

ALFREDO BECKERT NETO

**DETECÇÃO AUTOMÁTICA DE ARRITMIA
CARDÍACA UTILIZANDO WAVELET E REDES
NEURAIS TREINADAS COM OTIMIZAÇÃO
POR NUVEM DE PARTÍCULAS**

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

CURITIBA

2009

ALFREDO BECKERT NETO

**DETECÇÃO AUTOMÁTICA DE ARRITMIA
CARDÍACA UTILIZANDO WAVELET E REDES
NEURAIS TREINADAS COM OTIMIZAÇÃO
POR NUVEM DE PARTÍCULAS**

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

Área de atuação: Descoberta do Conhecimento
e Aprendizagem de Máquina

Orientador: Prof. Julio Cesar Nievola, PhD

CURITIBA

2009

Agradecimentos

Primeiramente gostaria de agradecer ao orientador Prof. Dr. Júlio Cesar Nievola, por me motivar, ensinar e me aconselhar com sua grande experiência em meio acadêmico.

Saliento o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), que me concedeu uma bolsa de estudos.

Agradeço também a toda equipe da Pontifícia Universidade Católica do Paraná que contribuiu com minha formação acadêmica, ética e responsável.

Agradeço também aos meus amigos e sócios Marcus Vinícius Mazega Figueredo e Sérgio Renato Rogal Jr., que me apóiam e auxiliam em todos os meus projetos, fazendo papel de irmãos em algumas ocasiões.

Também gostaria de agradecer à Naiara Niesciur pela compreensão e o companheirismo nos momentos em que precisei devido a este trabalho.

Dedico um agradecimento especial aos meus pais Alfredo e Mara, minha irmã Monique e ao meu cunhado Rafael, assim como aos meus amigos que estiveram me incentivando todos os momentos a concluir este trabalho.

Finalmente, gostaria de agradecer a todos que direta ou indiretamente colaboraram na execução deste trabalho e que não foram citados nas linhas anteriores desta página.

Sumário

Agradecimentos.....	iii
Lista de Figuras	vii
Lista de Tabelas.....	ix
Lista de Abreviaturas	xi
Resumo.....	xiii
<i>Abstract</i>	xv
Introdução.....	1
1.1. Motivação.....	1
1.2. Objetivos	2
1.3. Contribuições Esperadas	3
1.4. Organização do Documento.....	3
Descrição do Problema.....	4
2.1 O Coração.....	4
2.2. Eletrocardiograma (ECG)	6
2.3. Arritmia Cardíaca.....	13
2.4. Normalização do Sinal de ECG	17
2.5. Wavelet.....	17
2.5.1. Transformada Wavelet Contínua	18
2.5.2. Transformada Wavelet Discreta.....	20
2.6. Redes Neurais Artificiais	23
2.7. Otimização por Nuvem de Partículas (PSO).....	27
2.8. Algoritmo do PSO.....	28
Revisão de Literatura	35
Metodologia	43
4.1. Panorama Geral	43
4.1.1. Base de Dados	46
4.1.2. Segmentação.....	48

4.1.3. Aplicação da Transformada Wavelet.....	49
4.1.4. Formação dos Grupos e dos Conjuntos	50
4.1.5. RNA	50
4.1.6 Algoritmo PSO	52
4.1.7. Validação	56
Resultados e Discussão	61
5.1. Teste T de Student	71
5.2. Conclusão	75
Conclusão	77
Referências	81

