelo neuronal:

1. Um conjunto de sinapses, cada qual definida por um peso próprio (w_{kj}).
2. Um somador para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio.

3. Uma função de ativação para mapear a amplitude de saída do neurônio em um intervalo desejado.

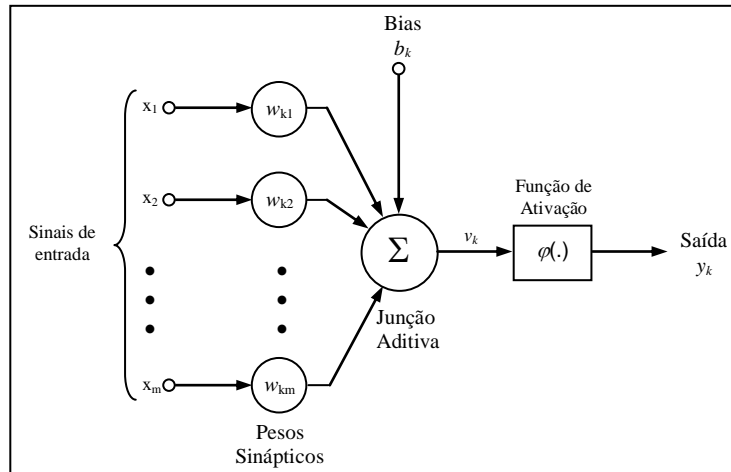


FIGURA B.2 – Modelo não-linear de um neurônio.
Fonte: Haykin, 2001.

A entrada de polarização (ou bias), b_k , do modelo neuronal tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação $\varphi(v)$ (B.1).

$$y_k = \varphi(v_k)$$

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k, \quad \text{onde} \quad (\text{B.1})$$

Quanto aos tipos de funções de ativação, pode-se relacionar três amplamente usadas (FIGURA B.3) [25]:




FIGURA B.3 – (a) Função de limiar. (b) Função linear por partes. (c) Função sigmóide para parâmetro de inclinação variável.
Fonte: MathWorks, 2000.

1. Função de Limiar (ou Função de *Heaviside*) (B.2):

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (\text{B.2})$$

2. Função Linear por Partes (B.3):

$$\varphi(v) = \begin{cases} 1, & v \geq 5 \\ v, & 5 > v > -5 \\ 0, & v \leq -5 \end{cases} \quad (\text{B.3})$$

3. Função Sigmóide (B.4) e (B.5):

Logística:
$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (\text{B.4})$$

Tangente Hiperbólica:
$$\varphi(v) = \tanh(v) \quad (\text{B.5})$$

B.4 MODELO DA REDE NEURAL ARTIFICIAL

As redes neurais artificiais são máquinas de aprendizagem distribuídas, adaptativas e geralmente não-lineares construídas a partir de diferentes elementos de processamento (PEs), denominados de neurônios. Cada PE recebe conexões de outros elementos de processamento e/ou de si mesmo. A interconectividade entre PEs define a topologia da rede neural.

De forma geral, as redes neurais são usadas para reconhecimento de padrões e para aproximação de funções. No caso de reconhecimento de padrões, as redes neurais constroem funções discriminantes a partir de seus elementos de processamento. A topologia de uma RNA define o número e a forma das funções discriminantes.

Como a forma das funções discriminantes modifica com a topologia da RNA, elas são consideradas classificadores semiparamétricos [46].

Uma das vantagens centrais das RNAs é que elas são suficientemente poderosas para criar funções discriminantes arbitrárias, logo, podem efetuar classificações ótimas [46].

A maneira como os neurônios estão interligados para formar uma rede neural está relacionada intimamente com o algoritmo de aprendizagem usado para treinar a rede. Abordagens completas nesse sentido podem ser vistas em [25][17][4] e [30], todavia, a explanação aqui se restringe apenas à estrutura simplista genérica de funcionamento das redes utilizadas no trabalho de classificação que se propõe.

Em geral, as redes neurais fundamentam-se em três topologias básicas:

- Acíclicas:
 - redes alimentadas adiante com camada única (*singlelayer feed-forward networks*).
 - redes alimentadas diretamente com múltiplas camadas (*multilayers feed-forward networks*).
- Cíclicas:
 - redes recorrentes (*recurrents networks*).

A primeira topologia compõe a estrutura que será apresentada no modelo do mapa auto-organizável (SOM – *self-organizing map*) a fim de introduzir a rede de quantização vetorial por aprendizagem (LVQ – *learning vector quantization*); a segunda, trata das redes de função de base radial (RBF – *radial base function*) com três camadas fixas e da rede perceptron multicamadas; a terceira foge ao escopo desse trabalho e, portanto, não será abordada aqui.

B.4.1 Mapa Auto-Organizável

O mapa auto-organizável é composto por uma grade neural de redes alimentadas adiante com camada única consistindo de neurônios arranjados em linhas e colunas. Um caso especial de configuração é apresentado na FIGURA B.4, onde a camada computacional consiste apenas de uma única linha de neurônios [25].

O processo de treinamento é baseado na aprendizagem competitiva: os neurônios de saída da grade competem entre si para serem ativados ou disparados, resultando que apenas um neurônio de saída, ou um neurônio por grupo (*cluster*), estará ligado em cada instante de tempo.




FIGURA B.4 – Grade bidimensional de neurônios.

Os neurônios se tornam seletivamente sintonizados a vários padrões de entrada (estímulos), ou classes de padrões, no decorrer de um processo de aprendizagem. O neurônio de saída que vence a competição é chamado de neurônio vencedor.

Um mapa auto-organizável é, portanto, caracterizado pela formação de um mapa topográfico dos padrões de entrada no qual as localizações espaciais (i. e., coordenadas) dos neurônios na grade são indicativas das características estatísticas intrínsecas contidas nos padrões de entrada.

Como modelo neural, o mapa auto-organizável fornece uma ponte entre dois níveis de adaptação [25]:

- Regras de adaptação formuladas ao nível microscópico de um único neurônio.
- Formação de padrões de seletividade de características experimentalmente melhores e fisicamente acessíveis ao nível microscópico de camadas neurais.

Devido a um mapa auto-organizado ser inerentemente não-linear, ele pode ser visto como uma generalização não-linear da análise de componentes principais [25].

O algoritmo de formação do mapa auto-organizável começa com a inicialização dos pesos sinápticos da grade por valores pequenos tomados aleatoriamente. Em seguida, três processos essenciais são envolvidos na constituição do mapa:

- **Competição.** Para cada padrão de entrada, os neurônios da grade calculam seus respectivos valores a partir de uma função discriminante. Essa função fornece a base para a competição entre os neurônios, onde o maior valor pertence ao neurônio vencedor.
- **Cooperação.** O neurônio vencedor determina a localização espacial de uma vizinhança topológica de neurônios excitados, fornecendo a base para a cooperação entre os neurônios vizinhos.
- **Adaptação Sináptica.** Esse mecanismo permite que os neurônios excitados aumentem seus valores individuais da função discriminante em relação ao padrão de entrada. Os ajustes feitos são tais que a resposta do neurônio vencedor à aplicação subsequente de um padrão de entrada similar é melhorada.

B.4.1.1 Quantização Vetorial por Aprendizagem

Em alguns casos, algoritmos auto-organizados (ou de “*clustering*”) podem ser usados para classificação de padrões desde que eles respondam por uma métrica de distância relativa no espaço de entrada [46]. Entretanto, no processo de classificação, as classes podem ser constituídas por um ou mais grupamentos (*clusters*) de padrões [46].

No método de quantização vetorial, um espaço de entrada é dividido em um número de regiões distintas (*clusters*), onde para cada região é definido um vetor de reprodução.

Quando um novo vetor de entrada é apresentado ao quantizador, há inicialmente a determinação de qual região o vetor pertence e, então, ela é representada pelo vetor de reprodução para aquela região.

Uma versão codificada desse vetor de reprodução, com mínima distorção de codificação, é chamado de quantizador de Voronoi. A FIGURA B.5 apresenta um diagrama de Voronoi envolvendo quatro regiões. As linhas tracejadas são os vetores de Voronoi, que determinam a fronteira entre essas regiões.

O algoritmo do mapa auto-organizável fornece um método aproximativo para calcular os vetores de Voronoi de uma maneira não supervisionada, com a aproximação sendo

especificada pelos vetores de pesos sinápticos dos neurônios no mapa de características [25].




FIGURA B.5 – Diagrama de Voronoi para quatro regiões.

A quantização vetorial por aprendizagem (LVQ, *learning vector quantization*) é uma técnica de aprendizagem supervisionada que usa a informação sobre as classes para mover ligeiramente os vetores de Voronoi, a fim de melhorar a qualidade das regiões de decisão do classificador. As classes na LVQ são dependentes apenas da distância entre os vetores de entrada [17], que são estatisticamente classificados para reconhecimento dessas classes [30].

Uma rede LVQ possui a primeira camada competitiva (SOM), para separação das classes pelos vetores de Voronoi, e a camada de saída linear para ajuste supervisionado das alocações dos vetores de Voronoi.

Se as classes para separação são unimodais e bem separáveis, então um algoritmo de *clustering* e um classificador vão gerar o mesmo resultado, entretanto, em classes multimodais de estruturas inter-relacionadas com mistura de amostras, os dois métodos produzem muitos resultados diferentes [46].

De forma abstrata, o algoritmo LVQ possui, em essência, o seguinte mecanismo: Um vetor de entrada x é tomado aleatoriamente do espaço de entrada. Se os rótulos de classe do vetor de entrada e de um vetor de Voronoi w_c (B.6) concordarem, então o vetor de Voronoi é movido em direção ao vetor de entrada ($s(n) = 1$). Caso contrário, o vetor de Voronoi é afastado do vetor de entrada ($s(n) = -1$) [25].

$$w_c(n+1) = w_c(n) + \alpha_c(n)s(n)[x_i - w_c(n)] \quad 0 < \alpha_c < 1 \quad (\text{B.6})$$

onde: x_i representa o i -ésimo vetor de entrada; α_c é a constante de aprendizagem que decresce monotonamente (linearmente) com o número de iterações n ; e c é dado por (B.7):

$$c = \arg \min_k \{\|x - w_k\|\} \quad (\text{B.7})$$

que define o índice c do mais próximo vetor de Voronoi w_k de x dentre os k vetores de Voronoi. Note que c , o índice do “vencedor”, depende de x e de todos os k vetores de Voronoi [30].

No algoritmo com a taxa de aprendizagem otimizada (LVQ1) o valor de α_c (B.8) é calculado de forma a permitir uma rápida convergência.

$$\alpha_c(n) = \frac{\alpha_c(n-1)}{1 + s(n)\alpha_c(n-1)} \quad (\text{B.8})$$

A real vantagem da rede LVQ sobre as demais redes baseadas em algoritmos de *clustering* é que ela sempre associa o mesmo neurônio (elemento de processamento) para o mesmo agrupamento (*cluster*) de dados [46]. No entanto, quando os *clusters* são multimodais ou mais complexos, a rede LVQ pode levar a um desempenho inaceitável [46].

B.4.2 Redes Alimentadas Diretamente Multicamadas

As redes alimentadas diretamente com múltiplas camadas (ou acíclicas) possuem neurônios ocultos cuja função é intervir entre a entrada externa e a saída da rede de maneira útil. Isso permite que a rede adquira uma perspectiva global, apesar de sua conectividade local, devido ao conjunto extra de conexões sinápticas e da dimensão extra de interações neurais [25].

Assim, o conjunto de sinais de saída dos neurônios da camada de saída da rede constitui a resposta global da rede para o padrão de ativação fornecido pelos nós de fonte da camada de entrada.

Tipicamente, os neurônios em cada camada oculta da rede e os da camada de saída têm como entradas apenas os sinais de saída da camada precedente. Assim, uma rede em que

todos os nós da camada precedente estão conectados a todos os nós da camada adjacente, é denominada totalmente conectada. Entretanto, se conexões sinápticas estiverem faltando na rede, diz-se que a rede é parcialmente conectada.

Os trabalhos de Minsky e Papert provaram que as redes diretas necessitam de camadas intermediárias (ocultas) para solucionar problemas não linearmente separáveis [2]. Posteriormente ficou provado que tudo que uma rede pode aprender com “n” camadas ocultas pode ser aprendido por uma rede de uma única camada oculta [2].

O problema das redes alimentadas diretamente com múltiplas camadas reside no número de neurônios da camada intermediária: se for um número grande, a rede pode se especializar e perder a capacidade de generalização; se for um número pequeno, a rede pode não aprender. Esse tem sido, até o presente momento, um problema em aberto [2].

A importância dos neurônios da camada oculta aumenta na medida em que aumenta o tamanho da camada de entrada. Isso acontece porque o aumento do volume de informações dispostas paralelamente na entrada possibilita, aos neurônios ocultos, a extração de estatísticas de ordem mais elevada [25].

Como exemplo de rede acíclica a FIGURA B.6 apresenta uma topologia de três camadas (10-4-2) com 10 neurônios de fonte (entrada), 4 neurônios ocultos e 2 neurônios de saída.




FIGURA B.6 – Rede alimentada adiante totalmente conectada com uma camada oculta e uma camada de saída.

Fonte: Haykin, 2001.

B.4.2.1 Redes de Função de Base Radial

Nas redes de função de base radial (RBF – *radial base function*), o enfoque do projeto concerne ao problema de ajuste de curva (aproximação) em um espaço de alta dimensionalidade. Aprender é equivalente a encontrar uma superfície, em um espaço multidimensional, que forneça o melhor ajuste para os dados de treinamento, com o critério de “melhor ajuste” sendo medido em um sentido estatístico [25].

As redes RBF possuem uma camada de entrada, que conecta a rede ao ambiente, uma camada oculta de alta dimensionalidade⁹ não linear e uma camada de saída linear, fornecendo a resposta da rede ao padrão de ativação aplicado à camada de entrada. Nada impede que mais de três camadas possam ser usadas [2].

No contexto de uma rede neural, as unidades ocultas fornecem um conjunto de “funções” que constituem uma “base” arbitrária para os padrões (vetores) de entrada, quando eles são expandidos sobre o espaço oculto: estas funções são denominadas de funções de base radial.

Uma justificativa matemática para a estratégia de uma transformação não-linear seguida de uma transformação linear é que um problema de classificação de padrões disposto em um espaço de alta dimensionalidade tem maior probabilidade de ser linearmente separável do que em um espaço de baixa dimensionalidade (teorema de Cover em [25]) — daí a razão de freqüentemente se fazer com que a dimensão do espaço oculto em uma rede RBF seja alta.

As RBFs treinam muito eficientemente desde que os centros das funções de base sejam determinados e o erro seja linear nos pesos [46]. Esse fato também garante a convergência do erro para o mínimo global, o que demonstra a grande utilidade da RBF para identificação de sistemas [46].

Na RBF as bases são locais, logo, cada base pode ser alterada sem provocar distúrbio na aproximação da rede em outras áreas do espaço [46] (FIGURA B.7).

⁹ Quanto mais alta for a dimensão do espaço oculto, mais precisa será a aproximação [25].




FIGURA B.7 – Aproximação por RBFs gaussianas em uma dimensão.
Fonte: Principe, 2000.

Do ponto de vista teórico das funções de aproximação, as RBFs possuem a propriedade de “melhor aproximação” como definida por Chebyshev, ou seja, há sempre uma RBF que provê o erro mínimo de aproximação para uma dada função [46].

A fase de treinamento e a de generalização do processo de aprendizagem podem ser vistas como [25]:

- O treinamento constitui a otimização de um procedimento de ajuste para a superfície baseado nos pontos dos dados conhecidos e apresentados à rede na forma de exemplos (padrões) de entrada-saída.
- A fase de generalização é sinônima de interpolação entre os pontos de dados — o ajustamento vai sendo formado ao longo da superfície restrita gerada pelo procedimento de ajuste — com a aproximação ótima à superfície verdadeira.

Considerando o espaço de entrada da rede com dimensionalidade m_0 e o espaço de saída unidimensional, o problema de interpolação, no sentido estrito, pode ser formulado como:

Dado um conjunto de N pontos diferentes $\{x_i \in R^{m_0} | i=1,2,\dots,N\}$ e um conjunto correspondente de N números reais $\{d_i \in R^1 | i=1,2,\dots,N\}$, encontre uma função $F : R^N \rightarrow R^1$ que satisfaça a condição de interpolação (B.9):

$$F(x_i) = d_i, \quad i = 1, 2, \dots, N \quad (\text{B.9})$$

A técnica de funções de base radial consiste em escolher a função F que tem a seguinte forma (B.10):

$$F(x) = \sum_{i=1}^N w_i \varphi(\|x - x_i\|) \quad (\text{B.10})$$

onde $\{\varphi(\|x - x_i\|) \mid i = 1, 2, \dots, N\}$ é um conjunto de N funções arbitrárias, conhecidas como funções de base radial, e $\|\cdot\|$ representa a norma euclidiana. Os pontos de dados conhecidos $\{x_i \in R^{m_0} \mid i = 1, 2, \dots, N\}$ são tomados como centros das funções de base radial.

