


**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**



**Classificação Automática de Cardiopatias
Baseada em Eletrocardiograma**

NINA MARIA BUENO

2006

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA



**Classificação Automática de Cardiopatias
Baseada em Eletrocardiograma**

Nina Maria Bueno

2006

Dados Internacionais de Catalogação na Publicação (CIP)

- B928c Bueno, Nina Maria, 1959-
 Classificação automática de cardiopatias baseada em eletrocardiograma / Nina Maria Bueno. - 2007.
 104 f. : il.
- Orientador: Alcimar Barbosa Soares.
 Dissertação (mestrado) – Universidade Federal de Uberlândia, Programa de Pós-Graduação em Engenharia Elétrica.
 Inclui bibliografia.
1. Eletrocardiografia - Teses. 2. Coração - Doenças - Diagnóstico - Teses. I. Soares, Alcimar Barbosa. II. Universidade Federal de Uberlândia. Programa de Pós-Graduação em Engenharia Elétrica. II. Título.

CDU: 616.12 - 073.97

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Classificação Automática de Cardiopatias Baseada em Eletrocardiograma

Nina Maria Bueno

**Texto da dissertação apresentada à
Universidade Federal de Uberlândia,
perante a banca de examinadores, como
parte dos requisitos necessários para
obtenção do título de Mestre em Ciências.**

Banca examinadora

Prof. Alcimar Barbosa Soares, PhD Orientador (UFU)

Prof. Dr. Adriano de Oliveira Andrade (UFU)

Prof. Dr. Weber Martins (UFG)

Classificação Automática de Cardiopatias Baseada em Eletrocardiograma

Nina Maria Bueno

Texto da dissertação apresentada à Universidade Federal de Uberlândia, perante a banca de examinadores abaixo, como parte dos requisitos necessários para obtenção do título de Mestre em Ciências.

Prof. Alcimar Barbosa Soares, PhD
Orientador

Prof. Darizon Alves de Andrade, PhD
Coordenador do Curso de Pós-Graduação

“Se deres um peixe a um homem faminto, vais alimentá-lo por um dia. Se o ensinares a pescar, vais alimentá-lo por toda a vida.”

Lao-Tsé

**Aos meus pais, Maria José e Aylton;
meus filhos, Natália e Vitor;
meus irmãos, Marilisa, Mário Sérgio e Marcelo;
ao meu amado marido Hélio Rangel.**

Agradecimentos

Agradeço a DEUS pela minha existência. A cada dia vejo o quão grande é a sua Criação e por mais que estudemos e pesquisemos, estamos ainda a uma enorme distância de compreender sua perfeição.

Agradeço aos meus pais por toda a dedicação e principalmente por terem me ensinado a me esforçar e trabalhar muito para alcançar meus objetivos e colocarem os estudos de seus filhos como seu maior legado, como diria meu saudoso vovô Massilon Bueno “Nunca dê os peixes, ensina-os a pescar” (parafraseando Lao-Tsé).

Agradeço também a minha família em nome de Marilisa e Eduardo, Mário Sérgio e Márcia, Marcelo e Paula e aos seus filhos Felipe, Gabriel, Bárbara, Breno e Bruna pelo irrestrito apoio e grande compreensão nas minhas ausências. Aos meus queridos e amados filhos Natália e Vitor, pela cessão do importante tempo que a eles seria dedicado, para que eu pudesse desenvolver este trabalho.

Cito ainda os amigos da primeira turma de mestrado da Universidade Santa Cecília, em especial à Mari, que tanto me ajudaram nesta luta.

À empresa DIXAmico Saúde, pela colaboração com o trabalho, representada pelos doutores Carlos Menna, Gilberto Baroni e Cláudia Cohn, disponibilizando seus conhecimentos e acesso às informações técnicas que tanto ajudaram. Os meus sinceros agradecimentos aos queridos Luiz Camargo e Paulo Sartori por toda compreensão e apoio neste longo período. Aos amigos do NAV e aos amigos da equipe de tecnologia da DIXAmico Saúde pela torcida.

A minha amiga e irmã Luciane Merli pelo incentivo, acompanhamento e grande força.

Muito obrigada aos colegas do BIOLAB da UFU, em especial ao Fábio, Jeovane, Ailton, Adriano, Adriano Oliveira, Eduardo e todos os demais, que a todo o momento me ajudaram pacientemente.

Agradeço à Marly, mais que uma excelente secretária, foi uma grande companheira, facilitando em tudo a minha passagem pela UFU.

Aos queridos professores e orientadores por todo o compartilhamento de seu rico conhecimento, pela paciência com a minha ignorância, transformando minha vontade de aprender em realidade. Muito obrigada aos professores Luciano, Edna, Edgar, Keiji, Guardieiro, José Manuel e em especial ao Alcimar por todo o tempo de dedicação para a realização deste sonho.

Agradeço especialmente àquele que me incentivou desde a inscrição no curso, durante todo o trajeto, nos momentos em que decidi “jogar a toalha”, até a conclusão do trabalho, àquele que DEUS me presenteou como um companheiro para todas as horas, o amor da minha vida, meu marido Hélio Rangel.

Resumo

BUENO, Nina Maria. Classificação Automática de Cardiopatias Baseada no Eletrocardiograma. Uberlândia: FEELT-UFU, 2006, 104 p.

Este trabalho dedica-se ao estudo do reconhecimento e classificação de cardiopatias, diagnosticadas através do exame de eletrocardiografia, ECG. Esse exame é comumente utilizado em visitas a cardiologistas, centros de emergência, centros de terapia intensiva e exames eletivos para auxílio de diagnóstico de cardiopatias como: infarto agudo do miocárdio, bloqueios de ramos, hipertrofia e outros. O aplicativo desenvolvido para apoio ao trabalho focaliza a extração de características do sinal ECG, representado por ciclos e a aplicação destas características a uma rede neural artificial para reconhecimento das cardiopatias. Para extração das características do sinal, utilizamos o modelo matemático de previsão de comportamento de curvas, chamado de auto-regressivo, AR, onde utilizamos o passado histórico recente da curva para determinar o próximo ponto; em nosso caso, utilizamos o algoritmo dos mínimos quadrados para adequação do erro, conhecido como LMS. A rede neural de topologia *perceptron* multicamadas e com algoritmo de treinamento *backpropagation* foi escolhida para o reconhecimento dos padrões, pela sua capacidade de generalização. O método se mostrou adequado e eficiente ao objetivo proposto.

Palavras chaves: ECG – eletrocardiograma, exame não invasivo dos sinais elétricos cardíacos. Cardiopatia – Doença que acomete o coração. RNA – rede Neural Artificial. Modelo AR – modelo matemático auto-regressivo.

Abstract

BUENO, Nina Maria. . Classificação Automática de Cardiopatias Baseada no Eletrocardiograma. Uberlândia: FEELT-UFU, 2006, 104 p.

This work is dedicated to study of the recognition and classification of cardiac disease, diagnosed through the electrocardiogram – ECG. This examination is normally used in heart medical center, emergency, intensive therapy, and with complement diagnosis in heart disease as: acute myocardium infarction, bundle block branches, hypertrophy and others. The software was developed for support to the model, with focus on extraction of ECG signal characteristics, and an artificial neural network for recognition of diseases. For extraction these characteristics, we have used a auto-regressive model, AR, with the algorithm least mean square LMS, to minimize the minimum error. The neural network, with architecture multilayer *perceptron* and back propagation algorithm of training, was chosen for the recognition of the standards. The method was showed efficient.

Key words: ECG – electrocardiograph, no invasive examination of the cardiac electric signals. Cardiopathy – Heart disease. RNA – Artificial Neural Network. AR model – Auto-regressive Model.

SUMÁRIO

<u>CAPÍTULO 1 INTRODUÇÃO</u>	1
<u>1.1. OBJETIVO DO TRABALHO</u>	5
<u>1.2. ESTRUTURA DO TRABALHO</u>	5
<u>CAPÍTULO 2 ELETROCARDIOGRAFIA E CARDIOPATIAS</u>	7
<u>2.1. INTRODUÇÃO</u>	7
<u>2.2. CORAÇÃO</u>	8
<u>2.3. SISTEMA ELÉTRICO DO CORAÇÃO</u>	11
<u>2.4. PRINCÍPIOS BÁSICOS DE ELETROCARDIOGRAFIA</u>	14
<u>2.5. DERIVAÇÕES DO ECG</u>	18
<u>2.6. CARDIOPATIAS</u>	22
<u>2.6.1. Infarto Agudo do Miocárdio - IAM</u>	24
<u>2.6.2. Bloqueios</u>	30
<u>2.6.3. Hipertrofia Ventricular Cardíaca</u>	32
<u>2.6.4. Miocardite</u>	34
<u>2.6.5. Cardiomiopatia</u>	35
<u>2.7. CONCLUSÃO</u>	36
<u>CAPÍTULO 3 TÉCNICAS PARA CLASSIFICAÇÃO DE CARDIOPATIAS</u>	37
<u>3.1. INTRODUÇÃO</u>	37
<u>3.2. ESTUDOS SOBRE ANÁLISE DE CLASSIFICAÇÃO DE ECGs</u>	38

3.3. CONCLUSÃO.....	45
<u>CAPÍTULO 4 SISTEMA PROPOSTO</u>	47
4.1. INTRODUÇÃO	47
4.2. METODOLOGIA PROPOSTA.....	48
4.2.1. <i>Extração de características do sinal ECG</i>	52
4.2.2. <i>Classificação das Cardiopatias</i>	55
4.3. IMPLEMENTAÇÃO DO MODELO EM SOFTWARE.....	57
4.3.1. <i>Aplicação em C++ para Seleção dos Ciclos e Extração de Características</i>	58
4.3.2. <i>Rede Neural em Matlab 7.0.1 para Treinamento e Reconhecimento das Cardiopatias</i>	63
4.3.3. <i>Conclusão</i>	65
<u>CAPÍTULO 5 EXPERIMENTOS E ANÁLISES</u>	67
5.1. FONTE DE DADOS.....	67
5.2. CENÁRIO 1 – AMOSTRAS COM UM CICLO DO ECG	71
5.2.1. <i>Treinamento</i>	71
5.2.2. <i>Reconhecimento</i>	78
5.3. CENÁRIO 2 – AMOSTRAS COM DEZ CICLOS DE ECG	83
5.3.1. <i>Treinamento</i>	83
5.3.2. <i>Reconhecimento</i>	84
5.4. CENÁRIO 3 – AMOSTRAS COM UM CICLO DE ECG – 4 NEURÔNIOS DE SAÍDA	87
5.4.1. <i>Treinamento</i>	87
5.4.2. <i>Reconhecimento</i>	88
5.5. CONCLUSÃO.....	90
<u>CAPÍTULO 6 CONCLUSÃO E TRABALHOS FUTUROS</u>	92
6.1. CONCLUSÕES GERAIS	92
6.2. TRABALHOS FUTUROS	96
<u>REFERÊNCIAS BIBLIOGRÁFICAS</u>	98

Lista de Figuras

<u>Figura 1.1 – Estatística de Projeção de Causa Mortis Mundial por Região para os próximos 10 anos – fonte Organização Mundial de Saúde - OMS.</u>	2
<u>Figura 1.2 – Galvanômetro capilar de Lippmann utilizado por Waller em 1887, para registrar o primeiro eletrocardiograma humano [BINTZ, Jacques; et al. 1997. 1].</u>	3
<u>Figura 1.3 – Galvanômetro de fio onde foi registrado o primeiro eletrocardiograma humano em 1902, onde temos o próprio Einthoven no experimento [BINTZ, Jacques; et al. 1997. 2].</u>	4
<u>Figura 2.1 - Anatomia Cardíaca, com a representação das câmaras, valvas e principais artérias e veias modificada [MANDARIM, Carlos Alberto.1990.].</u>	8
<u>Figura 2.2 – Esquema Representativo do Sistema Circulatório Cardíaco, em azul o circuito da circulação venosa e em vermelho a arterial, modificado [STANTON, Kathleen M. 2005.].</u>	11
<u>Figura 2.3 – Esquema gráfico do Sistema Condução Cardíaca (modificada) [Universal Medical Center. 2005.].</u>	13
<u>Figura 2.4 – Foto com a aplicação dos eletrodos para captação dos sinais elétricos cardíacos pelo aparelho de ECG [HEALTH, Heart. 2000.].</u>	14
<u>Figura 2.5 – Representação Gráfica do Ciclo Cardíaco composto de cada onda presente no ECG e os intervalos entre elas, chamados segmentos, modificada [EKG Measurements. 2004.].</u>	17
<u>Figura 2.6 – Derivações Bipolares ou dos Membros, derivações simples de braço direito, esquerdo e pé e sua representação no ECG, (parcialmente) [Les dérivations d' un électrocardiogramme. 2000.].</u>	19
<u>Figura 2.7 – Derivações Bipolares ou dos Membros, derivações compostas e aumentadas, aVR, aVL e aVF e sua representação no ECG.(parcialmente)[Les dérivations d' un électrocardiogramme. 2000.].</u>	20
<u>Figura 2.8A - Posição dos eletrodos para derivações unipolares ou precordiais normais. No esquema temos as derivações identificadas de V1 a V6 modificada [FELDMAN, Henry. 2006.].</u>	21
<u>Figura 2.8B – Representação gráfica no ECG, para derivações unipolares ou precordiais normais. De V1 a V6.</u>	22
<u>Figura 2.9 – Ilustração da alteração do músculo cardíaco acometido por um infarto agudo do miocárdio, modificada [LEE, Dennis. Illustration Heart Attack].</u>	24