Lista de Figuras

Figura 2.1: O coração (BUTTON, 2007).....	5
Figura 2.2: Formato do Eletrocardiograma (adaptado de (ELECTROCARDIOGRAMA, 2007)).	7
Figura 2.3: Exemplo de Eletrocardiograma (ECG, 2007).	8
Figura 2.4: Triângulo de Einthoven (BUTTON, 2007).....	9
Figura 2.5: Pontos de derivações sobre o peito (BUTTON, 2007).....	10
Figura 2.6: Exemplo de ECG da base de dados <i>MIT-BH</i> (PHYSIONET, 2007).	11
Figura 2.7: Exemplo de ECG com arritmia da base de dados <i>MIT-BH - Arrhythmia Database</i> (PHYSIONET, 2007).	12
Figura 2.8: Exemplo de ECG com taquicardia ventricular (área tracejada) (PHYSIONET, 2007).	14
Figura 2.9: Exemplo de ECG com fibrilação atrial (área tracejada) (PHYSIONET, 2007).....	15
Figura 2.10: Exemplo de ECG com flutter ventricular (área tracejada) (PHYSIONET, 2007).....	16
Figura 2.11: Exemplo de onda F na fibrilação atrial (área tracejada) (PHYSIONET, 2007).....	16
Figura 2.12: Diferentes famílias de Wavelets: (a) Daubechies; (b) Coiflet; (c) Haar; e, (d) Symmlet (GRAPS, 1995).....	19
Figura 2.13: Transformada Wavelet Discreta com três níveis (PEREIRA; NABETA, 2007).....	21
Figura 2.14: Família Daubechies (SILVA, 2006).	22
Figura 2.15: Estrutura básica do neurônio cerebral (LINHARES; GEWANDSZNAJDER, 1997).	23
Figura 2.16: Estrutura do neurônio artificial.	24
Figura 2.17: Estrutura de uma rede neural artificial MLP.....	25

Figura 2.18: Inicialização aleatória das partículas no espaço (MEDEIROS, 2005). ...	29
Figura 2.19: Vetores de velocidade das partículas (SARAMAGO; PRADO, 2005)...	31
Figura 2.20: Esboço do algoritmo PSO (ROJAS; VIANA; RADE, 2004).....	32
Figura 4.1: Visão geral.	44
Figura 4.2: Primeira abordagem de classificação dos sinais.	45
Figura 4.3: Segunda abordagem de classificação dos sinais.	45
Figura 4.4: ECG analisado com janela fixa.....	49
Figura 4.6: Aplicação Implementada para Formar a Rede Neural Evoluída através do PSO.....	51
Figura 4.7: Aplicação com o campo de resultados.....	54
Figura 4.8: O campo de resultados com indicações.	55
Figura 4.9: Nuvem de redes neurais.....	55

Lista de Tabelas

Tabela 2.1: As 12 derivações.....	10
Tabela 2.2: Exemplo dos dados da base <i>MIT-BH - Arrhythmia Database</i>	12
Tabela 3.1: Tabela de resultados da classificação dos sinais [adaptada de (OSOWSKI; HOAI, 2004)]......	37
Tabela 4.1: Exemplo dos dados da base <i>MIT-BH - Arrhythmia Database</i>	47
Tabela 4.2: Siglas do arquivo de anotações dos dados da base <i>MIT-BH - Arrhythmia Database</i>	47
Tabela 4.3: Exemplo das anotações dos dados da base <i>MIT-BH - Arrhythmia Database</i>	48
Tabela 4.4: Redes neurais implementadas e testadas no trabalho.	52
Tabela 4.5: Trabalhos comparados com as taxas de acerto deste trabalho.....	56
Tabela 5.1: Resultados obtidos das RNAs 120-50-4-a1, 120-100-4-a1 e 120-150-4-a1.	61
Tabela 5.2: Resultados obtidos das RNAs 120-50-3-a2, 120-100-3-a2 e 120-150-3-a2.	62
Tabela 5.3: Resultados obtidos da RNA 120-50-2-a2, 120-100-2-a2 e 120-150-2-a2.	63
Tabela 5.4: Resultados obtidos da 120-100-3-a2 X 120-150-2-a2.....	63
Tabela 5.5: Resultados obtidos das RNAs 100-50-4-a1, 100-100-4-a1 e 100-150-4-a1.	64
Tabela 5.6: Resultados obtidos das RNAs 100-50-3-a2, 100-100-3-a2 e 100-150-3-a2.	64
Tabela 5.7: Resultados obtidos das RNAs 100-50-2-a2, 100-100-2-a2 e 100-150-2-a2.	64
Tabela 5.8: Resultados obtidos da RNA 100-150-3-a2 X RNA 100-100-2-a2.....	65
Tabela 5.9: Resultados obtidos por tipo de sinal da RNA 120-150-3-a2.	66
Tabela 5.10: Resultados obtidos por tipo de sinal da RNA 120-150-4-a1.	66

