

SÉRGIO RENATO RO GAL JÚNIOR

**DETECCÃO E CLASSIFICAÇÃO DE
ARRITMIAS CARDÍACAS UTILIZANDO REDES
NEURAS ARTIFICIAIS AUTO-ORGANIZÁVEIS**

Dissertação de Mestrado apresentada ao
Programa de Pós-Graduação em Informática
da Pontifícia Universidade Católica do Paraná
como requisito parcial para a obtenção do
título de Mestre em Informática.

CURITIBA

2008

SÉRGIO RENATO RO GAL JÚNIOR

**DETECCÃO E CLASSIFICAÇÃO DE
ARRITMIAS CARDÍACAS UTILIZANDO REDES
NEURAS ARTIFICIAIS AUTO-ORGANIZÁVEIS**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Informática da Pontifícia Universidade Católica do Paraná como requisito parcial para a obtenção do título de Mestre em Informática.

Área de concentração: Ciência da Computação

Orientador: Prof. Dr. Emerson Cabrera Paraiso

Co-orientador: Prof. Dr. Celso Antônio Alves Kaestner

CURITIBA

2008

Agradecimentos

Inicialmente, gostaria de agradecer ao orientador Prof. Dr. Emerson Cabrera Paraiso, por todas as dicas e conselhos que ele forneceu durante a execução deste trabalho. Também gostaria de agradecer ao co-orientador Prof. Dr. Celso Antônio Alves Kaestner, pelas preciosas informações que ele forneceu no início da minha pesquisa. Agradeço também ao Prof. Dr. Júlio Cesar Nievola, que colaborou muito nas primeiras etapas deste trabalho com preciosas lições de Inteligência Artificial. É muito importante ressaltar o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), que me concedeu uma bolsa de estudos. Agradeço também aos meus amigos e sócios Alfredo Beckert Neto e Marcus Vinícius Mazega Figueredo, que sempre me auxiliaram nos projetos. Quero agradecer a minha família pela paciência que tiveram comigo durante toda a minha pesquisa. Por fim, quero agradecer a todos que contribuíram na execução deste trabalho cujos nomes não foram citados.

Sumário

| | |
|---|-------------|
| <i>Agradecimentos</i> | <i>iii</i> |
| <i>Lista de Figuras</i> | <i>vii</i> |
| <i>Lista de Tabelas</i> | <i>xi</i> |
| <i>Lista de Abreviaturas</i> | <i>xiii</i> |
| <i>Glossário</i> | <i>xv</i> |
| <i>Resumo</i> | <i>xvii</i> |
| <i>Abstract</i> | <i>xix</i> |
| | |
| <i>Capítulo 1 - Introdução</i> | <i>1</i> |
| 1.1 Objetivos | 3 |
| 1.2 Organização do Trabalho | 3 |
| | |
| <i>Capítulo 2 - O ECG e suas Arritmias</i> | <i>5</i> |
| 2.1 O Coração Humano..... | 5 |
| 2.2. O Eletrocardiograma (ECG)..... | 7 |
| 2.3. O Triângulo de Einthoven | 8 |
| 2.4. Derivações | 8 |
| 2.5. As Arritmias Cardíacas | 12 |
| 2.5.1. Taquicardia | 13 |
| 2.5.2. Bradicardia..... | 13 |
| 2.5.3. Contrações Prematuras | 14 |
| 2.5.4. <i>Paced Beat</i> (PB)..... | 15 |
| 2.5.5. <i>Left Bundle Branch Block</i> (LBBB) | 16 |
| 2.5.6. <i>Right Bundle Branch Block</i> (RBBB)..... | 16 |
| 2.5.7. <i>Aberrated APC</i> (AAPC)..... | 17 |
| 2.5.8. <i>Nodal (Junctional) Premature Beat</i> (NPB) | 17 |

| | |
|--|----|
| 2.6. Conclusão | 17 |
| <i>Capítulo 3 - Detecção Automática de Arritmias</i> | 19 |
| 3.1. Visão Geral..... | 19 |
| 3.2. Wavelets | 21 |
| 3.3 Redes Neurais Artificiais (RNAs) | 27 |
| 3.4. Trabalhos Relacionados | 33 |
| 3.4.1. Abordagem com RNA e análise no domínio do tempo | 33 |
| 3.4.2. Abordagem com RNA e utilização de <i>Wavelets</i> | 34 |
| 3.5. Conclusão | 35 |
| <i>Capítulo 4 - Metodologia</i> | 37 |
| 4.1. Base de Dados de Arritmias | 39 |
| 4.2. Segmentação..... | 41 |
| 4.3. Extração de Características | 42 |
| 4.4. Agrupamento das Arritmias | 43 |
| 4.5 Pós-processamento..... | 45 |
| 4.6. Validação..... | 46 |
| 4.6. Conclusão | 48 |
| <i>Capítulo 5 - Implementação da Arquitetura</i> | 49 |
| 5.1 Implementação da ART2 | 49 |
| 5.2 Conjunto de Dados..... | 50 |
| 5.3 Treinamento..... | 52 |
| 5.4 Testes | 53 |
| 5.5 Conclusão | 54 |
| <i>Capítulo 6 - Discussão dos Resultados Obtidos</i> | 55 |
| 6.1 Validação da Primeira Fase..... | 55 |
| 6.2 Validação da Segunda Fase..... | 57 |
| 6.3 Conclusão | 59 |

Capítulo 7 - Conclusões e Perspectivas 61

Referências..... 63

Lista de Figuras

| | |
|--|----|
| Figura 2.1. Vista frontal do coração humano (Extraído de (LETTNIN et al., 2002)).... | 6 |
| Figura 2.2. Elementos do eletrocardiograma normal (extraído de (FROWNFEELTER and DEAN, 2004) – Derivação MLII). | 7 |
| Figura 2.3. Disposição convencional dos eletrodos para o registro das derivações eletrocardiográficas padrão. O triângulo de Einthoven está sobreposto ao tórax. Extraído de (GUYTON and HALL, 1996). | 9 |
| Figura 2.4. Derivações torácicas ou pré-cordiais. Extraído de (GUYTON and HALL, 1996). | 11 |
| Figura 2.5. Conexões do corpo com o eletrocardiógrafo para registro das derivações pré-cordiais. Extraído de (GUYTON and HALL, 1996). | 11 |
| Figura 2.6. Eletrocardiogramas normais das 12 derivações. a) Derivações bipolares periféricas. b) Derivações pré-cordiais. c) Derivações unipolares periféricas aumentadas. Extraído de (GUYTON and HALL, 1996). | 12 |
| Figura 2.7. Taquicardia sinusal (derivação I). Intervalo da grade: 0.2 sec, 0.5mV. | 13 |
| Figura 2.8. Bradicardia sinusal (derivação III). Intervalo da grade: 0.2 sec, 0.5mV. .. | 14 |
| Figura 2.9. CPA - Contração prematura atrial. Extraído do registro 100 de (PHYSIONET, 2006). Intervalo da grade: 0.2 sec, 0.5mV..... | 14 |
| Figura 2.10. Contração prematura ventricular. Extraído do registro 100 de (PHYSIONET, 2006). Intervalo da grade: 0.2 sec, 0.5mV..... | 15 |
| Figura 2.11. <i>Paced beat</i> . Extraído do registro 102 de (PHYSIONET, 2006). Intervalo da grade: 0.2 sec, 0.5mV..... | 15 |
| Figura 2.12. <i>Left bundle branch block</i> . Extraído do registro 109 de (PHYSIONET, 2006). Intervalo da grade: 0.2 sec, 0.5mV. | 16 |
| Figura 2.13. <i>Right bundle branch block</i> . Extraído do registro 124 de (PHYSIONET, 2006). Intervalo da grade: 0.2 sec, 0.5mV. | 16 |

| | |
|--|----|
| Figura 2.14. <i>Aberrated</i> APC. Extraído do registro 113 de (PHYSIONET, 2006). Intervalo da grade: 0.2 sec, 0.5mV. | 17 |
| Figura 2.15. <i>Nodal premature beat</i> . Extraído do registro 114 de (PHYSIONET, 2006). Intervalo da grade: 0.2 sec, 0.5mV. | 17 |
| Figura 3.1. Principais etapas no processo de detecção de arritmias. | 20 |
| Figura 3.2. Diferentes famílias de <i>Wavelets</i> (<i>Daubechies</i> , <i>Coiflet</i> , <i>Haar</i> e <i>Symmlet</i>) (POLIKAR, 2007). | 22 |
| Figura 3.3. Computação da TWC ao longo do tempo para um sinal não-estacionário (POLIKAR, 2007). | 23 |
| Figura 3.4. Gráfico relacionando escala, translação e amplitude da transformada <i>Wavelet</i> de um sinal não-estacionário (POLIKAR, 2007). | 24 |
| Figura 3.5. Aplicação da TWD no sinal de ECG. | 24 |
| Figura 3.6. Filtragens sucessivas da TWD. | 25 |
| Figura 3.7. Aplicação da TWD em uma senóide ruidosa. | 26 |
| Figura 3.8. Sinal não-estacionário. | 26 |
| Figura 3.9. Coeficientes de detalhe e aproximação após a aplicação da TWD. | 27 |
| Figura 3.10. O modelo de McCulloch e Pitts (KROSE and SMAGT, 1996). | 28 |
| Figura 3.11. Genealogia das RNAs ART (CARPENTER et al., 1991). | 30 |
| Figura 3.12. Arquitetura de uma rede ART2 (CARPENTER and GROSSBERG, 1998) | 31 |
| Figura 4.1. Diagrama da arquitetura da hipótese levantada. | 38 |
| Figura 4.2. Diagrama do processo de segmentação do ECG. | 41 |
| Figura 4.3. Processo de seleção da janela. | 41 |
| Figura 4.4. Janela selecionada com 100 amostras de um ECG normal (valores extraídos do registro 100 de (PHYSIONET, 2006)). | 42 |
| Figura 4.5. Coeficientes <i>Wavelet</i> obtidos por uma TWD aplicada ao sinal de ECG apresentado na figura 4.4. Para esta transformação foi utilizada uma TWD da família <i>Daubechies</i> de nível quatro. | 42 |
| Figura 4.6. Processo de criação dos conjuntos de dados utilizados no treinamento e nos testes. | 43 |
| Figura 4.7. Processo de criação dos conjuntos de dados utilizados no treinamento e nos testes. | 44 |

| | |
|--|----|
| Figura 4.8.Arquitetura geral da ART2 criada. | 44 |
| Figura 4.9. Processo de escolha das classes pelo algoritmo (fase 1). A escala “-;*;**” é apenas ilustrativa e serve para indicar o funcionamento do algoritmo. | 46 |
| Figura 4.10. Processo de formação das classes pelo algoritmo (fase 2). A escala “-;*;**” é apenas ilustrativa e serve para indicar o funcionamento do algoritmo. | 46 |
| Figura 5.1. Tela principal do SNNS. | 49 |
| Figura 5.2. Tela da ferramenta BIGNET, selecionada para a RNA ART2. | 50 |
| Figura 5.3. Fragmento do arquivo com as amostras de ECG. Dados retirados do arquivo “101.DAT”..... | 50 |
| Figura 5.4. Fragmento do arquivo com os atributos que descrevem o arquivo de amostras. Dados retirados do arquivo “101.ATR”..... | 51 |
| Figura 5.5. Fragmento do arquivo com os dados segmentados para os batimentos normais. Para cada identificador (neste caso N) existe cem amostras..... | 51 |
| Figura 5.6. Fragmento do arquivo com os coeficientes <i>Wavelet</i> | 52 |
| Figura 5.7. Tela principal do JavaNNS com a ART2 e com a janela “ <i>Control Panel</i> ”. Esta janela é utilizada para o treinamento e para inserir todos os parâmetros da RNA. | 52 |
| Figura 5.8. Tela principal do JavaNNS com a ART2, com a janela “ <i>Control Panel</i> ” e com a janela da ferramenta “ <i>Analyzer</i> ”, utilizada em todos os testes da ART2. | 53 |
| Figura 5.9. Arquivo de LOG gerado na etapa de testes da RNA. | 54 |

Lista de Tabelas

| | |
|---|-----------|
| <i>Tabela 3.1. Tipos de RNAs.....</i> | <i>29</i> |
| <i>Tabela 3.2 Comparativo entre o número de arritmias detectadas, a taxa de acerto, as arritmias aqui trabalhadas e algumas etapas da análise do ECG.....</i> | <i>35</i> |
| <i>Tabela 4.1. Análise estatística da MIT-BIH Arrhythmia Database.....</i> | <i>40</i> |
| <i>Tabela 4.2. Valor dos parâmetros utilizados na RNA ART2.....</i> | <i>45</i> |
| <i>Tabela 4.4. Trabalhos que tiveram as suas taxas de acerto comparadas com as taxas de acerto deste trabalho.....</i> | <i>47</i> |
| <i>Tabela 6.1. Resultados das etapas da validação cruzada.....</i> | <i>55</i> |
| <i>Tabela 6.2. Resumo dos resultados obtidos através do algoritmo de validação cruzada.....</i> | <i>56</i> |
| <i>Tabela 6.3. Definição das classes formadas pelo algoritmo no pós-processamento... </i> | <i>56</i> |
| <i>Tabela 6.4. Trabalhos que tiveram as suas taxas de acerto comparadas com as taxas de acerto deste trabalho.....</i> | <i>57</i> |
| <i>Tabela 6.5. Resumo dos resultados obtidos através do algoritmo de validação cruzada.....</i> | <i>58</i> |
| <i>Tabela 6.6. Definição das novas classes formadas pelo algoritmo no pós-processamento.....</i> | <i>58</i> |

Lista de Abreviaturas

| | |
|------|---|
| AAPC | <i>aberrated atrial premature contraction</i> |
| ART | <i>adaptive resonance theory</i> |
| CPA | contração prematura atrial |
| CPV | contração prematura ventricular |
| ECG | eletrocardiograma |
| LBBB | <i>left bundle branch block</i> |
| NPB | <i>nodal (junctional) premature beat</i> |
| RBBB | <i>right bundle branch block</i> |
| RNA | rede neural artificial |
| TWC | transformada <i>Wavelet</i> contínua |
| TWD | transformada <i>Wavelet</i> discreta |

Glossário

Complexo QRS - Formado pelos potenciais elétricos gerados quando os ventrículos se despolarizam antes de se contraírem.

Eletrocardiógrafo - É um galvanômetro registrador da diferença de potencial elétrico entre as duas regiões sobre as quais foram aplicados os eletrodos.

Eletrocardiograma - É um exame médico na área de cardiologia onde é feito o registro da variação dos potenciais elétricos gerados pela atividade elétrica do coração.

Galvanômetro - É um instrumento capaz de medir correntes elétricas de baixa intensidade, ou a diferença de potencial elétrico entre dois pontos.

Hipopotassemia - Também chamada de hipocalemia, é um dos distúrbios eletrolíticos mais comuns da prática clínica. As principais manifestações da Hipopotassemia são de ordem cardiovascular e neuromusculares, incluindo arritmias. Em alguns casos, pode-se observar achatamento das ondas T, depressão do segmento ST, ondas P aumentadas, alargamento do QRS e aumento da onda U.

Isquemia Miocárdica - É o desbalanço temporário entre o suprimento de oxigênio e sua demanda pelo miocárdio. A disfunção miocárdica provocada é reversível, uma vez que o fluxo normal coronariano se restabeleça.

Marcapasso - É um dispositivo de aplicação médica que tem o objetivo de regular os batimentos cardíacos, emitindo impulsos elétricos para o coração quando o intervalo dos batimentos cardíacos estão abaixo do normal.

Onda P - Formada pelos potenciais elétricos gerados pelos átrios ao se despolarizarem.

Onda T - Formada pelos potenciais elétricos gerados pelos ventrículos ao se repolarizarem.

Resumo

As arritmias ou ritmos anormais do coração são distúrbios cardíacos comuns e podem causar sérios riscos à vida das pessoas, sendo uma das principais causas de óbito. Muitos destes óbitos poderiam ser evitados se fosse realizado um monitoramento prévio dessas arritmias, a partir do Eletrocardiograma (ECG). O monitoramento contínuo e a detecção automática de arritmias do coração podem auxiliar o médico em um diagnóstico mais rápido e preciso. Entretanto, a monitoração contínua de um paciente no decorrer de um dia pode gerar uma quantidade enorme de dados (aproximadamente 2Mb/h com apenas 1 derivação) devendo estes ainda serem analisados por um especialista. Este trabalho levanta a hipótese de que é possível classificar as arritmias cardíacas utilizando a transformada *Wavelet* em conjunto com redes neurais artificiais (RNAs) auto-organizáveis e um algoritmo de pós-processamento. Esta RNA permite que, a qualquer momento, possam ser adicionados outros tipos de arritmias, sem a necessidade de um novo treinamento da rede neural. Com este método incremental, o tempo de treinamento para novas arritmias diminui. Neste trabalho classificou-se os batimentos normais, as contrações prematuras atriais (CPA) e as contrações prematuras ventriculares (CPV). Ao final, adicionou-se dois novos tipos de arritmias, *left bundle branch block* (LBBB) e *right bundle branch block* (RBBB) para verificar a propriedade desta RNA de não perder o conhecimento adquirido.