<u>Figura 2.10 – Exemplo de IAM Inferior com o complexo QRS espessado. Derivação DII, com a característica da onda T negativa. [software Classificador de Cardiopatias].</u>	27
<u>Figura 2.11 – Exemplo de IAM Posterior apresentando infra-desnívelamento do segmento ST na derivação V3. [software Classificador de Cardiopatias].</u>	27
<u>Figura 2.12 – Exemplo de IAM Antero-Lateral com onda Q alargada na derivação DI. [software Classificador de Cardiopatias].</u>	28
<u>Figura 2.13 – Exemplo de IAM Antero-Septal apresentando elevação do segmento S-T. [software Classificador de Cardiopatias].</u>	28
<u>Figura 2.14 – Exemplo de IAM Lateral, onda Q com supra-desnívelamento. [software Classificador de Cardiopatias].</u>	29
<u>Figura 2.15 – Exemplo de IAM Anterior ondas T com supra-desnívelamento em V1. [software Classificador de Cardiopatias].</u>	29
<u>Figura 2.16 – Exemplo de ECG – Bloqueio de Ramo apresentando ondas RsR identificando a dificuldade de passagem do sinal elétrico pelo bloqueio de ramo direito. [software Classificador de Cardiopatias].</u>	32
<u>Figura 2.17 – Exemplo de ECG – Hipertrofia Ventricular Esquerda com ondas S de intensidade acima do normal, na derivação V1. [software Classificador de Cardiopatias].</u>	34
<u>Figura 2.18 – Exemplo de ECG – Miocardite apresentando ondas R de grande amplitude. [software Classificador de Cardiopatias].</u>	35
<u>Figura 2.19 – Exemplo de ECG – Cardiomiopatia com ondas T de baixa voltagem [software Classificador de Cardiopatias].</u>	36
<u>Figura 3.1 Gráfico com os coeficientes resultantes do modelo AR, extraídos do sinal EMG. [ANDRADE, Adriano de Oliveira, 2000.] [SOARES, Alcimar Barbosa; et al. 2003.].</u>	42
<u>Figura 4.1 – Esquema Gráfico do Sistema Proposto de Classificação de Cardiopatias através do ECG.</u>	48
<u>Figura 4.2 – Diagrama de blocos da estratégia adotada para localização de ciclos cardíacos. [RANGEL, Hélio, 2006.].</u>	49
<u>Figura 4.3 – Fluxo da Fase de Treinamento da RNA para Classificação de Cardiopatias.</u>	50
<u>Figura 4.4 – Fluxo da Fase de Reconhecimento de Cardiopatias.</u>	51
<u>Figura 4.5 – Fluxograma do modelo auto-regressivo, com o LMS customizado, utilizado para a extração das características do ciclo de ECG.</u>	54
<u>Figura 4.6 – Representação gráfica da uma das topologias utilizadas da Rede Neural Artificial (Cenário 3).</u>	56
<u>Figura 4.7 – Representação gráfica do modelo em software, com as duas técnicas escolhidas para o desenvolvimento do modelo, C++ e Matlab.</u>	58
<u>Figura 4.8 – Diagrama de Funcionalidades do Aplicativo Classificador de Cardiopatias.</u>	60
<u>Figura 4.9 – Tela Principal do Aplicativo Classificador de Cardiopatias, com os parâmetros, gráficos e ações para a geração da entrada de dados da RNA de identificação dos sinais de ECG.</u>	61
<u>Figura 4.10 – Organização dos arquivos contendo os ciclos de entrada para o sistema de classificação.</u>	64
<u>Figura 4.11 – Exemplo dos arquivos de dados e alvos gerados pelo aplicativo Classificador de Cardiopatias, e que serão utilizados pela Rede Neural para treinamento.</u>	65

<u>Figura 5.1 – Corte da Interface do software Classificador de Cardiopatias – área de seleção de parâmetros e amostras a ter suas características extraídas pelo modelo AR customizado, para treinamento da rede.</u>	73
<u>Figura 5.2 – Gráficos com o traçado dos ciclos de cada uma das derivações em “Derivações do ECG Selecionado” e a curva original e a gerada pela aplicação dos coeficientes calculados em “AR x Derivação Selecionada”.</u>	74
<u>Figura 5.3 – Gráfico em zoom do registro dos coeficientes AR sobre a curva do ciclo original, em vermelho o resultado do cálculo do modelo AR e em azul a curva original de ECG.</u>	74
<u>Figura 5.4 – Interface com o experimento de um ciclo por amostra.</u>	75
<u>Figura 5.5 – Interface do Matlab – Ilustração do Resultado do Treinamento de 10 amostras do arquivo de características do ECG, cardiopatia IAM.</u>	77
<u>Figura 5.6 – Interface do Matlab – Resultado da validação da massa de treinamento com 1 ciclo e 10 coeficientes.</u>	78
<u>Figura 5.7 – Interface do aplicativo – Seleção de uma amostra, com um ciclo para reconhecimento pela rede neural, com dez coeficientes.</u>	80
<u>Figura 5.8 – Interface Matlab – Reconhecimento de amostras aplicadas à rede neural após o treinamento, amostra com um ciclo e 10 coeficientes.</u>	81
<u>Figura 5.9 – Corte da Interface – área de seleção de parâmetros e gráficos de derivações para opção com dez ciclos.</u>	83
<u>Figura 5.10 – Gráfico em zoom do registro dos coeficientes AR sobre a curva do ciclo original, em vermelho o resultado do cálculo do modelo AR e em azul a curva original de ECG.</u>	84
<u>Figura 5.11 – Interface do aplicativo – Seleção de uma amostra, com dez ciclos para reconhecimento pela rede neural, com dez coeficientes.</u>	85
<u>Figura 5.12 – Interface Matlab – Reconhecimento de amostras aplicadas à rede neural após o treinamento, amostra com dez ciclo e dez coeficientes.</u>	86

Lista de Tabelas

<u>Tabela 3.1 – Tabela com o número de amostras aplicadas à solução da pesquisa e seu percentual de reconhecimento com a utilização do modelo AR para extração de características e o modelo GLM para reconhecimento [GE, Dingfei; et al. 2002.].</u>	45
<u>Tabela 5.1 – Estatística de cardiopatias da base de dados por número de amostras e número de pacientes, [OEFF, Michael. 2005.].</u>	69
<u>Tabela 5.2 – Resultados de validação e reconhecimento dos sinais ECG pela rede neural, cenário de 1 ciclo por amostra selecionada, com três ordens diferentes de análise.</u>	82
<u>Tabela 5.3 – Resultados de validação e reconhecimento dos sinais ECG pela rede neural, cenário de dez ciclos por amostra selecionada.</u>	87
<u>Tabela 5.4 – Resultados de validação e reconhecimento dos sinais ECG pela rede neural, cenário de dez ciclos por amostra selecionada.</u>	90

Capítulo 1

Introdução

O coração humano é uma máquina maravilhosa, ele realiza o bombeamento para que todo o organismo possa receber o sangue necessário ao seu funcionamento. Para a manutenção do suprimento sangüíneo em todo o corpo, temos como responsável o sistema circulatório. A função do coração é manter esse fluxo, contudo está sujeito a diversas cardiopatias, como infarto do miocárdio, hipertrofia e bloqueios, entre outras.

A incidência de doenças cardiovasculares é uma das principais causas de morte em todo o mundo. O Infarto Agudo do Miocárdio (IAM) está entre as cardiopatias de maior risco de mortalidade e outras cardiopatias (como arritmias, hipertrofia cardíaca e bloqueios), atingem grande parte da população mundial.

Na Figura 1.1, apresentamos a projeção de “*Causas Mortis*” até o ano de 2015, relatada pela Organização Mundial de Saúde (OMS), onde os índices atribuídos a cardiopatias são alarmantes nas regiões desenvolvidas e nas regiões subdesenvolvidas, perdendo apenas para as causas relacionadas à mortalidade infantil, agravados pela fome e doenças epidêmicas. Torna-se imperativa a busca de

novos métodos de diagnósticos precoces e tratamentos mais efetivos, bem como a prevenção de doenças ligadas ao coração.




Figura 1.1 – Estatística de Projeção de Causa Mortis Mundial por Região para os próximos 10 anos – fonte Organização Mundial de Saúde - OMS.

Para diagnosticar cardiopatias, há diversos métodos e um dos principais é o eletrocardiograma (ECG). O ECG é o registro do percurso do impulso elétrico cardíaco, cuja forma mais comum de captação é através de eletrodos colocados sobre a pele do paciente, em pontos específicos do corpo, que são ligados a um equipamento chamado eletrocardiógrafo. A interpretação desses registros permite ao profissional de saúde o diagnóstico e avaliação de cardiopatias.

A história do ECG iniciou no final do século XIX. O fisiologista francês, Augustus Desiré Waller, membro da “*Royal Society*” de Londres, diretor do Laboratório de Fisiologia da Universidade de Londres, realizou pesquisas sobre eletrocardiografia no *National Heart Hospital*, onde, em 1887, registrou pela primeira

vez o potencial elétrico cardíaco de um ser humano, empregando o galvanômetro capilar de *Lippman* (Figura 1.2.). Augustus Waller batizou estes registros gráficos de Eletrocardiograma [JENKINS, Dean. 2002.].



Figura 1.2 – Galvanômetro capilar de Lippmann utilizado por Waller em 1887, para registrar o primeiro eletrocardiograma humano [BINTZ, Jacques; et al. 1997. 1].

O fisiólogo inglês Willem Einthoven, nascido em Java (atual Indonésia), foi criado na Holanda onde estudou Medicina na Universidade de Utrecht e, em uma reunião da Associação Médica Holandesa, introduziu o termo eletrocardiograma com o seu trabalho “Novos Métodos de Investigação Clínica”. Em 1902, Einthoven publicou o primeiro eletrocardiograma registrado em um galvanômetro por fio. A Figura 1.3 registra Einthoven numa experiência com o galvanômetro. Em 1920, em Nova York, Harold Pardee, fisiologista americano formado na Universidade de Columbia, publica o primeiro eletrocardiograma de um infarto agudo do miocárdio em um ser humano [JENKINS, Dean. 2002.].




Figura 1.3 – Galvanômetro de fio onde foi registrado o primeiro eletrocardiograma humano em 1902, onde temos o próprio Einthoven no experimento [BINTZ, Jacques; et al. 1997. 2].

As técnicas de captação dos sinais elétricos cardíacos foram evoluindo e a análise do ECG com até 12 derivações é hoje realizada por cardiologistas do mundo todo. O ECG é classificado como um exame básico pela Agência Nacional de Saúde Suplementar (ANS) e ele pode ser realizado em consultórios, atendimentos emergenciais, hospitais, em unidades de tratamento intensivo para monitoramento do paciente e até à distância, onde os sinais dos pacientes podem ser enviados para o médico através da rede telefônica ou via internet.

Ao completar cem anos, o eletrocardiograma continua sendo um exame absolutamente necessário e fundamental no diagnóstico de doenças cardiovasculares. A identificação rápida da cardiopatia através da análise do ECG é praticada por médicos generalistas e cardiologistas em todo o mundo. Apesar de ser um exame rápido, é preciso uma análise visual do profissional e depende de sua interpretação para o diagnóstico correto. A automatização do diagnóstico ainda não

é uma prática comum aos equipamentos e programas disponíveis no mercado, mas poderá ser um auxílio importante no diagnóstico, conforme ilustrado no trabalho de Seven-Erik Olsson e Mattias Ohlsson [OHLSSON, E; et. al. 2002.]. Neste trabalho de pesquisa os autores reportam que o reconhecimento automático foi 12% mais eficiente do que os dois profissionais experientes participantes do estudo.

1.1. Objetivo do Trabalho

Este trabalho objetiva o desenvolvimento de uma proposta de metodologia para identificação e classificação de cardiopatias através da análise de sinais ECG digitais. Para atingir tal objetivo, a pesquisa teve como metas:

- Investigação do estado da arte das principais técnicas aplicadas para identificação das cardiopatias através da análise do eletrocardiograma;
- Proposta de um modelo para identificação e classificação de cardiopatias através de um ciclo de ECG;
- Implementação de um modelo em *software*;
- Avaliação do desempenho através da análise dos sinais ECG coletados do banco de dados Physionet [OEFF, Michael. 2005.] .

1.2. Estrutura do Trabalho

No Capítulo 2 será apresentado o tema coração, seu sistema elétrico e as cardiopatias que podem ser diagnosticadas a partir dos sinais elétricos cardíacos com a utilização do ECG. No Capítulo 3, trataremos a metodologia tipicamente utilizada para classificação dos sinais de ECG patológicos e normais. No Capítulo 4,

será apresentada a solução desenvolvida e, no Capítulo 5, apresentaremos os resultados dos experimentos realizados aplicando a solução sobre a base de dados de sinais eletrocardiográficos escolhida (Physionet/PTB [OEFF, Michael. 2005.]). No Capítulo 6, estão descritas as conclusões sobre a aplicação e possíveis trabalhos futuros complementares.

Capítulo 2

Eletrocardiografia e Cardiopatias

O objetivo deste capítulo é apresentar um breve estudo sobre o coração, mostrando sua anatomia, o sistema elétrico cardíaco e o sistema circulatório, bem como enumerar as cardiopatias ligadas a distúrbios elétricos cardíacos e de que forma o ECG pode auxiliar no diagnóstico das mesmas.