Tabela 5.11: Resultados obtidos por tipo de sinal da RNA 100-150-3-a2.....	67
Tabela 5.12: Resultados obtidos por tipo de sinal da RNA 100-100-4-a1.....	68
Tabela 5.13: Resultados obtidos por trabalhos da área que classificam também o flutter ventricular.....	69
Tabela 5.14: Resultados obtidos por trabalhos da área que classificam arritmias exceto o flutter ventricular.....	70
Tabela 5.15: Resultados obtidos com o teste T de Student comparando as abordagens.	71
Tabela 5.16: Resultados obtidos com o teste T de Student utilizando quantidade diferente de amostras.....	72
Tabela 5.17: Resultados obtidos com o teste T de Student utilizando quantidade de amostras diferentes na primeira abordagem para cada sinal.	73

Lista de Abreviaturas

AV	Atrioventricular
BbNN	<i>Block-based Neural Network</i>
BPM	Batimentos por Minuto
CE	Computação Evolucionária
ECG	Eletrocardiograma
FMC	Federação Mundial do Coração
MLP	<i>Multilayer Perceptron</i>
MOPSO	<i>Multiple Objective Particle Swarm Optimization</i>
PSO	<i>Particle Swarm Optimization</i>
RNA	Rede Neural Artificial
SA	Sinoatrial
TV	Taquicardia Ventricular
TWD	Transformada <i>Wavelet</i> Discreta
VEBs	<i>Ventricular Ectopic Beats</i>
Vp	Verdadeiros Positivos

Resumo

As doenças cardíacas são a principal causa de morte no mundo. A vida sedentária e a alimentação deficiente da maioria da população fazem com que as pessoas estejam com sua saúde cardíaca debilitada. Por isso, detectar automaticamente e de forma eficaz as arritmias cardíacas é um desafio de extrema importância.

Este trabalho apresenta a utilização de técnicas de otimização por nuvem de partículas (PSO), redes neurais e *Wavelet* para a detecção automática de arritmias cardíacas baseada na análise do eletrocardiograma (ECG). O sinal de ECG será avaliado no domínio tempo-frequência utilizando *Wavelets*. Os coeficientes *Wavelet* são apresentados à entrada de uma rede neural MLP de três camadas, a qual é treinada (otimização dos pesos) pelo algoritmo de PSO. A rede treinada foi capaz de classificar o sinal de ECG em sinal normal, fibrilação atrial, taquicardia ventricular e flutter ventricular. A base de dados utilizada pela pesquisa é a *MIT-BIH - Arrhythmia Database*. A taxa de acerto obtida foi de 86,58% para a classificação dos quatro tipos de sinais e de 97,03% para a base sem o flutter ventricular, classificando somente o sinal como fibrilação atrial, taquicardia ventricular e normal.

Palavras-Chave: Otimização por Nuvem de Partículas, Detecção de Arritmia, ECG, RNA.

Abstract

Heart diseases are leading causes of deaths worldwide. Sedentary lifestyle and poor diet of most of the population means that people should be careful about their heart health. Therefore, the automatic and effective detection of heart arrhythmias represents a challenge of paramount importance. This paper presents the use of particle swarm optimization (PSO), neural networks and Wavelet transforms for automatic detection of cardiac arrhythmias based on analysis of the electrocardiogram (ECG). The ECG signal is evaluated in time-frequency domain using Wavelets. Wavelet coefficients are presented to the entry of an MLP neural network of three layers, which is trained (weights optimization) by PSO algorithm. The trained network was able to classify the ECG signal in normal signal, atrial fibrillation, ventricular tachycardia and ventricular flutter. The utilized database was the MIT-BIH - Arrhythmia Database. The rate of accuracy obtained was 86.50% for the classification of four signal types and 97.8% for the base without ventricular flutter, describing only atrial fibrillation, ventricular tachycardia and normal.

Keywords: *Particle Swarm Optimization, Arrhythmia Detection, ECG, RNA.*

Capítulo 1

Introdução

Este documento apresenta uma pesquisa sobre a aplicação das técnicas de Otimização por Nuvem de Partículas (KENNEDY; EBERHART, 1995), *Wavelets* e Redes Neurais Artificiais combinadas para realizar a detecção automática de arritmias cardíacas, utilizando-se da análise do ECG.

1.1. Motivação

As doenças cardíacas e infartos são as razões da morte de aproximadamente 17,5 milhões de pessoas por ano no mundo (WORLD, 2002). Com isso, são as principais causas de mortalidade no mundo, segundo a Federação Mundial do Coração (FMC). A ONG FMC destacou que 80% dessas mortes ocorrem em países com nível de renda médio e baixo (WORLD, 2002), caso do Brasil. Este número vem aumentando devido ao sedentarismo, má qualidade da alimentação, estresse, e outros problemas comuns na cultura de um mundo capitalista globalizado.