Palavras-Chave: *classificação de arritmias cardíacas, transformada Wavelets, redes neurais artificiais, ECG*

Abstract

The arrhythmias or abnormal rhythms of the heart are common cardiac riots and may cause serious risks to the life of people, being one of the main causes of death. These deaths could be avoided if a previous monitoring of these arrhythmias was carried through, using the Electrocardiogram (ECG) exam. However, the continuous monitoring of a patient during the whole day generates an enormous amount of data (approximately 2Mb/h with only 1 derivation), that must be interpreted by a specialist. The continuous monitoring and the automatic detection of arrhythmias of the heart may help the specialist to perform a faster with precise diagnostic. This work raises the hypothesis that it is possible to classify the cardiac arrhythmias using the wavelet transform in conjunction with artificial neural network (ANN) Self-Organized and a post-processing algorithm. This ANN allows that, at any time, other groups of arrhythmias can be added, without the necessity of a new training phase. In this work was detected the normal beatings, the atrial premature contractions (APC) and the ventricular premature contractions (PVC). At the end, were added two new types of arrhythmias, left bundle branch block (LBBB) and right bundle branch block (RBBB) to verify if the ANN did not lose the knowledge acquired.

Keywords: *cardiac arrhythmia classification, Wavelets, neural networks, ECG.*

Capítulo 1

Introdução

As doenças cardiovasculares são hoje em dia uma das principais causas de óbitos em países desenvolvidos e em desenvolvimento. Estes óbitos poderiam ser reduzidos se fossem realizados a detecção e o monitoramento prévio das arritmias geradas por essas doenças a partir do Eletrocardiograma (ECG). O ECG é o registro de potenciais elétricos emitidos pelo coração que atingem a superfície do corpo (GUYTON and HALL, 1996).

As arritmias ou ritmos anormais do coração são distúrbios cardíacos comuns e podem causar sérios riscos à vida das pessoas. Estes distúrbios são caracterizados pela alteração da frequência ou ritmo dos batimentos cardíacos e podem ocorrer por várias razões (FROWNFEELTER and DEAN, 2004).

O ECG é um dos meios mais rápidos e precisos para diagnosticar arritmias cardíacas. Embora muitos cardiologistas interpretem o ECG com bastante precisão, sempre podem ocorrer erros. Além disto, a análise efetuada pelo especialista (geralmente um cardiologista) pode ser bastante pessoal, podendo existir uma grande variação do diagnóstico entre especialistas. Desta forma, o monitoramento contínuo e a detecção automática de arritmias do coração visam auxiliar o médico em um diagnóstico mais rápido e preciso.

A detecção automática de arritmias a partir do ECG pode ser obtida de várias maneiras distintas, com algoritmos específicos e métodos inteligentes. Nesta dissertação, utiliza-se uma abordagem baseada na aplicação de Redes Neurais Artificiais (RNAs) e transformadas *Wavelet*. Esta abordagem é dividida em quatro etapas: o pré-processamento, a extração de características, o processamento e o pós-processamento. Na primeira etapa, o sinal gerado pelo eletrocardiógrafo é segmentado. Na segunda etapa, é realizada a extração de informações do sinal segmentado, informações que são enviadas à terceira etapa onde serão processadas.

Na etapa de processamento é feito o agrupamento dos dados coletados na primeira etapa, ou seja, são criados grupos de similaridade dos dados analisados na entrada. Por fim, a última etapa ou etapa de pós-processamento classifica os dados que foram agrupados no processamento.

Até o fim da década de 90, a análise automática do ECG era feita no domínio do tempo, com algoritmos específicos que analisavam cada onda do sinal em busca de informações que posteriormente seriam classificadas por algum método inteligente, por exemplo, as RNAs (CAPUA et al., 2006). Nos últimos anos porém, a análise no domínio da frequência vem aumentando muito, pois ela permite obter informações adicionais que não aparecem na análise feita no domínio do tempo, como a frequência em que cada onda do ECG ocorre. Hoje em dia, muitos trabalhos continuam utilizando RNA na etapa de processamento, devido ao seu alto desempenho. Já na extração de informações do sinal e no pré-processamento, a utilização da transformada *Wavelet* vem ganhando muito espaço, já que faz a análise no domínio tempo-frequência, mostrando efetivamente onde cada frequência está ocorrendo.

Este trabalho levanta a hipótese de que RNAs auto-organizáveis podem ser utilizadas para o processamento das arritmias cardíacas. Esta RNA permite que, a qualquer momento, possam ser adicionados outros tipos de arritmias, sem a necessidade de um novo treinamento completo da rede neural. A principal vantagem é que este método de aprendizagem é incremental (MULHBAIER and POLIKAR, 2007) (MALOOF and MICHALSKI, 2004), ou seja, realiza-se o treinamento da RNA à medida que as arritmias são incluídas. Um ponto crítico das RNAs é o seu tempo de treinamento lento. Assim, o método proposto possui um desempenho melhor no processo de treinamento da RNA.

Neste trabalho, utilizou-se para o pré-processamento e para a extração de características dos sinais de entrada as transformadas *Wavelet*. Através de uma transformação do sinal para o domínio do tempo e da frequência, as amostras dos batimentos foram convertidas para coeficientes *Wavelet*. Em seguida, estes coeficientes foram submetidos a entrada da RNA auto-organizável, que irá agrupá-los. Ao final, os grupos formados são classificados por um algoritmo desenvolvido em Java durante a etapa de pós-processamento.

1.1 Objetivos

O principal objetivo do trabalho é verificar, através da metodologia apresentada, a validade do uso de redes neurais auto-organizáveis em conjunto com uma etapa de pós-processamento na classificação de arritmias cardíacas utilizando o sinal de ECG.

Para a classificação serão utilizados os batimentos normais e as seguintes arritmias:

- Contração Prematura Atrial (CPA);
- Contração Prematura Ventricular (CPV).

Estas arritmias foram escolhidas, pois são arritmias que ocorrem com grande frequência em pessoas saudáveis e possuem um grande número de exemplos na base de dados utilizada.

Ao final deste trabalho classificou-se outros tipos de arritmias sem a necessidade de um treinamento completo da RNA. As seguintes arritmias foram escolhidas para a segunda fase:

- *Left Bundle Branch Block* (LBBB);
- *Right Left Bundle Branch Block* (RBBB).

Estas outras arritmias também ocorrem com grande frequência e possuem um grande número de exemplos na base de dados.

1.2 Organização do Trabalho

O presente trabalho está organizado em seis capítulos. O presente capítulo apresenta o objetivo deste trabalho, os resultados que se esperam atingir e apresenta a sua organização. O capítulo 2 apresenta o eletrocardiograma, mostrando a parte fisiológica, comparando o funcionamento do coração com a formação das arritmias. O capítulo 3 mostra algumas técnicas que são utilizadas para a detecção automática de arritmias na etapa de extração de características e classificação, mostrando também alguns trabalhos da área. O capítulo 4 apresenta a metodologia proposta para comprovar a hipótese levantada neste capítulo. O capítulo 5 apresenta toda a implementação da arquitetura apresentada na metodologia. O capítulo 6 apresenta os resultados obtidos neste trabalho. O capítulo 7 apresenta as conclusões e perspectivas.

Capítulo 2

O ECG e suas Arritmias

Neste capítulo são apresentados os principais conceitos relacionados ao coração humano, à obtenção do ECG e à formação das arritmias.

O objetivo deste capítulo é apresentar a parte fisiológica relacionada ao ECG. Dessa forma, o capítulo é dividido da seguinte maneira: a primeira seção apresenta a composição e o funcionamento do coração humano; a seção seguinte mostra o ECG e suas derivações e a terceira seção apresenta os principais tipos de arritmias utilizadas neste trabalho.

2.1 O Coração Humano

O coração humano, mostrado na figura 2.1, é responsável pelo bombeamento do sangue através do organismo.

É formado por duas bombas distintas: o coração direito e o coração esquerdo. O coração direito é responsável pela circulação do sangue nos pulmões, e o coração esquerdo é responsável pela circulação do sangue nos órgãos periféricos (GUYTON and HALL, 1996). Cada um desses corações é uma bomba pulsátil com duas câmaras, denominadas de átrio e ventrículo. A principal função do átrio é mover o sangue para o ventrículo, atuando como uma bomba auxiliar. O ventrículo, por sua vez, fornece a força principal para a circulação do sangue para todo o organismo (GUYTON and HALL, 1996) (FROWNFEELTER and DEAN, 2004).




Figura 2.1. Vista frontal do coração humano (Extraído de (LETTNIN et al., 2002)).

O coração é constituído por três tipos principais de músculo cardíaco: o músculo atrial, o músculo ventricular e as especializadas fibras musculares excitatórias e condutoras. Os tipos atrial e ventricular do músculo contraem-se de forma muito semelhante a do músculo esquelético, mas a duração de sua contração é bem maior. Por outro lado, as fibras especializadas, excitatórias e condutoras, só se contraem de modo muito fraco, pois contém poucas fibrilas contráteis; ao contrário, apresentam ritmicidade e velocidade de condução variáveis, formando um sistema excitatório para o coração (GUYTON and HALL, 1996).

O coração é dotado de um sistema especializado para gerar impulsos rítmicos, capazes de promover a contração ritmada do músculo cardíaco e a condução desses impulsos, rapidamente, para todo o coração. Quando esse sistema funciona normalmente, os átrios contraem-se cerca de 1/6 s antes dos ventrículos, o que permite um enchimento adicional desses ventrículos antes que eles bombeiem o sangue pelos pulmões e circulação periférica. Outra importância especial desse sistema é fazer com que as porções dos ventrículos se contraíam de modo quase simultâneo, o que é essencial para a geração efetiva de pressão nas câmaras ventriculares.

Esse sistema rítmico e condutor do coração é suscetível de ser lesado na doença cardíaca, em especial pela isquemia dos tecidos cardíacos, resultante do fluxo sanguíneo coronário insuficiente. A consequência é, muitas vezes, o aparecimento de ritmo cardíaco

bizarro, ou uma seqüência anormal da contração das câmaras cardíacas. A eficiência do bombeamento do coração fica, com freqüência, gravemente afetada, podendo levar a morte (GUYTON and HALL, 1996).

2.2. O Eletrocardiograma (ECG)

À medida que o impulso cardíaco cursa pelo coração, correntes elétricas se propagam para os tecidos que cercam o coração e pequena fração dessas correntes atinge a superfície do corpo (FROWNELTER and DEAN, 2004). Se forem colocados eletrodos sobre a pele em pontos opostos do coração, os potenciais elétricos gerados por essas correntes podem ser registrados; esse registro corresponde ao ECG. Um ECG normal, para um batimento cardíaco, é mostrado na figura 2.2.




Figura 2.2. Elementos do eletrocardiograma normal (extraído de (FROWNELTER and DEAN, 2004) – Derivação MLII)¹.

O ECG normal é composto por uma onda P, um complexo QRS, uma onda T e uma onda U (FROWNELTER and DEAN, 2004). O complexo QRS muitas vezes (mas nem sempre) aparece sob a forma de três ondas: a onda Q, a onda R e a onda S.

¹ Este ECG não é real, é apenas uma ilustração com o objetivo de mostrar as ondas e os segmentos que formam um ECG

A onda P é formada pelos potenciais elétricos gerados pelos átrios ao se despolarizarem antes de se contraírem. Já o complexo QRS é causado pelos potenciais gerados quando os ventrículos se despolarizam antes de se contraírem, isto é, conforme a onda de despolarização cursa pelos ventrículos. Por conseguinte, tanto a onda P como o complexo QRS são ondas de despolarização (FROWNFEELTER and DEAN, 2004) (GUYTON and HALL, 1996).

A onda T é causada por potenciais gerados à medida que os ventrículos se recuperam do estado de despolarização. Esse processo normalmente ocorre, no músculo ventricular, de 0,25 a 0,35 s após a despolarização, e essa onda é conhecida como uma onda de repolarização (GUYTON and HALL, 1996).

Ocasionalmente pode ser identificada a onda U, quarta onda do ECG, vindo logo após a onda T. Esta onda é arredondada, de curta duração, de pequena amplitude e de mesma polaridade da onda T precedente. Vale salientar que a onda U de duração e amplitude aumentadas é observada na hipopotassemia e negativa na isquemia miocárdica (FROWNFEELTER and DEAN, 2004). Dessa forma, o ECG é composto por ondas de despolarização e por ondas de repolarização (GUYTON and HALL, 1996).

2.3. O Triângulo de Einthoven

Na figura 2.3 pode-se observar o triângulo de Einthoven, ao redor da área cardíaca. Esse esquema é um meio de ilustrar como os dois braços e a perna esquerda formam os vértices de um triângulo que circunda o coração (FROWNFEELTER and DEAN, 2004).

Existe também, a chamada “Lei de Einthoven”. Esta lei propõe que uma terceira derivação pode ser determinada matematicamente, caso sejam conhecidas quaisquer duas derivações bipolares periféricas (FROWNFEELTER and DEAN, 2004).

2.4. Derivações

A figura 2.3 apresenta as conexões elétricas entre os membros do paciente e o eletrocardiógrafo para o registro das chamadas derivações bipolares periféricas padrão.




Figura 2.3. Disposição convencional dos eletrodos para o registro das derivações eletrocardiográficas padrão. O triângulo de Einthoven está sobreposto ao tórax. Extraído de (GUYTON and HALL, 1996).

Quando o eletrocardiograma é registrado com a utilização de 2 (dois) eletrodos, significa que esta derivação é bipolar. Deste modo, uma derivação não é apenas 1 (um) único eletrodo conectado ao corpo, mas na verdade é uma combinação de 2 (dois) eletrodos para formar um circuito completo com o eletrocardiógrafo. Em todos os casos, o eletrocardiógrafo é representado pelo registrador (galvanômetro) na figura 2.3.

Derivação I. No registro de derivação periférica I, o terminal negativo do eletrocardiógrafo é ligado ao braço direito e o terminal positivo ao braço esquerdo. Como resultado, quando o ponto do tórax

onde começa o braço direito fica eletronegativo em relação ao ponto torácico onde se prende o braço esquerdo, o eletrocardiógrafo registra positividade, isto é, uma deflexão para cima da linha do zero no eletrocardiograma. Quando o inverso ocorrer, o registro eletrocardiográfico fica abaixo da linha do zero..

Derivação II. No registro da derivação periférica II, o terminal negativo do eletrocardiógrafo é ligado ao braço direito e o terminal positivo à perna esquerda. Portanto, quando o braço direito ficar negativo em relação à perna esquerda, o eletrocardiograma apresentará deflexão positiva.

Derivação III. No registro da derivação periférica III, o terminal negativo do eletrocardiógrafo é conectado ao braço esquerdo e o terminal positivo à perna esquerda. Isso significa que o registro eletrocardiográfico será positivo quando o braço esquerdo ficar negativo em relação à perna esquerda.(GUYTON and HALL, 1996)

A figura 2.6-a mostra os registros das derivações bipolares periféricas. Além dessas derivações, existem as derivações pré-cordiais. A figura 2.4 mostra os pontos para as seis principais derivações pré-cordiais. Os registros dessas derivações são mostrados na figura 2.6-b. Elas podem ser obtidas conectando-se o eletrodo do terminal positivo do eletrocardiógrafo a um dos seis pontos, enquanto o eletrodo negativo, chamado de eletrodo indiferente, conecta-se por meio de resistências elétricas, ao braço direito, ao braço esquerdo e a perna esquerda, ao mesmo tempo, como mostrado na figura 2.5 (GUYTON and HALL, 1996).




Figura 2.4. Derivações torácicas ou pré-cordiais. Extraído de (GUYTON and HALL, 1996).

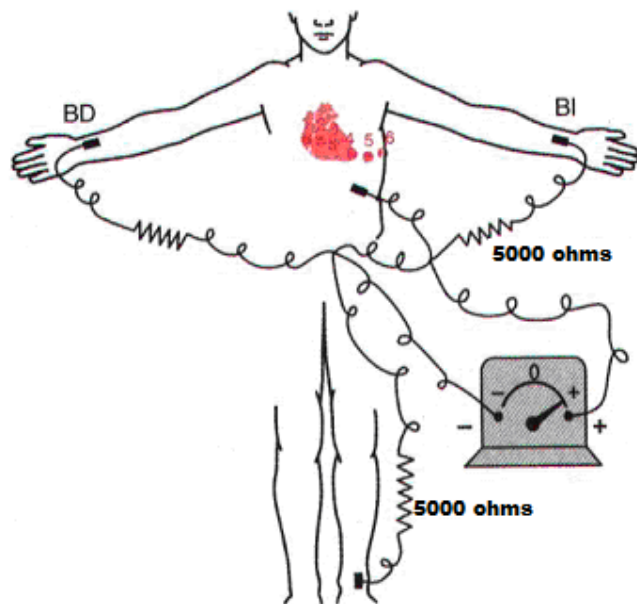


Figura 2.5. Conexões do corpo com o eletrocardiógrafo para registro das derivações pré-cordiais. Extraído de (GUYTON and HALL, 1996).