2.1. Introdução

Para iniciar os estudos sobre eletrocardiografia, é necessário aprimorar o conhecimento sobre o coração, um órgão muscular localizado logo atrás do esterno, osso anterior do tórax. Sua proporção assemelha-se ao tamanho do punho fechado de um adulto e sua principal função é realizar o bombeamento do sangue pelo corpo humano.

2.2. Coração

A anatomia do coração, em detalhes na Figura 2.1, é composta por dois átrios e dois ventrículos separados por um septo e duas válvulas atrioventriculares. A válvula tricúspide separa o átrio direito do ventrículo direito e a válvula mitral é responsável pela separação do átrio esquerdo e do ventrículo esquerdo. O “coração direito” (átrio e ventrículo direito) comunica-se com “coração esquerdo” (átrio e ventrículo esquerdo), via sistema vascular pulmonar contendo a artéria pulmonar e suas ramificações, os capilares pulmonares e as veias pulmonares que terminam diretamente no átrio esquerdo. O sistema vascular sistêmico via aorta faz a comunicação do ‘coração esquerdo’ com o ‘coração direito’. Na Figura 2.1 temos a ilustração gráfica da anatomia cardíaca com as câmaras, valvas e principais veias e artérias [MANDARIM, Carlos Alberto.1990.].




Figura 2.1 - Anatomia Cardíaca, com a representação das câmaras, valvas e principais artérias e veias modificada [MANDARIM, Carlos Alberto.1990.].

Como todas as células de nosso corpo necessitam de oxigênio para viver, o nosso sistema circulatório é quem cumpre o papel de levar esse oxigênio para todo o corpo. O coração é o principal órgão desse sistema e sua principal função é bombear o sangue através do corpo. Cada lado do coração é composto por duas câmaras, um *átrio* e um *ventrículo*. As principais “bombas” do coração são os ventrículos, pois é através deles que o sangue é enviado para fora do coração [MANDARIM, Carlos Alberto.1990.] [SILVA, Mauricio R. 2000.].

A Figura 2.2 ilustra graficamente o sistema circulatório do corpo humano: o sangue sai do coração para o corpo através do ventrículo esquerdo, que é a maior e mais forte das câmaras do coração. O ventrículo esquerdo com seus músculos espessos necessita executar contrações poderosas para bombear o sangue para todas as partes do corpo.

O sangue deixa o ventrículo esquerdo passando pela valva aórtica que permite o sangue fluir à aorta ascendente. A aorta é a principal artéria que alimenta de sangue o corpo inteiro. Artérias são as vias por onde o sangue oxigenado, conhecido como ‘sangue rico’, é enviado, elas se dividem em ramos cada vez menores, até os capilares sistêmicos, que são vasos, extremamente finos, através dos quais o oxigênio segue para os tecidos.

Após a retirada do oxigênio e o recebimento do gás carbônico que se encontram nos tecidos, os capilares levam o sangue, chamado sangue venoso ou sangue “sujo”, até as veias, que transportam o sangue com baixa quantidade de oxigênio e alto teor de gás carbônico de volta ao coração. O átrio direito recebe o sangue venoso, enchendo-se à medida que seus músculos relaxam para que o sangue venoso entre, após o retorno de todo o corpo. O sangue segue do átrio

direito para a câmara muscular chamada de ventrículo direito, através da valva tricúspide que regula o fluxo do sangue entre as duas câmaras. O ventrículo direito é uma das duas principais bombas do coração. Sua função é enviar o sangue aos pulmões, utilizando a valva pulmonar que se abre para permitir ao sangue fluir do ventrículo direito aos pulmões, onde o mesmo trocará o gás carbônico pelo oxigênio [BOYLER, JOSEPH III. 1998.] [DOUGLAS, Carlos Roberto. 2000.] [MANDARIM, Carlos Alberto.1990.] [SILVA, Mauricio R. 2000.].

Após o sangue ser oxigenado ele retorna ao coração, esse sangue rico em oxigênio chega ao coração por veias que vêm dos pulmões, chamadas veias pulmonares. O átrio esquerdo recebe o sangue que chega dos pulmões. Do átrio esquerdo segue para o ventrículo esquerdo, passando pela valva mitral que regula o fluxo do sangue entre as duas câmaras. Do ventrículo esquerdo o sangue segue para o corpo, reiniciando todo o processo.

A circulação do sangue ocorre pela geração de diferença de pressões entre dois ou mais pontos do sistema cardiovascular [DOUGLAS, Carlos Roberto. 2000.] [MENNA, Carlos. 2005.] [NEVILLER, Conway.1987.] [SILVA, Mauricio R. 2000.].




Figura 2.2 – Esquema Representativo do Sistema Circulatório Cardíaco, em azul o circuito da circulação venosa e em vermelho a arterial, modificado [STANTON, Kathleen M. 2005.] .

Para que este fluxo funcione continuamente, o coração depende dos impulsos que regulam as contrações cardíacas. Esses impulsos são coordenados pelo sistema elétrico cardíaco, que está descrito a seguir.

2.3. Sistema Elétrico do Coração

Para que o coração possa executar ritmicamente o bombeamento do sangue, temos o sistema de condução cardíaco que regula as batidas do coração. O sistema consiste em uma cadeia de células musculares especializadas que formam um complexo elétrico independente no interior da musculatura cardíaca. Essas células são conectadas por feixes que transmitem impulsos elétricos. Dos três tipos de

células musculares que formam o músculo cardíaco, duas possuem a propriedade de contração, sendo elas, as células atriais e as ventriculares e há o terceiro tipo de célula, as células condutoras que são as fibras especializadas condutoras do estímulo por todo o coração [MENNA, Carlos. 2005.] [NEVILLER, Conway.1987.] [SILVA, Mauricio R. 2000.].

O sistema de condução cardíaco, representado graficamente na Figura 2.3, tem como ponto de partida o impulso gerado pelo nodo sinusal, NSA que é uma estrutura atrial direita. O estímulo é levado do nodo sinusal ao nodo atrioventricular, NAV, pelos tratos internodais (anterior, médio e posterior) e para o átrio direito através do feixe de *Bachmann*. Quando o impulso chega ao nodo atrioventricular ele sofre um atraso na propagação para assegurar uma ativação coordenada de todo o ventrículo, em seguida o estímulo é levado ao feixe de His que cursa pelo trígono fibroso direito para alcançar o ápice do septo interventricular. O ramo de condução direito cursa ao longo das bandas septal e moderadora. No lado esquerdo do coração temos o feixe de condução esquerdo formado por uma rede de fibras ao longo da superfície septal, chamadas fibras de *Purkinje*, no momento que esse impulso chega à base dos ventrículos a contração dos mesmos é realizada, de baixo para cima, dessa maneira a contração dos ventrículos expulsa o volume de sangue suficiente para seguir por todo o sistema circulatório [BOYLER, JOSEPH III. 1998.] [MANDARIM, Carlos Alberto.1990.] [SILVA, Mauricio R. 2000.].




Figura 2.3 – Esquema gráfico do Sistema Condução Cardíaca (modificada) [Universal Medical Center. 2005.].

As células miocárdicas podem ser compostas de fibras lentas ou rápidas dependendo da forma e da velocidade de condução dos impulsos elétricos. As fibras lentas, normalmente, estão presentes somente nos nodos SA e AV. As fibras miocárdicas normais atriais e ventriculares e os tecidos especializados de condução do coração são fibras rápidas [BOYLER, JOSEPH III. 1998.]. A fibra cardíaca apresenta quatro propriedades: excitabilidade que permite às células cardíacas responderem ao estímulo; a contratilidade; a ritmicidade que está presente nas células do NSA que gera o impulso e funciona como marca-passo, podendo também o NAV ter essa propriedade e a condutibilidade, que está presente em todo o tecido cardíaco, no feixe de His, nas fibras de *Purkinje* e nos ramos direito e esquerdo que

possuem essa propriedade bem desenvolvida [BOYLER, JOSEPH III. 1998.] [MANDARIM, Carlos Alberto.1990.].

2.4. Princípios básicos de eletrocardiografia

Para que as fibras cardíacas se contraíam, é necessário que o estímulo as percorra. Este estímulo, nas fibras, é chamado de potencial de ação. Estes se propagam pelas fibras podendo ser detectados na superfície da pele por eletrodos [GUIMARÃES, Jorge; et al. 2003.]. O ECG representa a soma dos potenciais de ação do coração que emanam sobre a superfície do corpo. Na Figura 2.4 temos ilustrada a captação dos sinais elétricos através dos eletrodos colocados sobre a pele do paciente. Cada um desses eletrodos, ou a combinação deles, indica uma derivação de análise do ECG [BOYLER, JOSEPH III. 1998.] [MANDARIM, Carlos Alberto.1990.].



Figura 2.4 – Foto com a aplicação dos eletrodos para captação dos sinais elétricos cardíacos pelo aparelho de ECG [HEALTH, Heart. 2000.].

O padrão de um ECG é representado por uma série de ondulações que indicam o potencial elétrico dos tecidos cardíacos. A Figura 2.5 apresenta o esquema gráfico de um ECG, com suas ondas características e também as informações que podem ser extraídas para auxílio do diagnóstico. Um ECG típico é composto pelas ondas P, QRS, T e seus segmentos PQ e ST e eventualmente, podemos observar o aparecimento de mais uma onda, denominada U [DECCACHE, Waldemar; et al. 1993.] [HALLAKE, José. 1994.].

Na Figura 2.5 temos a representação gráfica de um ECG onde, através desse registro podemos acompanhar o curso do impulso elétrico no coração. A primeira onda registrada é a onda P, que mostra o impulso propagando-se do NSA em direção aos átrios representando eletricamente a despolarização atrial, ou seja, a contração dos átrios. A seguir temos, normalmente, uma linha isoeletrica, que representa o atraso do impulso elétrico no nodo AV, chamado sPR, que é o segmento entre a onda P e o início da onda R. A estimulação elétrica dos ventrículos é registrada no ECG por três ondas, normalmente apiculadas, chamado de Complexo QRS, a ação física da contração ventricular dura, na verdade, mais tempo que o complexo QRS, mas considera-se o complexo QRS como representante da contração ventricular (despolarização ventricular). A onda Q é a primeira deflexão (↓) do complexo QRS, ocorrendo no início do complexo QRS e é seguida de uma onda com deflexão positiva (↑) chamada onda R, que, por sua vez, é seguida de uma onda com deflexão negativa (↓) chamada onda S. A maioria das cardiopatias ligadas ao sistema elétrico cardíaco reflete alterações no complexo QRS, como bloqueio ventricular, hipertrofia e infarto. A repolarização dos átrios é tão pequena que se

perde dentro do complexo QRS, não sendo, portanto, frequentemente observada, ou registrada no ECG [BITTENCOURT, Murilo Guérios. 2001.] [HALLAKE, José. 1994.] [LINDER, Udo K.; et al. 1999.] [MENNA, Carlos. 2005.].

O ponto J, apresentado na Figura 2.5 é a junção entre o final do complexo QRS e o início do segmento ST. Após o complexo QRS existe uma pausa (fase inicial da repolarização ventricular) que é chamada segmento ST, representado por uma linha com pouca ou nenhuma inclinação entre QRS (ponto J) e a onda T.

A repolarização ventricular é representada pela onda T, que é uma onda arredondada e assimétrica, com fase ascendente mais lenta que a descendente. Sua amplitude normal é menor que a amplitude do complexo QRS. Quando tem a forma pontiaguda e simétrica, há suspeitas de isquemia miocárdica e nos casos em que sua base é estreita, e ampla, ultrapassando o comprimento de QRS, sugere hiperpotassemia. O intervalo S-T é o tempo medido entre o início do complexo QRS ao final da onda T. Corresponde à sístole elétrica total ventricular. O intervalo QT varia inversamente proporcional em relação à frequência cardíaca, sendo menor em FC mais rápida e maior na FC mais lenta.

Podemos ter a identificação da onda U ocasionalmente. Ela está localizada logo após a onda T, tem forma arredondada, de curta duração e pequena amplitude, ocorrendo devido à contração prematura do ventrículo, ocasionado por um pulso do NAV de pequena dimensão, independente da contração registrada pela onda R [HALLAKE, José. 1994.].

A Frequência Cardíaca (FC), é calculada com base no tempo da distância entre os dois complexos QRS. Dentro da normalidade a FC situa-se entre 60bpm e 100 bpm. Temos como frequência cardíaca fora da normalidade a bradicardia,

quando o batimento está abaixo de 60bpm e taquicardia quando temos o batimento acima de 100 bpm. Esta informação fornecida pelo ECG é de grande valor para o diagnóstico.

O Ritmo Cardíaco (RC), é avaliado pela medida dos intervalos entre os ciclos cardíacos, normalmente aferidos entre os ápices das ondas R, que chamamos de intervalo R-R. O ritmo cardíaco é considerado normal quando há regularidade e constância nos intervalos e quando há irregularidades nos intervalos são chamadas arritmias [BITTENCOURT, Murilo Guérios. 2001.] [DECCACHE, Waldemar; et al. 1993.] [LINDER, Udo K.; et al. 1999.] [HALLAKE, José. 1994.] [MENNA, Carlos. 2005.].




Figura 2.5 – Representação Gráfica do Ciclo Cardíaco composto de cada onda presente no ECG e os intervalos entre elas, chamados segmentos, modificada [EKG Measurements. 2004.].