O coração trabalha em certo ritmo, com um compasso determinado, podendo variar de acordo com o esforço físico, emoções, alterações metabólicas etc. Dessa forma quando um indivíduo está se exercitando o coração aumenta o ritmo do batimento, com o objetivo de enviar maior quantidade de sangue para as células, exigido pelo esforço despendido. Mas nem em todos os casos acontece isto. Certas pessoas apresentam o coração com batimento fora do ritmo ou descompassado sem motivo aparente. Ele pode apresentar aceleração repentino não desencadeado por esforço físico ou pode apresentar ritmo totalmente aleatório (fibrilação atrial). Estas alterações do ritmo cardíaco são denominadas de Arritmias Cardíacas, objeto de detecção da técnica proposta.

Poder antecipar ao máximo a descoberta de alguma disfunção cardíaca pode prevenir a morte súbita do paciente. Com o crescimento do número de pacientes, cada vez mais os métodos automáticos de diagnósticos são necessários para auxiliar os médicos. Um dos caminhos para este diagnóstico é utilizar o sinal de ECG. A alteração e distúrbios das ondas do ECG podem indicar uma possível arritmia.

A formulação de um algoritmo que em poucos segundos consiga detectar qualquer tipo de doença é um desafio para a ciência. Por isso, este trabalho explora uma técnica ainda não utilizada para a detecção de arritmias cardíacas, contribuindo assim com a pesquisa nesta área.

1.2. Objetivos

Tendo em vista a dificuldade de se implementar algoritmos que possuem taxas de 100% de acerto e que tenham resposta em tempo real, será criado um método que analisará o ECG e utilizando-se de uma rede neural treinada com a técnica de otimização por nuvem de partículas, classificará o sinal de ECG como normal ou possuidor de um dos três tipos de arritmias abordadas por este trabalho. As arritmias são: Taquicardia Ventricular, Fibrilação Atrial e Flutter Ventricular. A base de dados utilizada será a MIT-BIH - *Arrhythmia Database*. Pretende-se avaliar neste trabalho a taxa de acerto, comparando-a com a de outros trabalhos. Uma comparação também será feita em relação ao número de amostras utilizadas para a classificação, assim como o número de neurônios na camada intermediária das RNAs.

O objetivo principal do trabalho é desenvolver um algoritmo de classificação de sinais de ECG com arritmia, utilizando os conceitos cooperativos de Nuvem de Partículas (KENNEDY; EBERHART, 1995) para realizar a evolução de uma rede neural artificial, e esta realizará a classificação do sinal.

1.2.1. Objetivos Específicos

Os objetivos específicos compreendem:

- Implementar um método de pré-processamento do sinal baseado em *Wavelet* e normalização.
- Implementar uma rede neural MLP treinada pelo PSO.
- Definir coeficientes adequados ao funcionamento do algoritmo PSO.
- Utilizar a rede resultante para classificar os sinais da base de dados em: sinal saudável, Taquicardia Ventricular, Fibrilação Atrial e Flutter Ventricular.

- Comparar os resultados obtidos através das métricas do método proposto com as de outros métodos encontrados na literatura.

1.3. Contribuições Esperadas

As seguintes contribuições são esperadas após esta pesquisa:

- Validar ou não o método de PSO para a evolução de redes neurais para a classificação de sinais de ECG.
- Disponibilizar a técnica de detecção automática de arritmias cardíacas proposta para que futuramente possa ser implantada em sistemas de monitoração remota de pacientes.
- Comparações da técnica abordada em relação a outras pesquisas científicas, para que com isso, novos trabalhos possam utilizar as informações geradas pelas comparações.

1.4. Organização do Documento

O presente trabalho está organizado em seis capítulos. O capítulo 2 apresenta os conceitos técnicos necessários para a compreensão do trabalho proposto. Os conceitos principais são: eletrocardiograma, arritmia cardíaca, *Wavelet*, RNA e otimização por nuvem de partículas.

O capítulo 3 mostra a revisão da literatura sobre pesquisas onde é abordado o tema de classificação ou detecção de arritmias cardíacas utilizando o ECG.

O capítulo 4 apresenta a metodologia proposta para a realização do objetivo do trabalho.

O capítulo 5 apresenta os resultados obtidos por este trabalho.