Inserindo as condições de interpolação da eq. B.9 em B.10, obtém-se o seguinte conjunto de equações lineares simultâneas para coeficientes (pesos) desconhecidos da expansão $\{w_i\}$ (B.11):

$$\begin{bmatrix} \varphi_{11} & \varphi_{11} & \dots & \varphi_{1N} \\ \varphi_{21} & \varphi_{22} & \dots & \varphi_{2N} \\ \vdots & \vdots & \vdots & \vdots \\ \varphi_{N1} & \varphi_{N2} & \dots & \varphi_{NN} \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_N \end{bmatrix} = \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_N \end{bmatrix} \quad (\text{B.11})$$

onde cada elemento da matriz é dado por (B.12):

$$\varphi_{ji} = \varphi(\|x_j - x_i\|), \quad (j, i) = 1, 2, \dots, N \quad (\text{B.12})$$

Considerando:

$$\begin{aligned} \mathbf{d} &= [d_1, d_2, \dots, d_N]^T \\ \mathbf{w} &= [w_1, w_2, \dots, w_N]^T \\ \Phi &= \{\varphi_{ji} \mid (j, i) = 1, 2, \dots, N\} \end{aligned}$$

onde, \mathbf{d} e \mathbf{w} representam o vetor de respostas desejadas e o vetor de pesos lineares respectivamente; N é o tamanho da amostra de treinamento; e Φ é a matriz de interpolação.

Dessa forma, pode-se escrever (B.11) na forma compacta (B.13):

$$\Phi \mathbf{w} = \mathbf{d} \quad (\text{B.13})$$

Assumindo que Φ seja não-singular, tem-se (B.14):

$$\mathbf{w} = \Phi^{-1} \mathbf{x} \quad (\text{B.14})$$

Assim, é possível obter o ajuste no treinamento desde que a matriz de interpolação seja não-singular.

Segundo o teorema de Micchelli [25], há uma grande classe de funções de base radial que satisfazem à não singularidade da matriz de interpolação. Como exemplo, têm-se as funções de base radial [1]:

- Multiquadrática: $\varphi(r) = \sqrt{r^2 + c^2} \quad c > 0, r \in R$
- Multiquadrática Inversa: $\varphi(r) = \frac{1}{\sqrt{r^2 + c^2}} \quad c > 0, r \in R$
- Linear: $\varphi(r) = r \quad r \in R$
- Cúbica: $\varphi(r) = r^3 \quad r \in R$
- *Thin-plate spline*: $\varphi(r) = r^2 \log(r) \quad r \in R^{*+}$
- Gaussiana: $\varphi(r) = e^{-\left(r^2/2\sigma^2\right)} \quad \sigma > 0, r \in R$

De acordo com o teorema de Micchelli, para que as funções listadas acima sejam não singulares, o único critério é que os pontos $\{x_i\}_{i=1}^N$ (eq. B.13) devem ser todos distintos.

No processo de aprendizagem, ao qual uma rede de função de base radial está submetida, as funções de ativação da camada oculta evoluem lentamente de acordo com alguma estratégia de otimização não-linear, enquanto os pesos da camada de saída se ajustam rapidamente através de uma estratégia de otimização linear.

Existem diferentes estratégias de aprendizagem, dentre as quais pode-se destacar quatro abordagens:

- Centros fixos selecionados ao acaso.
- Seleção auto-organizada de centros.

- Seleção supervisionada de centros.
- Interpolação estrita com regularização.

As três primeiras estratégias referem-se a uma rede RBF cuja formulação é baseada na teoria da interpolação. A última, combina elementos da teoria da regularização e da teoria de estimação de regressão de núcleo e não será abordada aqui. A primeira estratégia foi apresentada nos parágrafos anteriores para mostrar que é possível obter o ajuste de treinamento da RBF desde que a matriz de interpolação seja não-singular. As demais abordagens serão apresentadas sucintamente a seguir, tendo como exemplo a função de base radial gaussiana.

No caso da base gaussiana, há basicamente dois modos de selecionar o posicionamento (μ) e a largura (σ) das funções nas RBFs: o método de seleção supervisionado de centros e o auto-organizado de centros [46].

O método supervisionado é uma simples extensão da idéia de retropropagação para a rede RBF. De fato, a gaussiana é uma função diferenciável, logo os erros podem ser retropropagados para adaptar simultaneamente os centros (μ) a variância (σ) e os pesos sinápticos da rede [46]. O problema é que o método pode resultar soluções quase ótimas devido ao mínimo local (a otimização é não-linear para os centros e variâncias) [46].

O método auto-organizado é bem diferente, dividindo a fase de treinamento em adaptações independentes dos pesos da primeira camada (i.e. os centros e variâncias das gaussianas), seguido de um segundo passo que apenas adapta os pesos de saída de forma supervisionada, mantendo a primeira camada com os pesos fixos.

A rede RBF é uma topologia neural que explora o conceito de construir um classificador a partir de algoritmos de agrupamentos (*clustering*), uma vez que as funções de base são locais no espaço e os pesos sinápticos de saída podem aprender o mapeamento para cada uma das classes [46].

O método auto-organizado é mais rápido, uma vez que o método da descida do gradiente consome mais tempo, entretanto, é negligente acreditar que uma boa cobertura da distribuição dos dados de entrada implica necessariamente em bons resultados [46].

Isso se deve ao fato de que a rede RBF efetua o ajuste de várias funções de densidade de probabilidade conhecidas, de uma mesma família, aos padrões de entrada. É importante frisar que as funções de base radial são usadas para aproximação dessa distribuição estatística dos dados de entrada, mas que nem sempre conseguem representá-la satisfatoriamente.

A tendência natural das redes RBF é a da substituição da camada das funções de base radial por uma rede competitiva [46]. Enquanto a rede RBF efetua o ajuste das várias funções de densidade de probabilidade, a rede LVQ, por exemplo, efetua a classificação dos padrões de forma competitiva possibilitando a sua utilização em problemas que contenham modelos não-paramétricos.

Uma vantagem das redes RBF em relação a LVQ está na simplicidade do processo de treinamento, associada à eficiência computacional permitindo que as redes RBF possam ser usadas em problemas de aproximação de funções, predição e classificação de padrões [2].

B.4.2.2 Redes Perceptron Multicamadas

O perceptron de Rosenblatt é uma máquina para reconhecimento de padrões criada em 1950 com o objetivo de efetuar o reconhecimento de caracteres ópticos. Cada perceptron é definido como um neurônio de McCulloch-Pitts (a função de ativação é a função de limiar) que interliga completamente as entradas com a camada de saída, não havendo camada oculta.

Um perceptron de múltiplas camadas, entretanto, possui três características distintas [25]:

- O modelo de cada neurônio da rede inclui uma função de ativação não-linear suave (i.e. diferenciável em qualquer ponto).
- A rede contém pelo menos uma camada de neurônios ocultos.
- A rede exibe um alto grau de conectividade, determinado pelas sinapses nervosas.

Os neurônios ocultos desempenham um papel crucial na operação de um perceptron de múltiplas camadas com aprendizagem por retropropagação, porque agem como detectores de características [25].

Conforme o processo de aprendizagem avança, os neurônios ocultos começam gradualmente a “descobrir” as características salientes que caracterizam os dados de treinamento. Eles fazem isso realizando uma transformação não-linear dos dados de entrada para um novo espaço denominado espaço oculto (ou espaço de características) [25].

Nesse novo espaço, as classes de interesse em uma tarefa de classificação de padrões, por exemplo, podem ser mais facilmente separadas entre si do que no espaço original de entrada [25].

O estudo das redes perceptrons de múltiplas camadas permitiram definir algumas conclusões importantes oriundas do seu comportamento em relação à classificação de padrões [46]:

- O número máximo de regiões distintas ($= 2^K$ $p/K \gg M$) do espaço de entrada (M entradas) da rede é controlado pelo número de neurônios (K neurônios ocultos) da camada oculta. Uma declaração alternativa é que cada neurônio oculto cria uma função discriminante linear.
- Os neurônios da camada de saída têm a habilidade para combinar algumas das regiões criadas pelos neurônios ocultos, por efeitos multiplicativos ou aditivos.
- Há mais de uma combinação dos pesos sinápticos passível de alcançar um particular arranjo das regiões de decisão.

Pode-se concluir que a classificação com a rede perceptron multicamadas ainda é realizado controlando adequadamente a posição das funções discriminantes de acordo com os dados de entrada e a resposta desejada [46]. O que implica em muito mais liberdade nas possíveis formas das funções discriminantes [46].

Os perceptrons de múltiplas camadas têm sido aplicados com sucesso para resolver diversos problemas, através de seu treinamento de forma supervisionada, com o algoritmo de retropropagação de erro (*error back-propagation*). Contudo, a presença de uma forma distribuída de não-linearidades e a alta conectividade da rede torna difícil a análise teórica dos neurônios que a compõem [25].

B.5 O PROCESSO DE APRENDIZAGEM

A aprendizagem, de forma geral, expressa o ato de aprender, tomar conhecimento, reter em memória mediante estudo, observação ou experiência. Contudo, em se tratando de sistemas neurais artificiais, a aprendizagem é definida como um método pelo qual os parâmetros livres de uma rede neural são adaptados, por meio de uma evolução de estímulos provenientes do ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre.

O processo de aprendizagem pode ser sintetizado da seguinte forma: A rede neural é estimulada por um ambiente e então sofre modificações nos seus parâmetros livres. Essa modificação faz com que a RNA passe a responder de uma maneira nova a esse ambiente.

Existem duas formas de aprendizado usadas em redes neurais. A primeira, utilizando um “professor”, ocorre de maneira supervisionada, onde um conjunto de dados de treinamento contendo um par de amostras, de entrada e saída, é submetido à rede para aprendizagem. A segunda, sem o “professor”, ocorre de forma não supervisionada não havendo exemplos rotulados da função a ser aprendida pela rede. Assim, a rede automaticamente se ajusta às regularidades estatísticas dos dados de entrada e desenvolve a habilidade de formar representações internas para codificar as características de entrada classificando os padrões entendidos.

O conjunto de regras bem definidas que procura a solução de um problema de aprendizagem é denominado de algoritmo de aprendizagem, e a maneira pela qual uma máquina de aprendizagem (rede neural) se relaciona com o seu ambiente é dito ser um paradigma de aprendizagem.

No presente contexto serão apresentados os algoritmos da descida do gradiente e o de Levenberg-Marquardt como métodos de minimização do erro quadrático médio na aprendizagem por retropropagação do erro da rede neural. Nota-se, entretanto, que a aprendizagem por correção de erro está fundamentada na filtragem ótima [25].

B.5.1 Algoritmo de Retropropagação do Erro

Basicamente, a aprendizagem por retropropagação de erro consiste de dois passos através das diferentes camadas da rede: um passo para frente, a propagação, e um passo para trás, a retropropagação.

No passo para frente, um padrão de atividade (vetor de entrada) é aplicado aos nós sensoriais da rede e seu efeito se propaga camada por camada produzindo um conjunto de saída como a resposta real da rede. Durante a propagação, os pesos sinápticos se mantêm fixos.

A resposta real da rede é subtraída de uma resposta desejada (alvo) para produzir um sinal de erro. Esse sinal é propagado para trás (retropropagação) através da rede, contra o sentido das conexões sinápticas, e os pesos são ajustados de acordo com alguma regra de correção de erros.

O ajuste dos pesos sinápticos faz com que a resposta da rede se mova para mais perto da resposta desejada, em um sentido estatístico [25].

B.5.2 Algoritmos de Correção de Erro

Os algoritmos de correção de erro da retropropagação fornecem uma maneira adequada de efetuar o ajuste dos pesos sinápticos da rede de acordo com a topologia, resultando em diferentes heurísticas de desempenho e aproximação dos alvos do conjunto de treinamento.

O método da descida do gradiente baseia-se na direção de descida mais íngreme do gradiente da superfície de erro para calcular o fator de correção dos pesos sinápticos em cada neurônio da rede.

O método de Levenberg-Marquardt foi baseado no método de Newton, que por sua vez surgiu no intuito de prover uma rápida otimização para o método do gradiente descendente.

B.5.2.1 Método da Descida do Gradiente

No esquema da FIGURA B.8 tem-se a saída (y_k) de cada neurônio (k) de uma rede multicamadas alimentadas adiante sendo comparada à saída desejada (d_k) do conjunto de treinamento (B.15).

$$e_k(n) = d_k(n) - y_k(n) \quad (\text{B.15})$$

o argumento n representa o passo de tempo de um processo iterativo envolvido no ajuste dos pesos sinápticos do neurônio k e e_k é o sinal de erro.

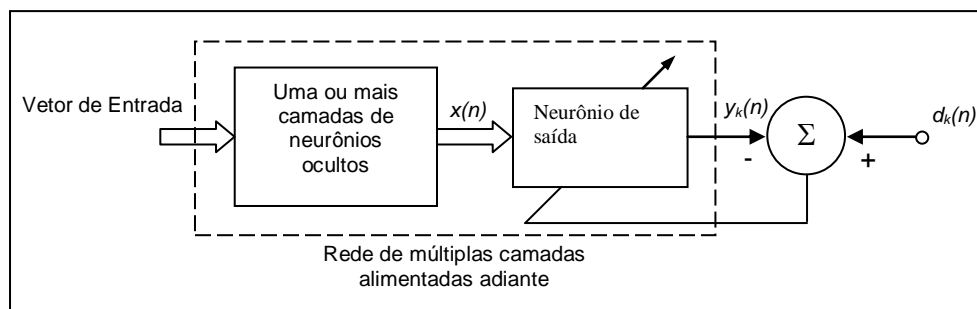


FIGURA B.8 – Diagrama de blocos de uma rede neural ressaltando o único neurônio da camada de saída.

Fonte: Haykin, 2001.

O sinal de erro $e_k(n)$ adiciona um mecanismo de controle em que se propõe aplicar uma sequência de ajustes corretivos aos pesos sinápticos do neurônio k de forma a aproximar a saída $y_k(n)$ do valor desejado $d_k(n)$. O objetivo é alcançado minimizando-se a função de custo (ou índice de desempenho), $\xi(n)$, definida em termos do sinal de erro como (B.16):

$$\xi_{kj}(n) = \frac{1}{2} e_{kj}^2(n) \quad (\text{B.16})$$

então, a energia total na camada de saída é (B.17):

$$\xi_j(n) = \frac{1}{2} \sum_{k \in C} e_{kj}^2(n) \quad (\text{B.17})$$

portanto, a energia média do erro quadrático é dada por (B.18):

$$\xi_{med} = \frac{1}{N} \sum_{n=1}^N \xi_j(n) \quad (\text{B.18})$$

onde, N é o número de padrões (exemplos) do conjunto de treinamento.

A minimização da função de custo ξ_{med} resulta na regra de aprendizagem normalmente referida como regra delta ou regra de Widrow-Hoff. De acordo com essa regra, o ajuste $\Delta w_{kj}(n)$ aplicado ao peso sináptico w_{kj} no passo de tempo n é definido por (B.19):

$$\Delta w_{kj}(n) = \eta e_k(n) x_j(n) \quad (\text{B.19})$$

onde η é uma constante positiva que determina a taxa de aprendizado quando se avança um passo no processo de aprendizagem; e x_j é um elemento da posição j do vetor de sinal de entrada do neurônio k .

A regra delta pode ser escrita em função do gradiente (B.20):

$$\Delta w_{kj}(n) = -\eta \frac{\delta \xi(n)}{\delta w_{kj}(n)} \quad (\text{B.20})$$

o sinal negativo representa a descida do gradiente.

Uma simplificação da eq. (B.20) é a eq. (B.21):

$$\Delta w_{kj}(n) = \eta \delta_k(n) y_j(n) \quad (\text{B.21})$$

onde, $\delta_k(n)$ é o gradiente local e $y_j(n)$ é o sinal de entrada do neurônio k e de saída do neurônio j .

O gradiente local aponta para as modificações necessárias nos pesos sinápticos (B.22).

$$\delta_k(n) = e_k(n) \dot{\phi}_k(v_k(n)) \quad (\text{B.22})$$

onde, $\dot{\phi}_k(\cdot)$ é a derivada da função de ativação e $v_k(n)$ é a saída da junção aditiva do neurônio (FIGURA B.2).

O sistema pode usar a estimativa instantânea do vetor de gradiente, supondo que os índices dos exemplos sejam os mesmos dos instantes de tempo. O uso de tal estimativa resulta em um movimento do ponto de operação sobre uma superfície de erro, que se dá tipicamente na forma de uma “caminhada aleatória”. O algoritmo de retropropagação fornece uma aproximação para a trajetória, no espaço de pesos calculado, pelo método da descida mais íngreme (gradiente descendente).

A diminuição da taxa de aprendizado, η , leva a um menor valor de correção dos pesos, Δw_{kj} , aumentando a estabilidade da rede, porém, tornando o treinamento mais lento.

Uma maneira de aumentar a taxa de aprendizado, evitando a perda de estabilidade, é feita pela modificação da regra delta, inserindo-se uma constante de momento (α) na equação (B.23).

$$\Delta w_{kj}(n) = \alpha \Delta w_{kj}(n-1) + \eta \delta_k(n) y_j(n) \quad (\text{B.23})$$

O momento (α) é uma constante sempre positiva que permite ainda evitar que o processo de aprendizagem termine em um mínimo local.

Em resumo, a regra delta pressupõe que:

- O sinal de erro é diretamente mensurável.
- O neurônio k é visível.
- A aprendizagem por correção de erro é de natureza local.

B.5.2.2 Método de Levenberg-Marquardt

Outro método de extrema importância na minimização do erro quadrático médio é conhecido como algoritmo de Levenberg-Marquardt e foi baseado no método de Newton, que por sua vez surgiu no intuito de prover uma rápida otimização para o método do gradiente descendente.