2.5. Derivações do ECG

Denomina-se derivação no ECG o registro obtido por um eletrodo posicionado em qualquer ponto do corpo. Normalmente os eletrodos são colocados na superfície do tórax e dos membros. Há dois tipos de derivações, as unipolares e as bipolares. Uma derivação é considerada unipolar quando um eletrodo explorador faz o registro da atividade elétrica cardíaca (ex : V1 a V6 e aVR, aVL, aVF). As derivações aVR, aVL e aVF são denominadas derivações unipolares aumentadas dos membros. Derivação bipolar é aquela onde o registro se faz através de dois eletrodos situados à mesma distância do coração (ex : DI, DII e DIII) [BITTENCOURT, Murilo Guérios. 2001.] [DECCACHE, Waldemar; et al. 1993.] [HALLAKE, José. 1994.].

O ECG padrão é composto de seis derivações precordiais e de seis derivações periféricas. As derivações periféricas (ou dos membros) são: DI, DII, DIII, aVR, aVL, aVF e as derivações unipolares ou precordiais são: V1, V2, V3, V4, V5 e V6. Podemos também ter derivações precordiais adicionais V7, V8, quando houver necessidade, a critério do profissional que estiver realizando e analisando o exame [HALLAKE, José. 1994.] [LINDER, Udo K.; et al. 1999.] [MENNA, Carlos. 2005.].

Derivações Bipolares ou dos Membros

Para obtenção das derivações dos membros (periféricos), colocam-se os eletrodos sobre os braços direito e esquerdo e sobre a perna esquerda (Figura 2.6), o que formará um triângulo imaginário descrito por Einthoven em 1912, [JENKINS, Dean. 2002.]. Os eletrodos ligam-se aos pólos elétricos correspondentes. O ECG registra a diferença de potencial entre os dois pontos, que é interpretada no traçado

como uma onda, podendo ser ela positiva ou negativa e no caso da diferença de potencial tender a zero, o registro se manterá próximo à linha base do ECG.

Cada um dos lados do triângulo, formado pelos eletrodos, representa uma derivação (DI, DII e DIII), usando-se diferentes pares de eletrodos para cada derivação. Quando consideramos um par de eletrodos, um é positivo e outro negativo, a derivação DI é horizontal e o explorador do braço esquerdo é positivo enquanto o do braço direito é negativo. Na derivação DII, o explorador do braço esquerdo é negativo e o da perna esquerda é positivo [BITTENCOURT, Murilo Guérios. 2001.] [HALLAKE, José. 1994.] [MENNA, Carlos. 2005.].




Figura 2.6 – Derivações Bipolares ou dos Membros, derivações simples de braço direito, esquerdo e pé e sua representação no ECG, (parcialmente) [Les dérivationes d' un électrocardiogramme. 2000.].

Em 1934 Frank Wilson definiu uma nova combinação de derivações que foram chamadas de Vf, Vr e VL. Essas derivações apresentam uma potência de

sinal muito baixa, por este motivo, em 1942, Emanuel Goldberger incrementa em 50% a potência dessas derivações chamando-as de derivações aVL, aVr e aVF, como vemos na Figura 2.7, para obter um traçado da mesma magnitude das derivações DI, DII e DIII, onde o “a” significa aumentada [DECCACHE, Waldemar; et al. 1993.] .





Figura 2.7 – Derivações Bipolares ou dos Membros, derivações compostas e aumentadas, aVR, aVL e aVF e sua representação no ECG.(parcialmente)[Les dérivations d' un électrocardiogramme. 2000.].

A mesma atividade cardíaca é registrada em cada derivação. As ondas parecem diferentes nas diversas derivações porque esta atividade elétrica é registrada em posições diferentes, conforme verificamos nas Figuras 2.6 e 2.7. A atividade elétrica nunca muda, mas os pares de eletrodos são diferentes para cada derivação e, desse modo, o traçado se modifica ligeiramente a cada derivação quando alteramos o ângulo do registro da atividade cardíaca [DECCACHE, Waldemar; et al. 1993.] [MENNA, Carlos. 2005.].

Derivações Unipolares ou Precordiais

Temos, além das derivações bipolares, as seis derivações unipolares ou precordiais e para obtê-las coloca-se um eletrodo positivo em seis diferentes posições ao redor do tórax. Na Figura 2.8A temos as derivações precordiais que são numeradas de V1 a V6 e se movem sucessivamente, do lado direito para o lado esquerdo do tórax do paciente. As derivações precordiais se projetam do nodo AV em direção ao dorso do paciente que é o pólo negativo de cada derivação torácica.

O traçado do ECG de V1 a V6 mostra uma mudança gradual em todas as ondas, à medida que a posição de cada derivação varia. A Figura 2.8A mostra a localização dos eletrodos, nas derivações precordiais e na Figura 2.8B, temos o traçado do ECG e suas variações de uma derivação para outra [BITTENCOURT, Murilo Guérios. 2001.] [SILVA, Mauricio R. 2000.].



- V1 → quarto espaço intercostal à direita do esterno
- V2 → quarto espaço intercostal à esquerda do esterno
- V3 → entre V2 e V4
- V4 → quinto espaço intercostal na linha hemiclavicular
- V5 → quinto espaço intercostal na linha axilar superior
- V6 → quinto espaço intercostal na linha axilar média

Figura 2.8A - Posição dos eletrodos para derivações unipolares ou precordiais normais. No esquema temos as derivações identificadas de V1 a V6 modificada [FELDMAN, Henry. 2006.].




Figura 2.8B – Representação gráfica no ECG, para derivações unipolares ou precordiais normais. De V1 a V6.

2.6. Cardiopatias

As cardiopatias são cardiopatias causadas por algum tipo de débito cardíaco. O débito cardíaco ou volume de débito cardíaco pode ser definido como o volume de sangue expulso pelo ventrículo, na unidade de tempo, ou seja, em um minuto.

As cardiopatias estão agrupadas em quatro tipos, segundo o tipo de mecanismo de ação:

- Lesão miocárdica: onde temos a função cardíaca comprometida baseada na alteração do músculo cardíaco como miocardites, doença de Chagas, difteria, infarto do miocárdio ou na miocardiopatia por falta de irrigação do músculo cardíaco, como no exemplo ilustrado na Figura 2.9;

- Cardiopatia por excesso de volume: por excessiva pressão de apoio de pré-carga. Nestes casos, o coração, apresenta uma falha, porque recebe um volume diastólico final exagerado e não pode transformar em débito cardíaco, ocorrendo na hipervolemia da gravidez, hipertireoidismo ou também quando há sobrecargas de algumas câmaras cardíacas;
- Cardiopatia por sobrecarga de pressão: ou por excessiva pressão de apoio de pós-carga, onde o coração torna-se insuficiente para bombear o volume cardíaco contra uma alta resistência, determinada pela excessiva pressão pós-carga, ocorrendo na presença de hipertensão arterial, estenose aórtica e na estenose mitral;
- Cardiopatia hipodiastólica: onde o volume diastólico está limitado por causa de uma pericardite constrictiva, que impede a distensão da parede ventricular durante a diástole.




Figura 2.9 – Ilustração da alteração do músculo cardíaco acometido por um infarto agudo do miocárdio, modificada [LEE, Dennis. *Illustration Heart Attack*].

Discorreremos a seguir sobre algumas das mais importantes Cardiopatias, onde o ECG é utilizado para o diagnóstico [BOYLER, JOSEPH III. 1998.] [DOUGLAS, Carlos Roberto. 2000.] [MANDARIM, Carlos Alberto.1990.].

2.6.1. Infarto Agudo do Miocárdio - IAM

O termo Infarto Agudo do Miocárdio, IAM, significa a morte das células cardíacas – cardiomiócitos, causada por isquemia prolongada. Normalmente essa isquemia (falta de suprimento sanguíneo) é causada por trombose (obstrução

causada pela presença de trombos) e/ou vasoespasmo sobre a placa arteroesclerótica [RIBEIRO, Antonio Luiz Pinho. 2002.].

A evolução ocorre em áreas com isquemia, seguida de lesão e por fim a necrose da área afetada, sendo que as duas primeiras alterações podem ser reversíveis, mas no processo de necrose os danos são definitivos.

Para a Organização Mundial de Saúde o infarto agudo do miocárdio será diagnosticado se o paciente apresentar duas das alterações abaixo:

- História típica de dor precordial;
- Alterações eletrocardiográficas;
- Elevação das enzimas cardíacas.

O quadro clínico do paciente enfartado apresenta: dores precordiais, retroesternais, constrictivas, não pleuríticas, com duração superior a 30 minutos, irradiada para ombros ou membros inferiores e não aliviada pelo repouso ou com uso de nitratos. A dor pode ser acompanhada pelos seguintes sintomas: náuseas, vômitos, sudorese e fraqueza muscular generalizada.

Os sintomas do infarto agudo do miocárdio podem não ser claros em até 12% dos pacientes ou se apresentar com quadros atípicos de dor ou desconforto em braços, dorso, mandíbula ou ter como sintoma básico: síncope, palpitações, ortopnéia ou agravamento da insuficiência cardíaca.

O exame eletrocardiográfico permite a identificação da topografia do IAM, sua extensão e a probabilidade de lesão obstrutiva nas demais artérias. No acompanhamento do paciente pós IAM, os exames eletrocardiográficos são muito

importantes para avaliação da cicatrização da lesão e sua evolução [MANDARIM, Carlos Alberto.1990.] [SILVA, Mauricio R. 2000.].

Quando apenas um único eletrocardiograma é realizado, o exame eletrocardiográfico pode falhar no diagnóstico em 50% a 70% dos pacientes enfartados. Quando o exame é seriado, o erro diagnóstico é reduzido para 10 a 20%, normalmente efetuado em intervalos de 30 minutos em até três séries e depois de 6 horas.

O Infarto Agudo do Miocárdio passa por algumas fases em sua evolução, sendo a primeira fase a superaguda, verificado no ECG com ondas T aumentadas; em seguida vem a fase aguda, onde o ECG apresenta elevação do segmento ST, diminuição da amplitude da onda T e o aparecimento de onda Q patológica; na fase subaguda a caracterização no ECG está na inversão da onda T e o retorno do segmento ST para a linha isoeletrica e na última fase que é a crônica, o ECG apresenta ondas Q patológicas com a elevação do segmento ST [DOUGLAS, Carlos Roberto. 2000.] [NEVILLER, Conway.1987.] [SILVA, Mauricio R. 2000.].

Do ponto de vista patológico os IAM são classificados por tamanho, tempo de evolução e localização podendo ser:

- **Infarto Inferior** – Na Figura 2.10 temos um ECG de um paciente que apresenta um IAM Inferior, onde temos padrão intracavitário de ventrículo esquerdo com QS espessadas ou, eventualmente, Qr em DII, DIII e aVF seguido de onda T negativa [HALLAKE,José. 1994.] [MANDARIM, Carlos Alberto.1990.] [SILVA, Mauricio R. 2000.];




Figura 2.10 – Exemplo de IAM Inferior com o complexo QRS espessado. Derivação DII, com a característica da onda T negativa. [software Classificador de Cardiopatias].

- **Infarto Posterior** – Ilustrado na Figura 2.11 temos o ECG de um paciente apresentando um infarto posterior, onde pode aparecer o infra-desnívelamento do segmento ST nas derivações V1, V2 e V3 [HALLAKE, José. 1994.] [MANDARIM, Carlos Alberto. 1990.] [SILVA, Mauricio R. 2000.];




Figura 2.11 – Exemplo de IAM Posterior apresentando infra-desnívelamento do segmento ST na derivação V3. [software Classificador de Cardiopatias].

- **Infarto Antero-lateral** – No ECG do paciente apresentado na Figura 2.12, temos como padrão a onda Q diminuída e alargada nas derivações DI e aVL,

inversão da onda T nas derivações DI, aVL e V6 e elevação do segmento ST nas derivações DI e aVL [HALLAKE, José. 1994.] [MANDARIM, Carlos Alberto. 1990.] [SILVA, Mauricio R. 2000.];




Figura 2.12 – Exemplo de IAM Antero-Lateral com onda Q alargada na derivação DI. [software Classificador de Cardiopatias].

- **Infarto Antero-septal** – Na Figura 2.13 temos como característica do infarto antero-septal a ocorrência de elevação do segmento ST nas derivações de V1 a V4 e elevação de ST em DI [HALLAKE, José. 1994.] [MANDARIM, Carlos Alberto. 1990.] [SILVA, Mauricio R. 2000.];




Figura 2.13 – Exemplo de IAM Antero-Septal apresentando elevação do segmento S-T. [software Classificador de Cardiopatias].

- **Infarto Lateral** – Temos o sinal elétrico deteriorado na parede lateral e há um desequilíbrio de forças entre os vetores da despolarização, gerando uma grande onda Q em DI conforme vemos na Figura 2.14 [HALLAKE, José. 1994.] [SILVA, Mauricio R. 2000.] [MANDARIM, Carlos Alberto. 1990.].




Figura 2.14 – Exemplo de IAM Lateral, onda Q com supra-desnivelamento. [software Classificador de Cardiopatias].

- **Infarto Anterior** – Na Figura 2.15 destacamos o supra-desnivelamento do segmento ST em V1, V2 e V3 e infra-desnivelamento nas derivações DII, DIII e aVF [HALLAKE, José. 1994.] [MANDARIM, Carlos Alberto. 1990.] [SILVA, Mauricio R. 2000.];




Figura 2.15 – Exemplo de IAM Anterior ondas T com supra-desnivelamento em V1. [software Classificador de Cardiopatias].

Os exemplos de eletrocardiogramas de vários tipos de infarto agudo do miocárdio ilustrado nas Figuras 2.11 a 2.15, foram processados pelo aplicativo desenvolvido para apoiar esse trabalho e utilizou a base de dados PTB Physionet [OEFF, Michael. 2005.] .