Outras derivações existentes são as derivações unipolares periféricas aumentadas, visualizadas na figura 2.6-c. Para este registro, dois dos membros são conectados através de

resistências, ao terminal negativo do eletrocardiograma, enquanto o terceiro membro é conectado ao terminal positivo.

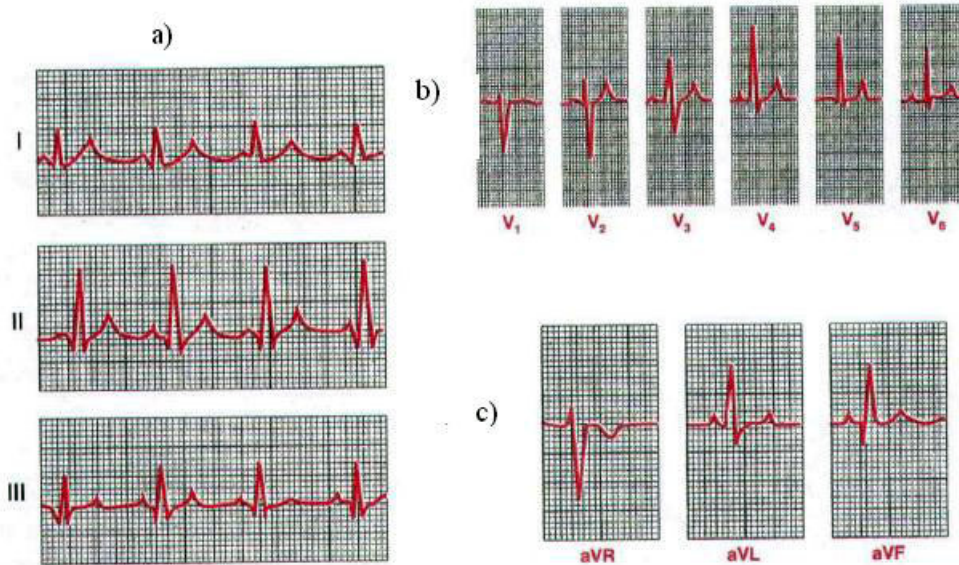


Figura 2.6. Eletrocardiogramas normais das 12 derivações. a) Derivações bipolares periféricas. b) Derivações pré-cordiais. c) Derivações unipolares periféricas aumentadas. Extraído de (GUYTON and HALL, 1996).

2.5. As Arritmias Cardíacas

Arritmia cardíaca é o nome genérico de diversas perturbações que alteram a frequência e/ou o ritmo dos batimentos cardíacos. Elas podem ocorrer por várias razões. As arritmias podem levar à morte e constituir, por isso, um caso de emergência médica. A maior parte delas é, no entanto, inofensiva. O nódulo sinusal, na aurícula direita, é um grupo de células que regula esses batimentos através de impulsos elétricos que estimulam a contração do músculo cardíaco ou miocárdio. Quando esses impulsos elétricos são emitidos de forma irregular ou conduzidos de forma deficiente, pode ocorrer a arritmia cardíaca. Esta pode ser caracterizada por ritmos excessivamente rápidos (taquicardia), lentos (bradicardia) ou apenas irregulares (GUYTON and HALL, 1996).

Alguns dos tipos mais perturbadores de disfunção cardíaca ocorrem não como resultado de um músculo cardíaco anormal, mas devido a um ritmo cardíaco anormal. Por exemplo, por vezes o batimento atrial não ocorre coordenado com o batimento ventricular, de modo que os átrios não mais funcionam como reforçadores do enchimento ventricular.

As arritmias cardíacas podem ter diversas causas, na grande maioria das vezes, uma anormalidade única ou uma combinação das anormalidades seguintes no sistema de ritmicidade/condução do coração (GUYTON and HALL, 1996):

- Ritmicidade anormal do marcapasso;
- Deslocamento do marcapasso do nodo sinusal para outras regiões cardíacas;
- Bloqueio, em diversos pontos, da transmissão do impulso pelo coração;
- Vias anormais para a transmissão do impulso para o coração;
- Geração espontânea de impulsos anormais em quase todas as regiões do coração (GUYTON and HALL, 1996).

2.5.1. Taquicardia

O termo taquicardia significa uma frequência cardíaca rápida, usualmente definida como a taxa acima de 100 bat/min (FROWNFEELTER and DEAN, 2004). A figura 2.7 mostra um eletrocardiograma registrado em um paciente com taquicardia. Esse eletrocardiograma é normal, exceto pelos intervalos de tempo reduzidos entre os complexos QRS, como sendo de cerca de 150 bat/min, em vez dos 72 bat/min normais (FROWNFEELTER and DEAN, 2004).



Figura 2.7. Taquicardia sinusal (derivação I). Intervalo da grade: 0.2 sec, 0.5mV.

A taquicardia pode ter diversas causas. Algumas causas gerais são: temperatura corporal elevada, estimulação cardíaca pelos nervos simpáticos e condições tóxicas do coração.

2.5.2. Bradicardia

O termo bradicardia significa uma frequência cardíaca lenta, usualmente definida como sendo uma taxa menor que 60 bat/min. A figura 2.8 mostra um eletrocardiograma com bradicardia.



Figura 2.8. Bradicardia sinusal (derivação III). Intervalo da grade: 0.2 sec, 0.5mV.

2.5.3. Contrações Prematuras

Uma contração prematura é uma contração que ocorre antes do momento em que deveria ocorrer uma contração normal. Este episódio também é conhecido como extra-sístole, batimento prematuro ou batimento ectópico.

A figura 2.9 apresenta uma contração prematura atrial (CPA) isolada, marcada pela letra “A”. A onda P desse batimento é encurtada.




Figura 2.9. CPA - Contração prematura atrial. Extraído do registro 100 de (PHYSIONET, 2006). Intervalo da grade: 0.2 sec, 0.5mV.

A CPA ocorre com grande frequência em pessoas saudáveis. O seu aparecimento resulta de fatores tais como fumo, falta de sono, ingestão excessiva de café, alcoolismo e outros (GUYTON and HALL, 1996).

Também existe a Contração Prematura Ventricular (CPV). As CPV produzem efeitos específicos no eletrocardiograma, mostrado na figura 2.10, representada pela letra “V”.




Figura 2.10. Contração prematura ventricular. Extraído do registro 100 de (PHYSIONET, 2006). Intervalo da grade: 0.2 sec, 0.5mV.

Algumas CPV resultam dos mesmos fatores das CPA e, até mesmo, irritabilidade emocional. Essas são relativamente benignas em sua origem. Por outro lado, algumas CPV resultam de sinais reentrantes que se originam ao redor dos limites de áreas cardíacas infartadas ou isquêmicas, podendo desenvolver fibrilação ventricular espontânea, o que é letal (GUYTON and HALL, 1996).

A seguir são apresentados alguns tipos diferentes de arritmias existentes em (PHYSIONET, 2006), mas que não serão abordadas neste trabalho.

2.5.4. Paced Beat (PB)




Figura 2.11. Paced beat. Extraído do registro 102 de (PHYSIONET, 2006). Intervalo da grade: 0.2 sec, 0.5mV.

2.5.5. *Left Bundle Branch Block (LBBB)*




Figura 2.12. *Left bundle branch block* . Extraído do registro 109 de (PHYSIONET, 2006).
Intervalo da grade: 0.2 sec, 0.5mV.

2.5.6. *Right Bundle Branch Block (RBBB)*



Figura 2.13. *Right bundle branch block*. Extraído do registro 124 de (PHYSIONET, 2006).
Intervalo da grade: 0.2 sec, 0.5mV.

2.5.7. Aberrated APC (AAPC)



Figura 2.14. *Aberrated APC*. Extraído do registro 113 de (PHYSIONET, 2006). Intervalo da grade: 0.2 sec, 0.5mV.

2.5.8. Nodal (Junctional) Premature Beat (NPB)




Figura 2.15. *Nodal premature beat*. Extraído do registro 114 de (PHYSIONET, 2006). Intervalo da grade: 0.2 sec, 0.5mV.

2.6. Conclusão

Este capítulo apresentou detalhes fisiológicos a respeito do ECG. Mostrou o coração humano, relacionando as contrações com as ondas do ECG, indicando as possíveis arritmias com as respectivas deformações do sinal do ECG.

O capítulo 3 seguinte apresenta o funcionamento da detecção automática de arritmias e os principais trabalhos da área.

Capítulo 3

Detecção Automática de Arritmias

O objetivo deste capítulo é apresentar os fundamentos teóricos das principais técnicas utilizadas na detecção de arritmias cardíacas, com um enfoque maior para as técnicas que serão utilizadas neste trabalho. Dessa forma, o capítulo é dividido da seguinte maneira: a primeira seção apresenta as principais etapas para a detecção automática de arritmias; a segunda seção oferece uma revisão da transformada *Wavelet*; a seção seguinte apresenta as RNAs; a quarta seção apresenta os principais trabalhos da área.

3.1. Visão Geral

A detecção automática de arritmias utilizando RNA é um processo que passa por diversas etapas. A figura 3.1 mostra as principais etapas.

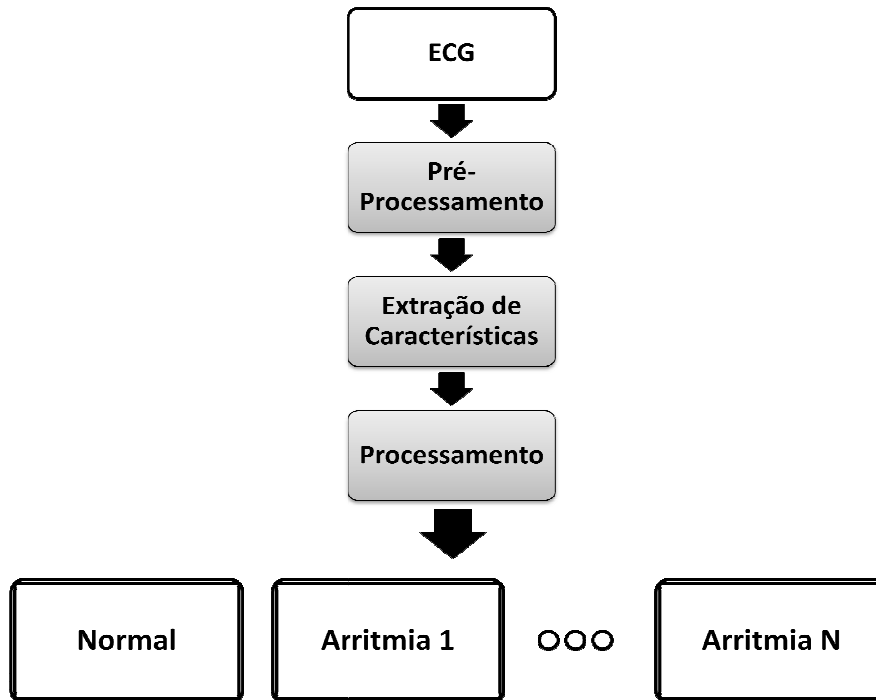


Figura 3.1. Principais etapas no processo de detecção de arritmias.

A figura 3.1 apresenta 3 blocos principais:

- pré-processamento;
- extração de características;
- processamento.

O pré-processamento é uma etapa muito importante em casos onde o sinal de ECG está muito ruidoso ou poluído, dificultando a sua análise. Estes ruídos podem ser originados a partir da rede elétrica ou através da má colocação dos eletrodos ou até mesmo quando o paciente se movimenta. É neste bloco que o sinal deverá passar por uma filtragem, eliminando os ruídos. Algumas vezes, esta primeira etapa não é executada, como observado em (LETTNIN et al., 2002), onde o autor selecionou apenas os registros que continham sinais “limpos” para o treinamento do sistema. Para cada registro da base de dados (PHYSIONET, 2006), existe um arquivo de descrição que mostra algumas informações importantes, entre elas, se o registro possui ou não sinais ruidosos.

Outra etapa muito importante é a extração de características. Esta etapa deve ser muito bem estudada, pois, ela pode interferir diretamente no desempenho e na exatidão de todo o processo. Uma técnica de extração de características que vem apresentando bons resultados nos últimos anos é a transformada *Wavelet*, discutida na próxima seção.

A última etapa é o processamento. É nesta etapa que as arritmias são de fato identificadas. As RNAs são bastante utilizadas nesta etapa, fazendo a classificação ou o agrupamento dos sinais de entrada (ROGAL et al., 2008a) (ROGAL et al., 2008b). Na classificação, o sinal analisado será colocado em uma determinada classe já existente. Já no agrupamento, à medida que os sinais são processados, são criados grupos com base na similaridade dos dados analisados. Assim, um sinal analisado poderá ser adicionado a um grupo já existente, caso exista uma similaridade de informações e caso não exista esta similaridade, um novo grupo será criado. As RNAs serão discutidas na terceira seção deste capítulo.

3.2. Wavelets

A utilização da transformada *Wavelet* em vários domínios diferentes de aplicação (compressão de dados (FIGUEREDO et al., 2008), processamento de imagens, reconhecimento de voz, etc), cresceu muito nos últimos anos (VIDAKOVIC and MUELLER, 1991). A aplicação da transformada *Wavelet* sobre um sinal mostra informações adicionais deste sinal que não eram conhecidas inicialmente sobre o sinal original, mostrando efetivamente onde cada frequência está ocorrendo.

A transformada *Wavelet* é similar à Transformada de Fourier. A Transformada de Fourier, batizada em homenagem ao físico e matemático Jean-Baptiste Joseph Fourier, é uma transformada integral que expressa uma função em termos de senos e co-senos, transformando um sinal do domínio do tempo para o domínio da frequência ou vice-versa. Mas, esta transformada não é capaz de representar os domínios do tempo e da frequência ao mesmo tempo, não podendo determinar para um sinal não-estacionário, quando cada frequência está ocorrendo efetivamente. Esse problema não ocorre em um sinal estático, dado que todas as componentes de frequência ocorrem ao mesmo tempo em todo o sinal (POLIKAR, 2007). A equação 3.1 descreve a Transformada de Fourier, onde ω é a frequência angular, t é a componente do tempo e $i = \pm\sqrt{1}$.

$$F(\omega) = \int_{-\infty}^{+\infty} f(t)e^{-i\omega t} dt \quad (3.1)$$

Por sua vez, a transformada *Wavelet* decompõe um sinal do domínio do tempo para o domínio tempo-frequência. Assim, a análise com *Wavelet* é mais aprofundada, já que mostra efetivamente onde cada frequência está ocorrendo.

A transformada *Wavelet* é definida na equação 3.2:

$$W(a, b) = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{|a|}} \psi \left(\frac{t-b}{a} \right) dt \quad (3.2)$$

A equação 3.2 é uma função de dois parâmetros reais, \mathbf{a} (translação) e \mathbf{b} (escala). A função ψ é chamada de *wavelet-mãe*. O parâmetro \mathbf{b} indica que a função ψ foi transladada no eixo t com uma distância equivalente a \mathbf{b} . O parâmetro \mathbf{a} modifica a escala da *Wavelet* formada pela função, aumentando (caso $\mathbf{a} > 1$) ou diminuindo (caso $\mathbf{a} < 1$). O termo *Wavelet* significa pequenas ondas com determinadas propriedades que as tornam adequadas para servirem de base na decomposição de outras funções (POLIKAR, 2007).

Na detecção de arritmias, ela será utilizada para filtrar o ECG ruidoso e para decompor o sinal de ECG no domínio do tempo e da frequência ao mesmo tempo, criando os coeficientes *Wavelet*. Estes coeficientes são coeficientes de aproximação e de detalhe obtidos após sucessivas filtragens sobre o sinal original, melhor descritos no decorrer desta seção.

Existem dois tipos de transformada *Wavelet*, a contínua (TWC) e a discreta (TWD) que será utilizada neste trabalho. A TWC é calculada nos computadores de maneira discreta, e demanda altos recursos computacionais. Para a computação da TWC diversos tipos de *wavelet-mãe* podem ser utilizados. Cada uma mostra-se mais adequada a um determinado sinal (POLIKAR, 2007). Na figura 3.2 pode-se observar algumas famílias de *wavelets*.