O método de Newton efetua a correção dos pesos sinápticos da RNA da seguinte forma (B.24) [17]:

$$w_{kj}(n+1) = w_{kj}(n) - \mathbf{H}^{-1}(n) \eta \frac{\delta \zeta(n)}{\delta w_{kj}(n)} \quad (\text{B.24})$$

onde, \mathbf{H} é a matriz Hessiana e é dada por (B.25) [4]:

$$\mathbf{H}(n) = \frac{\partial^2 \zeta_{med}}{\partial w_{kj}(n) \partial w_{k(j-1)}(n)} \quad (\text{B.25})$$

A matriz Hessiana é importante em diversos aspectos para a computação neural [4]:

- Vários algoritmos de otimização não linear usados para treinamento neural são baseados em consideração de propriedades de segunda ordem da superfície de erro, que são controladas pela matriz Hessiana [4].
- A Hessiana forma a base dos procedimentos rápidos de re-treinamento das redes multicamadas alimentadas adiante dirigindo uma pequena modificação nos dados de treinamento [4].
- A inversa da Hessiana pode ser usada para identificar os pesos menos significantes de uma rede como parte de algoritmos de poda e para assinalar erros por uma predição feia por uma rede treinada [4].
- Valores satisfatórios para parâmetros de regularização podem ser determinados a partir dos autovalores da matriz Hessiana [4].
- O determinante da matriz Hessiana pode ser usado para comparar as probabilidades relativas de diferentes modelos de redes [4].

Nas redes neurais multicamadas alimentadas adiante, o cálculo da matriz Hessiana é complexo e custoso, no entanto há uma classe de algoritmos, baseados no método de Newton, mas que não possuem a necessidade de calcular as derivadas de segunda ordem da matriz Hessiana. Esses métodos são denominados de quasi-Newton (ou métodos secante) [17].

Os métodos quasi-Newton atualizam uma matriz Hessiana aproximada a cada iteração do algoritmo de treinamento. Isso é computado como uma função do gradiente [17].

Tal como os métodos quasi-Newton, o algoritmo de Levenberg-Marquardt aproxima a matriz Hessiana por (B.26) [17]:

$$\mathbf{H}(n) = \mathbf{J}^T(n)\mathbf{J}(n) \quad (\text{B.26})$$

onde \mathbf{J} é a matriz Jacobiana contendo as derivadas de primeira ordem do erro (B.27):

$$\mathbf{J}(n) = \frac{\delta \xi_{med}}{\delta w_{kj}(n)} \quad (\text{B.27})$$

Assim, o vetor gradiente (\mathbf{g}_j) é definido como (B.28):

$$\mathbf{g}_j(n) = \mathbf{J}^T(n)\xi_j(n) \quad (\text{B.28})$$

O ajuste dos pesos sinápticos ocorre pela aplicação da equação (B.29):

$$w_j(n+1) = w_j(n) - \left[\mathbf{J}^T(n)\mathbf{J}(n) + \mu_m \mathbf{I} \right]^{-1} \mathbf{J}^T(n)\xi_j(n) \quad (\text{B.29})$$

onde, μ_m é um escalar que: quando é zero, a equação (B.29) recai no método de Newton; quando μ é muito grande a equação (B.29) se torna o método do gradiente descendente com um passo de pequeno tamanho.

Dessa forma, devido à rapidez e a melhor precisão em torno de um erro mínimo proporcionado pelo método de Newton, efetua-se a mudança de μ tão rápido quanto possível valorizando as qualidades abrangidas pelos dois métodos.

Como procedimento, o algoritmo decrementa μ após cada passo bem sucedido, reduzindo o desempenho da função, e aumenta μ somente quando uma tentativa de passo (estimativa do gradiente) irá aumentar o desempenho da função [17]. Dessa forma o desempenho da função sempre diminui a cada iteração [17].

As diversas formas de obtenção de Δw_{kj} permitem um aprendizado neural variado, salientando características consideradas por cada método, decerto que a atualização sináptica já ensinuada obedece em geral à regra (B.30):

$$w_{kj}(n+1) = w_{kj}(n) + \Delta w_{kj}(n) \quad (\text{B.30})$$

Para fins de comparação, as FIGURAS B.9 e B.10 apresentam as curvas de desempenho no treinamento de uma rede neural submetida às mesmas condições, porém com algoritmos de aprendizagem diferentes [17]. Os algoritmos estão representados por siglas: Levenberg-Marquardt (lm), Gradiente Conjugado Escalado (scg), Retropropagação Elástica (rp), Gradiente Conjugado com reinício Powell/Beale (cgb) e Gradiente Descendente (gdx).

Na FIGURA B.9 a rede é usada para efetuar uma aproximação de função e possui duas entradas com 30 neurônios na camada oculta e 2 neurônios de saída. A meta de erro é de 0.005 e o treinamento se processa em uma estação Sum Enterprise 4000.




FIGURA B.9 – Curvas de desempenho entre os algoritmos de aprendizagem submetidos às mesmas condições de ambiente (aproximação de função).

Fonte: MathWorks, 2000.

Na FIGURA B.10 a rede é usada para efetuar um reconhecimento de padrão e possui 9 entradas com duas camadas ocultas contendo 5 neurônios cada e 2 neurônios de saída. A meta de erro é de 0.012 e o treinamento se processa em uma estação Sum Sparc 2.

Observe como nos dois casos o erro quadrado médio, obtido pelo método de Levenberg-Marquardt, cai abruptamente atingindo a meta de erro antes do método da descida do gradiente. Isso permite inferir quanto à eficiência do método de Levenberg-Marquardt em localizar os pontos de mínimo na superfície de erro.




FIGURA B.10 – Curvas de desempenho entre os algoritmos de aprendizagem submetidos às mesmas condições de ambiente (reconhecimento de padrões).

Fonte: MathWorks, 2000.

B.5.3 Critérios de Parada do Treinamento

Até agora foram definidas algumas regras para atualização dos pesos sinápticos dos neurônios, no entanto, o processo iterativo necessita de assertivas de controle que determinem quando se deve parar o aprendizado.

Existem regras que estabelecem os critérios de convergência do algoritmo de retropropagação, interrompendo o processo de aprendizagem quando [25]:

1. A norma euclidiana do vetor gradiente alcança um limiar pequeno.
2. A taxa absoluta de variação do erro médio quadrático por época¹⁰ for suficientemente pequena.
3. O desempenho de generalização for adequado (validação cruzada).

No entanto pode-se destacar que: no primeiro critério o tempo de aprendizagem pode ser longo, além de que o procedimento requer o cálculo do vetor gradiente; no segundo, pode haver o encerramento prematuro do processo e, conseqüentemente, a perda do

¹⁰ Uma época é definida como uma passada completa de todo o conjunto de treinamento pela RNA [46].

desempenho de generalização; todavia, a terceira regra apresenta-se mais oportuna quando associada à segunda.

O uso da validação cruzada resulta na minimização do erro de classificação produzido pela hipótese quando ela é testada sobre o subconjunto de validação [25]. Esse método é usado quando [25]:

- Há uma RNA grande e se quer boa qualidade da generalização.
- Quer-se obter um número otimizado de neurônios nas camadas ocultas.
- Quer-se o melhor momento para parar o treinamento.

Entretanto, o uso de um processo de validação deve ser observado com cautela. Um estudo apresentado em [25] mostra que a aprendizagem exaustiva é satisfatória em uma rede perceptron com uma camada oculta quando o tamanho da amostra de treinamento (N) é grande ao ser comparado com o número de parâmetros da rede (W) (B.31).

$$N > 30W \quad (\text{B.31})$$

O tamanho do conjunto de validação pode ser obtido baseando-se nas seguintes considerações [25]:

- Quando a complexidade da função-alvo, que define a resposta desejada em termos da entrada, é pequena, comparada com o tamanho da amostra, o desempenho da validação cruzada é relativamente insensível à escolha do tamanho do conjunto de validação.
- Quando a função-alvo se torna mais complexa em relação ao tamanho da amostra, a escolha do tamanho ótimo do conjunto de validação tem um efeito mais pronunciado no desempenho da validação cruzada, e seu valor decresce.
- Um único valor fixo de tamanho do conjunto de validação funciona de forma quase ótima para um grande intervalo de complexidade da função-alvo.

Excetuando-se os casos onde a aprendizagem exaustiva é satisfatória, pode-se identificar o início do excesso de treinamento pelo uso da validação cruzada. As

amostras de treinamento são usadas para treinar a RNA da maneira usual, contudo a sessão de treinamento é interrompida periodicamente e a rede é testada com o conjunto de validação. Esse procedimento é referido como: método de treinamento com parada antecipada.

A FIGURA B.11 mostra formas conceituais de duas curvas de aprendizagem: uma relativa às medidas sobre o conjunto de estimação (treinamento) e outra relativa ao conjunto de validação. A curva de aprendizagem de estimação decresce monotonicamente para um número crescente de épocas; diferentemente, a curva de aprendizagem de validação decresce monotonicamente para um mínimo e depois começa a subir, conforme o treinamento continua.




FIGURA B.11 – Ilustração da regra de parada antecipada baseada na validação cruzada.
Fonte: Haykin, 2001.

Observando-se a curva de aprendizagem de estimação pode parecer que o desempenho da rede poderia ser melhorado indo além do ponto mínimo na curva de aprendizagem de validação. Na realidade, entretanto, o que a rede aprende após esse ponto é essencialmente o ruído contido nos dados de treinamento [25]. Essa heurística sugere que o ponto mínimo na curva de aprendizagem de validação seja usado como critério sensato para encerrar a sessão de treinamento [25].

Em se tratando da teoria da aprendizagem, o enfoque em torno da complexidade da amostras submerge uma série de questões do tipo:

- Quantos exemplos aleatórios devem ser apresentados ao algoritmo de aprendizagem para que ele adquira informações suficientes para aprender um conceito-alvo desconhecido?
- Quão grande deve ser o tamanho do conjunto de treinamento?
- Qual algoritmo de treinamento pode ser melhor para um dado conjunto de amostras?

Estudos desenvolvidos por Vapnik-Chervonenkis e citados em [25] procuram responder a algumas dessas questões, entretanto eles limitam o problema a um ambiente restrito.

APÊNDICE C - A BASE DE DADOS DO MIT

C.1 INTRODUÇÃO

No presente trabalho utiliza-se a base de dados de sinais eletrocardiográficos (ECG) do MIT (*Massachusetts Institute of Technology*) contendo representações de doenças cardíacas.

Do que há disponível na internet para *download* [45], pode-se salientar, de forma breve, algumas indagações observadas e que serão posteriormente discutidas ao final desse capítulo. Para tanto as seções que seguem apresentam uma síntese dessas informações para avaliação e segregação das partes relevantes a essa dissertação.

C.2 DESCRIÇÃO DOS BANCOS DE DOENÇAS CARDÍACAS

C.2.1 *The MIT-BIH Atrial Fibrillation Database*

Esse banco de dados inclui 25 gravações de ECG, em longo prazo, de sinais humanos com fibrilação atrial (principalmente *paroxysmal*).

Atualmente existem 23 registros com 10 horas de duração cada e duas derivações do ECG (nos arquivos .dat) a uma taxa de 250 amostras por segundo com resolução de 12 bits a ± 10 mV. Foram utilizados registradores de ECG ambulatoriais com uma largura de banda típica de 0.1 Hz a 40 Hz aproximadamente.

Os arquivos de anotações manuais de ritmo (com sufixo .atr) informam os instantes de ocorrência da fibrilação atrial (AFIB), flutter atrial (AFL) e todos os demais ritmos (N). Os arquivos de anotações de batida (com sufixo .qrs) foram gerados automaticamente e não foram corrigidos manualmente. Para alguns registros, houve a correção manual (com sufixo .qrsc).

As anotações de batida podem ser úteis para estudos de métodos de descoberta de fibrilação atrial de forma automatizada, onde tais métodos devam ser robustos com respeito a erros típicos de detecção do complexo QRS.

C.2.2 The MIT-BIH Malignant Ventricular Arrhythmia Database

Essa base de dados inclui 22 gravações de ECG de 30 minutos cada com duas derivações, contendo principalmente episódios de taquicardia ventricular contínua (VT) e flutter ventricular (VFL) registrados nos arquivos de anotação (sufixo .atr).

C.2.3 MIT-BIH Arrhythmia Database

Esse banco de dados contém 23 registros de 10 minutos cada (100 a 124) e 25 registros de 30 minutos cada (200 a 234), extraídos a partir de uma/duas derivações de eletrocardiogramas ambulatoriais e obtidos de 47 pessoas estudadas pelo BIH Arritmia Laboratório entre 1975 e 1979. Os 23 registros foram escolhidos ao acaso de um conjunto total de 4000 registros com 24 horas de duração cada, coletado de uma população mista de pacientes internos (aproximadamente 60%) e externos (aproximadamente 40%) do Beth Israel Hospital de Boston.

As demais 25 gravações foram selecionadas do mesmo conjunto, porém com arritmias menos comuns, mas clinicamente significativas e que não seriam bem representadas em uma parcela de amostras pequena.

As gravações foram feitas a uma taxa de 360 amostras por segundo por canal e convertidas (com o *xform*) para 250 amostras por segundo por canal com resolução de 11 bits em 10 mV.

Dois ou mais médicos anotaram de forma independente cada registro e as discordâncias observadas foram solucionadas e os resultados registrados nos arquivos de anotações (sufixo .atr)

A TABELA C.1 apresenta a descrição dos símbolos utilizados nos arquivos de anotações médicas.

TABELA C.1
ANOTAÇÕES MÉDICAS

Anotações de Batimento		Anotações de Ritmo	
Símbolo	Descrição	Símbolo	Descrição
.	Normal beat	(AB)	Atrial bigeminy
L	Left bundle branch block beat	(AFIB)	Atrial fibrillation
R	Right bundle branch block beat	(AFL)	Atrial flutter
A	Atrial premature beat	(B)	Ventricular bigeminy
a	Aberrated atrial premature beat	(BII)	2° heart block
J	Nodal (junctional) premature beat	(IVR)	Idioventricular rhythm
S	Supraventricular premature beat	(N)	Normal sinus rhythm
V	Premature ventricular contraction	(NOD)	Nodal (A-V junctional) rhythm
F	Fusion of ventricular and normal beat	(P)	Paced rhythm
[Start of ventricular flutter/fibrillation	(PREX)	Pre-excitation (WPW)
!	Ventricular flutter wave	(SBR)	Sinus bradycardia
]	End of ventricular flutter/fibrillation	(SVTA)	Supraventricular tachyarrhythmia
e	Atrial escape beat	(T)	Ventricular trigeminy
j	Nodal (junctional) escape beat	VF	Ventricular fibrillation
E	Ventricular escape beat	(VFL)	Ventricular flutter
/	Paced beat	(VT)	Ventricular tachycardia
f	Fusion of paced and normal beat		
P	Non-conducted P-wave (blocked APB)	Anotações de Qualidade	
Q	Unclassifiable beat	Símbolo	Descrição
	Isolated QRS-like artifact	<i>qq</i>	Signal quality change: the first character (`c' or `n') indicates the quality of the upper signal (clean or noisy), and the second character indicates the quality of the lower signal
		U	Extreme noise or signal loss in both signals: ECG is unreadable
		M (or MISSB)	Missed beat
		P (or PSE)	Pause
		T (or TS)	Tape slippage

Fonte: Physionet, 2002.

C.2.4 The QT Database

A base de dados QT inclui ECGs que foram escolhidos para representar uma grande variedade de morfologias QRS e ST-T com intuito de permitir a elaboração de algoritmos para detecção de uma grande variedade de situações reais.

O banco QT possui um total de 105 registros de 15 minutos cada e duas derivações do corpo humano. As gravações foram feitas a uma taxa de 250 amostras por segundo por canal.

Registros entre 30 e 100 batimentos representativos foram manualmente anotados por cardiologistas, que identificaram o início, pico e fim da onda P; o início e o fim do complexo QRS; o pico e o fim da onda T; e, se presente, o pico e o fim da onda U. Para permitir o estudo de variações de batida-para-batida, 30 batimentos consecutivos de morfologia dominante foram anotados em cada caso quando possível.

Os arquivos de anotações médicas foram separados conforme apresenta a TABELA C.2.

TABELA C.2 ARQUIVOS DE ANOTAÇÕES MÉDICAS	
Sufixo	Descrição
.hea	header file, describing signal file contents and format
.dat	signal file
.atr	reference beat annotations from original database (not available in all cases)
.man	reference beat annotations for selected beats only
.q1c	manually determined waveform boundary measurements for selected beats (annotator 1 only -- second pass)
.q2c	manually determined waveform boundary measurements for selected beats (annotator 2 only -- second pass; available for only 11 records)
.qt1	manually determined waveform boundary measurements for selected beats (annotator 1 only -- first pass)
.qt2	manually determined waveform boundary measurements for selected beats (annotator 2 only -- first pass; available for only 11 records)
.pu	automatically determined waveform boundary measurements for all beats (based on both signals)
.pu0	automatically determined waveform boundary measurements for all beats (based on signal 0 only)
.pu1	automatically determined waveform boundary measurements for all beats (based on signal 1 only)

Fonte: Physionet, 2002.

C.2.5 *Ventricular Tachyarrhythmia (ou Taquicardia) Database*

Essa base de dados possui 35 registros de ECG de 8 minutos cada e com uma derivação contendo episódios de taquiarritmia ventricular contínua (VT), flutter ventricular (VFL) e fibrilação ventricular (VF).