2.6.2. Bloqueios

Os bloqueios representam atrasos na condução do impulso elétrico pelos tecidos cardíacos. O bloqueio provoca a dificuldade na passagem do impulso e também sua progressão desde o nodo sinusal às demais regiões. Esse atraso modifica de forma peculiar o traçado do ECG do paciente. Em geral os bloqueios podem ser classificados:

- Bloqueio sinoatrial: acometem a área compreendida entre o nodo sinusal e os átrios, comprometendo o traçado da onda P;
- Bloqueio intra-atrial: o impulso gerado no nodo sinusal tem dificuldade em sua progressão dentro do átrio, nos feixes internodais;
- Bloqueio átrio-ventricular: ocorrem no momento em que o impulso elétrico alcança o nodo AV e tem dificuldade de passagem entre o átrio e o ventrículo. Podemos ter graus de bloqueio, sendo que o primeiro apenas retarda a passagem pela junção AV, o segundo tem alguns impulsos que são bloqueados e os demais têm continuidade e chegam

ao ventrículo. O bloqueio AV de terceiro grau também é conhecido como bloqueio completo, onde o estímulo sinusal não consegue atravessar a junção AV, colocando os batimentos ventriculares inteiramente independentes dos átrios e neste caso há a ação de dois marca-passos comandando os batimentos cardíacos, um sinusal e outro ventricular localizado abaixo da junção AV;

- Bloqueio de Ramo e hemibloqueio: são bloqueios intra-ventriculares, onde o defeito de condução ocorre dentro dos ramos do Feixe de His, esse tipo de bloqueio provoca atrasos ventriculares e dificuldade da passagem do impulso elétrico para as fibras de *Purkinje* [DECCACHE, Waldemar; et al. 1993.] .

No registro eletrocardiográfico de bloqueios ventriculares de ramo pode-se observar o complexo QRS alargado e entalhado em forma de 'M' ou 'W'. A repolarização é também anormal invertendo as ondas T. Em V6, a onda Q se perde porque o septo não é mais ativado a partir do lado esquerdo. Nas derivações precordiais direitas observam-se padrões de imagem em espelho, com ondas R diminuídas ou ausentes, ondas P elevadas e supra-desnívelamento do segmento ST. Na Figura 2.16 ilustramos um bloqueio de ramo direito onde, nas derivações precordiais direitas há presença de complexos RSR, com ondas R secundárias de duração aumentada.

As características do ECG de bloqueio podem variar de acordo com o grau do mesmo. Os bloqueios de 1º grau apresentam o segmento P-R prolongado e

podemos ter o desaparecimento das ondas P e inconstância dos intervalos P-R. Nos bloqueios de 2º grau o segmento S-T vai aumentando progressivamente, até que apresenta uma falha de condução completa, onde teremos uma onda P não sucedida pelo complexo QRS. Para os bloqueios de 3º grau ou bloqueio completo, onde os átrios e ventrículos batem independentemente, não existindo relação entre a onda P e o complexo QRS ou onda T [HALLAKE, José. 1994.] [MANDARIM, Carlos Alberto. 1990.] [SILVA, Mauricio R. 2000.].




Figura 2.16 – Exemplo de ECG – Bloqueio de Ramo apresentando ondas RsR identificando a dificuldade de passagem do sinal elétrico pelo bloqueio de ramo direito. [software Classificador de Cardiopatias].

2.6.3. Hipertrofia Ventricular Cardíaca

O coração tem duas câmaras ventriculares: a direita responsável por bombear o sangue para o pulmão e a esquerda, maior e mais forte, responsável pelo bombeamento do sangue para todo o corpo. O crescimento de um ventrículo está na dependência de sua etiologia, ou seja, das causas do crescimento, como hipertensão, Doenças de Chagas e outras. O aumento da superfície e da espessura ventriculares que alteram a rotação e a posição do coração, provocam um maior

tempo de ativação pelo aumento da massa, prolonga o caminho a ser percorrido pelo estímulo, modificando tanto a despolarização como a repolarização ventriculares, traduzindo assim aumento nas distâncias e intervalos nas ondas registradas no eletrocardiograma. [DECCACHE, Waldemar; et al. 1993.] [HALLAKE, José. 1994.] [MANDARIM, Carlos Alberto. 1990.] [SILVA, Mauricio R. 2000.]

Hipertrofia Ventricular Esquerda

O padrão de ECG que encontramos nos casos de Hipertrofia Ventricular Esquerda, em um adulto de constituição normal, apresenta a onda R em V5 ou V6, ou a onda S em V1 ou V2, com amplitudes acima da normalidade, como podemos verificar na Figura 2.17. Poderemos achar também inversão de ondas T em V6 e ondas T achatadas em V5, aVL e DI. Quando há em conjunto sobrecarga sistólica teremos inversão de onda T de V4 a V6 [DECCACHE, Waldemar; et al. 1993.] [HALLAKE, José. 1994.] [MANDARIM, Carlos Alberto. 1990.] [SILVA, Mauricio R. 2000.].

Hipertrofia Ventricular Direita

A presença de Hipertrofia Ventricular Direita é caracterizada no ECG pela presença da onda R mais elevada que a onda S em V1 e uma onda S mais profunda que a onda R em V6. A tensão ventricular direita se manifesta como uma depressão de ST e inversão da onda T de V1 até V4. Podemos destacar como padrões básicos as ondas R elevadas sobre o ventrículo direito e ondas S dominantes nas derivações precordiais. O sinal de hipertrofia grave é o surgimento de um complexo

qR em V1 [DECCACHE, Waldemar; et al. 1993.] [HALLAKE, José. 1994.]
[MANDARIM, Carlos Alberto. 1990.] [SILVA, Mauricio R. 2000.].




Figura 2.17 – Exemplo de ECG – Hipertrofia Ventricular Esquerda com ondas S de intensidade acima do normal, na derivação V1. [software Classificador de Cardiopatias].

2.6.4. Miocardite

Miocardite é caracterizada por uma inflamação do miocárdio, que pode levar a uma destruição do tecido cardíaco. O quadro clínico de um paciente com miocardite não é muito específico, podendo apresentar fadiga, dispnéia moderada, insuficiência cardíaca congestiva, palpitações, dor torácica, mialgias ou morte súbita em casos raros. Uma síndrome viral é o antecedente documentado em 60% dos casos de pacientes com miocardite e o intervalo de tempo entre a enfermidade viral e o comprometimento cardíaco é de duas semanas [DECCACHE, Waldemar; et al. 1993.] [HALLAKE, José. 1994.] [MANDARIM, Carlos Alberto. 1990.] [SILVA, Mauricio R. 2000.].

O traçado de ECG da miocardite possui alterações específicas de ondas T em todas as derivações, como vemos destacado na Figura 2.18, alterações essas que sugerem anormalidades difusas no miocárdio.




Figura 2.18 – Exemplo de ECG – Miocardite apresentando ondas R de grande amplitude. [software Classificador de Cardiopatias].

2.6.5. Cardiomiopatia

A cardiomiopatia é uma insuficiência cardíaca essencialmente diastólica, podendo levar a morte súbita. O sintoma mais freqüente é a dispnéia, principalmente durante o esforço físico. Alguns fatores podem estar presentes na ocorrência da cardiomiopatia, como a hipertrofia e a fibrose do músculo cardíaco. A primeira atua principalmente dificultando o relaxamento miocárdio e a última, aumentando a rigidez da câmara. As cardiomiopatias são normalmente de difícil identificação em sua fase aguda, no ECG observamos em destaque na Figura 2.19, curvas de baixa voltagem com alterações de onda T [DECCACHE, Waldemar; et al. 1993.] [HALLAKE, José. 1994.] [MANDARIM, Carlos Alberto. 1990.] [SILVA, Mauricio R. 2000.].




Figura 2.19– Exemplo de ECG – Cardiomiopatia com ondas T de baixa voltagem [software Classificador de Cardiopatias].

2.7. Conclusão

Neste capítulo estudamos o coração, sua anatomia, o funcionamento dos sistemas elétrico e circulatório, algumas cardiopatias relacionadas a problemas de condução cardíaca e como elas podem ser identificadas através do eletrocardiograma. No Capítulo 3 teremos a análise de algumas técnicas de classificação de cardiopatias através do sinal ECG.

Capítulo 3

Técnicas para Classificação de Cardiopatias

O objetivo deste capítulo é a discussão dos principais métodos de classificação automática de Cardiopatias. Para tal discorreremos sobre algumas técnicas encontradas na literatura.

3.1. Introdução

Os especialistas identificam várias cardiopatias através da identificação visual, com base em seu conhecimento na interpretação do ECG.

Os pesquisadores já discutem há algum tempo, formas de automatizar essa identificação, para automatização deste processo, existem basicamente duas linhas de pesquisa: a primeira utilizando o sinal original de ECG, onde há uma dificuldade de análise, em função da necessidade de processamento de grande volume de dados e redundância de informações. Em contrapartida há a vantagem de estar analisando o sinal original, descartando assim qualquer tipo de distorção. A segunda

linha de pesquisa opta por extrair características, que sejam representativas do sinal original, trabalhando com um volume menor de informações, podendo gerar um resultado rápido e eficiente [GE, Dingfei; et al. 2002.] [HOLST, Holger; et al. 1999.].

3.2. Estudos sobre Análise de Classificação de ECGs

Em 1997, Hedén et al., desenvolveram um estudo sobre detecção de infarto agudo do miocárdio, utilizou características extraídas do sinal ECG para alimentar uma rede neural artificial. Os sinais de ECG foram captados através de um sistema computadorizado (Siemens-Elema AB) e suas doze derivações foram utilizadas com utilização de medidas do segmento ST e da onda T, como: a amplitude do segmento J-ST; inclinação de ST; amplitudes, positiva e negativa da onda T e duas medidas de ST para cada uma das derivações, sendo estas medidas, frações do segmento ST, onde ele dividiu o segmento em oito partes iguais e selecionou a segunda e a terceira partes.

Essas características foram aplicadas a uma rede neural artificial, com topologia *perceptron* multicamadas. A rede foi composta por 72 neurônios de entrada, sendo seis características para cada uma das doze derivações, 15 neurônios na camada intermediária e um neurônio de saída, identificando se o ECG é de um paciente com infarto do miocárdio ou não. O objetivo do trabalho era identificar a eficiência do sistema desenvolvido, comparada com a identificação por dois especialistas experientes dos mesmos ECGs testados pela rede neural. Os resultados do trabalho atestam que uma rede neural artificial, treinada com uma grande base de informações, possui uma maior sensibilidade de identificação de ECGs de pacientes com infarto agudo do miocárdio do que os dois cardiologistas

experientes que ajudaram nos experimentos, indicando que a utilização da automação no diagnóstico pode ser uma ferramenta válida como forma de agilizar o diagnóstico [HEDEN, Bo; et al. 1997.].

Em 1999, Gamlyn et al., realizaram um estudo com o objetivo de analisar a eficiência de uma rede neural artificial, acoplada a um monitor ECG em tempo real. A expectativa era verificar os benefícios da automação para os pacientes, diminuindo o tempo entre a identificação da cardiopatia e o início do tratamento. A tecnologia escolhida foi uma rede neural artificial do tipo Kohonen. No primeiro estudo realizado, foram analisados 26 minutos de sinais ECG de 67 pessoas, divididas entre pacientes cardíacos, pacientes em recuperação e indivíduos saudáveis. A eficiência da identificação de arritmias cardíacas foi comparada entre os resultados da rede neural e a análise de cinco cardiologistas. O resultado alcançado pela rede neural foi 96% de acerto na identificação, contudo, as análises realizadas pelos cardiologistas obtiveram um índice de 89% de acerto [GAMLYN, L.; et al. 1999.].

Em 1999, Holst et al., desenvolveram um trabalho com objetivo de criar um método para validar a análise de sinais de ECG através de um sistema computacional confiável. Para tal, eles optaram pela utilização de uma rede neural artificial e como informações de entradas, eles utilizaram as mesmas características que os cardiologistas analisam visualmente. São elas: amplitudes das ondas Q, R e S, duração das ondas Q e R e amplitudes entre a onda S e o final da onda T. As derivações analisadas foram V2, V3 e V4, que são as comumente analisadas pelos cardiologistas e profissionais médicos. A topologia de rede neural escolhida foi *perceptron* multicamadas, com 24 neurônios de entrada, sendo oito para cada uma

das derivações. A camada intermediária foi construída com 5 neurônios e um único neurônio na camada de saída, identificando a presença de infarto agudo do miocárdio ou não. As informações de entrada foram divididas em três grupos distintos, sendo: o primeiro para o treino da rede, o segundo utilizado para a aferição do nível de erro e o terceiro grupo para testes de validação do experimento. A criação de um sistema computacional, utilizando redes neurais, analisando as mesmas características que os cardiologistas e nas mesmas derivações, na conclusão dos autores, é totalmente confiável, podendo ser utilizado clinicamente como suporte à decisão [HOLST, Holger; et al. 1999.].