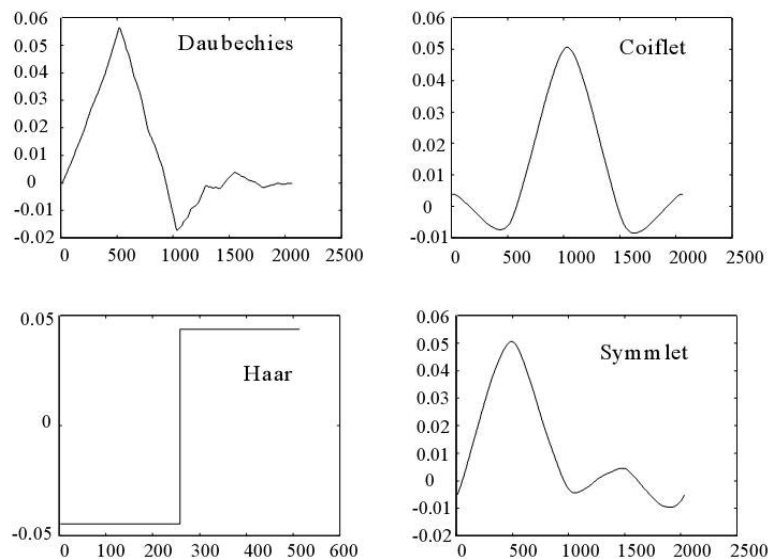


Figura 3.2. Diferentes famílias de *Wavelets* (*Daubechies*, *Coiflet*, *Haar* e *Symmlet*) (POLIKAR, 2007).

A computação da TWC para um sinal não-estacionário pode ser observado na figura 3.3.




Figura 3.3. Computação da TWC ao longo do tempo para um sinal não-estacionário (POLIKAR, 2007).

Com a escolha da *wavelet-mãe*, são geradas janelas de escalas diferentes, que cobrem todo o espectro da frequência do sinal. Ainda na figura 3.3 é possível observar a translação da janela ao longo do tempo sobre todo o sinal. Em cada translação é possível obter a amplitude do sinal para um determinado intervalo de tempo. A relação dessas informações (escala, translação e amplitude) pode ser observada na figura 3.4.

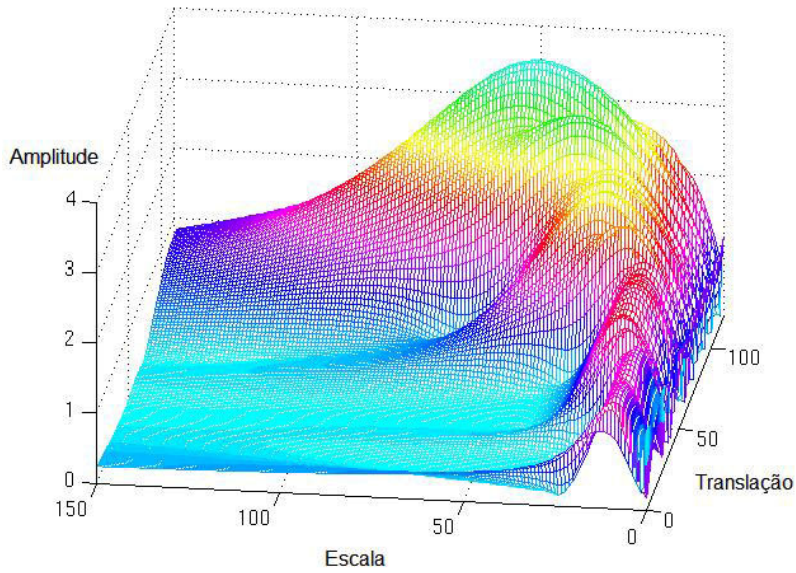


Figura 3.4. Gráfico relacionando escala, translação e amplitude da transformada *Wavelet* de um sinal não-estacionário (POLIKAR, 2007).

A Transformada *Wavelet* Discreta (TWD) fornece informação suficiente para analisar e reconstruir o ECG de entrada, exigindo menos recursos computacionais. A figura 3.5 apresenta um exemplo da aplicação da DWT no sinal de ECG. Neste exemplo utilizou-se uma *Wavelet-mãe* da família *Daubechies* com cinco níveis de resolução.




Figura 3.5. Aplicação da TWD no sinal de ECG.

A TWD é implementada por filtragens digitais sucessivas sobre o sinal de entrada. O processo é mostrado na figura 3.6, onde um par de filtros digitais, representados pelas funções $h(n)$ e $g(n)$ (funções resposta ao impulso de um filtro passa-baixa e passa-alta), é responsável pelo trabalho com o sinal original (cada função com 50% da banda original) (POLIKAR, 2007). A função $h(n)$ gera os coeficientes de aproximação enquanto a função $g(n)$ gera os coeficientes de detalhe.

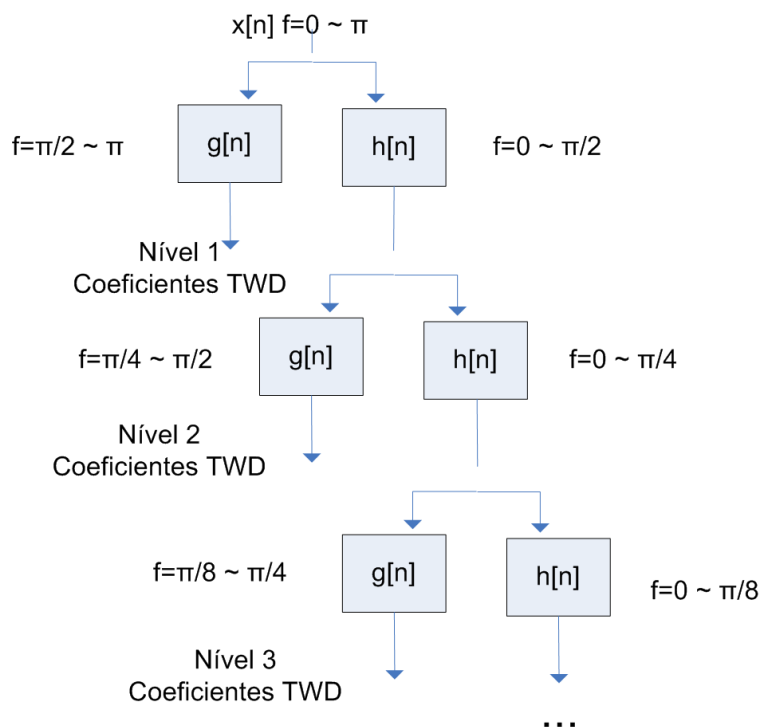


Figura 3.6. Filtragens sucessivas da TWD.

A figura 3.7 mostra a aplicação da TWD em uma senóide com ruído de alta frequência. Com a utilização de filtros passa-alta e passa-baixa, a TWD separou a senóide ruidosa (com 1000 amostras) em dois sinais (com 500 amostras), um sinal contendo o ruído da senóide inicial e o outro com a senóide filtrada, ou seja, sem ruído.

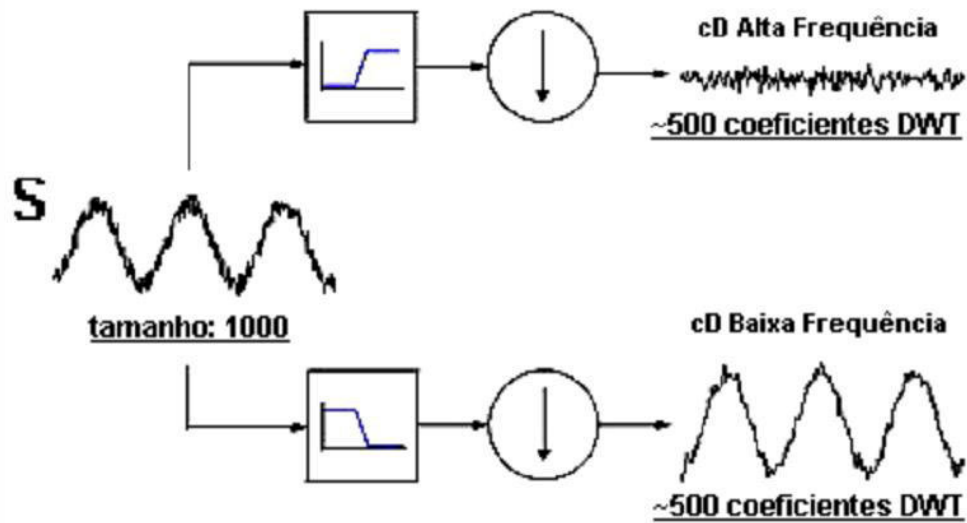


Figura 3.7. Aplicação da TWD em uma senóide ruidosa.

Para exemplificar de maneira clara a obtenção dos coeficientes *Wavelet*, será mostrado um exemplo. A figura 3.8 mostra um sinal fictício e não-estacionário.




Figura 3.8. Sinal não-estacionário.

A figura 3.9 apresenta o resultado da aplicação de uma TWD ao espectro da figura 3.8. Esta TWD empregou uma *Wavelet-mãe* da família *Symlet* com dois níveis de resolução.

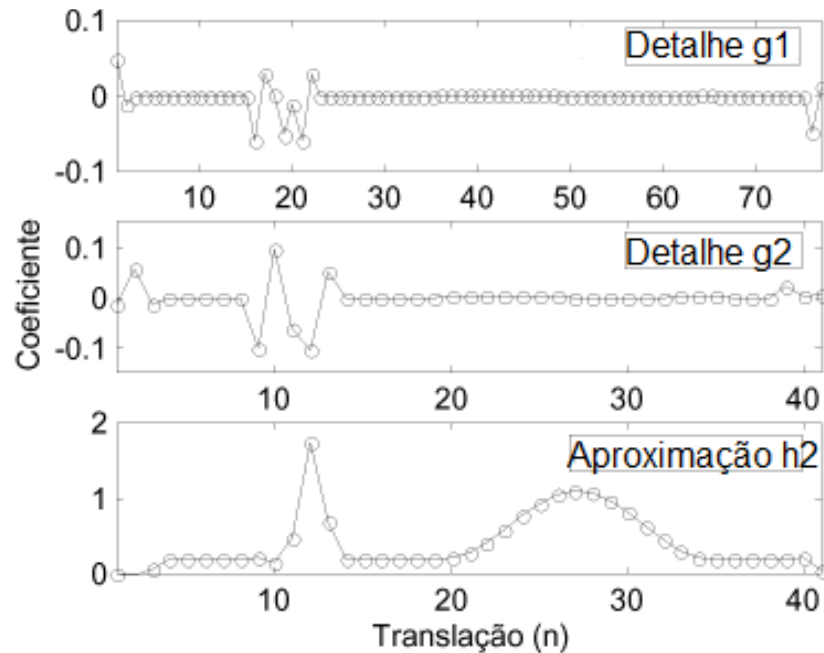


Figura 3.9. Coeficientes de detalhe e aproximação após a aplicação da TWD.

Em (JUNG and TOMPKINS, 2003) foi desenvolvido um algoritmo baseado na transformada *Wavelet* para detectar e classificar 4 tipos de arritmias ventriculares. O algoritmo implementado utilizou 4 *Wavelets* diferentes (*Haar*, *Daubechies*, *Coiflet* e *FBI fingerprint image coder*) e os autores compararam cada resultado. Para episódios extraídos das bases de dados MIT-BIH *Arrhythmia* (PHYSIONET, 2006) e *Malignant Ventricular Arrhythmia*, uma *Wavelet* de *Daubechies* de comprimento 4 obteve o melhor resultado das quatro *Wavelets* estudadas. Por usar a decomposição *Wavelet*, os dados necessários para serem processados pelo algoritmo foram reduzidos em 10%. O método teve uma taxa de acerto de 91,1%.

3.3 Redes Neurais Artificiais (RNAs)

A utilização de RNA é crescente na tarefa de classificação e agrupamento de arritmias, já que possuem um alto desempenho nesta tarefa.

As RNAs são técnicas computacionais que apresentam um modelo baseado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência (KROSE and SMAGT, 1996). Possuem boas aplicações onde as regras de resolução do problema são desconhecidas ou difíceis de formalizar, e quando necessita-se de grande rapidez na resolução do problema (MITCHELL, 1997). Existem vários domínios de

aplicação como, reconhecimento de formas, tratamento de sinal, visão, fala, previsão, modelagem, auxílio à decisão, robótica e extração de regras (STEINER et al., 2006).

O funcionamento do neurônio biológico foi interpretado pelo fisiologista Warren MacCulloch como sendo um circuito de entradas binárias combinadas por uma soma ponderada (com pesos) produzindo uma entrada efetiva. Dessa forma, o neurônio é constituído de:

- Entradas (dendritos) - onde são aplicados os sinais;
- Pesos (sinapses) - onde fica retido o conhecimento;
- Função soma - somatório da relação dos sinais de entrada e dos pesos sinápticos;
- Função de ativação - função que dependendo do valor do somatório irá ou não ativar a saída dependendo do *threshold* (sigmoidal, escada, *gaussian*, etc.);
- Saída (axônio) - saída de interface.

A Figura 3.10 apresenta o modelo de neurônio artificial de McCulloch e Pitts.




Figura 3.10. O modelo de McCulloch e Pitts (KROSE and SMAGT, 1996).

Para iniciar o processamento, a RNA deve ser treinada, assim ela “aprende” a partir de exemplos do domínio de aplicação. Essa aprendizagem pode ser supervisionada (onde os exemplos já possuem respostas) ou não-supervisionada. A aprendizagem supervisionada e não supervisionada podem ser utilizadas em diversas tarefas, como classificação e agrupamento, respectivamente.

A tabela 3.1 mostra algum dos diferentes tipos de RNAs existentes.

Tabela 3.1. Tipos de RNAs.

| Paradigma | Regra de Aprendizagem | Arquitetura | Algoritmo de Aprendizagem | Tarefa |
|--------------------|---------------------------------|-------------------------------|--|---|
| Supervisionada | Correção de erro | Perceptron com uma camada | Algoritmos de aprendizagem do Perceptron | Classificação de padrões |
| | | Perceptron com várias camadas | Retro-propagação; Adaline e Madaline | Aproximação de funções, previsão e controle |
| | Boltzmann | Recorrente | Algoritmo de aprendizagem de Boltzmann | Classificação de padrões |
| | Hebb | Multicamadas em avanço | Análise discriminante linear | Análise de dados, classificação de padrões |
| | Competitiva | Competitiva | Quantização do vetor de aprendizagem | Categorização em classes internas, compressão de dados |
| | | Rede ART | ARTMAP | Classificação de padrões, categorizações em classes internas |
| Não supervisionado | Correção de erro | Multicamadas em avanço | Projeção de Sammon | Análise de dados |
| | Hebb | Em avanço ou competitiva | Análise da componente principal | Análise de dados, compressão de dados |
| | | Rede Hopfield | Aprendizagem de memória associativa | Memória associativa |
| | Competitiva | Competitiva | Quantização de vetores | Categorização, compressão de dados |
| | | SOM (Kohonen) | SOM (Kohonen) | Categorização, análise de dados |
| | | Rede RBF | ART1, ART2 | Categorização |
| Híbrido | Correção de erros e competitiva | Rede RBF | Algoritmo de Aprendizagem RBF | Classificação de padrões, aproximações de funções, previsão, controle |

Neste trabalho serão utilizadas as RNAs auto-organizáveis. Os modelos *Adaptive Resonance Theory* (ART) englobam uma grande variedade de RNAs, e são definidos de

acordo com seu algoritmo de treinamento. Existem redes ART dos mais diversos tipos, utilizando paradigmas de aprendizado tanto supervisionado como não supervisionado (CARPENTER et al., 1991). A figura 3.11 apresenta a genealogia das redes ART.

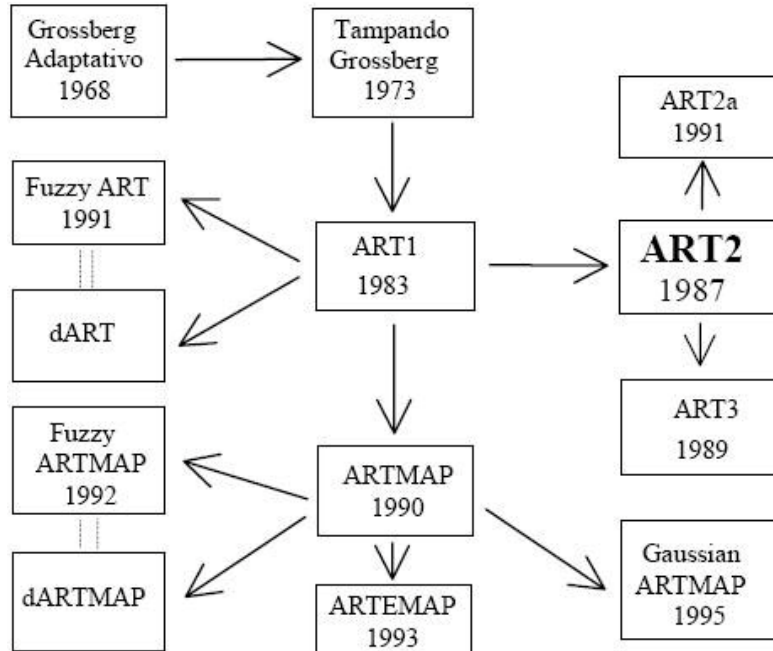


Figura 3.11. Genealogia das RNAs ART (CARPENTER et al., 1991).