C.2.6 European ST-T Database

A base de dados Européia ST-T foi construída para ser usada em avaliações de algoritmos que efetuam a análise das mudanças ocorridas na onda T e no segmento ST.

Essa base de dados consiste em 90 anotações de gravações ambulatoriais de ECG de 78 pacientes, sendo 70 homens com idade entre 30 e 84 anos e 8 mulheres com idade entre 55 e 71 anos.

Foi diagnosticada isquemia do miocárdio (ou suspeita) em cada paciente. Critérios adicionais de seleção foram estabelecidos para obter uma seleção representativa das anormalidades do ECG na base de dados, incluindo o deslocamento na linha de base do segmento ST resultante de condições, tais como, hipertensão ventricular diskinesia e efeitos de medicações.

A base de dados inclui 367 episódios de mudanças do segmento ST, 401 episódios de mudanças na onda T, com duração de 30 segundos até vários minutos, e deslocamentos de picos de 100 μV até mais que 1 mV. Há, ainda, 11 episódios de deslocamento de eixo resultando em aparente mudança no segmento ST e 11 resultando em aparente mudança na onda T.

Relatórios clínicos compactos documentam cada registro e estão dispostos no interior dos arquivos de cabeçalho (sufixo .hea), contendo: resumo da patologia, medicações, desbalanço eletrolítico e informações técnicas.

Cada gravação possui duração de duas horas com taxa de 250 amostras por segundo em dois canais com resolução de 12 bits sobre uma faixa nominal de entrada de 20 mV. Os valores de amostras, após a digitalização, foram re-escalados com referência ao sinal de calibração do gravador analógico original com objetivo de obter uma escala uniforme de 200 unidades A/D por mV para todo os sinais (O sinal de calibração não está incluído nos arquivos de sinais).

Dois cardiologistas trabalharam independentemente para anotar cada registro, batimento por batimento, as alterações na morfologia do segmento ST e da onda T, ritmo e qualidade do sinal. Mudanças nos segmento ST e onda T foram identificadas em ambas

derivações (usando critérios pré-definidos que foram aplicados uniformemente em todos os casos) em seus: início, extremo e fim. As anotações foram comparadas e as discordâncias resolvidas e anotadas.

Foram feitas 802.866 anotações e 48 dos 90 registros completos estão disponíveis em PhysioNet [45].

Os cardiologistas participaram conjuntamente no projeto definindo o seguinte conjunto de regras para localização dos episódios ST e episódios T (i.e. intervalos durante o qual o ECG exibe mudanças significantes no segmento ST ou onda T). Para identificar e anotar um episódio ST os seguintes critérios foram aplicados:

- *Desvios do Segmento ST*: Foram medidos em relação a uma forma de onda de referência para cada paciente (usualmente selecionado dos primeiros 30 segundos de cada registro). Medidas de desvio do segmento ST foram pegadas a 80 milissegundos depois do ponto J com frequência cardíaca abaixo de 120 bpm. Para frequências maiores, as medidas foram efetuadas a 60 milissegundos após o ponto J.
- *Episódios ST*: Devem conter um intervalo de pelo menos 30 segundos durante o qual o valor absoluto do desvio ST não é menor que 0.1 mV.
- *Início dos Episódios ST*: São anotados e localizados pesquisando-se o sinal para traz até o primeiro instante em que o valor absoluto do desvio ST excede o patamar de 0.1 mV. A pesquisa continua até se encontrar um batimento onde o valor absoluto do desvio ST é menor que 0.05 mV e para o qual o desvio ST absoluto é menor que 0.1 mV ao longo dos prévios 30 segundos. Uma anotação de mudança que indica o início do episódio é colocada imediatamente após esse batimento.
- *O Pico*: Ou seja, o maior desvio positivo ou negativo de cada episódio ST é anotado. Uma anotação de mudança do trecho ST é colocada antes do batimento que possui o maior desvio ST; essa anotação contém uma medida manual do pico do desvio ST.

- *O Fim dos Episódios ST*: São anotados e localizados pesquisando-se para frente do instante no qual o último desvio ST absoluto excede 0.1 mV. A pesquisa continua até ser encontrado um batimento para o qual o desvio ST absoluto é menor que 0.05 mV e para o qual o desvio ST absoluto é menor que 0.1 mV ao longo dos próximos 30 segundos. Uma anotação de mudança do segmento ST que indica o fim do episódio é colocada imediatamente antes dessa batida.

Para identificar e anotar os episódios T, critérios similares foram anotados:

- *Desvios T*: São medidos em relação à mesma forma de onda de referência que é usada para medir os desvios ST. A quantidade AT é definida como a amplitude da fase dominante da onda T medida em relação à linha de base (até a junção PQ); se a onda T está invertida, ou se a fase dominante de uma onda T bifásica está abaixo da linha de base, AT é negativo. O desvio T é definido como a diferença (positiva ou negativa) entre os valores de AT para a forma de onda corrente e para a forma de onda de referência.
- *Episódios T*: Devem conter um intervalo de pelo menos 30 segundos durante o qual o valor absoluto do desvio T não é menor que 0.2 mV.
- *Início dos Episódios T*: São anotados e localizados pesquisando-se o sinal para traz até o primeiro instante em que o valor absoluto do desvio T excede o patamar de 0.2 mV. Quando um intervalo de pelo menos 30 segundos é encontrado, no qual o valor absoluto do desvio T não excede 0.2 mV, o fim do intervalo define o início do episódio. Uma anotação é colocada antes do início de cada batimento do episódio.
- *O Pico*: Ou seja, o maior desvio positivo ou negativo de cada episódio T é anotado. Uma anotação de mudança da onda T é colocada antes do batimento que possui o maior desvio T; essa anotação contém uma medida manual do pico do desvio T.
- *O Fim dos Episódios ST*: São anotados e localizados pesquisando-se para frente do instante no qual o último desvio T absoluto excede 0.2 mV. Quando um

intervalo de pelo menos 30 segundos é encontrado, no qual o valor absoluto do desvio T não excede 0.2 mV, o início do intervalo define o fim do episódio. Uma anotação é colocada após o fim de cada batimento do episódio.

- *Desvio T Extremo*: Quando um episódio que contém desvio T absoluto excedendo 0.4 mV, anotações adicionais são colocadas sempre que ocorre o cruzamento em 0.4 mV. Essas anotações adicionais na mudança da onda T indicam o início e o fim de cada intervalo T extremo.

Essas regras são aplicadas a cada um dos dois sinais da derivação independentemente. Por essa razão, cada anotação de mudança ST e T indicam o sinal para o qual se aplicam.

Cada anotação de mudança ST e T contém um campo texto que descreve sua significância. O campo texto contém caracteres que indicam o tipo de episódio (ST ou T), o número do sinal (0 ou 1) e a direção do desvio (+ ou - e, para desvio extremo, ++ ou --). O campo texto de uma anotação que marca o início de um episódio contém um parêntese aberto como prefixo. O fim do episódio é marcado com o prefixo A e um número decimal de 3 ou 4 dígitos que expressa a magnitude do desvio do pico em μV . Uma anotação que marca o fim de um episódio possui um parêntese fechando o fim do campo texto. Por exemplo, um episódio de depressão ST no sinal 0 com um desvio de pico absoluto de $200\mu\text{V}$ pode ser marcado por três anotações com um campo de texto: (ST0-, AST0-200, ST0-).

Em seis registros (e0161, e0509, e0601, e0611, e0613, e0615), deslocamentos de eixos resultantes de mudança de posição dão a aparência de mudanças reais de trecho ST e onda T. Esses deslocamentos de eixos foram anotados usando anotações comentadas. Os campos texto de anotações foram construídos do mesmo modo para anotações ST e T, exceto pelo uso de caracteres minúsculos que são usados para facilitar a distinguir esses episódios de deslocamento de eixos dos episódios reais de deslocamentos ST e T. Por exemplo, um deslocamento de eixo no sinal 1 que aparenta um desvio de pico T absoluto de $350\mu\text{V}$ pode ser marcado por três anotações com um campo de texto: (t1+, at1+350, t1+).

A TABELA C.3 mostra os tipos de anotações presentes na base de dados MIT ST-T.

TABELA C.3
TIPOS DE ANOTAÇÃO ST-T

Categoria	Símbolo	Descrição
NORMAL	N	Batimento normal
ABERR	a	Batimento prematuro atrial <i>aberrated</i>
NPC	J	Batimento prematuro nodal (juncional)
SVPB	S	Batimento supraventricular ou ectópico prematuro (atrial ou nodal)
PVC	V	Contração ventricular prematura
FUSION	F	Fusão de batimento ventricular e normal
UNKNOWN	Q	Batimento não classificado
ARFCT		Artefato QRS-like isolado
RHYTHM	(AB	Bigeminia atrial
	(AFIB	Fibrilação atrial
	(B	Bigeminia ventricular
	(B3	Bloqueio de coração do 3º grau
	(N	Ritmo sinus normal
	(SAB	Bloqueio sino-atrial
	(SBR	Braquicardia sinusal
	(SVTA	Taquiarritmia supraventricular
	(T	Trigeminia ventricular
	(VT	Taquicardia ventricular
STCH	(ST...	Início do episódio ST
	AST...	Pico do episódio ST
	ST...)	Fim do episódio ST
TCH	(T...	Início do episódio T
	AT...	Pico do episódio T
	T...)	Fim do episódio T
NOTE	(st... ast... st...)	Início do desvio ST resultante do deslocamento de eixo Pico do desvio ST resultante do deslocamento de eixo Fim do desvio ST resultante do deslocamento de eixo
	(t... at... t...)	Início do desvio T resultante do deslocamento de eixo Pico do desvio T resultante do deslocamento de eixo Fim do desvio T resultante do deslocamento de eixo
	BUTTON	Botão de evento ativado pelo paciente
	TS	<i>Tape slippage</i>
NOISE	cc	Sinal 0 clean e sinal 1 clean
	nc	Sinal 0 noisy e sinal 1 clean
	cn	Sinal 0 clean e sinal 1 noisy
	nn	Sinal 0 noisy e sinal 1 noisy
	uc	Sinal 0 unreadable e sinal 1 clean
	un	Sinal 0 unreadable e sinal 1 noisy
	cu	Sinal 0 clean e sinal 1 unreadable
	nu	Sinal 0 noisy e sinal 1 unreadable
	uu	Sinal 0 unreadable e sinal 1 unreadable

Fonte: Physionet, 2002.

C.2.7 The PAF Prediction Challenge Database

Essa base de dados possui gravações de dois canais do ECG de pacientes contendo fibrilação atrial paroxysmal (PAF). A base de dados é dividida em conjunto de aprendizagem (registros com nome na forma n* e p*) e conjunto de teste (registros com nome na forma t*).

O conjunto de aprendizagem possui 50 registros contendo 30 minutos de gravações cada em duas tomadas consecutivas em arquivo (ex.: p15 e p16) e dois registros de continuação de 5 minutos cada gravados em arquivos consecutivos (ex.: p15c e p16c). Cada conjunto de quatro arquivos foi obtido pela gravação contínua do ECG de um único paciente. Os 50 conjuntos de arquivos são provenientes de 48 pacientes distintos.

Os arquivos com nomes iniciados com a letra P são provenientes de pacientes que possuem fibrilação atrial paroxysmal (PAF). O segundo registro (o de número par) em cada par de 30 minutos contém o sinal de ECG imediatamente precedente ao episódio de PAF. Assim, por exemplo, o registro p16 precede imediatamente o episódio de PAF no registro p16c.

O primeiro registro (o de número ímpar – ex.: p15) em cada par de 30 minutos contém o sinal de ECG durante o período distante de qualquer episódio de PAF. O arquivo correspondente de 5 minutos (continuação – ex.: p15c) mostra os minutos imediatamente seguintes ao que se pode considerar “distante-do-PAF”. Alguns registros nesse grupo podem conter estouros muito curtos de PAF que passaram sem ser notados durante a construção do conjunto de aprendizagem.

Os registros com nomes iniciando com a letra N são provenientes de pacientes que não possuem fibrilação atrial documentada. Os pacientes testados pertencem aos grupos de controle de saúde, monitoramento de longo tempo e de unidades intensivas de tratamento.

Os conjuntos de teste são numerados de t01 a t100. Como nos conjuntos de aprendizagem, pares de registros numerados consecutivamente são provenientes de um mesmo ECG do paciente. Aproximadamente metade do conjunto de teste é proveniente de pacientes com PAF sendo que a primeira parte identifica esses conjuntos de registros

e a segunda parte identifica os registros em cada par que precedem imediatamente a PAF.

Os sinais do ECG foram gravados a uma taxa de 128 amostras por segundo a 16 bits alternando nominalmente 200 unidades A/D por mV.

C.2.8 The MIT-BIH Normal Sinus Rhythm Database

Essa base de dados inclui 18 gravações de ECG de longa duração com duas derivações tomadas de 5 pacientes masculinos com idade de 26 a 45 anos e 13 femininas com idades de 20 a 50 anos. ECG normal onde são encontradas arritmias insignificantes.

C.2.9 The MIT-BIH Supraventricular Arrhythmia Database

Essa base de dados inclui 78 gravações de ECG de 30 minutos cada escolhidas para complementar os exemplos de arritmias suplementares da base de dados de arritmia do MIT-BIH.

As anotações médicas correspondem aos critérios da TABELA C.1 para de arritmias.

C.2.10 The MIT-BIH LT_ST Database

Essa base de dados inclui 86 registros de ECG de 80 pessoas com episódios ST, anotações da qualidade do sinal, ocorrência de complexo QRS e medidas de nível do segmento ST. No entanto, apenas 5 registros completos estão disponíveis (s20011, s20021, s20031, s20041, e s30661).

Cada arquivo de gravação possui de 21 a 24 horas de duração e contém dois ou três sinais de ECG amostrados a 250 amostras por segundo com 12 bits de resolução em uma faixa de ± 10 mV. Cada registro possui um arquivo de cabeçalho (sufixo .hea) , um arquivo de sinal (sufixo .dat) e alguns arquivos de anotações identificados pelo sufixo conforme mostra a TABELA C.4.

TABELA C.4
ARQUIVOS DE ANOTAÇÕES MÉDICAS

Sufixo	Descrição
.ari	automatically-generated beat annotations
.atr	manually corrected beat annotations
.16a	automatically-generated, manually-corrected ST-segment measurements (based on 16-second moving averages, updated for each beat)
.sta	ST-segment episode annotations, $V_{min} = 75 \mu V$, $T_{min} = 30$ s (see below)
.stb	ST-segment episode annotations, $V_{min} = 100 \mu V$, $T_{min} = 30$ s
.stc	ST-segment episode annotations, $V_{min} = 100 \mu V$, $T_{min} = 60$ s

Fonte: Physionet, 2002.

As medidas nos arquivos “.16a” foram usadas para construir uma função de divergência ST para cada sinal. Os episódios ST foram identificados independentemente para cada sinal, baseado na função de divergência ST e nos seguintes critérios:

1. Um episódio inicia quando a magnitude da função de divergência ST excede $50 \mu V$;
2. A divergência deve alcançar uma magnitude de V_{min} ou mais ao longo de um intervalo contínuo de pelo menos T_{min} ;
3. O episódio termina quando a divergência se torna menor que $50 \mu V$, contanto que ela não exceda os $50 \mu V$ nos próximos 30 segundos.

As anotações correspondem às da TABELA C.1 de arritmia.

C.3 DESCRIÇÃO DOS ARQUIVOS

Segue abaixo uma breve descrição dos arquivos utilizados pela base MIT e os criados para uso nesta dissertação:

- *Arquivos de Sinal:* Pertencem ao MITDB, compactados, possuem extensão .DAT e armazenam os sinais elétricos do ECG de uma ou duas derivações.
- *Arquivos de Cabeçalho:* Possuem informações do arquivo de sinal correspondente. Com extensão .HEA, portam as seguintes informações: frequência de amostragem original, frequência de amostragem alterada pelo *xform* (quando efetuada), número de derivações, nomes das derivações, total de

amostras, nome do arquivo de sinal, formato MITDB, amplitude de tensão, bits de resolução e comentários extras.

- *Arquivos de Anotações do MITDB*: Possuem extensões variadas (.MAN, .PU, .QT1...) no entanto a extensão .ATR é a mais utilizada. Essa categoria de arquivos da base MIT possui anotações efetuadas por médicos quanto à ocorrência de doenças observadas pelo ECG. As anotações estão codificadas conforme descrito na seção 1.1.
- *Arquivos de Anotações da Dissertação*: Os arquivos com extensão .ANT são a versão descompactada (com o programa *rdann.exe*) dos arquivos de anotações do MITDB. Os arquivos com extensão .FAN foram processados pelo programa *panot.exe* sobre os arquivos com extensão .ANT, concatenando os blocos de anotações de cada arquivo. Os arquivos com extensão .DOE informam quais as anotações contidas nos arquivos com extensão .FAN.

C.4 CONSIDERAÇÕES SOBRE O BANCO DE DADOS – MITDB

Uma abordagem comparativa de parâmetros, que permita a segregação de classes de padrões (doenças), obriga o estabelecimento de preceitos igualitários para a seleção de características relevantes que permitirão uma inquirição plausível da técnica estudada. Dessa forma, parâmetros como: tipos de derivações, qualidade das anotações médicas, natureza das doenças e qualidade elétrica do sinal do ECG devem ser tomados para agrupar classes passíveis de comparação, como mostra resumidamente a TABELA¹¹

C.5.