Baseado na experiência de Hedén et al., 1997. Olsson et al., 2002 propõem uma ferramenta de diagnóstico automatizado para reconhecimento de infarto agudo do miocárdio combinado com bloqueio de ramo esquerdo, através da análise do ECG. O propósito dos autores era a detecção em ECGs das cardiopatias citadas, comparando a eficiência de uma rede neural artificial com o método tradicional utilizando dois cardiologistas experientes. Como informações de entrada da rede neural, foram escolhidas 11 medidas extraídas do sinal ECG, para as doze derivações, sendo elas: duração do complexo QRS, área do mesmo complexo, amplitudes das ondas Q, R e S, amplitude do segmento ST-J, inclinação de ST, amplitude negativa e positiva da onda T e duas amplitudes parciais de ST. Num segundo momento, essas variáveis foram agrupadas e priorizadas, tendo seu número reduzido para 30 variáveis por ECG. Os experimentos foram realizados com 518 amostras de ECGs, divididos em grupos de treino, validação e teste, numa rede neural de topologia *perceptron* multicamadas. Os resultados do sistema computadorizado foram 12% mais eficiente que a análise dos dois cardiologistas

com 25 anos de experiência, concluindo a confiabilidade do método, podendo ele ser utilizado pelos profissionais com um ganho de *performance* no diagnóstico [OHLSSON, E; et. al., 2002.].

Um trabalho similar aos que já observamos até o momento, tratando também de sinais biomédicos, foi realizado por Soares et al., 2003, objetivando o desenvolvimento de uma prótese virtual mioelétrica controlada por um sistema de reconhecimento do sinal biomédico eletromiográfico (EMG), baseado em redes neurais. Em suas pesquisas, os autores verificaram a grande dificuldade de adaptação de pacientes ao uso de próteses, em função da perda de membros por amputação ou por defeitos congênitos, sendo que o grande desafio dos pesquisadores era encontrar a melhor forma de criar controles baseados na detecção e processamento dos sinais EMG, que permitam ao paciente uma adaptação mais simples à prótese, com movimentos mais naturais e com menor esforço. Como forma de reduzir o número de informações a serem analisadas, os autores optaram por utilizar um modelo linear estocástico para extrair características do sinal EMG e não utilizar o sinal original em função do grande volume de dados. Eles identificaram o modelo autoregressivo (AR), como o mais apropriado para ser aplicado em sinais eletromiográficos, bem como a utilização do algoritmo LMS (método dos mínimos quadrados – *least mean square*) para a minimização dos erros no cálculo dos coeficientes do modelo AR. Os coeficientes AR extraídos do sinal EMG foram utilizados como características representativas do sinal analisado e classificados através de redes neurais. Suas conclusões apontaram para a utilização do modelo auto-regressivo AR, pois a característica do sinal não-estacionário não

permite a utilização dos métodos tradicionais. Na Figura 3.1, temos o gráfico com os coeficientes extraídos pelo modelo AR, em um dos cenários utilizado pelos autores.




Figura 3.1 Gráfico com os coeficientes resultantes do modelo AR, extraídos do sinal EMG. [ANDRADE, Adriano de Oliveira. 2000.] [SOARES, Alcimar Barbosa; et al. 2003.].

Após a extração das características, os autores utilizaram uma rede neural artificial para a etapa de classificação. Seu objetivo era o reconhecimento de padrões do sinal eletromiográfico, distinguindo-os em classes previamente classificadas. Foi adotada uma topologia de rede neural MLP (*Perceptron* Multicamadas) e o número de neurônios de entrada foi ajustado de acordo com a eficiência do número de coeficientes do modelo AR (entre 4 e 10), com 80 neurônios na camada intermediária e 4 neurônios na camada de saída. Como treinamento da

rede foi utilizado o algoritmo *Backpropagation*, escolhido pelo conhecimento prévio da massa de treino e teste. Em seus experimentos foram utilizados modelos AR de ordem 10 e de ordem 4. Foram escolhidos quatro diferentes movimentos musculares, através de cinco eletrodos colocados na superfície do braço e cada movimento foi repetido 50 vezes, sendo: flexão e extensão do braço e flexão para cima e para baixo do pulso. As informações foram divididas em dois grupos, um para treino e outro para teste, cada grupo continha 100 amostras, 25 para cada tipo de movimento. As apurações foram efetuadas por tipo de movimento e pelo total das amostras, sendo que o número de 4 coeficientes mostrou-se mais adequado para representar o sinal EMG. O reconhecimento da rede apresentou um índice de acerto acima de 95% [ANDRADE, Adriano de Oliveira. 2000.] [SOARES, Alcimar Barbosa; et al. 2003.].

Pesquisadores da Universidade de Nanyang em Singapura, Dingfei, Ge, et al., realizaram estudos sobre sinais biomédicos na área cardiológica, utilizando modelo AR. [GE, Dingfei; et al. 2002.]. O objetivo da pesquisa era a classificação de arritmias cardíacas, separando-as por grupos:

- VT – Taquicardia Ventricular;
- VF – Fibrilação Ventricular;
- APC – Contração Atrial Prematura;
- PVC – Contração Ventricular Prematura;
- SVT – Taquicardia Supraventricular;
- NSR – Ritmo Sinusal Normal.

A análise automática do ECG é considerada por eles como crítica no auxílio ao diagnóstico e tratamento de pacientes com problemas cardíacos. A detecção confiável das arritmias cardíacas é um desafio para a melhoria do sistema de diagnóstico cardíaco. Nesta pesquisa foi utilizada a base de dados de ECG do banco de dados MIT-BIH, realizando um pré-processamento dos sinais para a filtragem de ruídos provocados pela linha de energia, respiração e movimentação muscular. Para a localização dos picos das ondas R, utilizou-se o algoritmo de *Tompkins* [AFONSO, VX; et al. 1999.]. Na extração das características do sinal biomédico foi utilizado o modelo AR e os pesquisadores testaram várias ordens para verificar a melhor precisão na reconstrução dos sinais. Diferentemente do artigo anterior, que utilizou o algoritmo LMS para auxílio na determinação dos coeficientes, este artigo utilizou o algoritmo de BURG, que é um algoritmo recursivo, onde os parâmetros de uma ordem são obtidos a partir da ordem anterior.

Após seus experimentos, os pesquisadores chegaram à conclusão de que a ordem 4, era a mais eficiente para a reconstrução da curva e com baixo custo computacional, o que o tornou ideal para o resultado da pesquisa. Para a classificação dos grupos de arritmias pré-determinados, foi utilizado o modelo linear generalizado GLM, que utiliza o método dos quadrados mínimos. Os índices de reconhecimento alcançados estão descritos na Tabela 3.1.

Tabela 3.1 – Tabela com o número de amostras aplicadas à solução da pesquisa e seu percentual de reconhecimento com a utilização do modelo AR para extração de características e o modelo GLM para reconhecimento [GE, Dingfei; et al. 2002.].

<i>Tipo de Arritmia</i>	<i>Amostras</i>	<i>Reconhecimento</i>
VT – Taquicardia Ventricular	143	97,7%
VF – Fibrilação Ventricular	142	98,6%
APC – Contração Atrial Prematura	140	96,4%
PVC – Contração Ventricular Prematura	155	94,8%
SVT – Taquicardia Supra-ventricular	133	100%
NSR – Ritmo Sinusal Normal	143	93,2%

Os autores mostraram que esse método, apesar de simples, é bastante eficiente, podendo ser implementado em tempo real, pois houve uma preocupação com sua agilidade no tempo de resposta [GE, Dingfei; et al. 2002.].

3.3. Conclusão

Neste capítulo estudamos alguns métodos e tecnologias que estão sendo utilizadas para extração de características de sinais digitais biomédicos como o ECG e identificamos também o modelo AR como uma solução possível para extração de características de sinais biomédicos não estacionários como ECG. Discutimos e analisamos alguns trabalhos realizados nesta área. Focamos o estudo na área de redes neurais, por elas trazerem um resultado eficiente e largamente utilizado no ambiente de pesquisa de sinais biomédicos. Mais recentemente temos a utilização

de técnicas de reconhecimento através da utilização de transformadas *wavelets*, com resultados bastante expressivos, que poderá ser foco de um novo estudo sobre o assunto [LI, C; ZHENG, et al. 2000.]. Entendemos que apesar da boa qualidade de reconhecimento de cardiopatias a partir do sinal ECG, ainda não obtivemos um método com um índice de acerto em torno de 100% e por este motivo, focamos nossa pesquisa nesta área de reconhecimento. No próximo capítulo apresentaremos o método proposto para a extração de características e a classificação das cardiopatias a partir do sinal ECG.

Capítulo 4

Sistema Proposto

4.1. Introdução

Este capítulo objetiva a descrição da proposta para reconhecimento de cardiopatias a partir do sinal ECG. Considerando que o ECG é a ferramenta de diagnóstico de Cardiopatias de mais rápido resultado, nossa proposta pretende acoplar funcionalidades ao ECG, para que o especialista possa ter uma sugestão diagnóstica automatizada. Na Figura 4.1, temos o esquema gráfico da proposta, onde o sinal captado por um eletrocardiógrafo digital terá seus ciclos separados através da utilização do *software* disponibilizado no trabalho de Rangel, 2006. Esses ciclos terão suas características extraídas através de um modelo AR, e os coeficientes obtidos serão aplicados a uma rede neural artificial para a classificação das Cardiopatias.




Figura 4.1 – Esquema Gráfico do Sistema Proposto de Classificação de Cardiopatias através do ECG.

4.2. Metodologia Proposta

A proposta de desenvolvimento da solução utiliza ciclos de registros de ECG previamente separados e disponíveis em uma base de dados. Na Figura 4.2, mostramos o esquema gráfico do algoritmo de separação de ciclos cardíacos proposto por Rangel, 2006, onde o sinal ECG pode ser adquirido diretamente a partir de um eletrocardiógrafo digital ou de arquivos binários no formato PTB Physionet [OEFF, Michael. 2005.]. Assim que adquirido, o sinal é filtrado por um filtro de média móvel, para atenuação de ruídos (normalmente provocados por linha de força ou movimentos musculares) sendo a seguir derivado duas vezes. A detecção é

realizada por intermédio de um limiar, procurando ocorrências da onda R, representada em sua segunda derivada. O limiar é estabelecido dinamicamente com base nos últimos 10 segundos de sinal e seu valor é calculado levando-se em conta o desvio padrão das variações da segunda derivada no período. As derivadas são aplicadas sobre o sinal de ECG filtrado, utilizando um filtro de média móvel com frequência de corte de 50 Hz. Para cada uma das doze derivações os ciclos são normalizados, posicionados a 240 ms à esquerda do pico da onda R, identificados e finalmente armazenados em base de dados digital.




Figura 4.2 – Diagrama de blocos da estratégia adotada para localização de ciclos cardíacos. [RANGEL, Hélio. 2006.].

A proposta de classificação dos ciclos cardíacos está dividida em duas fases: o treinamento da rede neural e o reconhecimento das amostras pela rede treinada. As Figuras 4.3 e 4.4 representam, graficamente, as duas fases que detalharemos a seguir.




Figura 4.3 – Fluxo da Fase de Treinamento da RNA para Classificação de Cardiopatias.

A primeira fase da proposta de metodologia de classificação de Cardiopatias é o treinamento da rede neural para futuro reconhecimento das amostras de ECG. Utilizamos uma base de dados com ciclos cardíacos separados pelo trabalho desenvolvido por Rangel, 2006. Estes ciclos são utilizados no treinamento da rede neural artificial. Para esta seleção, temos os ciclos identificados por cardiopatia. Dentre a base de dados original, extraída do banco de dados Physionet [OEFF, Michael. 2005], selecionamos três grupos de cardiopatias, (sendo, o IAM e bloqueios, as cardiopatias de maior incidência), a serem submetidos a treinamento e reconhecimento, sendo eles: infarto agudo do miocárdio (IAM), bloqueios, grupo de controle com pacientes sem cardiopatia e outras cardiopatias agrupadas. Na Figura 4.3, ilustramos o fluxo da primeira fase da proposta.

No tratamento dos registros, para extrair as características do sinal, utilizamos o modelo matemático auto-regressivo - AR e o algoritmo de mínimos quadrados

(*Least Mean Squared* - LMS) [ANDRADE, Adriano de Oliveira. 2000.] [SOARES, Alcimar Barbosa; et al. 2003.]. Em seguida, os coeficientes do modelo AR foram utilizados como parâmetros de entrada na rede neural utilizando a topologia *perceptron* multicamadas, com o modelo *feed-foward* e o algoritmo de treinamento *backpropagation*. Na Figura 4.3, apresentamos a topologia da rede que foi utilizada para o terceiro e melhor cenário analisado, onde temos os quatro grupos a serem treinados, tendo como camada de saída da rede neural, quatro neurônios com o seguinte significado: “-1, 1, -1, 1” para o grupo de controle de pacientes saudáveis, “-1, -1, -1, -1” para o grupo de IAM, “1, 1, 1, 1” para o grupo portador de bloqueios e “1, -1, 1, -1” para o grupo portador de outras cardiopatias. Desta forma temos a rede treinada para que, na segunda fase (fase de reconhecimento), possamos ter os ciclos escolhidos testados e sua eficiência avaliada.




Figura 4.4 – Fluxo da Fase de Reconhecimento de Cardiopatias.

Na segunda fase realizamos a extração de características pelo mesmo método da primeira fase. Os coeficientes obtidos pelo modelo AR, que representam

a curva do ciclo cardíaco, são aplicados à rede neural para o reconhecimento e o resultado expresso nos quatro neurônios de saída conforme pode ser visto na Figura 4.3.

Para os dois primeiros cenários, utilizamos uma topologia com quatorze neurônios na camada intermediária e dois neurônios de saída, no próximo capítulo, descreveremos os resultados alcançados com esta topologia e a composta com 5 neurônios na camada intermediária e quatro neurônios de saída.