Os modelos mais conhecidos e utilizados são:

- ART-1: primeiros modelos desenvolvidos, sua principal peculiaridade é a utilização de dados binários como entradas da rede;
- ART-2: modelo desenvolvido para processar dados contínuos;
- ARTMAP: composto por duas sub-redes, ART-a, que recebe e processa um determinado padrão de entradas apresentado, e ART-b, que constitui a resposta desejada para o padrão apresentado à rede;
- *Fuzzy ART*: rede ART que processa dados *fuzzy*.

Em (HAM and HAN, 1996) os autores utilizaram o mapeamento *fuzzy* da teoria da ressonância adaptativa (ARTMAP) para classificar as arritmias cardíacas. Foram analisadas duas condições diferentes: contração prematura ventricular (CPV) normal e anormal. Os sinais de ECG foram extraídos da base de dados MIT-BIH *Arrhythmia Database*.

A despeito das topologias ART apresentarem uma maior complexidade do que outras topologias neurais de uso mais geral, salienta-se que a introdução de neurônios que atuam como controladores do processo de treinamento possibilitam às redes ART se mostrarem mais capazes de armazenar informações sem incorrer na criação de falsos padrões através de generalização espúria (CARPENTER and GROSSBERG, 1998).

A seguir, apresentam-se a arquitetura de uma rede ART-2 na figura 3.12 e os parâmetros utilizados no algoritmo de treinamento de uma rede ART-2, conforme descrito por (CARPENTER et al., 1991).

A arquitetura da rede ART-2 pode ser dividida em três camadas:

- **F1**: camada de processamento de entrada;
- **F2**: camada de unidade de agrupamento;
- **RESET**: camada que controla o grau de similaridade.

A camada **F1** está conectada à Camada **F2** através dos pesos a_{ij} . A camada **F2**, por sua vez, está conectada à camada **F1** através dos pesos d_{ji} . Estas conexões duplicadas são utilizadas para controlar a similaridade dos padrões de um mesmo grupo.

Como o modelo ART-2 possui mecanismos de normalização e filtragem de ruídos incluídos na camada **F1**, ele se torna mais complexo que o modelo ART-1. O parâmetro ρ controla a eliminação dos ruídos, ajudando a rede a se tornar estável.




Figura 3.12. Arquitetura de uma rede ART2 (CARPENTER and GROSSBERG, 1998)

Parâmetros:

- **t**: número de iterações do treinamento, ou a quantidade de vezes que um padrão deve ser apresentado à rede até que seja obtida sua classificação;
- **n**: número de unidades de entrada (camadas **F1a** e **F1b**);
- **m**: número de unidades de cluster (camada **F2**);
- **a, b**: pesos fixos na camada **F1**;
- **c**: peso fixo utilizado no teste de *reset*. Valores pequenos para *c* permitem uma faixa larga para o parâmetro de vigilância (ρ). Exemplo: $c = 0.1$.;
- **d**: ativação da unidade **F2** vencedora;
- **e**: parâmetro introduzido para prevenir divisão por zero quando a norma de um vetor de dados de entrada é nula, sendo que seu valor deve ser qualquer número inteiro positivo;
- α : taxa de aprendizagem, sendo que $0 < \alpha < 1$; seu valor indica o grau em que os novos padrões pertencentes a cada *cluster* terão na atualização de seus pesos no próximo ciclo de treinamento;
- ρ : parâmetro de vigilância, sendo que $0 < \rho < 1$; este parâmetro determina quantos clusters serão formados, em uma razão direta ao valor adotado, o que significa que este parâmetro define o grau de variação entre cada cluster.

Na ART-2 a aprendizagem pode ser rápida ou lenta. Esta variação de velocidade afeta, além da aprendizagem, as características dos grupos e dos vetores de pesos que serão formados. Quando a aprendizagem é rápida, os pesos são atualizados durante a ressonância (comentada a seguir). O tempo para esta atualização é equivalente ao tempo de apresentação de um padrão. Nesta aprendizagem poucas épocas são necessárias e são necessárias várias iterações para a alteração dos pesos entre a camada **F1** e a entrada (CARPENTER et al., 1991).

O modo lento altera os pesos em um tempo equivalente ao tempo de aprendizagem. Antes de se obter a estabilidade da rede, são necessárias muitas apresentações dos padrões.

A ressonância ocorre apenas no modo de aprendizagem rápido, após a escolha do grupo vencedor. Sua caracterização ocorre pela repetição alternada no processo de atualização dos pesos nos dois sentidos (**F1** \leftrightarrow **F2**) e na atualização da camada **F1**. O **RESET** não pode ocorrer durante a ressonância (CARPENTER et al., 1991).

A velocidade de aprendizagem em ART2 pode ser controlada também através do parâmetro α (taxa de aprendizagem). A velocidade reduz com valores pequenos de α , mas garante que os pesos alcancem equilíbrio no modo lento.

O algoritmo da RNA ART-2 é apresentado a seguir de forma simplificada:

- 1) Repita EP vezes (épocas)
 - 2) Repita para cada vetor de entrada
 - 3) Ativar a camada **F1**;
 - 4) Atualizar **F1**;
 - 5) Calcular sinais para enviar à **F2**;
 - 6) Enquanto **RESET** = **V** faça
 - 7) Encontrar o vencedor;
 - 8) Calcular **RESET**;
 - 9) se **RESET** = **V** {se o vencedor for rejeitado}
 - então inibir **J**;
 - Fim_enquanto passo 6.
 - 10) Atualizar **F1**;
 - 11) Repita **APR** vezes {aprendizagem}
 - 12) Atualizar pesos;
 - 13) Atualizar **F1**;
 - Fim_repita passo 11.
 - Fim_repita passo 2.
 - Fim_repita passo 1.

3.4. Trabalhos Relacionados

Nesta seção são apresentados alguns trabalhos da área de classificação e agrupamento automático de Arritmias.

3.4.1. Abordagem com RNA e análise no domínio do tempo

Em (OZBAK and KARLIK, 2001) utilizou-se RNA do tipo *Multilayer Perceptron* (MPL) para classificar as arritmias do ECG. A análise do sinal de ECG foi feita no domínio do tempo. Para classificar as arritmias, o intervalo entre dois picos (R-R) foi normalizado em 200 amostras, formando as 200 entradas da rede neural. O algoritmo de aprendizagem utilizado foi o *back-propagation*. Para a avaliação do método proposto, a classificação das 10 arritmias foi definida em duas etapas. Na primeira, as arritmias foram classificadas separadamente com um erro de 4,3%. Na segunda, a classificação envolveu todos os tipos de arritmias, e a média dos erros diminuiu para 2,2%.

Em (SRINIVASAN et al., 2003) foi proposto um novo algoritmo para análise do espaço de fase para sinais de eletrocardiograma (ECG), visando facilitar a detecção de arritmias cardíacas. Um traçado da densidade do espaço de fase foi obtido com o mapeamento da distribuição dos pontos do sinal de ECG no espaço de fase e os valores da densidade do espaço de fase dentro de uma janela predefinida. A classificação foi executada usando uma RNA MLP com o algoritmo *back-propagation* e a taxa de acerto total obtida foi de 98.55%.

3.4.2. Abordagem com RNA e utilização de Wavelets

Em (PRASAD and SAHAMBI, 2003) foi proposto um método para classificar as arritmias cardíacas utilizando uma combinação de *Wavelets* e RNA. A habilidade da transformada *Wavelet* para decompor o sinal em resoluções variadas, permite a detecção e extração de características de sinais não estacionários como o ECG. O valor dos coeficientes da transformada *Wavelet* discreta (TWD), que contém a informação máxima sobre as arritmias, é selecionado da decomposição da *Wavelet*. Estes coeficientes junto com a informação do intervalo RR (a diferença entre os picos atuais e precedentes do complexo QRS) alimentam a rede neural *back-propagation* que classifica as arritmias. Foi utilizado um algoritmo robusto para eliminar os ruídos. Este método é capaz de distinguir além do ritmo normal, mais 12 arritmias diferentes com uma taxa de acerto de 96,77%.

Em (JUNG and TOMPKINS, 2003) desenvolveu-se um algoritmo baseado na transformada *Wavelet* para detectar e classificar 4 tipos de arritmias ventriculares. O algoritmo implementado utilizou 4 *Wavelets* diferentes e comparou cada resultado. Para episódios extraídos das bases de dados MIT-BIH *Arrhythmia* (PHYSIONET, 2006) e *Malignant Ventricular Arrhythmia*, uma *Wavelet* de *Daubechies* de comprimento 4 obteve o melhor resultado das quatro *Wavelets* estudadas. Por usar a decomposição *Wavelet*, os dados necessários para serem processados pelo algoritmo foram reduzidos em 10%. O método teve uma taxa de acerto de 91,1%.

Em (LEE et al., 2005) foi proposto um método para a classificação de arritmias utilizando redes neurais artificiais e com a redução das características de entrada pela análise do discriminante linear. Inicialmente foram extraídas 17 características de entrada baseadas nos coeficientes da transformada *Wavelet*. Aplicando a análise do discriminante linear nestes dados, reduziu a dimensão das características para 4. Com a construção da nova dimensão, o classificador MLP foi treinado para detectar 6 tipos de arritmias. O resultado da classificação das arritmias foi satisfatório reduzindo o tempo e os custos computacionais.

A tabela 3.2 mostra resumidamente as técnicas utilizadas para a detecção das arritmias, apresenta as arritmias trabalhadas e as taxas de acerto nos diversos trabalhos consultados.

Tabela 3.2 Comparativo entre o número de arritmias detectadas, a taxa de acerto, as arritmias aqui trabalhadas e algumas etapas da análise do ECG.

| Trabalho | Arritmias | | Nº total de arritmias analisadas | Correção Preditiva ou Taxa de Acerto | Pré-processamento | Extração de Características | Processamento |
|---------------------------|-----------|-----|----------------------------------|--------------------------------------|-------------------|-----------------------------|----------------------------|
| | CPA | CPV | | | | | |
| (LETTNIN et al., 2002) | | x | 2 | 80% | não | análise no tempo | MLP |
| (HAM and HAN, 1996) | | x | 1 | 96,90% | sim | análise no tempo | ARTMAP |
| (LEE et al., 2005) | | x | 1 | 98,60% | sim | <i>Wavelet</i> | ORG, LDA e PCA |
| (LIN et al., 2005) | | | 3 | 90% | sim | análise no tempo | <i>Clustering</i> |
| (OSOWSKI and HOAI, 2004) | | | 6 | 93,20% | sim | análise no tempo | <i>Neuro-fuzzy Network</i> |
| (ZHANG et al., 2004) | x | x | 4 | 98,30% | sim | análise no tempo | ARTMAP |
| (JUNG and TOMPKINS, 2003) | | | 4 | 91,1% | não | <i>Wavelet</i> | Algoritmo de Classificação |
| (SRINIVASAN et al., 2003) | | x | 4 | 93,70% | sim | análise na frequência | MLP |

3.5. Conclusão

Este capítulo apresentou os principais trabalhos relacionados à detecção automática de arritmias cardíacas. Mostrou também as principais técnicas utilizadas nessa tarefa e indicou a importância da transformada *Wavelet* como elemento de pré-processamento. A utilização da transformada *Wavelet* será muito útil neste trabalho, dado que ela representa um sinal não-estacionário (como o ECG) no domínio tempo-frequência, mostrando com clareza onde cada frequência está ocorrendo. Por fim, o capítulo mostrou algumas RNAs existentes dando um foco maior para as RNAs auto-organizáveis. Entre as RNAs auto-organizáveis, a ART-2 foi a rede que mais se destacou, pelo fato de não perder o conhecimento adquirido. A ART-2 será muito importante neste trabalho, já que processará os dados provenientes da transformada *Wavelet* criando grupos de similaridade.

O capítulo seguinte apresenta a metodologia proposta neste trabalho.

Capítulo 4

Metodologia

Os capítulos anteriores apresentaram a forma de funcionamento do coração, o sinal de ECG, as arritmias cardíacas e métodos de análise automática para este sinal.

Como o ECG é um sinal não-estacionário, optou-se pela utilização da transformada *Wavelet* na etapa de pré-processamento por fornecer informações suficientes para analisar o ECG de entrada, mostrando claramente onde ocorre cada frequência. Com esta transformada, a análise do sinal é feita no domínio do tempo e da frequência ao mesmo tempo. Em específico, optou-se pela TWD, por exigir menos recursos computacionais.

Na detecção automática de arritmias, a fundamentação teórica apresentou as RNAs como o método mais eficiente para esta tarefa de processamento, já que possuem um bom desempenho computacional. Mais especificamente, as RNAs auto-organizáveis foram utilizadas nesta etapa, criando grupos a partir da similaridade dos dados de entrada. Escolheu-se a ART-2, dado que ela é uma RNA plástica, ou seja, não perde o seu conhecimento ao longo do tempo. Como esta RNA é não-supervisionada ela não consegue classificar os dados de entrada, ela apenas os agrupa. Desta forma, necessitou-se da etapa de pós-processamento, possibilitando-se a classificação dos dados de entrada.

Neste trabalho as arritmias foram analisadas em duas fases. Inicialmente analisou-se três padrões de entrada, ECG normal, ECG com CPA e ECG com CPV. Em seguida, as arritmias LBBB e RBBB foram tratadas com o objetivo de verificar o comportamento da rede após a inserção de novas arritmias na segunda fase.

Com a utilização da transformada *Wavelet* na etapa de extração de características, a utilização de RNAs auto-organizáveis na etapa de processamento e a utilização de um algoritmo de classificação na etapa de pós-processamento, é possível analisar o ECG em

busca de arritmias, classificando-as. Para provar a hipótese anteriormente levantada, propõe-se a metodologia descrita nas seções deste capítulo. Pode-se observar um diagrama da arquitetura da hipótese levantada na figura 4.1.

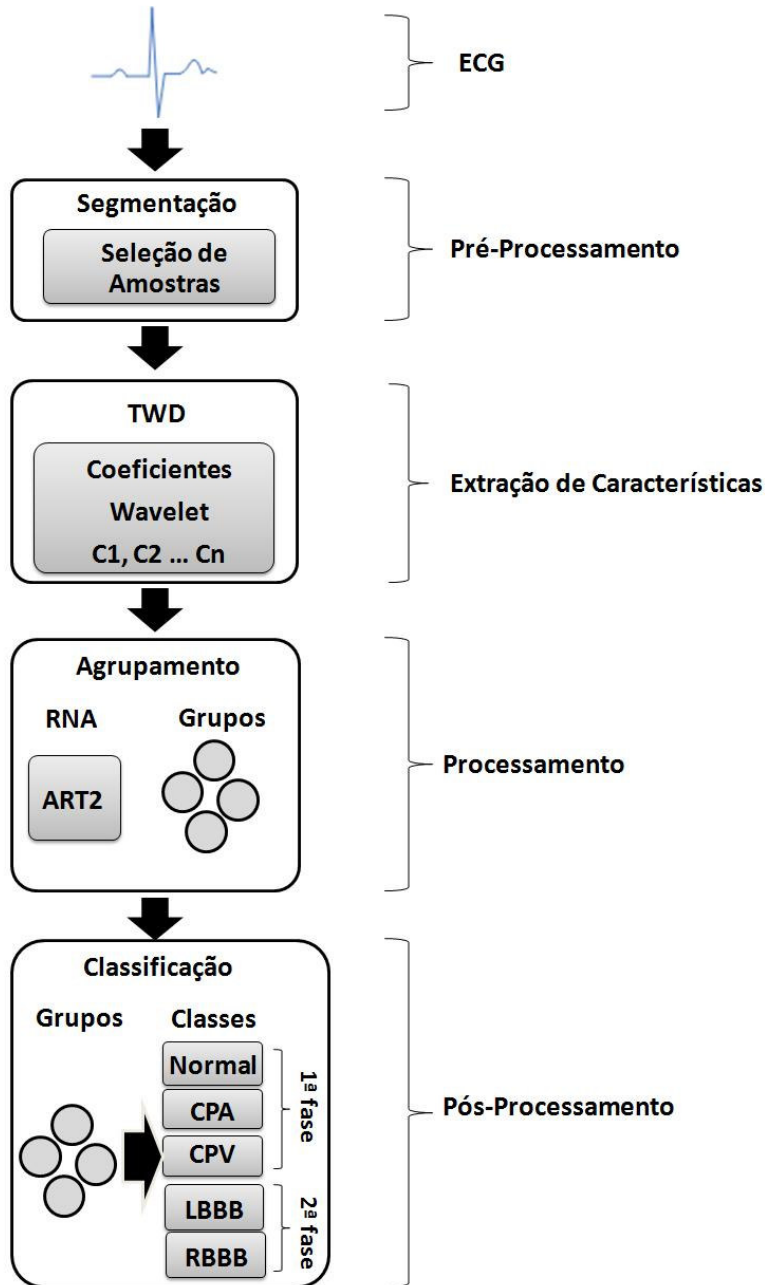


Figura 4.1. Diagrama da arquitetura da hipótese levantada.