¹¹ O banco “PAF” foi desconsiderado da análise por ser originário do banco de “Fibrilação Atrial”.

TABELA C.5
RESUMO COMPARATIVO DAS DOENÇAS

Grupo	Doenças	Derivações	Observações
A	Taquicardia Ventricular	signal 0	Possui apenas uma derivação
	Arritmias Supraventriculares	signal 0 e signal 1	Não há discriminação dos tipos de arritmias.
	Fibrilação Atrial		
	Arritmia Ventricular Maligna		Possui apenas rótulos de ritmo. Alguns rótulos não possuem explicação.
	Episódios QT	Variadas	Há somente anotações de ocorrência das ondas P-QRS-T-U
	Normal		
B	Episódios ST_T	MLII e Precordiais	
	Arritmia		
	Episódios QT	Variadas	Há somente anotações de ocorrência das ondas P-QRS-T-U
	Normal		
-	Episódio LT_ST	-	

C.5 CONTEÚDO DO MITDB

Os arquivos de anotações médicas descompactados (extensão .ant) e formatados (extensão .fan) foram obtidos com os programas *rdann.exe* e *panot.exe* constantes na biblioteca de programas. Devido à sua grande extensão, esses arquivos não foram incluídos nesse texto.

Os dados das TABELAS C.6 a C.14 foram obtidos dos arquivos de cabeçalho (extensão .hea), que acompanham seus respectivos arquivos de sinais (extensão .dat), através do programa *kltsens.m*.

TABELA C.6 – The MIT-BIH Atrial Fibrillation Database

Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
04015	250	212	2	10:13:430		
04043	250	212	2	10:13:430		
04048	250	212	2	10:13:430		
04126	250	212	2	10:13:430		
04746	250	212	2	10:13:430		
04908	250	212	2	10:13:430		
04936	250	212	2	10:13:430	record 04936, signal 0	record 04936, signal 1

TABELA C.6 – (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
05091	250	212	2	10:13:430		
05121	250	212	2	10:13:430		
05261	250	212	2	10:13:430		
06426	250	212	2	10:13:430		
06453	250	212	2	9:15:0		
06995	250	212	2	10:13:430		
07162	250	212	2	10:13:430		
07859	250	212	2	10:13:430		

TABELA C.7 – The MIT-BIH Malignant Ventricular Arrhythmia Database						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
418	250	212	2	0:35:0	record 418, signal 0	record 418, signal 1
419	250	212	2	0:35:0	record 419, signal 0	record 419, signal 1
420	250	212	2	0:35:0	record 420, signal 0	record 420, signal 1
421	250	212	2	0:35:0	record 421, signal 0	record 421, signal 1
422	250	212	2	0:35:0	record 422, signal 0	record 422, signal 1
423	250	212	2	0:35:0	record 423, signal 0	record 423, signal 1
424	250	212	2	0:35:0	record 424, signal 0	record 424, signal 1
425	250	212	2	0:35:0	record 425, signal 0	record 425, signal 1
426	250	212	2	0:35:0	record 426, signal 0	record 426, signal 1
427	250	212	2	0:35:0	record 427, signal 0	record 427, signal 1
428	250	212	2	0:35:0	record 428, signal 0	record 428, signal 1
429	250	212	2	0:35:0	record 429, signal 0	record 429, signal 1
430	250	212	2	0:35:0	record 430, signal 0	record 430, signal 1
602	250	212	2	0:35:0	record 602, signal 0	record 602, signal 1
605	250	212	2	0:35:0	record 605, signal 0	record 605, signal 1
607	250	212	2	0:35:0	record 607, signal 0	record 607, signal 1
609	250	212	2	0:35:0	record 609, signal 0	record 609, signal 1

TABELA C.7 – (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
610	250	212	2	0:35:0	record 610, signal 0	record 610, signal 1
611	250	212	2	0:35:0	record 611, signal 0	record 611, signal 1
612	250	212	2	0:35:0	record 612, signal 0	record 612, signal 1
614	250	212	2	0:35:0	record 614, signal 0	record 614, signal 1
615	250	212	2	0:35:0	record 615, signal 0	record 615, signal 1

TABELA C.8 – The MIT-BIH Arrhythmia Database						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
100	360	212	2	0:30:55	MLII	V5
101	360	212	2	0:30:55	MLII	V1
102	360	212	2	0:30:55	V5	V2
103	360	212	2	0:30:55	MLII	V2
104	360	212	2	0:30:55	V5	V2
105	360	212	2	0:30:55	MLII	V1
106	360	212	2	0:30:55	MLII	V1
107	360	212	2	0:30:55	MLII	V1
108	360	212	2	0:10:0	MLII	V1
109	360	212	2	0:10:0	MLII	V1
111	360	212	2	0:10:0	MLII	V1
112	360	212	2	0:10:0	MLII	V1
113	360	212	2	0:10:0	MLII	V1
114	360	212	2	0:10:0	V5	MLII
115	360	212	2	0:10:0	MLII	V1
116	360	212	2	0:10:0	MLII	V1
117	360	212	2	0:10:0	MLII	V2
118	360	212	2	0:30:55	MLII	V1
119	360	212	2	0:30:55	MLII	V1
_121	360	212	2	0:10:0	MLII	V1
_122	360	212	2	0:10:0	MLII	V1
_123	360	212	2	0:10:0	MLII	V5
_124	360	212	2	0:10:0	MLII	V4
200	360	212	2	0:30:55	MLII	V1
201	360	212	2	0:30:55	MLII	V1
202	360	212	2	0:30:55	MLII	V1
203	360	212	2	0:30:55	MLII	V1
205	360	212	2	0:30:55	MLII	V1

TABELA C.8 – (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
207	360	212	2	0:30:55	MLII	V1
208	360	212	2	0:30:55	MLII	V1
209	360	212	2	0:30:55	MLII	V1
210	360	212	2	0:30:55	MLII	V1
212	360	212	2	0:30:55	MLII	V1
213	360	212	2	0:30:55	MLII	V1
214	360	212	2	0:30:55	MLII	V1
215	360	212	2	0:30:55	MLII	V1
217	360	212	2	0:30:55	MLII	V1
219	360	212	2	0:30:55	MLII	V1
220	360	212	2	0:10:0	MLII	V1
221	360	212	2	0:10:0	MLII	V1
222	360	212	2	0:10:0	MLII	V1
223	360	212	2	0:10:0	MLII	V1
228	360	212	2	0:10:0	MLII	V1
230	360	212	2	0:10:0	MLII	V1
231	360	212	2	0:10:0	MLII	V1
232	360	212	2	0:10:0	MLII	V1
233	360	212	2	0:10:0	MLII	V1
234	360	212	2	0:10:0	MLII	V1

TABELA C.9 – The QT Database						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
sel100	250	212	2	0:15:0	MLII	V5
sel102	250	212	2	0:15:0	V5	V2
sel103	250	212	2	0:15:0	MLII	V2
sel104	250	212	2	0:15:0	V5	V2
sel114	250	212	2	0:15:0	V5	MLII
sel116	250	212	2	0:15:0	MLII	V1
sel117	250	212	2	0:15:0	MLII	V2
sel123	250	212	2	0:15:0	MLII	V5
sel14046	250	212	2	0:14:599	record 14046, signal 0	record 14046, signal 1
sel14157	250	212	2	0:14:599	record 14157, signal 0	record 14157, signal 1
sel14172	250	212	2	0:14:599	record 14172, signal 0	record 14172, signal 1

TABELA C.9 – (Continuação)

Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
sel15814	250	212	2	0:14:599	record 15814, signal 0	record 15814, signal 1
sel16265	250	212	2	0:14:599	record mqt2, signal 0	record mqt2, signal 1
sel16272	250	212	2	0:14:599	record mqt2, signal 0	record mqt2, signal 1
sel16273	250	212	2	0:14:599	record 16273, signal 0	record 16273, signal 1
sel16420	250	212	2	0:14:599	record 16420, signal 0	record 16420, signal 1
sel16483	250	212	2	0:14:599	record 16483, signal 0	record 16483, signal 1
sel16539	250	212	2	0:14:599	record 16539, signal 0	record 16539, signal 1
sel16773	250	212	2	0:14:599	record 16773, signal 0	record 16773, signal 1
sel16786	250	212	2	0:14:599	record 16786, signal 0	record 16786, signal 1
sel16795	250	212	2	0:14:599	record 16795, signal 0	record 16795, signal 1
sel17152	250	212	2	0:14:599	record mqt2, signal 0	record mqt2, signal 1
sel17453	250	212	2	0:14:599	record 17453, signal 0	record 17453, signal 1
sel213	250	212	2	0:15:0	MLII	V1
sel221	250	212	2	0:15:0	MLII	V1
sel223	250	212	2	0:15:0	MLII	V1
sel230	250	212	2	0:15:0	MLII	V1
sel231	250	212	2	0:15:0	MLII	V1
sel232	250	212	2	0:15:0	MLII	V1
sel233	250	212	2	0:15:0	MLII	V1
sel30	250	212	2	0:14:599	record 30, signal 0	record 30, signal 1
sel301	250	212	2	0:14:599	record 301, signal 0	record 301, signal 1
sel302	250	212	2	0:15:0	record 302, signal 0	record 302, signal 1
sel306	250	212	2	0:15:0	record 306, signal 0	record 306, signal 1
sel307	250	212	2	0:15:0	record 307, signal 0	record 307, signal 1
sel308	250	212	2	0:15:0	record 308, signal 0	record 308, signal 1
sel31	250	212	2	0:14:599	record 31, signal 0	record 31, signal 1

TABELA C.9 – (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
sel310	250	212	2	0:15:0	record 310, signal 0	record 310, signal 1
sel32	250	212	2	0:14:599	record 32, signal 0	record 32, signal 1
sel33	250	212	2	0:14:599	record 33, signal 0	record 33, signal 1
sel34	250	212	2	0:14:599	record 34, signal 0	record 34, signal 1
sel35	250	212	2	0:14:599	record 35, signal 0	record 35, signal 1
sel36	250	212	2	0:14:599	record 36, signal 0	record 36, signal 1
sel37	250	212	2	0:14:599	record 37, signal 0	record 37, signal 1
sel38	250	212	2	0:14:599	record 38, signal 0	record 38, signal 1
sel39	250	212	2	0:14:599	record 39, signal 0	record 39, signal 1
sel40	250	212	2	0:14:599	record 40, signal 0	record 40, signal 1
sel41	250	212	2	0:14:599	record 41, signal 0	record 41, signal 1
sel42	250	212	2	0:14:599	record 42, signal 0	record 42, signal 1
sel43	250	212	2	0:14:599	record 43, signal 0	record 43, signal 1
sel44	250	212	2	0:14:599	record 44, signal 0	record 44, signal 1
sel45	250	212	2	0:14:599	record 45, signal 0	record 45, signal 1
sel46	250	212	2	0:14:599	record 46, signal 0	record 46, signal 1
sel47	250	212	2	0:14:599	record 47, signal 0	record 47, signal 1
sel48	250	212	2	0:14:599	record 48, signal 0	record 48, signal 1
sel49	250	212	2	0:14:599	record 49, signal 0	record 49, signal 1
sel50	250	212	2	0:14:599	record 50, signal 0	record 50, signal 1
sel51	250	212	2	0:14:599	record 51, signal 0	record 51, signal 1
sel52	250	212	2	0:14:599	record 52, signal 0	record 52, signal 1
sel803	250	212	2	0:14:599	record 803, signal 0	record 803, signal 1

TABELA C.9 – (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
sel808	250	212	2	0:14:599	record 808, signal 0	Record 808, signal 1
sel811	250	212	2	0:14:599	record 811, signal 0	record 811, signal 1
sel820	250	212	2	0:14:599	record 820, signal 0	record 820, signal 1
sel821	250	212	2	0:14:599	record 821, signal 0	record 821, signal 1
sel840	250	212	2	0:14:599	record 840, signal 0	record 840, signal 1
sel847	250	212	2	0:14:599	record 847, signal 0	record 847, signal 1
sel853	250	212	2	0:14:599	record 853, signal 0	record 853, signal 1
sel871	250	212	2	0:14:599	record 871, signal 0	record 871, signal 1
sel872	250	212	2	0:14:599	record 872, signal 0	record 872, signal 1
sel873	250	212	2	0:14:599	record 873, signal 0	record 873, signal 1
sel883	250	212	2	0:14:599	record 883, signal 0	record 883, signal 1
sel891	250	212	2	0:14:599	record 891, signal 0	record 891, signal 1
sele0104	250	212	2	0:15:0	D3	D4
sele0106	250	212	2	0:15:0	D3	V3
sele0107	250	212	2	0:15:0	D3	V4
sele0110	250	212	2	0:15:0	V3	D3
sele0111	250	212	2	0:15:0	D3	V4
sele0112	250	212	2	0:15:0	D3	V4
sele0114	250	212	2	0:15:0	D3	V4
sele0116	250	212	2	0:15:0	V4	D3
sele0121	250	212	2	0:15:0	V4	D3
sele0122	250	212	2	0:15:0	V4	D3
sele0124	250	212	2	0:15:0	V4	D3
sele0126	250	212	2	0:15:0	V4	D3
sele0129	250	212	2	0:15:0	D3	V3
sele0133	250	212	2	0:15:0	D3	V3
sele0136	250	212	2	0:15:0	D3	V4
sele0166	250	212	2	0:15:0	V4	D3
sele0170	250	212	2	0:15:0	V4	D3
sele0203	250	212	2	0:15:0	CM5	CC5
sele0210	250	212	2	0:15:0	CM5	CC5
sele0211	250	212	2	0:15:0	CM5	CC5

TABELA C.9 – (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
sele0303	250	212	2	0:15:0	V2-V3	V5
sele0405	250	212	2	0:15:0	CM5	mod.V1
sele0406	250	212	2	0:15:0	CM5	CC5
sele0409	250	212	2	0:15:0	CM5	CC5
sele0411	250	212	2	0:15:0	CM5	CC5
sele0509	250	212	2	0:15:0	V1-V2	V4-V5
sele0603	250	212	2	0:15:0	CM5	CM2
sele0604	250	212	2	0:15:0	CM2	ML5
sele0606	250	212	2	0:15:0	CM5	ML5
sele0607	250	212	2	0:15:0	CM5	CM4
sele0609	250	212	2	0:15:0	CM5	ML5
sele0612	250	212	2	0:15:0	CM5	ML5
sele0704	250	212	2	0:15:0	V5	V1

TABELA C.10 – Ventricular Tachyarrhythmia Database					
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1
cu01	250	212	1	0:8:289	record cu01, signal 0
cu02	250	212	1	0:8:289	record cu02, signal 0
cu03	250	212	1	0:8:289	record cu03, signal 0
cu04	250	212	1	0:8:289	record cu04, signal 0
cu05	250	212	1	0:8:289	record cu05, signal 0
cu06	250	212	1	0:8:289	record cu06, signal 0
cu07	250	212	1	0:8:289	record cu07, signal 0
cu08	250	212	1	0:8:289	record cu08, signal 0
cu09	250	212	1	0:8:289	record cu09, signal 0
cu10	250	212	1	0:8:289	record cu10, signal 0
cu11	250	212	1	0:8:289	record cu11, signal 0
cu12	250	212	1	0:8:289	record cu12, signal 0
cu13	250	212	1	0:8:289	record cu13, signal 0
cu14	250	212	1	0:8:289	record cu14, signal 0
cu15	250	212	1	0:8:289	record cu15, signal 0
cu16	250	212	1	0:8:289	record cu16, signal 0
cu17	250	212	1	0:8:289	record cu17, signal 0
cu18	250	212	1	0:8:289	record cu18, signal 0

TABELA C.10 (Continuação)					
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1
cu19	250	212	1	0:8:289	record cu19, signal 0
cu20	250	212	1	0:8:289	record cu20, signal 0
cu21	250	212	1	0:8:289	record cu21, signal 0
cu22	250	212	1	0:8:289	record cu22, signal 0
cu23	250	212	1	0:8:289	record cu23, signal 0
cu24	250	212	1	0:8:289	record cu24, signal 0
cu25	250	212	1	0:8:289	record cu25, signal 0
cu26	250	212	1	0:8:289	record cu26, signal 0
cu27	250	212	1	0:8:289	record cu27, signal 0
cu28	250	212	1	0:8:289	record cu28, signal 0
cu29	250	212	1	0:8:289	record cu29, signal 0
cu30	250	212	1	0:8:289	record cu30, signal 0
cu31	250	212	1	0:8:289	record cu31, signal 0
cu32	250	212	1	0:8:289	record cu32, signal 0
cu33	250	212	1	0:8:289	record cu33, signal 0
cu34	250	212	1	0:8:289	record cu34, signal 0
cu35	250	212	1	0:8:289	record cu35, signal 0