4.2.1. Extração de características do sinal ECG

As características a serem utilizadas na fase de classificação são cruciais para o sucesso do modelo. Alguns autores, conforme descrito no Capítulo 3, utilizaram características extraídas diretamente do sinal. Outros autores trabalharam com dados temporais do sinal original, como amplitude de ondas, medidas de segmentos etc. As técnicas mais modernas de extração de características se valem de modelos matemáticos para o levantamento comportamental da curva do ECG. Como exemplo, podemos citar os modelos AR e as transformadas *wavelet*. [GE, Dingfei; et al. 2002.] [LI, C; ZHENG, et al. 2000.] [ANDRADE, Adriano de Oliveira. 2000.] [SOARES, Alcimar Barbosa; et al. 2003.].

Neste trabalho optou-se pelo uso do modelo AR, adaptado por Soares et al., 2003, e Andrade, 2000., por se adequar a sinais não estacionários como é o caso dos sinais biomédicos, conforme destacado por Dingfei em 2002. Além disso, a utilização dos coeficientes tem a vantagem de manipular pequenas quantidades de dados e ainda assim representar bem o sinal original. Em nossa proposta de classificação, experimentamos o modelo AR com 6, 8 e 10 coeficientes, buscando

encontrar o número de coeficientes de melhor desempenho quando aplicados à rede neural.

Para que possamos utilizar o modelo AR da melhor forma, devemos realizar vários experimentos aplicando uma variada gama de configurações e calibrações do modelo AR. A ferramenta de *software* desenvolvida deve permitir que os diversos parâmetros (seleção da derivação, janela do sinal a ser analisado, parâmetros de erro mínimo e coeficiente de convergência), sejam facilmente determinados. Para minimização do erro quadrático, utilizamos o algoritmo LMS (método dos mínimos quadrados – *Least Mean Square*), para refinamento dos índices obtidos no modelo AR. A adaptação do algoritmo LMS foi realizada para minimizar os erros, onde foi incluído um *looping* aplicado n vezes dentro do modelo auto-regressivo AR como pode ser observado no fluxograma apresentado na Figura 4.5. [ANDRADE, Adriano de Oliveira. 2000.] [SOARES, Alcimar Barbosa; et al. 2003.]

A expressão abaixo representa o modelo AR.

$$\hat{Y}^{(1)}(n) = \sum_{m=1}^M a_m(n) y(n-m) + e(n)$$

Onde $\hat{Y}(n)$ é o valor estimado da série $y(n)$ no tempo discreto n , a é o valor de entrada, e m é o número de coeficientes do modelo AR, $e(n)$ é o erro de estimativa e M é a ordem do modelo [ANDRADE, Adriano de Oliveira. 2000.]. A figura 4.5 apresenta o fluxograma dos algoritmos do modelo AR e LMS utilizados na elaboração do aplicativo de *software* desenvolvido para os testes do modelo.




Figura 4.5 – Fluxograma do modelo auto-regressivo, com o LMS customizado, utilizado para a extração das características do ciclo de ECG.

4.2.2. Classificação das Cardiopatias

Uma vez extraídas as características do sinal ECG, devemos encaminhá-las para uma unidade responsável por classificá-las em grupos de Cardiopatias.

Para realizar a classificação que estamos propondo, podemos utilizar outros recursos como: ferramentas estatísticas, RNA, extração de características através de *wavelet*, entre outras. [LI, C; ZHENG, et al. 2000.] [LIN, Kang-Ping; et al. 1989.] [REBROVA, O. Yu; et al. 2004.] [TU, C; et al. 2004.]

Neste trabalho optou-se pelo uso de uma rede neural artificial devido a sua grande capacidade de generalização, funcionalidade importante ao tratarmos de sinais biomédicos, por se tratar de sinais com alto índice de variabilidade e com grande volume de informações. A arquitetura escolhida para a construção RNA foi a *perceptron* multicamada, e o tipo da rede *feed-forward*, com três camadas. Neurônios de entrada recebem os sensores das características extraídas pelo modelo AR, podendo ser seis, oito ou dez coeficientes (um neurônio para cada coeficiente), que serão correspondentes aos cenários a serem testados em nossos experimentos. Uma camada intermediária, formada por cinco neurônios, determinada empiricamente através de experimentos e baseada na experiência de HEDEN, Bo; et al., em 1997. A camada de saída é formada por quatro neurônios, que indicam como resposta as Cardiopatias reconhecidas, sendo: (-1, 1, -1, 1) para pacientes saudáveis, (-1, -1, -1, -1) para os pacientes com infarto do miocárdio, (1, 1, 1, 1) para pacientes com bloqueios de ramo e (1, -1, 1, -1) para pacientes das demais cardiopatias. Adotamos o método de treinamento *backpropagation*, onde aproveitamos esse procedimento para ajuste automático dos pesos da rede. A escolha das amostras para o treinamento é realizada por intermédio do aplicativo

desenvolvido, de forma empírica, onde experimentamos algumas amostras de ciclos cardíacos dentre as disponíveis. A Figura 4.6 exemplifica uma das topologias utilizadas no método proposto, com seis neurônios de entrada, de acordo com o parâmetro de número de coeficientes aplicados à fase de extração de características, 5 neurônios na camada intermediária e quatro na camada de saída. A topologia utilizada para os dois primeiros cenários foi formada pelos coeficientes extraídos pelo modelo AR, quatorze neurônios na camada intermediária e dois neurônios de saída.




Figura 4.6 – Representação gráfica da uma das topologias utilizadas da Rede Neural Artificial (Cenário 3).

Para treinamento ou aferição da rede, podemos utilizar as doze derivações, uma ou algumas delas, uma vez que o *software* localizador de ciclos cardíacos identifica quais as melhores e piores derivações, ou seja, ele identifica as derivações mais adequadas na localização da onda R, as piores podem sinalizar a ocorrência de falsos positivos ou falsos negativos na localização dos ciclos. Muitos pesquisadores utilizam as doze derivações, mas para melhoria do tempo de processamento alguns como Chazal, pesquisador da Universidade N.S.W. em Sydney, Austrália, utilizou oito derivações em suas pesquisas [CHAZAL, P; et al. 1997.]. Em nossa proposta, selecionaremos as seis derivações de melhor desempenho com o objetivo de otimizar o processamento do modelo.

4.3. Implementação do modelo em *software*

O modelo proposto foi desenvolvido em *software* no sistema operacional Microsoft Windows XP ®, utilizando a linguagem C++ por ser uma linguagem que atende ao desenvolvimento orientado a objetos e *Matlab* 7.0.1 para a geração da RNA, com o algoritmo de treinamento *backpropagation*. Conforme vemos na Figura 4.7, a aplicação foi desenvolvida em duas etapas, sendo a primeira na linguagem C++ que chamamos de “Classificador de Cardiopatias”, onde temos a escolha do ciclo ou dos ciclos a terem suas características extraídas pelo modelo AR, e a geração da base de dados para a segunda etapa, etapa esta onde foi utilizado o *software Matlab* 7.0.1. A escolha deu-se em função de ser um aplicativo estável e de uso mundial, com suas funcionalidades testadas e certificadas no ambiente científico e acadêmico.




Figura 4.7 – Representação gráfica do modelo em software, com as duas técnicas escolhidas para o desenvolvimento do modelo, C++ e Matlab.

4.3.1. Aplicação em C++ para Seleção dos Ciclos e Extração de Características

Para atender parte das funcionalidades necessárias à classificação de cardiopatias a partir de sinais ECG foi desenvolvido o aplicativo “Classificador de Cardiopatias”. Para tal, conforme ilustrado pela Figura 4.8, devemos informar inicialmente os parâmetros de cálculo para o modelo AR. Em seguida, as derivações que farão parte do arquivo a ser importado pela rede neural e a janela no tempo do ciclo a ser selecionado, que na Figura 4.8 está registrado como “Parâmetros, Derivações e Janela do Ciclo”. A seguir, temos a opção do tipo de operação a ser executada: preparação dos dados para treinamento ou teste de reconhecimento.

Para a opção “Treinamento” , como descrito na Figura 4.8, temos como próximo passo a seleção da cardiopatia. A escolha das amostras ou ciclos é o passo seguinte, depois temos o processamento da amostra, utilizando os parâmetros selecionados. Para a conclusão do processo de criação de informações para o reconhecimento pela RNA temos a extração de características através do modelo AR e a criação da base de dados.

Na Figura 4.8, observamos que a segunda opção de operação é o “Reconhecimento”, para tal, temos a seleção da amostras, sem distinção de cardiopatia, a seguir o processamento da amostra com os parâmetros escolhidos previamente, que devem ser os mesmos parâmetros da fase de treinamento, como: janelamento do ciclo, número de ordens, coeficiente de convergência, erro mínimo e também as derivações selecionadas. Esse processamento gera os coeficientes pelo modelo AR e cria a base de dados de entrada da rede neural para classificação.




Figura 4.8 – Diagrama de Funcionalidades do Aplicativo Classificador de Cardiopatias.

A tela principal do aplicativo está dividida em funcionalidades distintas e é composta de quadros, gráficos e área de relatórios como ilustrado na Figura 4.9.

Classificador de Cardiopatias

Seleção de amostras (4):

- s0390lre_Separadas.bin
- s0432_re_Separadas.bin
- s0443_re_Separadas.bin
- s0450_re_Separadas.bin

Operação:

☒ Treino ☐ Classificação

Grupo:

☐ Normal ☐ IAM ☐ Bloqueio ☒ Demais

Derivação: Deriv.

Parâmetros AR

Início: 20 Fim: 500

Ordem: 10 Const. C: 0.05

Erro: 0.001

Fixa atual Tira última Limpa

Deriv.:

☐ DI ☒ DII ☐ DIII ☐ aVR ☐ aVL ☐ aVF ☐ V1 ☐ V2 ☐ V3 ☐ V4 ☐ V5 ☐ V6

AR x Derivação Selecionada

Derivações do ECG Selecionado

Índices do Modelo AR

Relatório:

Índice

Ordem

Núm. Ciclos

☐ Série 10

Figura 4.9 – Tela Principal do Aplicativo Classificador de Cardiopatias, com os parâmetros, gráficos e ações para a geração da entrada de dados da RNA de identificação dos sinais de ECG.

O primeiro quadro destacado no aplicativo é a área que marcamos como “**A**” na Figura 4.9. Nesta área, informamos todos os parâmetros, iniciando pela indicação da operação, podendo ser “treino” ou “classificação” e, em seguida, os demais parâmetros necessários para os cálculos dos coeficientes do modelo AR, sendo eles: início e fim do janelamento, ordens do modelo AR, coeficiente de convergência, erro mínimo, derivações utilizadas, cardiopatias, amostras, número de ciclos, derivação para área do gráfico e indicador de normalização dos coeficientes.

Na área sinalizada como “**B**” na Figura 4.9, temos os gráficos gerados pelo aplicativo. No gráfico “Derivações do ECG Selecionado” estão traçados os ciclos ou grupo de ciclos nas derivações selecionadas na área de parâmetros, este gráfico permite uma clara visualização da forma dos ciclos. No gráfico “AR x Derivação Selecionada”, temos o traçado do ciclo original e a curva reconstruída utilizando os coeficientes calculados pelo modelo. A visualização deste gráfico é uma importante ferramenta de validação dos coeficientes calculados. No gráfico “Índices do Modelo AR”, estão traçados todos os coeficientes calculados para cada amostra selecionada, após o cálculo dos coeficientes o *software* permite a geração dos arquivos em formato texto, com os coeficientes e alvos que serão utilizados como entrada na RNA.

A área de relatórios identificada pela letra “**C**” na Figura 4.9 traz as informações referentes à amostra selecionada, sendo: número de identificação da amostra, cardiopatia diagnosticada, idade, sexo do paciente e informações estatísticas de cada derivação. Após a geração dos arquivos para a RNA nesta área são registrados os coeficientes calculados para a amostra.

4.3.2. Rede Neural em *Matlab* 7.0.1 para Treinamento e Reconhecimento das Cardiopatias

A classificação das cardiopatias foi realizada utilizando os recursos disponíveis no *Matlab* 7.0.1, sendo a primeira operação a importação dos arquivos com as informações de entrada com os coeficientes formatados de acordo com o padrão esperado pelo aplicativo *Matlab*, e também o arquivo com os alvos utilizados no treinamento da rede neural artificial.

As funcionalidades do *Matlab*, para a criação da rede neural de classificação do sinal patológico, foram as seguintes: “Newff” para a geração da rede neural artificial do tipo *feed-forward*, utilizando o parâmetro “Minmax” para a normalização dos dados de entrada, o número estipulado para a camada de saída, em nosso caso dois ou quatro neurônios. A seguir temos as funções de transformação “TANSIG” que é uma função tangente hiperbólica e a função de treinamento “TRAINBFG” função escolhida pela característica de ajuste automático de pesos.

Para o treinamento da rede, utilizaremos o arquivo de entrada com as amostras escolhidas e com o arquivo de alvos criado pela aplicação “Classificador de Cardiopatias”. A função “TRAIN” tem como parâmetros de entrada a base de dados de entrada, gerada pelo aplicativo, e a base de dados com os alvos de cada amostra do treinamento; o alvo pode ter como valores válidos -1 e 1. Para o teste de reconhecimento, a função “SIM” de simulação da rede treinada, onde temos como parâmetro de entrada, uma amostra para identificação do sinal, o resultado desta simulação é o nível de aderência da amostra submetida à rede, em relação ao treinamento antes efetuado. O limiar para indicação do reconhecimento escolhido foi de 50% de aproximação do alvo, escolha baseada na experiência descrita no artigo

de Andrade (2005). Descreveremos esta metodologia de limiar de reconhecimento no próximo capítulo.