4.1. Base de Dados de Arritmias

Para este trabalho foi escolhida a MIT-BIH *Arrhythmia Database* (PHYSIONET, 2006), que é uma base de dados utilizada para o desenvolvimento e avaliação de monitores de arritmias. Esta base é referência para o desenvolvimento de pesquisas na área de análise de arritmias. Ela foi criada pelo *Boston's Beth Israel Hospital* entre os anos de 1975 e 1979 (BIH, 2006), tendo sido publicada em 1980. Esta base possui 48 registros de ECG com arritmias, cada registro contendo duas derivações. O *Boston's Beth Israel Hospital* digitalizou os sinais com uma frequência de amostragem de 360 Hz e com 11 bits de resolução. Destes 48 registros, 25 foram coletados de um conjunto específico de exames e os outros 23 registros foram selecionados aleatoriamente para representar outras arritmias (PHYSIONET, 2006). Especialistas da área avaliaram cada batimento cardíaco dos registros, informando a ocorrência de uma arritmia ou não, totalizando cerca de 110000 anotações de batimentos cardíacos. (MIT, 2006)

A tabela 4.1 apresenta uma análise estatística desta base, realizada com o objetivo de melhor interpretar o seu conteúdo. Para tal, um algoritmo em Java foi escrito. A tabela mostra todos os batimentos dos 48 registros existentes na base, indicando o número de batimentos normais e com arritmias. As duas últimas colunas da tabela apresentam a quantidade de batimentos com as arritmias escolhidas neste trabalho.

Tabela 4.1. Análise estatística da MIT-BIH Arrhythmia Database.

| Registro | Batimentos | | | Tipo de Arritmia | | | |
|--------------|--------------|--------------|---------------|------------------|-------------|-------------|-------------|
| | Normal | Arritmia | Total | CPA | CPV | LBBB | RBBB |
| 100 | 2239 | 34 | 2273 | 33 | 1 | | |
| 101 | 1860 | 5 | 1865 | 3 | | | |
| 102 | 99 | 2088 | 2187 | | 4 | | |
| 103 | 2082 | 2 | 2084 | 2 | | | |
| 104 | 163 | 2066 | 2229 | | 2 | | |
| 105 | 2526 | 46 | 2572 | | 41 | | |
| 106 | 1507 | 520 | 2027 | | 520 | | |
| 107 | 0 | 2137 | 2137 | | 59 | | |
| 108 | 1740 | 34 | 1774 | 4 | 16 | | |
| 109 | 0 | 2532 | 2532 | | 38 | 2492 | |
| 111 | 0 | 2124 | 2124 | | 1 | 2123 | |
| 112 | 2537 | 2 | 2539 | 2 | | | |
| 113 | 1789 | 6 | 1795 | | | | |
| 114 | 1820 | 59 | 1879 | 10 | 43 | | |
| 115 | 1953 | 0 | 1953 | | | | |
| 116 | 2302 | 110 | 2412 | 1 | 109 | | |
| 117 | 1534 | 1 | 1535 | 1 | | | |
| 118 | 2166 | 112 | 2278 | 96 | 16 | | |
| 119 | 1543 | 444 | 1987 | | 444 | | |
| 121 | 1861 | 2 | 1863 | 1 | 1 | | |
| 122 | 2476 | 0 | 2476 | | | | |
| 123 | 1515 | 3 | 1518 | | 3 | | |
| 124 | 0 | 1619 | 1619 | 2 | 47 | | 1531 |
| 200 | 1743 | 858 | 2601 | 30 | 826 | | |
| 201 | 1625 | 375 | 2000 | 30 | 198 | | |
| 202 | 2061 | 75 | 2136 | 36 | 19 | | |
| 203 | 2529 | 451 | 2980 | | 444 | | |
| 205 | 2571 | 85 | 2656 | 3 | 71 | | |
| 207 | 0 | 2332 | 2332 | 107 | 105 | 1457 | 86 |
| 208 | 1586 | 1369 | 2955 | | 992 | | |
| 209 | 2621 | 384 | 3005 | 383 | 1 | | |
| 210 | 2423 | 227 | 2650 | | 194 | | |
| 212 | 923 | 1825 | 2748 | | | | 1825 |
| 213 | 2641 | 610 | 3251 | 25 | 220 | | |
| 214 | 0 | 2262 | 2262 | | 256 | 2003 | |
| 215 | 3196 | 167 | 3363 | 2 | 164 | | |
| 117 | 244 | 1964 | 2208 | | 162 | | |
| 219 | 2082 | 205 | 2287 | 7 | 64 | | |
| 220 | 1954 | 94 | 2048 | 94 | | | |
| 221 | 2031 | 396 | 2427 | | 396 | | |
| 222 | 2062 | 421 | 2483 | 208 | | | |
| 223 | 2029 | 576 | 2605 | 72 | 473 | | |
| 228 | 1688 | 365 | 2053 | 3 | 362 | | |
| 230 | 2255 | 1 | 2256 | | 1 | | |
| 231 | 314 | 1259 | 1573 | 1 | 2 | | 1254 |
| 232 | 0 | 1780 | 1780 | 1382 | | | 397 |
| 233 | 2230 | 849 | 3079 | 7 | 831 | | |
| 234 | 2700 | 53 | 2753 | | 3 | | |
| Total | 77220 | 32929 | 110149 | 2545 | 7129 | 8075 | 5093 |

4.2. Segmentação

Todo o sinal da base de dados é segmentado na fase de pré-processamento por um algoritmo escrito em Java. Este algoritmo seleciona a janela para a análise do ECG. Este processo é apresentado a seguir, na figura 4.2.

A figura 4.2 apresenta todo o processo de segmentação.




Figura 4.2. Diagrama do processo de segmentação do ECG.

A detecção de picos não foi necessária, visto que a base utilizada já está com os picos marcados. Para a seleção da janela, será definido um batimento inteiro, contendo todas as ondas possíveis para a detecção de uma arritmia. Esta janela foi definida como mostrado na figura 4.3.

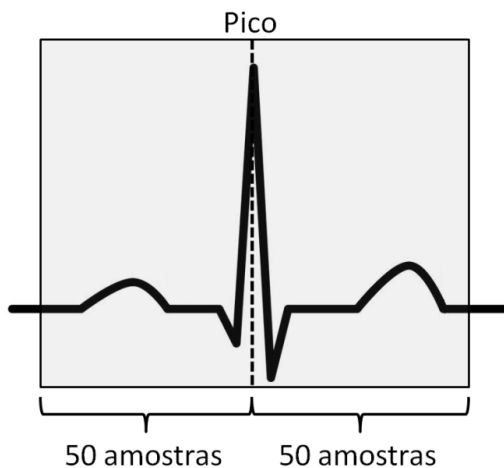


Figura 4.3. Processo de seleção da janela.

Para definir esta janela é necessário encontrar o pico. A janela é formada pelo intervalo de 100 amostras, 50 amostras antes do pico e 50 amostras depois do pico. Estes valores garantem que esta janela não contenha amostras do próximo batimento e foram escolhidos com base em outros trabalhos (OZBAK and KARLIK, 2001) (LETTNIN et al., 2002).

4.3. Extração de Características

A figura 4.4 apresenta a janela selecionada com amostras de um ECG normal. Os dados contidos na janela foram analisados por uma TWD da família *Daubechies*, onde os coeficientes *Wavelet* foram obtidos, para formar o vetor de características, como observado na figura 4.5.




Figura 4.4. Janela selecionada com 100 amostras de um ECG normal (valores extraídos do registro 100 de (PHYSIONET, 2006)).




Figura 4.5. Coeficientes *Wavelet* obtidos por uma TWD aplicada ao sinal de ECG apresentado na figura 4.4. Para esta transformação foi utilizada uma TWD da família *Daubechies* de nível quatro.

A transformada *Wavelet*, já estudada no capítulo 3, foi parametrizada até a quarta camada. Este número foi escolhido com base em trabalhos anteriores (JUNG and TOMPKINS, 2003), que obtiveram uma correção preditiva acima de 90% na classificação de arritmias.

4.4. Agrupamento das Arritmias

Para o agrupamento das arritmias na etapa de processamento, utilizou-se uma RNA ART2. O uso desta rede é muito importante neste trabalho, visto que a ART2 é uma rede “plástica”², não sendo necessário treiná-la novamente desde o início para a adição de outros tipos de arritmias. Ela se ajusta automaticamente, formando novos grupos se necessário. Os 48 registros da base (PHYSIONET, 2006) foram utilizados para o processamento. Dividiu-se o processamento em duas fases. Na primeira, analisou-se o sinal de ECG normal e as arritmias CPA e CPV. Na segunda fase, adicionou-se à RNA da primeira fase dois tipos diferentes de arritmias, LBBB e RBBB. Para cada tipo de sinal analisado, foram criados dois conjuntos de dados, um para treinamento e outro para testes. Estes conjuntos foram replicados 10 vezes, alternando-se os dados entre os conjuntos de treinamento e teste. A figura 4.6 apresenta estes conjuntos utilizados para a validação cruzada.




Figura 4.6. Processo de criação dos conjuntos de dados utilizados no treinamento e nos testes.

Cada conjunto utilizado no treinamento foi formado por 1800 batimentos e cada conjunto utilizado nos testes foi formado por 200 batimentos. A figura 4.7 apresenta o processo de criação dos conjuntos de dados.

² Trata-se da propriedade da RNA que permite o desenvolvimento de alterações estruturais em resposta à experiência, e como adaptação a condições mutantes e a estímulos repetidos.

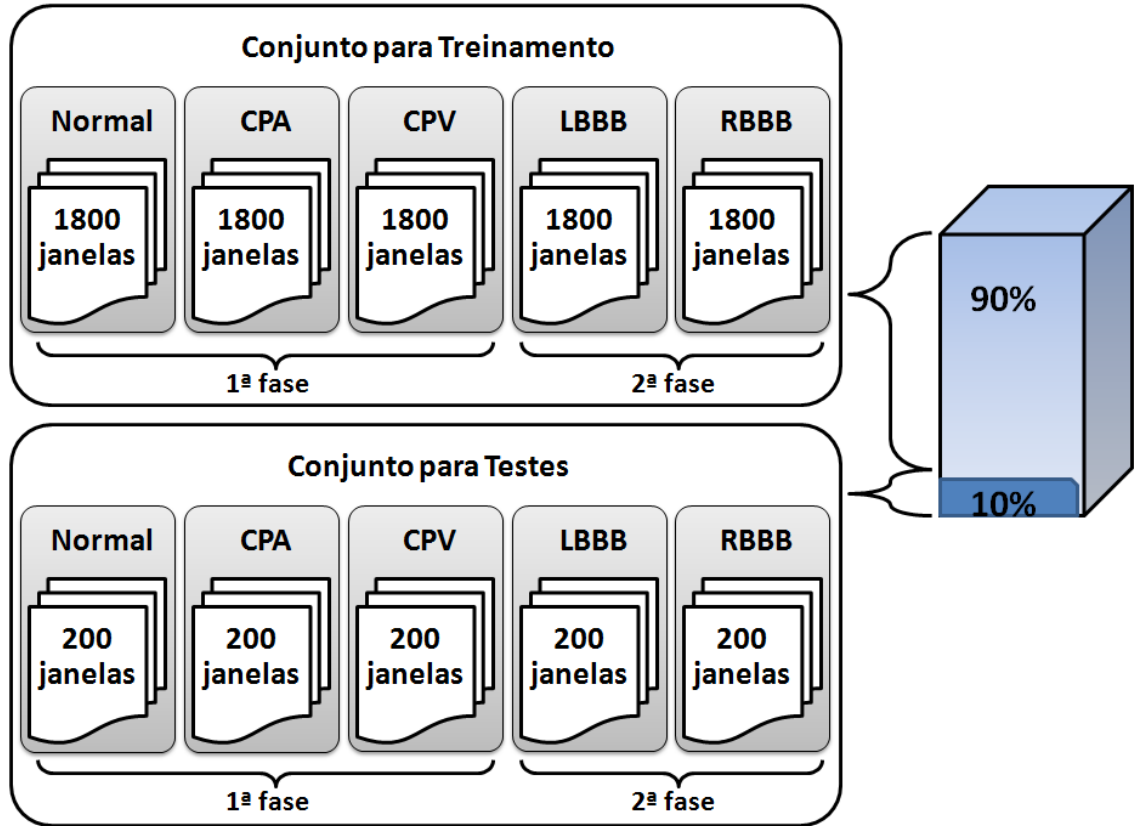


Figura 4.7. Processo de criação dos conjuntos de dados utilizados no treinamento e nos testes.

Construiu-se uma ART2 com 100 unidades de entrada e com 15 unidades de saída. A figura 4.8 apresenta a arquitetura geral da rede criada. Para esta tarefa inicial, de criação da RNA, utilizou-se a ferramenta BigNet. Esta ferramenta é encontrada no *software Stuttgart Neural Network Simulator (SNNS)*.

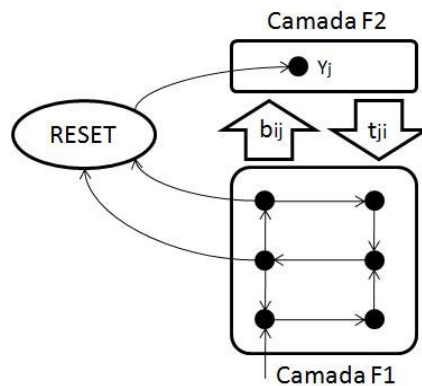


Figura 4.8. Arquitetura geral da ART2 criada.

Após a criação, disponibilizou-se o vetor de características formado à entrada da RNA. Os parâmetros da ART2 foram ajustados empiricamente, até chegar a um nível de agrupamentos adequados. Realizaram-se testes com várias redes ART2 com unidades de entrada e de saída diferentes. A ART2 que obteve os melhores resultados foi a ART2 com 100 unidades de entrada e 15 unidades de saída. Para este processo de seleção da ART2 utilizou-se um conjunto com 1500 batimentos (500 batimentos normais, 500 batimentos com CPA e 500 batimentos com CPV). Este conjunto não foi re-utilizado em etapas posteriores deste trabalho. Os parâmetros obtidos são apresentados na tabela 4.2.

Tabela 4.2. Valor dos parâmetros utilizados na RNA ART2.

| Parâmetro | Valor | Descrição |
|------------------|--------------|---|
| t | 100 | Ciclos de treinamento |
| n | 100 | Unidades de entrada |
| m | 15 | Unidades de saída |
| a | 10 | Peso fixo da primeira camada |
| b | 10 | Peso fixo da segunda camada |
| c | 0.1 | Peso fixo utilizado no teste de reset |
| d | 0.9 | Ativação da unidade vencedora de saída |
| ρ | 0.98 | Determina a taxa de formação dos grupos |

4.5 Pós-processamento

Os grupos formados no treinamento foram analisados por um algoritmo na etapa de pós-processamento. Na primeira fase este algoritmo verificou a quantidade de vezes que os padrões de entrada apareceram em cada unidade de saída da RNA. Para a primeira fase ele analisou os padrões normal, CPA e CPV. Na segunda fase adicionou-se dois novos padrões para a análise, as arritmias LBBB e RBBB. Após esta análise inicial, o algoritmo selecionou as unidades de saída que possuíam o maior número de exemplos para cada padrão. O processo para a primeira fase pode ser observado na figura 4.9. A marcação “-“ da tabela indica que não houve nenhuma ocorrência. A marcação “*” indica o menor número de ocorrências. Já a marcação “***” indica o maior número de ocorrências.

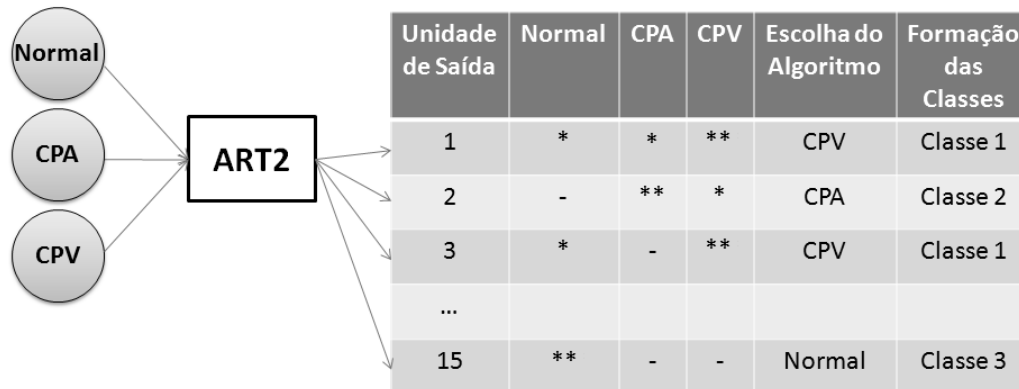


Figura 4.9. Processo de escolha das classes pelo algoritmo (fase 1). A escala “-;*;**” é apenas ilustrativa e serve para indicar o funcionamento do algoritmo.