TABELA C.11 – European ST-T Database						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
e0103	250	212	2	2:0:0	V4	MLIII
e0105	250	212	2	2:0:0	MLIII	V4
e0107	250	212	2	2:0:0	D3	V4
e0111	250	212	2	2:0:0	MLIII	V4
e0113	250	212	2	2:0:0	MLIII	V4
e0115	250	212	2	2:0:0	V5	MLIII
e0119	250	212	2	2:0:0	V4	MLIII
e0121	250	212	2	2:0:0	V4	MLIII
e0123	250	212	2	2:0:0	V4	MLIII
e0125	250	212	2	2:0:0	V4	MLIII
e0127	250	212	2	2:0:0	V4	MLIII
e0129	250	212	2	2:0:0	MLIII	V3
e0133	250	212	2	2:0:0	MLIII	V3
e0139	250	212	2	2:0:0	MLIII	V4
e0147	250	212	2	2:0:0	MLIII	V4
e0151	250	212	2	2:0:0	V3	MLIII
e0155	250	212	2	2:0:0	MLIII	V4
e0159	250	212	2	2:0:0	MLIII	V4

TABELA C.11 – (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
e0161	250	212	2	2:0:0	V4	MLIII
e0163	250	212	2	2:0:0	MLIII	V4
e0203	250	212	2	2:0:0	V5	MLI
e0205	250	212	2	2:0:0	V5	MLI
e0207	250	212	2	2:0:0	V5	MLI
e0211	250	212	2	2:0:0	V5	MLI
e0213	250	212	2	2:0:0	V5	MLI
e0303	250	212	2	2:0:0	V2	V5
e0305	250	212	2	2:0:0	V2	V5
e0403	250	212	2	2:0:0	V5	V1
e0405	250	212	2	2:0:0	V5	V1
e0409	250	212	2	2:0:0	V5	MLI
e0411	250	212	2	2:0:0	V5	MLI
e0413	250	212	2	2:0:0	V2	V5
e0415	250	212	2	2:0:0	V2	V5
e0417	250	212	2	2:0:0	V5	MLI
e0501	250	212	2	2:0:0	V2	V4
e0509	250	212	2	2:0:0	V2	V4
e0515	250	212	2	2:0:0	V2	V5
e0601	250	212	2	2:0:0	V5	MLIII
e0603	250	212	2	2:0:0	V5	V2
e0605	250	212	2	2:0:0	V5	MLIII
e0607	250	212	2	2:0:0	V5	V4
e0609	250	212	2	2:0:0	V5	MLIII
e0611	250	212	2	2:0:0	V5	MLIII
e0613	250	212	2	2:0:0	V5	MLIII
e0615	250	212	2	2:0:0	V5	MLIII
e0801	250	212	2	2:0:0	V1	V5
e0817	250	212	2	2:0:0	V5	V1
e1301	250	212	2	2:0:0	V1	V5

TABELA C.12 – The PAF Prediction Challenge Database

Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
n01	128	16	2	0:30:0	ECG0	ECG1
n01c	128	16	2	0:5:0	ECG0	ECG1
n02	128	16	2	0:30:0	ECG0	ECG1
n02c	128	16	2	0:5:0	ECG0	ECG1
n03	128	16	2	0:30:0	ECG0	ECG1
n03c	128	16	2	0:5:0	ECG0	ECG1
n04	128	16	2	0:30:0	ECG0	ECG1
n04c	128	16	2	0:5:0	ECG0	ECG1
n05	128	16	2	0:30:0	ECG0	ECG1
n05c	128	16	2	0:5:0	ECG0	ECG1
n06	128	16	2	0:30:0	ECG0	ECG1
n06c	128	16	2	0:5:0	ECG0	ECG1
n07	128	16	2	0:30:0	ECG0	ECG1
n07c	128	16	2	0:5:0	ECG0	ECG1
n08	128	16	2	0:30:0	ECG0	ECG1
n08c	128	16	2	0:5:0	ECG0	ECG1
n09	128	16	2	0:30:0	ECG0	ECG1
n09c	128	16	2	0:5:0	ECG0	ECG1
n10	128	16	2	0:30:0	ECG0	ECG1
n10c	128	16	2	0:5:0	ECG0	ECG1
n11	128	16	2	0:30:0	ECG0	ECG1
n11c	128	16	2	0:5:0	ECG0	ECG1
n12	128	16	2	0:30:0	ECG0	ECG1
n12c	128	16	2	0:5:0	ECG0	ECG1
n13	128	16	2	0:30:0	ECG0	ECG1
n13c	128	16	2	0:5:0	ECG0	ECG1
n14	128	16	2	0:30:0	ECG0	ECG1
n14c	128	16	2	0:5:0	ECG0	ECG1
n15	128	16	2	0:30:0	ECG0	ECG1
n15c	128	16	2	0:5:0	ECG0	ECG1
n16	128	16	2	0:30:0	ECG0	ECG1
n16c	128	16	2	0:5:0	ECG0	ECG1
n17	128	16	2	0:30:0	ECG0	ECG1
n17c	128	16	2	0:5:0	ECG0	ECG1
n18	128	16	2	0:30:0	ECG0	ECG1
n18c	128	16	2	0:5:0	ECG0	ECG1
n19	128	16	2	0:30:0	ECG0	ECG1
n19c	128	16	2	0:5:0	ECG0	ECG1

TABELA C.12 (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
n20	128	16	2	0:30:0	ECG0	ECG1
n20c	128	16	2	0:5:0	ECG0	ECG1
n21	128	16	2	0:30:0	ECG0	ECG1
n21c	128	16	2	0:5:0	ECG0	ECG1
n22	128	16	2	0:30:0	ECG0	ECG1
n22c	128	16	2	0:5:0	ECG0	ECG1
n23	128	16	2	0:30:0	ECG0	ECG1
n23c	128	16	2	0:5:0	ECG0	ECG1
n24	128	16	2	0:30:0	ECG0	ECG1
n24c	128	16	2	0:5:0	ECG0	ECG1
n25	128	16	2	0:30:0	ECG0	ECG1
n25c	128	16	2	0:5:0	ECG0	ECG1
n26	128	16	2	0:30:0	ECG0	ECG1
n26c	128	16	2	0:5:0	ECG0	ECG1
n27	128	16	2	0:30:0	ECG0	ECG1
n27c	128	16	2	0:5:0	ECG0	ECG1
n28	128	16	2	0:30:0	ECG0	ECG1
n28c	128	16	2	0:5:0	ECG0	ECG1
n29	128	16	2	0:30:0	ECG0	ECG1
n29c	128	16	2	0:5:0	ECG0	ECG1
n30	128	16	2	0:30:0	ECG0	ECG1
n30c	128	16	2	0:5:0	ECG0	ECG1
n31	128	16	2	0:30:0	ECG0	ECG1
n31c	128	16	2	0:5:0	ECG0	ECG1
n32	128	16	2	0:30:0	ECG0	ECG1
n32c	128	16	2	0:5:0	ECG0	ECG1
n33	128	16	2	0:30:0	ECG0	ECG1
n33c	128	16	2	0:5:0	ECG0	ECG1
n34	128	16	2	0:30:0	ECG0	ECG1
n34c	128	16	2	0:5:0	ECG0	ECG1
n35	128	16	2	0:30:0	ECG0	ECG1
n35c	128	16	2	0:5:0	ECG0	ECG1
n36	128	16	2	0:30:0	ECG0	ECG1
n36c	128	16	2	0:5:0	ECG0	ECG1
n37	128	16	2	0:30:0	ECG0	ECG1
n37c	128	16	2	0:5:0	ECG0	ECG1
n38	128	16	2	0:30:0	ECG0	ECG1
n38c	128	16	2	0:5:0	ECG0	ECG1
n39	128	16	2	0:30:0	ECG0	ECG1

TABELA C.12 (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
n39c	128	16	2	0:5:0	ECG0	ECG1
n40	128	16	2	0:30:0	ECG0	ECG1
n40c	128	16	2	0:5:0	ECG0	ECG1
n41	128	16	2	0:30:0	ECG0	ECG1
n41c	128	16	2	0:5:0	ECG0	ECG1
n42	128	16	2	0:30:0	ECG0	ECG1
n42c	128	16	2	0:5:0	ECG0	ECG1
n43	128	16	2	0:30:0	ECG0	ECG1
n43c	128	16	2	0:5:0	ECG0	ECG1
n44	128	16	2	0:30:0	ECG0	ECG1
n44c	128	16	2	0:5:0	ECG0	ECG1
n45	128	16	2	0:30:0	ECG0	ECG1
n45c	128	16	2	0:5:0	ECG0	ECG1
n46	128	16	2	0:30:0	ECG0	ECG1
n46c	128	16	2	0:5:0	ECG0	ECG1
n47	128	16	2	0:30:0	ECG0	ECG1
n47c	128	16	2	0:5:0	ECG0	ECG1
n48	128	16	2	0:30:0	ECG0	ECG1
n48c	128	16	2	0:5:0	ECG0	ECG1
n49	128	16	2	0:30:0	ECG0	ECG1
n49c	128	16	2	0:5:0	ECG0	ECG1
n50	128	16	2	0:30:0	ECG0	ECG1
n50c	128	16	2	0:5:0	ECG0	ECG1
p01	128	16	2	0:30:0	ECG0	ECG1
p01c	128	16	2	0:5:0	ECG0	ECG1
p02	128	16	2	0:30:0	ECG0	ECG1
p02c	128	16	2	0:5:0	ECG0	ECG1
p03	128	16	2	0:30:0	ECG0	ECG1
p03c	128	16	2	0:5:0	ECG0	ECG1
p04	128	16	2	0:30:0	ECG0	ECG1
p04c	128	16	2	0:5:0	ECG0	ECG1
p05	128	16	2	0:30:0	ECG0	ECG1
p05c	128	16	2	0:5:0	ECG0	ECG1
p06	128	16	2	0:30:0	ECG0	ECG1
p06c	128	16	2	0:5:0	ECG0	ECG1
p07	128	16	2	0:30:0	ECG0	ECG1
p07c	128	16	2	0:5:0	ECG0	ECG1
p08	128	16	2	0:30:0	ECG0	ECG1
p08c	128	16	2	0:5:0	ECG0	ECG1

TABELA C.12 (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
p09	128	16	2	0:30:0	ECG0	ECG1
p09c	128	16	2	0:5:0	ECG0	ECG1
p10	128	16	2	0:30:0	ECG0	ECG1
p10c	128	16	2	0:5:0	ECG0	ECG1
p11	128	16	2	0:30:0	ECG0	ECG1
p11c	128	16	2	0:5:0	ECG0	ECG1
p12	128	16	2	0:30:0	ECG0	ECG1
p12c	128	16	2	0:5:0	ECG0	ECG1
p13	128	16	2	0:30:0	ECG0	ECG1
p13c	128	16	2	0:5:0	ECG0	ECG1
p14	128	16	2	0:30:0	ECG0	ECG1
p14c	128	16	2	0:5:0	ECG0	ECG1
p15	128	16	2	0:30:0	ECG0	ECG1
p15c	128	16	2	0:5:0	ECG0	ECG1
p16	128	16	2	0:30:0	ECG0	ECG1
p16c	128	16	2	0:5:0	ECG0	ECG1
p17	128	16	2	0:30:0	ECG0	ECG1
p17c	128	16	2	0:5:0	ECG0	ECG1
p18	128	16	2	0:30:0	ECG0	ECG1
p18c	128	16	2	0:5:0	ECG0	ECG1
p19	128	16	2	0:30:0	ECG0	ECG1
p19c	128	16	2	0:5:0	ECG0	ECG1
p20	128	16	2	0:30:0	ECG0	ECG1
p20c	128	16	2	0:5:0	ECG0	ECG1
p21	128	16	2	0:30:0	ECG0	ECG1
p21c	128	16	2	0:5:0	ECG0	ECG1
p22	128	16	2	0:30:0	ECG0	ECG1
p22c	128	16	2	0:5:0	ECG0	ECG1
p23	128	16	2	0:30:0	ECG0	ECG1
p23c	128	16	2	0:5:0	ECG0	ECG1
p24	128	16	2	0:30:0	ECG0	ECG1
p24c	128	16	2	0:5:0	ECG0	ECG1
p25	128	16	2	0:30:0	ECG0	ECG1
p25c	128	16	2	0:5:0	ECG0	ECG1
p26	128	16	2	0:30:0	ECG0	ECG1
p26c	128	16	2	0:5:0	ECG0	ECG1
p27	128	16	2	0:30:0	ECG0	ECG1
p27c	128	16	2	0:5:0	ECG0	ECG1
p28	128	16	2	0:30:0	ECG0	ECG1

TABELA C.12 (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
p28c	128	16	2	0:5:0	ECG0	ECG1
p29	128	16	2	0:30:0	ECG0	ECG1
p29c	128	16	2	0:5:0	ECG0	ECG1
p30	128	16	2	0:30:0	ECG0	ECG1
p30c	128	16	2	0:5:0	ECG0	ECG1
p31	128	16	2	0:30:0	ECG0	ECG1
p31c	128	16	2	0:5:0	ECG0	ECG1
p32	128	16	2	0:30:0	ECG0	ECG1
p32c	128	16	2	0:5:0	ECG0	ECG1
p33	128	16	2	0:30:0	ECG0	ECG1
p33c	128	16	2	0:5:0	ECG0	ECG1
p34	128	16	2	0:30:0	ECG0	ECG1
p34c	128	16	2	0:5:0	ECG0	ECG1
p35	128	16	2	0:30:0	ECG0	ECG1
p35c	128	16	2	0:5:0	ECG0	ECG1
p36	128	16	2	0:30:0	ECG0	ECG1
p36c	128	16	2	0:5:0	ECG0	ECG1
p37	128	16	2	0:30:0	ECG0	ECG1
p37c	128	16	2	0:5:0	ECG0	ECG1
p38	128	16	2	0:30:0	ECG0	ECG1
p38c	128	16	2	0:5:0	ECG0	ECG1
p39	128	16	2	0:30:0	ECG0	ECG1
p39c	128	16	2	0:5:0	ECG0	ECG1
p40	128	16	2	0:30:0	ECG0	ECG1
p40c	128	16	2	0:5:0	ECG0	ECG1
p41	128	16	2	0:30:0	ECG0	ECG1
p41c	128	16	2	0:5:0	ECG0	ECG1
p42	128	16	2	0:30:0	ECG0	ECG1
p42c	128	16	2	0:5:0	ECG0	ECG1
p43	128	16	2	0:30:0	ECG0	ECG1
p43c	128	16	2	0:5:0	ECG0	ECG1
p44	128	16	2	0:30:0	ECG0	ECG1
p44c	128	16	2	0:5:0	ECG0	ECG1
p45	128	16	2	0:30:0	ECG0	ECG1
p45c	128	16	2	0:5:0	ECG0	ECG1
p46	128	16	2	0:30:0	ECG0	ECG1
p46c	128	16	2	0:5:0	ECG0	ECG1
p47	128	16	2	0:30:0	ECG0	ECG1
p47c	128	16	2	0:5:0	ECG0	ECG1

TABELA C.12 (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
p48	128	16	2	0:30:0	ECG0	ECG1
p48c	128	16	2	0:5:0	ECG0	ECG1
p49	128	16	2	0:30:0	ECG0	ECG1
p49c	128	16	2	0:5:0	ECG0	ECG1
p50	128	16	2	0:30:0	ECG0	ECG1
p50c	128	16	2	0:5:0	ECG0	ECG1
t01	128	16	2	0:30:0	ECG0	ECG1
t02	128	16	2	0:30:0	ECG0	ECG1
t03	128	16	2	0:30:0	ECG0	ECG1
t04	128	16	2	0:30:0	ECG0	ECG1
t05	128	16	2	0:30:0	ECG0	ECG1
t06	128	16	2	0:30:0	ECG0	ECG1
t07	128	16	2	0:30:0	ECG0	ECG1
t08	128	16	2	0:30:0	ECG0	ECG1
t09	128	16	2	0:30:0	ECG0	ECG1
t10	128	16	2	0:30:0	ECG0	ECG1
t11	128	16	2	0:30:0	ECG0	ECG1
t12	128	16	2	0:30:0	ECG0	ECG1
t13	128	16	2	0:30:0	ECG0	ECG1
t14	128	16	2	0:30:0	ECG0	ECG1
t15	128	16	2	0:30:0	ECG0	ECG1
t16	128	16	2	0:30:0	ECG0	ECG1
t17	128	16	2	0:30:0	ECG0	ECG1
t18	128	16	2	0:30:0	ECG0	ECG1
t19	128	16	2	0:30:0	ECG0	ECG1
t20	128	16	2	0:30:0	ECG0	ECG1
t21	128	16	2	0:30:0	ECG0	ECG1
t22	128	16	2	0:30:0	ECG0	ECG1
t23	128	16	2	0:30:0	ECG0	ECG1
t24	128	16	2	0:30:0	ECG0	ECG1
t25	128	16	2	0:30:0	ECG0	ECG1
t26	128	16	2	0:30:0	ECG0	ECG1
t27	128	16	2	0:30:0	ECG0	ECG1
t28	128	16	2	0:30:0	ECG0	ECG1
t29	128	16	2	0:30:0	ECG0	ECG1
t30	128	16	2	0:30:0	ECG0	ECG1
t31	128	16	2	0:30:0	ECG0	ECG1
t32	128	16	2	0:30:0	ECG0	ECG1
t33	128	16	2	0:30:0	ECG0	ECG1