O capítulo 6 descreve a conclusão do trabalho realizado.

Capítulo 2

Descrição do Problema

Neste capítulo são apresentados os conceitos necessários para a compreensão do problema, tendo como finalidade prover o leitor de informações técnicas relevantes para o entendimento do trabalho. O problema consiste na detecção automática de arritmias cardíacas através do ECG utilizando a técnica de otimização por nuvem de partículas para evoluir redes neurais MLP.

2.1 O Coração

O coração é um órgão localizado na parte central do peito, sob o osso esterno, ligeiramente deslocado para a esquerda que se apresenta como uma bomba muscular, cuja função primária é impulsionar o sangue, para todas as partes do corpo através de um sistema fechado de vasos sanguíneos (GRAY, 1979).

O coração humano apresenta quatro cavidades: duas superiores, denominadas átrios (ou aurículas) e duas inferiores, denominadas ventrículos. O átrio esquerdo comunica-se com o ventrículo esquerdo através da válvula bicúspide ou mitral. Já o átrio direito comunica-se com o ventrículo direito através da válvula tricúspide. As válvulas cardíacas têm como função garantir que o sangue siga uma única direção, sempre dos átrios para os ventrículos.

Na figura 2.1 são indicadas as quatro câmaras do coração: átrios esquerdo e direito e ventrículos esquerdo e direito; a veia cava superior; e o sistema de condução elétrico do coração: nodos sino-atrial ou sinusal (SA) e atrioventricular (AV), redes de Purkinje e feixe de His.




Figura 2.1: O coração (BUTTON, 2007).

As câmaras cardíacas dilatam-se e contraem-se alternadamente cerca de 70 vezes por minuto. O processo de contração de cada câmara do miocárdio denomina-se sístole e o relaxamento, que acontece entre uma sístole e a seguinte, chama-se diástole.

O nódulo sinoatrial (SA) ou marca-passo é uma estrutura anatômica localizada perto da junção entre o átrio direito e a veia cava superior, sendo constituído por um aglomerado de células musculares especializadas (GUYTON; HALL, 2006). Ele realiza uma atividade especial, atuando como um marca-passo e controlando a frequência dos batimentos cardíacos (GONÇALVES, 1995). As fibras musculares do nódulo SA possuem uma frequência de aproximadamente 72 contrações por minuto, sendo que o músculo atrial se contrai cerca de 60 vezes por minuto e o músculo ventricular, em torno de 20 vezes por minuto. Sendo a frequência do nódulo SA maior em relação às outras partes do coração, os impulsos gerados neste nódulo espalham-se para os átrios e ventrículos, excitando essas áreas de forma tão rápida, que o ritmo do nódulo SA torna-se o ritmo de todo o coração. Por este fato, o nódulo SA é chamado de marca-passo (GUYTON; HALL, 2006).

O Sistema De Purkinje ou fascículo átrio-ventricular é um sistema especial de condução, que possui fibras musculares cardíacas especializadas, ou fibras de Purkinje (Feixe

de His), que transmitem os impulsos com uma velocidade aproximadamente seis vezes maior do que o músculo cardíaco normal, variando de 1,5m/s até 4m/s.

2.2. Eletrocardiograma (ECG)

Introduzido por Eithoven em 1902, o eletrocardiograma (ECG) consiste no registro dos fenômenos elétricos que se originam durante a atividade cardíaca (FELDMAN; GOLDWASSER, 2004). Ele é um auxílio importante no diagnóstico de um grande número de cardiopatias e outras condições patológicas. Porém sabe-se que algumas anomalias cardíacas não alteram o ECG e por isso, ele é considerado um exame complementar.

O eletrocardiograma é um exame bastante utilizado, devido à sua praticidade e seu baixo custo (SOCIEDADE BRASILEIRA DE CARDIOLOGIA, 2003). O médico pode realizá-lo no consultório, durante a consulta do paciente. Entretanto, esse exame só permitirá o diagnóstico de uma arritmia se for realizado no momento da ocorrência da mesma. Em casos de emergência, a identificação da arritmia se torna nítida, agilizando a indicação do tratamento.

O registro das atividades elétricas cardíacas é realizado através de um equipamento denominado de eletrocardiógrafo. Este tem seu funcionamento baseado em um galvanômetro (aparelho que mede a diferença de potencial elétrico entre dois pontos) que determina pequenas intensidades de corrente elétrica através de dois eletrodos (pequenas placas de metal conectadas a um fio condutor) dispostos em pontos pré-definidos do corpo humano.