Já a figura 4.10 apresenta o processo de formação das classes para a segunda fase.




Figura 4.10. Processo de formação das classes pelo algoritmo (fase 2). A escala “-;*;**” é apenas ilustrativa e serve para indicar o funcionamento do algoritmo.

Com as classes formadas, utilizou-se o conjunto de testes para avaliar o método proposto.

4.6. Validação

Realizou-se a validação dos resultados obtidos através da comparação com outros trabalhos utilizando um algoritmo de validação cruzada e testando o método proposto com

outros tipos de arritmias. Na primeira, comparou-se a taxa de acerto obtida na validação cruzada com os trabalhos apresentados na tabela 4.4.

Tabela 4.4. Trabalhos que tiveram as suas taxas de acerto comparadas com as taxas de acerto deste trabalho.

| Trabalho | Arritmias | | Nº total de arritmias analisadas | Taxa de acerto |
|---------------------------|-----------|-----|----------------------------------|----------------|
| | CPA | CPV | | |
| (LETTNIN et al., 2002) | | x | 2 | 80% |
| (HAM and HAN, 1996) | | x | 1 | 96,90% |
| (LEE et al., 2005) | | x | 1 | 98,60% |
| (LIN et al., 2005) | | | 3 | 90% |
| (OSOWSKI and HOAI, 2004) | | | 6 | 93,20% |
| (ZHANG et al., 2004) | x | x | 4 | 98,30% |
| (JUNG and TOMPKINS, 2003) | | | 4 | 91,10% |
| (SRINIVASAN et al., 2003) | | x | 4 | 93,70% |

Adicionou-se a esta tabela uma nova coluna com o desvio padrão de cada trabalho. Para o cálculo do desvio padrão utilizaram-se as equações 4.1 e 4.2.

$$\sigma = \sqrt{(x_i - \bar{x})^2} \quad (4.1)$$

Onde \bar{x} é a taxa de classificação média dos trabalhos.

$$\bar{x} = \frac{\sum_n x_i}{n} \quad (4.2)$$

Na segunda parte da validação, testaram-se dois tipos diferentes de arritmias, a *Left Bundle Branch Block* (LBBB) e *Right Bundle Branch Block* (RBBB). Escolheram-se estas arritmias por apresentarem uma grande quantidade de exemplos na base de dados. Para esta validação, utilizou-se a ART2 já treinada com os batimentos normais, CPA e CPV adicionando-se apenas o treinamento das novas arritmias. Para este treinamento utilizaram-se 1800 batimentos de cada arritmia. Para os testes utilizaram-se 200 batimentos para cada arritmia. Para esta validação aplicou-se o algoritmo de validação cruzada, já explicado na seção anterior.

Após os novos treinamentos, utilizou-se o algoritmo de classificação na etapa de pós-processamento para definir as duas novas classes.

A base de dados utilizada neste trabalho possui um arquivo de atributos contendo a classificação de cada batimento cardíaco, assim, o algoritmo de classificação verificou se o padrão analisado foi classificado corretamente.

4.6. Conclusão

Este capítulo apresentou a metodologia utilizada para comprovar a hipótese proposta neste trabalho. Mostrou o funcionamento de todo o processo para se chegar até a classificação das arritmias. Apresentou o método incremental de aprendizado para novas arritmias e mostrou como o algoritmo de classificação forma as classes a partir do agrupamento feito pela ART2. Os resultados obtidos nos experimentos são descritos no capítulo 6. O próximo capítulo mostrará toda a implementação do sistema proposto.

Capítulo 5

Implementação da Arquitetura

O capítulo anterior apresentou a arquitetura do sistema. Neste capítulo apresenta-se a implementação de cada etapa da arquitetura do sistema.

Inicialmente apresenta-se a criação e configuração da ART2. Em seguida, serão mostrados a criação dos conjuntos de dados, o treinamento e os testes da ART2.

5.1 Implementação da ART2

Criou-se a RNA ART com o *software* SNNS. A tela principal deste *software* é mostrada na figura 5.1.

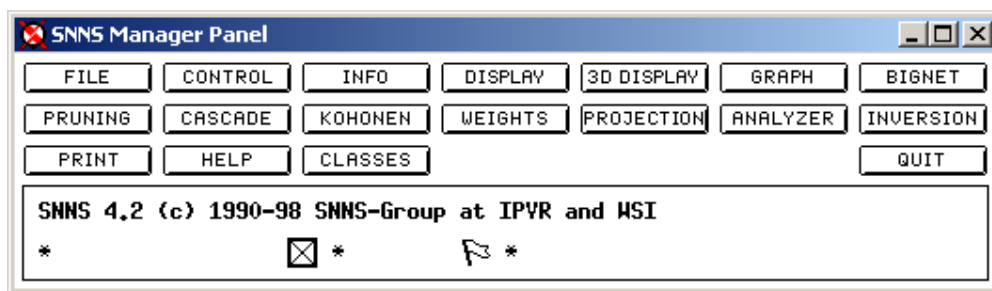


Figura 5.1. Tela principal do SNNS.

O SNNS possui uma ferramenta chamada BIGNET que auxilia na criação de RNA. A tela desta ferramenta é apresentada na figura 5.2.




Figura 5.2. Tela da ferramenta BIGNET, selecionada para a RNA ART2.

Nesta figura observa-se as caixas para a entrada dos dados, neste caso, 100 unidades na camada F1 e 15 unidades na camada F2.

5.2 Conjunto de Dados

Para a criação dos conjuntos de dados foi escrito um algoritmo em Java que segmentou todos os registros da MIT-BIH, conforme descrito no Capítulo 4. Cada registro desta base de dados é formado por dois arquivos. Um arquivo com amostras de ECG e o outro com atributos que descrevem estas amostras. Estes atributos são descritos abaixo. As figuras 5.3 e 5.4 apresentam fragmentos dos respectivos arquivos. Cada linha do fragmento abaixo é composta pelo tempo, por uma amostra da primeira derivação e por uma amostra da segunda derivação. Para este trabalho utilizou-se apenas a primeira derivação. As siglas MLII e V1 representam duas derivações do coração já apresentadas no capítulo 2.

| time (sec) | MLII (mV) | V1 (mV) |
|---------------|--------------|-------------|
| 0.000 | -0.34500000 | -0.16000000 |
| 0.003 | -0.34500000 | -0.16000000 |
| 0.006 | -0.34500000 | -0.16000000 |
| 0.008 | -0.34500000 | -0.16000000 |

Figura 5.3. Fragmento do arquivo com as amostras de ECG. Dados retirados do arquivo "101.DAT".

| Time | Sample # | Type | Sub Chan | Num | Aux |
|----------|----------|------|----------|-----|------|
| 0:00.019 | 7 | + | 0 | 0 | 0 (N |
| 0:00.230 | 83 | N | 0 | 0 | 0 |
| 0:01.100 | 396 | N | 0 | 0 | 0 |
| 0:01.975 | 711 | N | 0 | 0 | 0 |
| 0:02.866 | 1032 | N | 0 | 0 | 0 |

Figura 5.4. Fragmento do arquivo com os atributos que descrevem o arquivo de amostras. Dados retirados do arquivo “101.ATR”.

Cada linha do arquivo da figura 5.4 corresponde a um batimento cardíaco, ou seja, a ocorrência de um pico (complexo QRS). A coluna “Time” registra o momento da ocorrência do pico. A coluna “Sample” identifica a amostra em que ocorreu o pico. Por sua vez a coluna “Type” identifica o tipo do batimento cardíaco (N para normal, A para CPA, V para CPV, L para LBBB e R para RBBB). Os dados das outras colunas não são utilizados no presente trabalho.

A figura 5.5 apresenta um fragmento do arquivo com os dados segmentados pelo algoritmo de segmentação.

```

N
0.465 0.47 0.485 0.505 0.51 0.535
0.53 0.545 0.595 0.655 ...
N
-0.25 -0.24 -0.255 -0.255 -0.255 -0.25
-0.26 -0.26...

```

Figura 5.5. Fragmento do arquivo com os dados segmentados para os batimentos normais. Para cada identificador (neste caso N) existe cem amostras.

Com os dados segmentados em um arquivo, utilizou-se a TWD para a criação dos coeficientes *Wavelet*. Implementou-se a TWD em JAVA. A figura 5.6 apresenta o arquivo com os coeficientes *Wavelet*. Este arquivo encontra-se no padrão dos *softwares* SNNS e

JavaNNS. O cabeçalho deste arquivo apresenta o número de padrões e o número de unidades de entrada.

```

SNNs pattern definition file V3.2
generated at Mon Sep 4 15:43:27 2008

No. of patterns : 250
No. of input units : 100
No. of output units : 0

0.07136437716059216 0.020870810214006053 0.04099906075441768
0.06398949564020619 0.07837986115409859 0.05354260185662611

```

Figura 5.6. Fragmento do arquivo com os coeficientes *Wavelet*.

5.3 Treinamento

Para o treinamento da ART2 optou-se pela utilização do *software* JavaNNS. Este *software* facilita a visualização da RNA e a inclusão dos parâmetros de treinamento. A tela principal do JavaNNS com a ART2 é apresentada na figura 5.7.

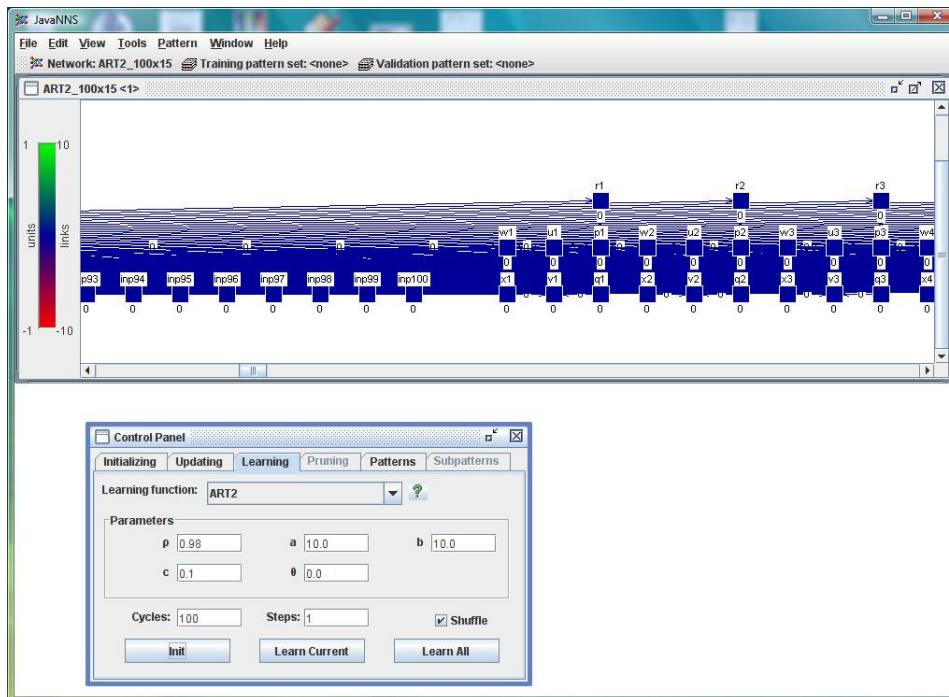


Figura 5.7. Tela principal do JavaNNS com a ART2 e com a janela “Control Panel”. Esta janela é utilizada para o treinamento e para inserir todos os parâmetros da RNA.

5.4 Testes

Para a realização de todos os testes foi necessário alterar e re-compilar o código fonte do JavaNNS. Nesta alteração foi adicionado um algoritmo de classificação que fez o pós-processamento dos grupos. A tela do JavaNNS utilizado para os testes é apresentada na figura 5.8.

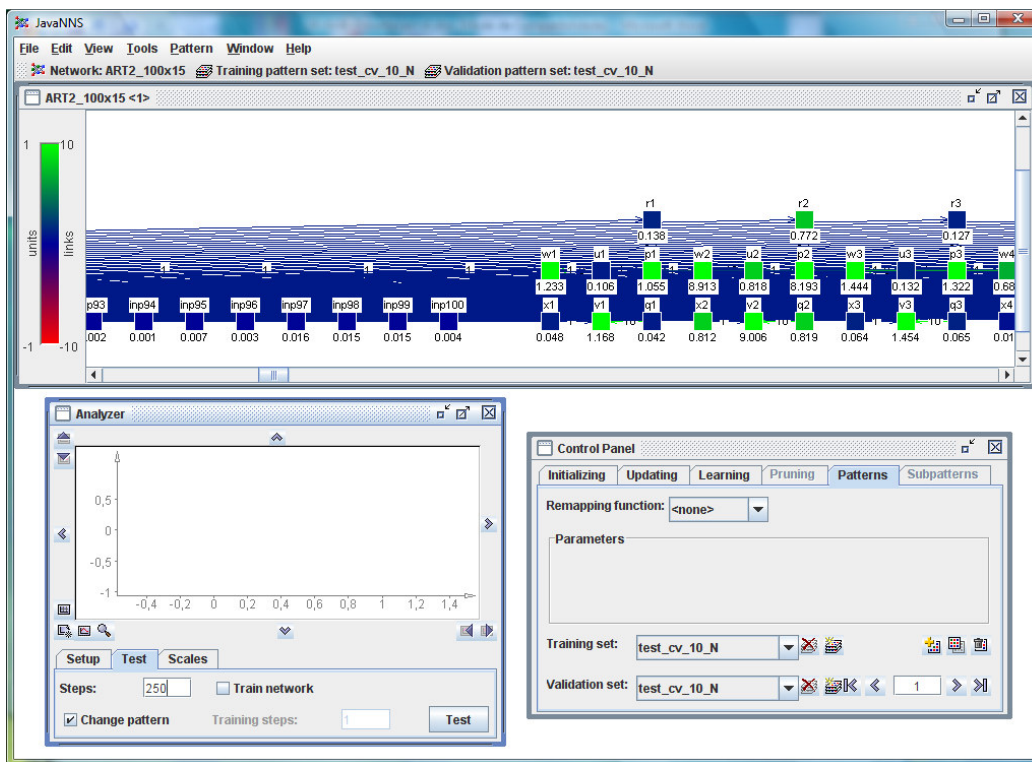


Figura 5.8. Tela principal do JavaNNS com a ART2, com a janela “Control Panel” e com a janela da ferramenta “Analyzer”, utilizada em todos os testes da ART2.

Para RNAs do tipo ART, o *software* JavaNNS não cria arquivos de LOG, assim, não seria possível verificar em quais grupos os dados de entrada estavam sendo agrupados. Desta forma, o código fonte foi alterado e um algoritmo foi adicionado permitindo o registro desta informação em um arquivo de LOG.

Um modelo do arquivo de LOG é apresentado na figura 5.9. Este arquivo registra em que unidade de saída (rec) um padrão de entrada foi agrupado. No fim do arquivo é registrado o somatório das unidades de saída.




Figura 5.9. Arquivo de LOG gerado na etapa de testes da RNA.

Por fim, o algoritmo analisou todos os arquivos de LOG e criou as classes necessárias para a classificação dos padrões normal, CPA e CPV na primeira fase e LBBB e RBBB na segunda fase.

5.5 Conclusão

Este capítulo mostrou a implementação do sistema proposto. Apresentou todas as etapas da criação da ART2 e a criação dos conjuntos de dados. No final apresentou a estrutura do arquivo de LOG que foi utilizado para a formação das classes. O próximo capítulo irá discutir todos os resultados obtidos com o sistema implementado.

Capítulo 6

Discussão dos Resultados Obtidos

Este capítulo apresenta os resultados obtidos a partir dos experimentos realizados seguindo a metodologia descrita no capítulo 4. Inicialmente mostram-se os resultados da primeira validação, ou seja, a validação da fase 1 que utilizou os batimentos normais, CPA e CPV. Confrontam-se estes resultados com os resultados de outros trabalhos que utilizaram ou não estas arritmias. Em seguida, mostram-se os resultados da segunda validação, que utiliza a RNA da primeira validação incluindo as arritmias da fase 2 (LBBB e RBBB).

6.1 Validação da Primeira Fase

Esta seção apresenta os resultados para a classificação dos batimentos normais, CPA e CPV. A tabela 6.1 apresenta os resultados das 10 etapas da validação cruzada.

Tabela 6.1. Resultados das etapas da validação cruzada.

| Etapas da Validação Cruzada | CPA | CPV | Normal |
|--------------------------------------|------------|------------|---------------|
| 1 | 93% | 95% | 93,5% |
| 2 | 95,4% | 98% | 87,5% |
| 3 | 95,5% | 91,5% | 93% |
| 4 | 91,5% | 94% | 90% |
| 5 | 89% | 94,5% | 96,5% |
| 6 | 91,5% | 93% | 95,5% |
| 7 | 88% | 95% | 90,5% |
| 8 | 91,5% | 98% | 99% |
| 9 | 93,5% | 95,5% | 90% |
| 10 | 95% | 95,5% | 90% |
| Taxa de Classificação Correta | 93,42% | | |

Para a realização destes testes, treinou-se a ART2 com 90% dos dados e testou-se com 10 % dos dados. Este processo repetiu-se 10 vezes, alterando-se os dados de treinamento e testes, conforme apresentado na metodologia.