TABELA C.12 (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
t34	128	16	2	0:30:0	ECG0	ECG1
t35	128	16	2	0:30:0	ECG0	ECG1
t36	128	16	2	0:30:0	ECG0	ECG1
t37	128	16	2	0:30:0	ECG0	ECG1
t38	128	16	2	0:30:0	ECG0	ECG1
t39	128	16	2	0:30:0	ECG0	ECG1
t40	128	16	2	0:30:0	ECG0	ECG1
t41	128	16	2	0:30:0	ECG0	ECG1
t42	128	16	2	0:30:0	ECG0	ECG1
t43	128	16	2	0:30:0	ECG0	ECG1
t43	128	16	2	0:30:0	ECG0	ECG1
t44	128	16	2	0:30:0	ECG0	ECG1
t45	128	16	2	0:30:0	ECG0	ECG1
t46	128	16	2	0:30:0	ECG0	ECG1
t47	128	16	2	0:30:0	ECG0	ECG1
t48	128	16	2	0:30:0	ECG0	ECG1
t49	128	16	2	0:30:0	ECG0	ECG1
t50	128	16	2	0:30:0	ECG0	ECG1
t51	128	16	2	0:30:0	ECG0	ECG1
t52	128	16	2	0:30:0	ECG0	ECG1
t53	128	16	2	0:30:0	ECG0	ECG1
t54	128	16	2	0:30:0	ECG0	ECG1
t55	128	16	2	0:30:0	ECG0	ECG1
t56	128	16	2	0:30:0	ECG0	ECG1
t57	128	16	2	0:30:0	ECG0	ECG1
t58	128	16	2	0:30:0	ECG0	ECG1
t59	128	16	2	0:30:0	ECG0	ECG1
t60	128	16	2	0:30:0	ECG0	ECG1
t61	128	16	2	0:30:0	ECG0	ECG1
t62	128	16	2	0:30:0	ECG0	ECG1
t63	128	16	2	0:30:0	ECG0	ECG1
t64	128	16	2	0:30:0	ECG0	ECG1
t65	128	16	2	0:30:0	ECG0	ECG1
t66	128	16	2	0:30:0	ECG0	ECG1
t67	128	16	2	0:30:0	ECG0	ECG1
t68	128	16	2	0:30:0	ECG0	ECG1
t69	128	16	2	0:30:0	ECG0	ECG1
t70	128	16	2	0:30:0	ECG0	ECG1
t71	128	16	2	0:30:0	ECG0	ECG1

TABELA C.12 (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
t72	128	16	2	0:30:0	ECG0	ECG1
t73	128	16	2	0:30:0	ECG0	ECG1
t74	128	16	2	0:30:0	ECG0	ECG1
t75	128	16	2	0:30:0	ECG0	ECG1
t76	128	16	2	0:30:0	ECG0	ECG1
t77	128	16	2	0:30:0	ECG0	ECG1
t78	128	16	2	0:30:0	ECG0	ECG1
t79	128	16	2	0:30:0	ECG0	ECG1
t80	128	16	2	0:30:0	ECG0	ECG1
t81	128	16	2	0:30:0	ECG0	ECG1
t82	128	16	2	0:30:0	ECG0	ECG1
t83	128	16	2	0:30:0	ECG0	ECG1
t84	128	16	2	0:30:0	ECG0	ECG1
t85	128	16	2	0:30:0	ECG0	ECG1
t86	128	16	2	0:30:0	ECG0	ECG1
t87	128	16	2	0:30:0	ECG0	ECG1
t88	128	16	2	0:30:0	ECG0	ECG1
t89	128	16	2	0:30:0	ECG0	ECG1
t90	128	16	2	0:30:0	ECG0	ECG1
t91	128	16	2	0:30:0	ECG0	ECG1
t92	128	16	2	0:30:0	ECG0	ECG1
t93	128	16	2	0:30:0	ECG0	ECG1
t94	128	16	2	0:30:0	ECG0	ECG1
t95	128	16	2	0:30:0	ECG0	ECG1
t96	128	16	2	0:30:0	ECG0	ECG1
t97	128	16	2	0:30:0	ECG0	ECG1
t98	128	16	2	0:30:0	ECG0	ECG1
t99	128	16	2	0:30:0	ECG0	ECG1

TABELA C.13 – The MIT-BIH Normal Sinus Rhythm Database						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
16265	128	212	2	25:27:280		
16272	128	212	2	25:0:0		
16273	128	212	2	24:38:240		
16420	128	212	2	23:58:560		
16483	128	212	2	25:57:200		
16539	128	212	2	24:34:560		

TABELA C.13 (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
16773	128	212	2	23:58:240		
16786	128	212	2	24:29:200		
16795	128	212	2	23:34:560		
17052	128	212	2	23:8:0		
17453	128	212	2	24:22:560		
18177	128	212	2	25:57:200		
18184	128	212	2	23:44:480		
19088	128	212	2	23:48:0		
19090	128	212	2	24:10:560		
19093	128	212	2	23:14:0		
19140	128	212	2	24:10:240		
19830	128	212	2	23:13:280		

TABELA C.14 – The MIT-BIH Supraventricular Arrhythmia Database						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
800	128	212	2	0:30:0	record 800, signal 0	record 800, signal 1
801	128	212	2	0:30:0	record 801, signal 0	record 801, signal 1
802	128	212	2	0:30:0	record 802, signal 0	record 802, signal 1
803	128	212	2	0:30:0	record 803, signal 0	record 803, signal 1
804	128	212	2	0:30:0	record 804, signal 0	record 804, signal 1
805	128	212	2	0:30:0	record 805, signal 0	record 805, signal 1
806	128	212	2	0:30:0	record 806, signal 0	record 806, signal 1
807	128	212	2	0:30:0	record 807, signal 0	record 807, signal 1
808	128	212	2	0:30:0	record 808, signal 0	record 808, signal 1
809	128	212	2	0:30:0	record 809, signal 0	record 809, signal 1
810	128	212	2	0:30:0	record 810, signal 0	record 810, signal 1
811	128	212	2	0:30:0	record 811, signal 0	record 811, signal 1

TABELA C.14 (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
812	128	212	2	0:30:0	record 812, signal 0	record 812, signal 1
820	128	212	2	0:30:0	record 820, signal 0	record 820, signal 1
821	128	212	2	0:30:0	record 821, signal 0	record 821, signal 1
822	128	212	2	0:30:0	record 822, signal 0	record 822, signal 1
823	128	212	2	0:30:0	record 823, signal 0	record 823, signal 1
824	128	212	2	0:30:0	record 824, signal 0	record 824, signal 1
825	128	212	2	0:30:0	record 825, signal 0	record 825, signal 1
826	128	212	2	0:30:0	record 826, signal 0	record 826, signal 1
827	128	212	2	0:30:0	record 827, signal 0	record 827, signal 1
828	128	212	2	0:30:0	record 828, signal 0	record 828, signal 1
829	128	212	2	0:30:0	record 829, signal 0	record 829, signal 1
840	128	212	2	0:30:0	record 840, signal 0	record 840, signal 1
841	128	212	2	0:30:0	record 841, signal 0	record 841, signal 1
842	128	212	2	0:30:0	record 842, signal 0	record 842, signal 1
843	128	212	2	0:30:0	record 843, signal 0	record 843, signal 1
844	128	212	2	0:30:0	record 844, signal 0	record 844, signal 1
845	128	212	2	0:30:0	record 845, signal 0	record 845, signal 1
846	128	212	2	0:30:0	record 846, signal 0	record 846, signal 1
847	128	212	2	0:30:0	record 847, signal 0	record 847, signal 1
848	128	212	2	0:30:0	record 848, signal 0	record 848, signal 1
849	128	212	2	0:30:0	record 849, signal 0	record 849, signal 1
850	128	212	2	0:30:0	record 850, signal 0	record 850, signal 1

TABELA C.14 (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
851	128	212	2	0:30:0	record 851, signal 0	record 851, signal 1
852	128	212	2	0:30:0	record 852, signal 0	record 852, signal 1
853	128	212	2	0:30:0	record 853, signal 0	record 853, signal 1
854	128	212	2	0:30:0	record 854, signal 0	record 854, signal 1
855	128	212	2	0:30:0	record 855, signal 0	record 855, signal 1
856	128	212	2	0:30:0	record 856, signal 0	record 856, signal 1
858	128	212	2	0:30:0	record 858, signal 0	record 858, signal 1
859	128	212	2	0:30:0	record 859, signal 0	record 859, signal 1
860	128	212	2	0:30:0	record 860, signal 0	record 860, signal 1
861	128	212	2	0:30:0	record 861, signal 0	record 861, signal 1
862	128	212	2	0:30:0	record 862, signal 0	record 862, signal 1
863	128	212	2	0:30:0	record 863, signal 0	record 863, signal 1
864	128	212	2	0:30:0	record 864, signal 0	record 864, signal 1
865	128	212	2	0:30:0	record 865, signal 0	record 865, signal 1
866	128	212	2	0:30:0	record 866, signal 0	record 866, signal 1
867	128	212	2	0:30:0	record 867, signal 0	record 867, signal 1
868	128	212	2	0:30:0	record 868, signal 0	record 868, signal 1
869	128	212	2	0:30:0	record 869, signal 0	record 869, signal 1
870	128	212	2	0:30:0	record 870, signal 0	record 870, signal 1
871	128	212	2	0:30:0	record 871, signal 0	record 871, signal 1
872	128	212	2	0:30:0	record 872, signal 0	record 872, signal 1
873	128	212	2	0:30:0	record 873, signal 0	record 873, signal 1

TABELA C.14 (Continuação)						
Arquivo	Freq. Am.	Formato	Nº Deriv.	Duração	Deriv. 1	Deriv. 2
874	128	212	2	0:30:0	record 874, signal 0	record 874, signal 1
875	128	212	2	0:30:0	record 875, signal 0	record 875, signal 1
876	128	212	2	0:30:0	record 876, signal 0	record 876, signal 1
877	128	212	2	0:30:0	record 877, signal 0	record 877, signal 1
878	128	212	2	0:30:0	record 878, signal 0	record 878, signal 1
879	128	212	2	0:30:0	record 879, signal 0	record 879, signal 1
880	128	212	2	0:30:0	record 880, signal 0	record 880, signal 1
881	128	212	2	0:30:0	record 881, signal 0	record 881, signal 1
882	128	212	2	0:30:0	record 882, signal 0	record 882, signal 1
883	128	212	2	0:30:0	record 883, signal 0	record 883, signal 1
884	128	212	2	0:30:0	record 884, signal 0	record 884, signal 1
885	128	212	2	0:30:0	record 885, signal 0	record 885, signal 1
886	128	212	2	0:30:0	record 886, signal 0	record 886, signal 1
887	128	212	2	0:30:0	record 887, signal 0	record 887, signal 1
888	128	212	2	0:30:0	record 888, signal 0	record 888, signal 1
889	128	212	2	0:30:0	record 889, signal 0	record 889, signal 1
890	128	212	2	0:30:0	record 890, signal 0	record 890, signal 1
891	128	212	2	0:30:0	record 891, signal 0	record 891, signal 1
892	128	212	2	0:30:0	record 892, signal 0	record 892, signal 1
893	128	212	2	0:30:0	record 893, signal 0	record 893, signal 1
894	128	212	2	0:30:0	record 894, signal 0	record 894, signal 1

C.5.1 Anotações Médicas

O arquivo de anotações médicas condensadas (rotulos.fdo) foi construído pelo programa pdoe.exe através do processamento dos arquivos de anotações médicas formatadas (extensão .fan).

O arquivo *rotulos.fdo* possui todos os símbolos de anotações médicas existentes em cada arquivo de paciente, como mostram as TABELAS C.15 a C.26.

TABELA C.15 – ARRITMIA.FAN	
Arquivos	Rótulos
100.ANT	N
101.ANT	N Q ~ A + (P f V (N /
106.ANT	+ (N ~ V (B (T (P x A
109.ANT	L
111.ANT	L
112.ANT	N
113.ANT	N
114.ANT	N J V F
115.ANT	N
116.ANT	N
117.ANT	N
118.ANT	R A V
119.ANT	N V + (B (N (T ~ (NOD (IVR A (VT (AFIB a j x J (SVTA (AFL Q
205.ANT	N + (VT (N
207.ANT	R L V + (VFL (N (B (IVR A (SVTA ~ (T Q
209.ANT	N A ~ + (SVTA (N
210.ANT	N V ~ a F + (VT (AFIB (B (N
213.ANT	N V A F + (B (N (VT a
214.ANT	L V Q + (VT (N (T
215.ANT	N V ~ A + (VT (N F TS (P f / (B (AFIB (T PSE x
220.ANT	N A
221.ANT	N V + (T
222.ANT	N j
223.ANT	N e V ~ A F + (VT (N (B (PREX
231.ANT	R N + (BII A x (N MISSB (SBR ~ V (VT (T F
234.ANT	N

TABELA C.16 – ATRIAL FIBRILATION.FAN

Arquivos	Rótulos	
	atr	qrs
04015.ANT	+ (AFIB (N (AFL	N
04048.ANT		N
04126.ANT	+ (AFIB (N	
04746.ANT		N
04908.ANT	+ (AFIB (N (AFL	N
05091.ANT	+ (AFIB (N (J	N
05261.ANT		N
06426.ANT	+ (N (AFL (J (AFIB	N
06453.ANT		N
06995.ANT	+ (AFL (N (AFIB	N
07162.ANT		N
07859.ANT	+ (N (J	N
07879.ANT		N
07910.ANT	+ (AFIB	N
08215.ANT	+ (AFIB	N
08219.ANT	+ (AFIB (N	N
08378.ANT		N
08405.ANT	+ (AFIB	N
08434.ANT	+ (AFIB (N	N

TABELA C.17 – MALIGNANT_VA.FAN

Arquivos	Rótulos
418.ANT	+ (VFL (N (NOISE
420.ANT	+ (NOISE (VT
423.ANT	+ (NOISE (VT (ASYS
424.ANT	+ (VFIB (ASYS (NSR (NOISE (NOD
425.ANT	+ (NOISE
426.ANT	+ (VF (N (NOISE (SVTA (ASYS
428.ANT	+ (NOISE (VT (BI
430.ANT	+ (VT (NOISE (VFL (SBR (HGEA (ASYS (VER (PM
607.ANT	+ (VT (NOD (SVTA
609.ANT	+ (VFL (N (HGEA
610.ANT	+ (HGEA (N (VT
611.ANT	+ (VT
612.ANT	+ (VT
614.ANT	+ (N (VT
615.ANT	+ (VT

TABELA C.18 – PAF.FAN			
Arquivos			Rótulos
N01.ANT	P01.ANT	T01.ANT	N
-	P02.ANT	T03.ANT	N
-	P03.ANT	T05.ANT	N
-	P04.ANT	T07.ANT	N
N05.ANT	P05.ANT	T09.ANT	N
N06.ANT	P06.ANT	T11.ANT	N
N07.ANT	P07.ANT	T13.ANT	N
N08.ANT	P08.ANT	T15.ANT	N
N09.ANT	P09.ANT	T17.ANT	N
N10.ANT	P10.ANT	T19.ANT	N
N11.ANT	P11.ANT	T21.ANT	N
N12.ANT	P12.ANT	T23.ANT	N
N13.ANT	P13.ANT	T25.ANT	N
N14.ANT	P14.ANT	T27.ANT	N
N15.ANT	P15.ANT	T29.ANT	N
N16.ANT	P16.ANT	T31.ANT	N
N17.ANT	P17.ANT	T33.ANT	N
N18.ANT	P18.ANT	T35.ANT	N
N19.ANT	P19.ANT	T37.ANT	N
N20.ANT	P20.ANT	T39.ANT	N
N21.ANT	P21.ANT	T41.ANT	N
N22.ANT	P22.ANT	T43.ANT	N
N23.ANT	P23.ANT	T45.ANT	N
N24.ANT	P24.ANT	T47.ANT	N
N25.ANT	P25.ANT	T49.ANT	N
N26.ANT	P26.ANT	T51.ANT	N
N27.ANT	P27.ANT	T53.ANT	N
N28.ANT	P28.ANT	T55.ANT	N
N29.ANT	P29.ANT	T57.ANT	N
N30.ANT	P30.ANT	T59.ANT	N
N31.ANT	P31.ANT	T61.ANT	N
N32.ANT	P32.ANT	T63.ANT	N
N33.ANT	P33.ANT	T65.ANT	N
N34.ANT	P34.ANT	T67.ANT	N
N35.ANT	P35.ANT	T69.ANT	N
N36.ANT	P36.ANT	T71.ANT	N
N37.ANT	P37.ANT	T73.ANT	N
N38.ANT	P38.ANT	T75.ANT	N
N39.ANT	P39.ANT	T77.ANT	N
N40.ANT	P40.ANT	T79.ANT	N
N41.ANT	P41.ANT	T81.ANT	N
N42.ANT	P42.ANT	T83.ANT	N
N43.ANT	P43.ANT	T85.ANT	N

TABELA C.18 (Continuação)			
Arquivos			Rótulos
N44.ANT	P44.ANT	T87.ANT	N
N45.ANT	P45.ANT	T89.ANT	N
N46.ANT	P46.ANT	T91.ANT	N
N47.ANT	P47.ANT	T93.ANT	N
N48.ANT	P48.ANT	T95.ANT	N
N49.ANT	P49.ANT	T97.ANT	N
N50.ANT	P50.ANT	T99.ANT	N

TABELA C.19 – NORMAL SINUS RHYTHM.FAN	
Arquivos	Rótulos
16265.ANT	N
16272.ANT	N ~ S
16273.ANT	~ S N V
16483.ANT	~ N S
16773.ANT	N ~ S V F
16795.ANT	~ N S
19088.ANT	N ~ V
19090.ANT	N J ~ S V
19830.ANT	N ~