O método utilizado para a apresentação dos ciclos separados à rede neural artificial, foi por segregação em pastas identificadas por cardiopatias e em seguida distinguidas entre dados de treino, separadas por cardiopatias e dados de teste, com amostras de todas as cardiopatias, conforme ilustrado na Figura 4.10.




Figura 4.10 –Organização dos arquivos contendo os ciclos de entrada para o sistema de classificação.

Após a separação, os ciclos foram processados pelo aplicativo Classificador de Cardiopatias e, a seguir, os resultados transferidos para o *Matlab* para serem aplicados na rede neural artificial, sendo que nesta fase de treinamento utilizamos o arquivo com os coeficientes e o arquivo com os alvos de cada ciclo processado. Na Figura 4.11 podemos observar um exemplo dos arquivos de dados e alvo preparados pelo Classificador.




Figura 4.11 – Exemplo dos arquivos de dados e alvos gerados pelo aplicativo Classificador de Cardiopatias, e que serão utilizados pela Rede Neural para treinamento.

Para a fase de reconhecimento, utilizamos a segunda metade das amostras, selecionada aleatoriamente. O software Classificador de Cardiopatias cria para cada uma das amostras ou um grupo de amostras, um arquivo com as características do modelo AR, que serão a entrada da RNA para o teste de reconhecimento.

4.3.3. Conclusão

Neste capítulo, descrevemos o aplicativo desenvolvido para alcançar nosso objetivo descrito no Capítulo 1, que é a criação de um sistema que possibilite distinguir, através dos sinais eletrocardiográficos, os sinais patológicos dos sinais normais, classificando-os por tipo de cardiopatia. Os arquivos gerados pelo aplicativo

foram aplicados a uma rede neural artificial, com modelo de treinamento *backpropagation*, gerando o indicador de reconhecimento de cada ciclo testado. No próximo capítulo, apresentaremos os resultados e análises do modelo proposto.

Capítulo 5

Experimentos e Análises

Neste capítulo, descrevemos os resultados de nossos experimentos, onde analisamos ciclos de sinais de ECG, extraímos suas características através do modelo AR e aplicamos essas características a uma rede neural artificial, para reconhecimento das cardiopatias através dos sinais de ECG.

5.1. Fonte de Dados

Os ciclos separados utilizados em nossos experimentos foram extraídos do banco de dados de sinais Physionet [OEFF, Michael. 2005.] onde dispomos de um grande número de amostras de ECG. Optamos pela base alemã PTB “Physikalisch – Technische Bundesanstalt”, o Instituto Nacional Alemão de Metrologia, no qual os exames eletrocardiográficos foram coletados de voluntários saudáveis e pacientes com diferentes cardiopatias, pelo Professor Michael Oeff, M.D., do Departamento de Cardiologia da Universidade Benjamin Franklin em Berlim, Alemanha [OEFF, Michael. 2005.].

O eletrocardiógrafo utilizado para a coleta da base de dados é um protótipo PTB, equipamento não comercial com as seguintes especificações:

- 16 canais de entrada (14 para ECG, 1 para respiração e 1 linha de energia;
- Voltagem de entrada ± 16 mV;
- Resistência de entrada $100\ \Omega$ (DC);
- Resolução de 16 bit com $0,5\ \mu\text{V/LSB}$;
- Tensão de ruído máxima de $10\ \mu\text{V}$ (pp).

A base de dados conta com 549 registros para 294 pacientes (cada paciente pode ter de um a cinco registros). Cada registro contém 15 derivações de sinais eletrocardiográficos, sendo os 12 convencionais (DI, DII, DIII, aVR, aVL, aVF, v1, v2, v3, v4, v5, v6) e inclui também outras três derivações complementares (vx, vy e vz), que não foram utilizados neste estudo.

Cada sinal foi digitalizado com taxa de aquisição de 1000 amostras por segundo (frequência de amostragem de 1000 Hz), com resolução de 16 bits. Está disponível na base de dados um registro *‘.dat’* com o sinal e o registro *header* contendo informações detalhadas como:

- Resumo clínico do paciente;
- Idade;
- Sexo;
- Diagnóstico;
- Histórico médico;
- Cardiopatia existente;
- Medicação que o paciente está utilizando;
- Informações hemodinâmicas.

Os registros estão classificados e divididos de acordo com a cardiopatia diagnosticada, como mostrado na Tabela 5.1, a seguir:

Tabela 5.1 – Estatística de cardiopatias da base de dados por número de amostras e número de pacientes, [OEFF, Michael. 2005.].

<i>Classe de Diagnóstico</i>	<i>Número de Amostras</i>	<i>Número de Pacientes</i>
Infarto Agudo do Miocárdio	365	158
Cardiomiopatia	17	18
Bloqueio	17	15
Disritmia	16	14
Hipertrofia do Miocárdio	7	7
Disfunção de Válvulas	5	6
Miocardite	4	4
Demais cardiopatias	7	5
Normais - Controle	111	67
Total de Pacientes	549	294

Em nossos experimentos, selecionamos aleatoriamente 20 amostras de ciclos separados de cada uma das cardiopatias para análise: grupo de controle com pacientes normais, infarto agudo do miocárdio, bloqueio (17 amostras) e demais cardiopatias. O arquivo de entrada para a rede neural foi formatado com os seguintes atributos: nome da amostra, os coeficientes obtidos (AR) e o resultado esperado (alvo) para uso no treino da rede neural artificial. Cada um dos alvos pode

assumir os valores 1 ou -1, para o cenário com a topologia de quatro neurônios de saída temos as seguintes combinações possíveis:

- -1, 1, -1, 1 → amostras ECG normais;
- -1, -1, -1, -1 → amostras de IAM;
- 1, 1, 1, 1 → amostras de Bloqueio;
- 1, -1, 1, -1 → demais cardiopatias.

Para o cenário com a topologia de dois neurônios de saída temos as seguintes combinações possíveis:

- 1, 1, → amostras ECG normais;
- -1, -1, → amostras de IAM;
- 1, -1, → amostras de Bloqueio;
- 1, -1, → demais cardiopatias.

Realizamos nossa análise tendo como base com três cenários: o primeiro, utilizando um ciclo aleatório de cada amostra e no segundo foram selecionados dez ciclos seqüenciais de cada amostra, nestes dois utilizamos a topologia da RNA com dois neurônios de saída. Para o terceiro cenário foi utilizado um ciclo por amostra selecionada, uma topologia de RNA com quatro neurônios de saída. Os padrões utilizados no treinamento da rede foram compostos por um grupo de 80 amostras, sendo 20 para cada um dos tipos de cardiopatia, exceto para Bloqueio, onde utilizamos as 17 amostras disponíveis. Procuramos um equilíbrio no número de amostras utilizadas no treinamento para que a rede não fosse treinada de modo tendencioso.

A aplicação utilizada nos experimentos permite três tipos de operação: Treino, onde preparamos os dados para o treinamento da RNA, Validação, onde verificamos o reconhecimento de uma amostra dentre as utilizadas para treinamento e classificação, que gera os parâmetros para o reconhecimento da cardiopatia através da RNA.

Realizamos vários experimentos com diversos cenários diferenciados entre si pelos parâmetros de processamento, como o número de ciclos, as derivações e os dados para o cálculo dos coeficientes pelo modelo AR. A seguir apresentaremos os cenários que obtiveram o melhor comportamento entre todos os testados, sendo eles:

- ⇒ Cenário 1 com um ciclo por amostra e massa de treinamento selecionada uma única vez, com quatorze neurônios na camada intermediária e dois neurônios de saída;
- ⇒ Cenário 2 com dez ciclos consecutivos por amostra selecionada com quatorze neurônios na camada intermediária e dois neurônios de saída;
- ⇒ Cenário 3 composto por amostras com um ciclo e a seleção da massa de treinamento realizada aleatoriamente com dez combinações diferentes de amostras. Utilizando cinco neurônios da camada intermediária e quatro neurônios na camada de saída.

5.2. Cenário 1 – Amostras com um ciclo do ECG

5.2.1. Treinamento

A fase de treinamento é a primeira etapa do experimento e para sua realização é preciso inserir na aplicação alguns parâmetros, tais como: opção de

operação (treinamento ou diagnóstico), derivação mestre para traçado de gráficos, cardiopatias que terão suas amostras selecionadas para o treino, parâmetros usados no cálculo dos coeficientes AR, derivações que têm seus coeficientes calculados, número de ciclos e amostras selecionadas.

Quando selecionamos a opção “Treino” (destaque marcado com **1** da Figura 5.1), devemos selecionar a derivação para o traçado nos gráficos. A seguir o aplicativo disponibiliza as cardiopatias a serem selecionadas, após essa seleção o sistema carrega todas as amostras disponíveis para esta cardiopatia e assim, podemos clicar sobre uma delas para efetuar a seleção, conforme ilustramos no destaque marcado com **2** da Figura 5.1.

A etapa seguinte é informamos os parâmetros para o cálculo dos coeficientes AR (identificados com **3** na Figura 5.1), sendo: janelamento em milissegundos (em relação a referência de início do ciclo), as ordens do modelo AR, a constante de convergência e o erro mínimo. Em seguida temos a seleção das derivações que terão suas características extraídas para o treinamento da rede. Essas derivações foram definidas tendo com base o trabalho de Rangel, 2006, onde são classificadas as derivações com melhor qualidade na separação dos ciclos (precisão na detecção da onda R e inexistência de falsos positivos ou falsos negativos).

As amostras selecionadas, com o número de ciclos informado (marcado com **4** na Figura 5.1) têm suas características registradas em um arquivo de saída em formato texto no instante em que o botão “Fixa atual” for acionado.




Figura 5.1 – Corte da Interface do software Classificador de Cardiopatias – área de seleção de parâmetros e amostras a ter suas características extraídas pelo modelo AR customizado, para treinamento da rede.

Neste cenário, onde escolhemos realizar os testes com apenas um ciclo para cada amostra, experimentamos cada um deles com quatro diferentes ordens, na geração dos coeficientes sendo eles: dez oito e seis. Para o janelamento do ciclo realizamos os testes com dois segmentos diferentes, sendo: o ciclo completo de 20 a 600 ms e o trecho procurando conter o complexo QRS e suas adjacências (de 40 ms à 400 ms). As derivações utilizadas foram DIII, aVR, aVF, v1, v2 e v3 (apontadas como as mais indicadas no trabalho de Rangel, 2006) e a partir de seus ciclos, os coeficientes foram calculados para geração da entrada na rede neural.




Figura 5.2 – Gráficos com o traçado dos ciclos de cada uma das derivações em “Derivações do ECG Selecionado” e a curva original e a gerada pela aplicação dos coeficientes calculados em “AR x Derivação Selecionada”.

Na Figura 5.2, observamos dois gráficos com informações sobre o ciclo selecionado onde o primeiro é o “Derivações do ECG Selecionado”, gráfico que traz as curvas do ciclo em cada derivação escolhida. Nele podemos observar o formato característico de cada derivação selecionada, todos em fase. O segundo gráfico “AR x Derivação Selecionada” mostra a curva do ciclo original e o resultado da curva reconstruída com a aplicação dos coeficientes calculados pelo modelo AR. Esta curva corresponde à última amostra na derivação escolhida na área de parâmetros “Derivação”.




Figura 5.3 – Gráfico em zoom do registro dos coeficientes AR sobre a curva do ciclo original, em vermelho o resultado do cálculo do modelo AR e em azul a curva original de ECG.

Na Figura 5.3 temos o zoom do gráfico “AR x Derivação Seleccionada” ilustrado na Figura 5.2, o gráfico tem como objetivo mostrar a reconstrução da curva original utilizando os coeficientes calculados pelo modelo AR, temos em azul o registro da curva original e em vermelho, a curva reconstruída. Esse gráfico foi idealizado para confrontação da curva original e a reconstruída.




Figura 5.4 – Interface com o experimento de um ciclo por amostra.

A Figura 5.4 apresenta uma visão completa da interface do software “Classificador de Cardiopatias”, com o processamento dos ciclos das amostras utilizadas no treinamento da rede neural.

O gráfico “Índices do Modelo AR”, da Figura 5.4, tem como objetivo traçar os coeficientes calculados de cada amostra. A opção existente na Figura 5.4 “Montar arquivo para a Rede Neural”, processa o tratamento do arquivo texto criado na opção “Salvar...”, transformando-o em um arquivo com o formato no padrão esperado pelo *software Matlab* para utilização nas fases de treino, validação e reconhecimento. Nesse momento há também a gravação do arquivo com os alvos de entrada na rede para uso na fase de treino.

Após a geração dos dados para entrada e alvo no aplicativo mostrado na Figura 5.4, utilizamos o *Matlab* para o processamento da rede neural artificial, que realiza o treinamento da RNA deixando-a pronta para o reconhecimento das amostras.

As topologias utilizadas na construção da rede neural artificial (descrita no Capítulo 4), testaram três possibilidades diferentes para os neurônios de entrada: dez, oito e seis coeficientes. Para a camada intermediária utilizamos quatorze neurônios e para a camada de saída dois neurônios de forma que suas combinações indicam o resultado da rede.

Utilizamos o treinamento supervisionado para a RNA, com base nos alvos estabelecidos. Na Figura 5.5 temos o gráfico com o resultado do treinamento de um grupo de amostras, de ordem dez e janelamento do ciclo de 20 a 600 ms. O treinamento teve como ponto de parada o erro mínimo quadrático de 0,01 ou 100 épocas de processamento. Estes números foram estipulados com base em experimentos publicados [ANDRADE, Adriano de Oliveira. 2000.] [BAXT, WG; et al. 2004.] [SOARES, Alcimar Barbosa; et al. 2003.].