O resumo dos resultados desta primeira validação é apresentado na tabela 6.2.

Tabela 6.2. Resumo dos resultados obtidos através do algoritmo de validação cruzada.

| Sinal de ECG | Classificação Correta |
|------------------|-----------------------|
| Batimento Normal | 92,9% |
| Arritmia CPA | 92,25% |
| Arritmia CPV | 95,1% |

Com a utilização do algoritmo de classificação no pós-processamento, formaram-se as classes desejadas. As unidades de saída da ART2 que originaram as classes são apresentadas na tabela 6.3. Nesta tabela observa-se a marcação de um “X” nas colunas.

Tabela 6.3. Definição das classes formadas pelo algoritmo no pós-processamento.

| Unidade de Saída | Classes | | |
|------------------|---------|-----|-----|
| | Normal | CPA | CPV |
| 1 | | X | |
| 2 | | | X |
| 3 | | X | |
| 4 | | | |
| 5 | | X | |
| 6 | | | X |
| 7 | | | X |
| 8 | X | | |
| 9 | X | | |
| 10 | | | X |
| 11 | | | X |
| 12 | | | |
| 13 | | | |
| 14 | | | X |
| 15 | | | |

Esta marcação indica que aquela unidade de saída obteve os maiores resultados para certo padrão entre os três padrões analisados. Assim, formam-se as três classes.

Observa-se que algumas unidades de saída não foram selecionadas para nenhuma classe. Estas unidades apresentaram estatisticamente valores insignificantes para os padrões analisados e foram descartadas.

A tabela 6.4 confronta o resultado obtido com resultados de outros trabalhos. Além de apresentar as taxas de acerto, esta tabela apresenta o desvio padrão para cada trabalho.

Tabela 6.4. Trabalhos que tiveram as suas taxas de acerto comparadas com as taxas de acerto deste trabalho.

| Trabalho | Arritmias | | Nº total de arritmias analisadas | Taxa de classificação correta | Desvio Padrão |
|---------------------------|-----------|----------|----------------------------------|-------------------------------|---------------|
| | CPA | CPV | | | |
| ART2 | x | x | 2 | 93,42% | 0,62 |
| (LETTNIN et al., 2002) | | x | 2 | 80% | 12,80 |
| (HAM and HAN, 1996) | | x | 1 | 96,90% | 4,10 |
| (LEE et al., 2005) | | x | 1 | 98,60% | 5,80 |
| (LIN et al., 2005) | | | 3 | 90% | 2,80 |
| (OSOWSKI and HOAI, 2004) | | | 6 | 93,20% | 0,40 |
| (ZHANG et al., 2004) | x | x | 4 | 98,30% | 5,50 |
| (JUNG and TOMPKINS, 2003) | | | 4 | 91,10% | 1,70 |
| (SRINIVASAN et al., 2003) | | x | 4 | 93,70% | 0,90 |

Após os testes iniciais, realizaram-se novos testes com outros tipos de arritmias. Estes testes são apresentados na próxima seção.

6.2 Validação da Segunda Fase

Para verificar o funcionamento da rede ART-2 neste trabalho, adicionou-se outros tipos de arritmias. Escolhemos as arritmias LBBB e RBBB por existirem vários exemplos na base de dados. Utilizando-se a ART2 já treinada com os sinais CPV, CPA e normal, adicionaram-se os dois novos conjuntos de padrões. Treinou-se a ART2 com novos conjuntos de dados contendo apenas as duas novas arritmias. Estes novos conjuntos foram formados por 4000 batimentos, 2000 com LBBB e 2000 com RBBB.

Assim como ocorreu nos testes da seção anterior, utilizou-se a validação cruzada. Treinou-se a ART2 com 90% dos dados e testou-se com 10 % dos dados, repetindo-se este processo 10 vezes, alterando-se os dados de treinamento e testes, conforme apresentado na metodologia. Os resultados são apresentados na tabela 6.5.

Tabela 6.5. Resumo dos resultados obtidos através do algoritmo de validação cruzada.

| Sinal de ECG | Classificação Correta |
|---------------------|------------------------------|
| Batimento Normal | 92,76% |
| Arritmia CPA | 92,08% |
| Arritmia CPV | 95,22% |
| LBBB | 90,9% |
| RBBB | 93,43% |
| Total | 92,88% |

Após estes testes, formaram-se duas novas classes utilizando o algoritmo de classificação na etapa de pós-processamento. A tabela 6.6 apresenta as novas classes.

Tabela 6.6. Definição das novas classes formadas pelo algoritmo no pós-processamento.

| Unidade de Saída | Classes antigas | | | Classes novas | |
|-------------------------|------------------------|------------|------------|----------------------|-------------|
| | Normal | CPA | CPV | LBBB | RBBB |
| 1 | | X | | | |
| 2 | | | X | | |
| 3 | | X | | | |
| 4 | | | | | |
| 5 | | X | | | |
| 6 | | | X | | |
| 7 | | | X | | |
| 8 | X | | | | |
| 9 | X | | | | |
| 10 | | | X | | |
| 11 | | | | X | |
| 12 | | | | X | |
| 13 | | | | | X |
| 14 | | | X | | |
| 15 | | | | | |

Observa-se que houve uma pequena mudança na formação das classes já existentes. A unidade de saída 11 que pertencia à classe CPV, passou a formar a classe LBBB. Já as taxas de classificação para os padrões já existentes tiveram pequenas oscilações, menores que 0.25%.

Assim, comprova-se que o método proposto conseguiu classificar novos tipos de arritmias sem a necessidade de um treinamento completo da RNA. Com este método incremental o tempo de treinamento é reduzido para a adição de novas arritmias. Nos testes, a RNA obteve o mesmo desempenho para as fases 1 e 2.

6.3 Conclusão

Este capítulo apresentou todos os resultados obtidos nos experimentos realizados e os valores obtidos foram confrontados com outros trabalhos. O valor da taxa de correção (93,42%) é comparável com outros trabalhos. Também comprovou-se o método proposto com a adição de novas arritmias. Um ponto crítico das RNAs é o tempo de treinamento lento. Com este método incremental foi possível reduzir o tempo de treinamento para as novas arritmias adicionadas. O próximo capítulo irá apresentar as conclusões e as perspectivas para trabalhos futuros.

Capítulo 7

Conclusões e Perspectivas

Este estudo apresentou detalhes fisiológicos a respeito do ECG, mostrando o coração humano, relacionando as contrações com as ondas do ECG, indicando as possíveis arritmias com as respectivas deformações do sinal de ECG. Apresentou também como funciona a detecção automática de arritmias e alguns trabalhos da área, indicando as principais técnicas utilizadas para esta tarefa.

O estudo destas técnicas comprovou a seguinte hipótese: “um sistema utilizando a transformada *Wavelet* na etapa de extração de características em conjunto com RNAs auto-organizáveis na etapa de processamento e uma etapa de pós-processamento, pode analisar o sinal de ECG em busca de arritmias, classificando-as”.

Através da metodologia proposta a hipótese levantada foi comprovada. Assim, este trabalho teve várias contribuições. Provou-se a importância da transformada *Wavelet* como elemento de extração de características. A utilização desta transformada foi muito útil neste trabalho, dado que ela representou o sinal de ECG no domínio tempo-frequência, mostrando com clareza onde cada frequência ocorria. Por fim, provou-se que a RNA auto-organizável ART2 foi muito importante para este trabalho, dado que ela não perde o conhecimento adquirido. Desta forma, foi possível adicionar outros tipos de arritmias sem a necessidade de um treinamento completo da RNA.

Uma vez que este trabalho comprovou a hipótese levantada, novas questões podem ser levantadas:

- Quais outras formas de segmentação podem ser utilizadas?
- Quais outras famílias da transformada *Wavelet* podem ser utilizadas?

- Quais outros parâmetros e unidades da ART2 podem ser utilizados?
- Quais outras RNAs auto-organizáveis podem ser utilizadas?

As próximas etapas desta pesquisa podem ser divididas da seguinte forma:

- Adicionar outras arritmias para verificar ao final se a correção preditiva continuará constante;
- Realizar testes com outras famílias da transformada *Wavelet*. Neste trabalho utilizou-se a transformada de *Daubechies*, mas foram realizados alguns testes com a transformada *Coiflet* obtendo resultados semelhantes. Um parâmetro que poderia ser alterado na transformada seria o número de níveis. Para a *Wavelet* utilizada neste trabalho utilizou-se o nível quatro;
- Utilizar outras formas de segmentação. Neste trabalho utilizou-se para a segmentação do ECG a seguinte configuração: 50 amostras antes do pico e 50 amostras depois do pico. Poderiam ser utilizadas outras formas de segmentação, por exemplo, 40 amostras antes do pico e 60 amostras depois do pico;
- Utilizar outras configurações para a RNA. Poderiam ser adicionadas mais unidades de saída para a RNA, permitindo desta forma um maior número de grupos e conseqüentemente através do algoritmo de classificação, um maior número de classes. Os parâmetros da ART2 também poderiam ser alterados para tentar melhorar a taxa de agrupamento.

Referências

BIH. Beth Israel Hospital Inc. Disponível em: <http://www.bih.harvard.edu>. Acesso em: 15 de dezembro de 2006.

CAPUA, C. D.; FALCO, S. D.; MORELLO, R. A. Soft Computing-Based Measurement System for Medical Applications in Diagnosis of Cardiac Arrhythmias by ECG Signals Analysis. *Computational Intelligence for Measurement Systems and Applications, Proceedings of 2006 IEEE International Conference*, p. 2–7, July 2006.

CARPENTER, G. A.; GROSSBERG, S. *Adaptive Resonance Theory. Department of Cognitive and Neural Systems. September 1998.*

CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: Supervised Real-Time Learning and Classification of Nonstationary Data by a Self-Organizing Neural Network. *Center for Adaptive Systems and Department of Cognitive and Neural Systems. February 1991.*

FROWNFEELTER, D.; DEAN, E. *Fisioterapia Cardiopulmonar – Princípios e Prática. Terceira Edição. Editora Revinter, 2004.*

FIGUEREDO, M. V. M.; NIEVOLA, J. C.; ROGAL JR., S. R.; BECKERT NETO, A.. Compression of Electrocardiogram Using Neural Networks and Wavelets. In: 7th IEEE International Conference on Computer and Information Science, 2008, Portland. *Proceedings of the 7th IEEE International Conference on Computer and Information Science. Los Alamitos, CA : IEEE Presss, v. 1, p. 1, 2008.*

GUYTON, A. C.; HALL, J. E. *Tratado de Fisiologia Médica. Guanabara & Koogan, 1996.*

HAM, F. M.; HAN, S. Classification of Cardiac Arrhythmias Using Fuzzy ARTMAP. *Biomedical Engineering, IEEE Transaction*, v. 43, Issue 4, p 425–429, April 1996.

JUNG, Y.; TOMPKINS, W. J. Detecting and classifying life-threatening ECG ventricular arrhythmias using wavelet decomposition. *Engineering in Medicine and Biology Society, 2003. Proceedings of the 25th Annual International Conference of the IEEE*, v.3, p. 2390-2393, Sept. 2003.

KROSE, B.; SMAGT, P. V. D. *An Introduction Neural Networks*. 8ª ed., November 1996.

LIN, Z.; GE, Y.; TAO, G. Algorithm for Clustering Analysis of ECG Data. *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference*, p. 3857–3860, 01-04 Sept. 2005.

LEE, J.; PARK, K. L.; SONG, M. H.; LEE, K. J. Arrhythmia Classification with Reduced Features by Linear Discriminant Analysis. *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference*, p. 1142-1144, 01-04 Sept. 2005.

LETTNIN, D. V.; VARGAS, F.; MACARTHY, M. *Estudo de um Sistema para Classificação de Batimentos Cardíacos Utilizando Redes Neurais*. Universidade Federal de Pelotas (UFPel), Pontifca Universidade Católica do Rio Grande do Sul (PUCRS). 2002.

MALOOF, M. A.; MICHALSKI, R. S. *Incremental learning with partial instance memory*. *Artificial Intelligence* 154, p. 95-126, 2004.

MIT, Massachusetts Institute of Technology. Disponível em <http://www.mit.edu>. Acesso em: 15 de dezembro de 2006.

MITCHELL, T. *Machine Learning*, McGraw-Hill. 1997.

MULHBAIER, D.; POLIKAR, R. *Multiple Classifiers Based Incremental Learning Algorithm for Learning in Nonstationary Environments*, IEEE International Conference on Machine Learning and Cybernetics, v. 6, p. 3618-3623, 19-22 August 2007.

OSOWSKI, S.; HOAI, L. T. Analysis of Features for Efficient ECG Signal Classification Using Neuro-fuzzy Network. *Neural Networks*, 2004. Proceedings. 2004 *IEEE International Joint Conference*, v. 3, p. 2443-2448, 25-29 July 2004.

OZBAK, Y.; KARLIK, B. A RECOGNITION OF ECG ARRHYTHMIAS USING ARTIFICIAL NEURAL NETWORKS. *Engineering in Medicine and Biology Society*, 2001. *Proceedings of the 23rd Annual International Conference of the IEEE*, v. 2, p. 1680-1683, 25-28 Oct. 2001.

PHYSIONET. PhysioBank. MIT-BIH Arrhythmia Database. Disponível em: <http://www.physionet.org/physiobank/database/mitdb>. Acesso em: 15 de dezembro de 2006.

POLIKAR, R. The Wavelet Tutorial. Rowan University, College of Engineering Web Servers. Disponível em: <http://users.rowan.edu/~polikar/WAVELETS/WTpart1.html>. Acesso em: 20 de junho de 2007.

PRASAD, G. K.; SAHAMBI, J. S.. Classification of ECG arrhythmias using multi-resolution analysis and neural networks. *TENCON 2003. Conference on Convergent Technologies for Asia-Pacific Region*, v.1, p. 227-231, 15-17 Oct. 2003.

ROGAL, S., PARAISO, E. C., KAESTNER, C. A. A., FIGUEREDO, M., BECKERT, A. Agrupamento de Arritmias Cardíacas Utilizando ART2 In: *IV Workshop em Algoritmos e Aplicações de Mineração de Dados*, 2008, Campinas. *IV Workshop em Algoritmos e Aplicações de Mineração de Dado*, p. 27-36, ISBN: 857669205-8, 2008.

ROGAL, S., PARAISO, E. C., KAESTNER, C. A. A., FIGUEREDO, M., BECKERT, A. *Detecção Automática de Arritmias Cardíacas Utilizando Redes Neurais Artificiais Auto-*

Organizáveis In: CLEI - Conferencia Latinoamericana de Informática, 2008, Santa Fé - Argentina. XXXIV Conferencia Latinoamericana de Informática (CLEI 2008), p. 1090–1099, ISBN: 978-950-9770-02-7, 2008.

SRINIVASAN, N.; WONG, M. T.; KRISHNAN, S. M. A new phase space analysis algorithm for cardiac arrhythmia detection. *Engineering in Medicine and Biology Society, 2003. Proceedings of the 25th Annual International Conference of the IEEE*, v.1, p. 82-85, 17-21 Sept. 2003.

STEINER, M. T. A.; SOMA, N. Y.; SHIMIZU, T.; NIEVOLA, J. C.; STEINER NETO, P. J. Using Neural Networks Rule Extraction for Credit-Risk Evaluation. *International Journal Of Computer Science And Network Security*, v. 6, n. 5A, p. 6-17, 2006.

UNICAMP, *Jornal da Unicamp* - http://www.unicamp.br/unicamp/unicamp_hoje/ju/dezembro2006/ju348pag9a.html. Acessado em 2006.

VIDAKOVIC, B.; MUELLER, P. *Wavelets for Kids. A Tutorial Introduction*. Duke University. 1991.

WANG, F.;CARRAULT, G.; QUINIOU, R.; CORDIER M.;LUO, L. Temporal reasoning based automatic arrhythmias recognition. *Robotics, Intelligent Systems and Signal Processing, 2003. Proceedings. 2003 IEEE International Conference*, v. 2, p. 1114-1119, 8-13 Oct. 2003.

ZHOU, H.; HOU, K. M.; PONSONNAILLE, J.; GINESTE, L.;VALUX, C. De. A Real-Time Continuous Cardiac Arrhythmias Detection System RECAD. *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference*, p. 875–881, 2005.

ZHANG, Z. G.; JIANG, H. Z.; GE, D. F.; XIANG, X. J. Pattern Recognition of Cardiac Arrhythmias Using Scalar Autoregressive Modeling. *Intelligent Control and Automation, 2004. WCICA 2004*. Fifth World Congress, v. 6, 15-19 June, p. 5545-5548, 2004.