TABELA C.20 – ST-T.FAN			
Arquivos	Rótulos		
	atr	ari	cnt
S20011.ANT	S V N	N	A T 17 L B / t Q D + p * j u ~ E s
S20021.ANT		N S r V E	
S20031.ANT	S V Q N	N S r V	A T 17 L B / t Q D + p * j u ~ E
S20041.ANT			A T 17 L B / t Q D + p * j u ~ E s
S30661.ANT	N V S a		

TABELA C.21 – QT.FAN (ATR)	
Arquivos	Símbolos
SEL100.ANT	A /
SEL103.ANT	N
SEL104.ANT	f / N + (P (N
SEL114.ANT	N J V F A
SEL116.ANT	N
SEL117.ANT	N
SEL213.ANT	N V A F + (B (N (AFIB (T ~ (VT e a
SEL230.ANT	+ (N (PREX (BII
SEL232.ANT	A R ~
SEL233.ANT	V A N + (B (N F
SEL301.ANT	S V N
SEL306.ANT	N
SEL308.ANT	V S N
SEL803.ANT	V
SEL808.ANT	V S N
SEL820.ANT	S V N a
SEL847.ANT	V S ~ N Q
SEL872.ANT	S V N
SEL883.ANT	S N
SEL891.ANT	N V S
SEL14046.ANT	V N F
SEL15814.ANT	V F N
SEL16272.ANT	N
SEL16420.ANT	N
SEL16539.ANT	N
SEL16786.ANT	N
SEL17152.ANT	N
SELE0104.ANT	T (T2- AT2-300 V T2-) s (ST2+ (ST1- AST2+200 AST1-100 ST1-) ST2+) N
SELE0107.ANT	~ N
SELE0111.ANT	N
SELE0114.ANT	S N T (T2+ (T1- AT2+300 AT1-500 s AST1-200 T1-) V T2+) ST1-) (ST1- AT2+400 AST1-100 AT1-600 (T2- AT2-600
SELE0121.ANT	+ (VT (N F
SELE0124.ANT	N
SELE0129.ANT	s (ST2- (T1+ (ST1+ (T1++ ~ AT1+600 AST1+500 AST2-200 N
SELE0133.ANT	N
SELE0166.ANT	T AT2+300 s (ST2+ AST2+100 ST2+) (T2+ AT2+250 N
SELE0203.ANT	+ (SAB (N s AST2+100 AST1-100 ST1-) ST2+)
SELE0211.ANT	T AT2+200 T2+) T1+) N
SELE0405.ANT	s ST1-) AT2+400 T2+) (T1- AT1-200 N
SELE0409.ANT	T (T2- AT2-200 N

TABELA C.21 (Continuação) (ATR)	
Arquivos	Símbolos
SELE0509.ANT	V T (T2- N
SELE0604.ANT	s (ST2- (T1+ AST2-100 AT1+300 T1+) ST2-) (T1- AT1-200 T1-) (ST1+ (T1++ AST1+100 AT1+400 T1++) ST1+) AST2-200 ~
SELE0606.ANT	V T T2-) s ST1-) ST2-) N
SELE0609.ANT	V s ST2-) ~ F N
SELE0612.ANT	~ N

TABELA C.22 – QT.FAN								
Arquivos	Símbolos							
	man	pu	pu0	pu1	q1c	q2c	qt1	qt2
SEL30.ANT	N	p () t N	p () t N	p () t N	p () t N		N	
SEL31.ANT				p () t N	p () t N			
SEL32.ANT	N	N () p t			p () t N		N	
SEL33.ANT			p () t N		p () t N			
SEL34.ANT	N			p () t N	p () t N		N	
SEL35.ANT				p () N t	N () B		N	
SEL36.ANT	N			p () t N				
SEL37.ANT		p () t N		p () t N	N () Q B		N Q B	
SEL38.ANT	N	p () t N	N t () p	p () t N	p () t N			
SEL39.ANT		p () t N	p () t N		p () t N Q		N Q	
SEL40.ANT	N		p () t N		p () t N		N	
SEL41.ANT			p () t N	N () p t	p () t N Q			
SEL42.ANT	N	p () t N			p () t N		N	
SEL43.ANT		p () t N		p () t N	p () t N			
SEL44.ANT	N	p () t N		p () t N	p () t N V Q		N Q V	
SEL45.ANT		p () t N	p () t N	p () t N	p () t u N Q			
SEL46.ANT	N	p () t N			p () t N u Q			
SEL47.ANT		p () t N	p () t N				N Q	
SEL48.ANT	N			p () t N				
SEL49.ANT		p () t N		p () t N			N	
SEL50.ANT	N							
SEL51.ANT			p () t N	p () t N			N	
SEL52.ANT	N							
SEL100.ANT			p () t N			N t ()	N	N
SEL102.ANT	N	p () t N	p () t N			N t () u		
SEL103.ANT			p () t N	N () p t	p ()		N	
SEL104.ANT	N	N () p t		N () p t	N t () p u			

TABELA C.22 (Continuação)								
Arquivos	Símbolos							
	man	pu	pu0	pu1	q1c	q2c	qt1	qt2
SEL106.ANT								
SEL114.ANT		p()tN		N()pt	p()tNu		N	N
SEL116.ANT	N	p()tN	p()tN	p()tN		Nt()		
SEL117.ANT		p()tN				Nt()	N	N
SEL123.ANT	N		p()tN	p()tN		Nt()		
SEL213.ANT				p()tN		Nt()	N	N
SEL221.ANT	N			p()tN		Nt()		
SEL223.ANT		p()tN	p()tN			Nt()	N	N
SEL230.ANT	N	p()tN	p()tN	p()tN	p()			
SEL231.ANT		p()tN		p()tN	p()		N	
SEL232.ANT	N		p()tN	p()tN	At()			
SEL233.ANT		p()tN			p()		N	
SEL301.ANT	N		p()tN		p()tN			
SEL302.ANT			p()tN	p()tN	p()		N	
SEL306.ANT	N			p()tN	p()			
SEL307.ANT			p()tN		p()		N	
SEL308.ANT	N	p()tN			p()tNu			
SEL310.ANT			p()tN	N()pt			N	
SEL803.ANT	N	p()tN	p()tN	p()tN				
SEL808.ANT			p()tN	p()tN			N	
SEL811.ANT	N			p()tN				
SEL820.ANT		p()tN	p()tN	p()tN			N	
SEL821.ANT	N	p()tN						
SEL840.ANT			N()pt	p()tN			N	
SEL847.ANT	N	p()tN	p()tN		p()			
SEL853.ANT		p()tN		p()tN	p()		N	
SEL871.ANT	N	p()tN	p()tN		p()			
SEL872.ANT				p()tN	p()		N	
SEL873.ANT	N			p()tN	p()			
SEL883.ANT		p()tN			p()		N	
SEL891.ANT	N	p)Nt(p()Nt	p()tN	p()Nt			
SEL14046.ANT		p()tN	p()tN	p()tN	p()tN		N	
SEL14157.ANT	N	p()tN	p()tN	N()pt	Ntu()p			
SEL14172.ANT		p()tN	p()tN		p()t		N	
SEL15814.ANT	N		p()tN	p()tN	p()			
SEL16265.ANT		p()tN	N()pt	p()tN	p()		N Q	
SEL16272.ANT	N	p()tN	p()tN	p()tN	p()Q			
SEL16273.ANT		p()tN		p()tN	p()		N	
SEL16420.ANT	N		p()tN	p()tN	p()			
SEL16483.ANT		p()tN	p()tN	p()tN	p()		N Q	
SEL16539.ANT	N	p()tN	p()tN		p()tN			

TABELA C.22 (Continuação)								
Arquivos	Símbolos							
	man	pu	pu0	pu1	q1c	q2c	qt1	qt2
SEL16773.ANT		p()tN	p()tN	p()tN	p()			
SEL16786.ANT	N	p()tN			p()tN		N	
SEL16795.ANT			p()tN		p()tNu			
SEL17152.ANT	N						N	
SEL17453.ANT		p()tN						
SELE0104.ANT	N		p()tN		p()		N	
SELE0106.ANT			p()tN		p()tuN			
SELE0107.ANT	N	p()Nt	p()tN		p()		N Q	
SELE0110.ANT			p()tN	p()tN	p()Q			
SELE0111.ANT	N			p()tN	p()Q			
SELE0112.ANT		p()tN	p()tN	N()pt	p()Q			
SELE0114.ANT	N			p()tN	p()tuNQ		N	
SELE0116.ANT)t(pN	p()tN)t(Np				
SELE0121.ANT	N	p()tN		p()tN			N	
SELE0124.ANT	N	p()tN					N Q	
SELE0126.ANT			p()tN					
SELE0129.ANT	N	p()tN		p()tN				
SELE0133.ANT		p()tN		p()tN			N	
SELE0136.ANT	N							
SELE0166.ANT					p()tN		N	
SELE0170.ANT	N	p()tN	p()tN		p()			
SELE0203.ANT		p()tN			p()Q		N	
SELE0210.ANT	N		p()tN		p()tN		N	
SELE0211.ANT				p()tN	p()tN			
SELE0303.ANT	N	p()tN		p()tN	p()tN		N Q	
SELE0405.ANT		p()tN	p()tN	p()tN	p()Q			
SELE0406.ANT	N	p()tN	p()tN		p()Q			
SELE0409.ANT		p()tN			p()tN			
SELE0411.ANT	N	p()tN			p()		N	
SELE0509.ANT		p()tN			p()			
SELE0603.ANT	N		p()tN		p()Q		N Q	
SELE0604.ANT				p()tN	p()		N	
SELE0606.ANT	N	p()tN	p()tN	p()tN	p()Q			
SELE0607.ANT		p()tN		p()tN	p()Q		N Q	
SELE0609.ANT	N	p()tN			p()tN		N Q	
SELE0612.ANT		p()tN	p()tN		p()tNQ			
SELE0704.ANT				p()tN	p()tuNQ			



TABELA C.23 – ST_T.FAN	
Arquivos	Símbolos
E0103.ANT	N V F
E0105.ANT	N
E0107.ANT	N
E0111.ANT	N S ~ + (N V T (T1+ AT1+300 T1+))
E0115.ANT	N
E0119.ANT	N ~ T (T1+ s (ST1+ (T1++ (ST0- AST1+500 AT1+800 T1++)) AST0-150 T1+) ST0-) ST1+) (T1- AT1-300 T1-) (T0- AT1+700 AT0-200 AST1+600 AST1+200 AST0-200 AT1+200 AT0-300 (N AT1-200 (T0+ AT0+300 T0+) AST1+800 AST0-300 (VT F AT0+200 (T0++ AT0+600 T0++)) AST0-100 AT0+250 (ST1- (ST0+ AST0+100 AST1-100 ST0+) ST1-) AT0+350 AST0+200 AST1+100 AST0+500 AST1-200
E0133.ANT	N
E0139.ANT	N
E0147.ANT	N
E0151.ANT	N
E0155.ANT	N
E0159.ANT	N ~ V S + (AB (N s (ST1- (B AST1-300 ST1-))
E0161.ANT	N
E0163.ANT	N S ~ T (T1- AT1-250 T1-) V + (N (SAB F s (ST1+ (ST0- AST1+100 AST0-100 ST0-) ST1+))
E0205.ANT	N ~ T (T1- s AST0+150 AST1-400 AT1-400 ST0+) ST1-) AT1-300 (N V (ST0- AST0-100 ST0-) AST0-150 (ST1- AST1-100 AT1-200 (T0+ AT0+200 AST0-250 AT0+400 (T1+ AT1+200 (B3 T1+) (T0- (T0-- AST0-300 F AT0-1000 AST1-200 T0--)) AT0-600 AST1-900 (ST0+ AST0+200 (ST1+ AST1+100 ST1+) AT0-400 AT0-500 AST0-200 AT1+400 AT0-200 AT0-300 AT0-350 AT1+250 AT0-250 AST1-600 (AFIB AST0-800 AT0+350 AST0-400 AST1-350 AT1-350 AST1-500
E0417.ANT	N
E0501.ANT	N
E0509.ANT	N V ~ t0--) ast1-300 at1-800 st0-) t1--) st1-) + (N T (T0- AT0-200 T0-) (ST0+ (ST1- (T1- AST0+200 AT1-350 AST1-200 ST0+) ST1-) AST0+150 AST1-150 AT1-250 AT0-250 AT1-200 AT1-300 AST0+250 AST1-250 (ST1+ (T1+ (T1++ AT1+600 AST1+400 T1++)) T1+) ST1+)
E0603.ANT	N V n s ST0+) T0++) ST1-) (ST1- (ST0+ (T0+ AST1-100 AST0+100 AT0+250 (T0++ AT0+500 AST0+200 AT0+200 AT0+300 (N (ST0- F (VT
E0607.ANT	N S + (SVTA (N s AST1-300 ~ (AB ST1-) ST0-) (ST1- (ST0- AST0-250 AST1-200 AST0-350 BUTTON F AST0-150 AST1-100
E0611.ANT	N
E0613.ANT	N
E0615.ANT	N V + (N (T S ~ BUTTON s ST0-)
E0801.ANT	N
E0817.ANT	N
E1301.ANT	N
E1304.ANT	N T T0-) S ~ + (SVTA (N (T0-

TABELA C.24 – ST.FAN	
Arquivos	Símbolos
300.ANT	V N
302.ANT	N
304.ANT	N V S
307.ANT	S N
309.ANT	V N
311.ANT	N
313.ANT	S N
315.ANT	V N
317.ANT	S N
319.ANT	~ N
321.ANT	N
323.ANT	N V S
325.ANT	N V S
327.ANT	




TABELA C.25 – SUPRAVENTRICULAR.FAN	
Arquivos	Símbolos
800.ANT	S ~ V F N
803.ANT	V ~ F N
805.ANT	V N
806.ANT	S V F N
808.ANT	V S N
810.ANT	V N ~ S
811.ANT	S V N ~
820.ANT	S V N Q a
822.ANT	S N
823.ANT	S N
825.ANT	S N
827.ANT	S N
829.ANT	S V N
841.ANT	S V Q N
842.ANT	S V N
843.ANT	V S N
845.ANT	S V N
846.ANT	~ S N V Q
851.ANT	V N S ~
852.ANT	V S N




TABELA C.25 (Continuação)		TABELA C.26 – TACHYARRHYTHMIA.FAN	
Arquivos	Símbolos	Arquivos	Símbolos
853.ANT	V S Q N	CU01.ANT	+ (VF
854.ANT	V N ~ S Q	CU02.ANT	~ + (VT (N
855.ANT	S N V ~ Q	CU05.ANT	[N
862.ANT	N S V ~ Q	CU06.ANT	[] N
864.ANT	V S ~ N	CU08.ANT	N]
865.ANT	V N S ~ Q	CU09.ANT	+ (AF (N [
867.ANT	V S N ~ Q B	CU10.ANT	[N]
869.ANT	S V N ~	CU12.ANT	N]
871.ANT	S V ~ N	CU15.ANT	[
873.ANT	S F V N	CU16.ANT	+ (N []
875.ANT	V F S N	CU18.ANT	+ (AF [~ N]
877.ANT	S N ~ V J	CU20.ANT	[
880.ANT	S V N ~	CU21.ANT] + (N [
882.ANT	S V N Q ~	CU22.ANT	[~ N]
885.ANT	S N ~ V Q	CU25.ANT	[~ N]
886.ANT	V S	CU27.ANT	N]
887.ANT	V ~ N S	CU28.ANT	[
889.ANT	S V ~ N	CU29.ANT	~ [
891.ANT	N S V ~ Q	CU30.ANT	[~
893.ANT	V	CU31.ANT	[
894.ANT	S V N ~	CU32.ANT	[~ N]




APÊNDICE D - GRÁFICOS DE ERROS









APÊNDICE E - MATRIZES DE CONFUSÃO

















































rna1_haar_ff.mat 12N com VT sem níveis 1D e 8A









rna2_haar_ff.mat 12N com VT sem níveis 1D e 8A









rna3_haar_ff.mat 12N com VT sem níveis 1D e 8A











































































































































rna1_db4_G1_rbf.mat com VT sem níveis 1D e 8A









rna2_db4_G1_rbf.mat com VT sem níveis 1D e 8A









rna3_db4_G1_rbf.mat com VT sem níveis 1D e 8A



















rna1_haar_rbf.mat com VT sem níveis 1D e 8A









rna2_haar_rbf.mat com VT sem níveis 1D e 8A









rna3_haar_rbf.mat com VT sem níveis 1D e 8A


















rna1_db4_G2_rbf.mat com VT sem níveis 1D e 8A




%	N	AFIB	AFL	VFL	VT
N	100	0	0	0	0
AFIB	0	90	0	0	10
AFL	0	0	100	0	0
VFL	0	0	0	70	30
VT	0	0	0	40	60

rna2_db4_G2_rbf.mat com VT sem níveis 1D e 8A



%	N	AFIB	AFL	VFL	VT
N	100	0	0	0	0
AFIB	0	100	0	0	0
AFL	0	0	80	20	0
VFL	0	0	0	60	40
VT	0	0	0	30	70

rna3_db4_G2_rbf.mat com VT sem níveis 1D e 8A



%	N	AFIB	AFL	VFL	VT
N	100	0	0	0	0
AFIB	0	100	0	0	0
AFL	0	0	100	0	0
VFL	0	0	0	70	30
VT	0	0	0	50	50