A figura 2.2 representa um sinal de ECG, que é formado pela onda P, complexo QRS e a onda T. Existem também segmentos e intervalos que são utilizados para a análise da onda.

A ativação do miocárdio auricular produz a onda P. No ritmo sinusal, a parte inicial da onda P representa a ativação da aurícula direita e a parte final da onda P representa a ativação da aurícula esquerda. Os ventrículos não podem ser diretamente alcançados pelos impulsos auriculares, devido à existência de um tecido conjuntivo que separa os ventrículos das aurículas. Somente através do nó aurículo-ventricular (AV), localizado na aurícula direita junto da válvula tricúspide, o impulso pode passar normalmente. A partir deste nó o impulso atravessa o feixe de His.

O impulso despolariza o nó AV, o feixe de His, os ramos do feixe, a rede de Purkinje e o miocárdio ventricular. A propagação deste impulso através do nó AV e feixe de His não é

registrada no ECG e acontece durante o segmento isoelétrico PR. O complexo QRS é gerado pela despolarização do músculo ventricular.

A repolarização ventricular, que se segue ao complexo QRS, é registrada no ECG, gerando a onda T (CHAVES; MOREIRA, 2001).

Eventualmente a onda U pode ser registrada pelo ECG, encontrando-se após a onda T. A onda U possui uma curta duração, baixa amplitude, forma arredondada e mesma polaridade da onda T.




Figura 2.2: Formato do Eletrocardiograma (adaptado de (ELECTROCARDIOGRAMA, 2007)).

Como indicado na figura 2.3, no registro eletrocardiográfico utiliza-se um papel quadriculado que é dividido em pequenos quadrados de 1mm de lado. Um agrupamento de cinco quadrados na horizontal e vertical compreende um quadrado maior, que é demarcado por uma linha de maior espessura. O eixo vertical representa a tensão elétrica, sendo que cada quadrado menor equivale a 0,1mV. Já o eixo horizontal retrata o tempo, cada quadrado menor equivalendo a 0,04s. Conseqüentemente o quadrado maior representa no eixo do tempo 0,2s e no eixo da tensão elétrica 0,5mV, como mostrado na figura 2.3.




Figura 2.3: Exemplo de Eletrocardiograma (ECG, 2007).

Os principais pontos que devem ser analisados em cada ECG são (PDAMED, 2007):

- Frequência cardíaca: é a quantidade de vezes que o coração bate por minuto.
- Ritmo: sucessão dos batimentos cardíacos.
- Intervalo PR: componente de um traçado do ECG que reflete a condução de um impulso elétrico através do nódulo AV.
- Complexo QRS: deflexão eletrocardiográfica que representa a despolarização ventricular. A deflexão inferior inicial é denominada onda Q; a deflexão inicial superior, onda R, e a deflexão inferior seguinte à onda R é denominada onda S.
- Onda P: uma característica do ECG que reflete a condução de um impulso elétrico através do átrio; despolarização atrial.
- Eixo elétrico médio do QRS.
- Onda T: uma característica do ECG que reflete a repolarização dos ventrículos.
- Onda U: uma característica do ECG que pode refletir a repolarização da fibra de Purkinje; geralmente observada quando o nível sérico de potássio do paciente é baixo.

Um ECG considerado saudável se enquadra nas seguintes características:

- Frequência cardíaca: 60-100 batimentos/min
- Ritmo cardíaco comandado pelo nó sinusal
- Onda P: duração < 0,12s / amplitude < 0,25mV
- Intervalo PR: 0,12s - 0,20s
- Segmento PR: 0,1s

- Intervalo QRS: 0,04s – 0,12s / 0,5mV - 1mV
- Intervalo QT: 0,39s – 0,42s
- Eixo elétrico médio: $+70^\circ$
- As derivações precordiais apresentam uma progressão normal da onda R

As ondas de despolarização e repolarização que se propagam pelas fibras cardíacas podem ser consideradas dipolos em movimento como momentos dipolares variáveis. Estes dipolos determinam campos elétricos variáveis que podem ser detectados pela medida da diferença de potencial através de eletrodos colocados na superfície cutânea.

O potencial medido no pulso ou sobre o tórax é praticamente o mesmo. O corpo oferece uma baixa resistência para a corrente elétrica. Para facilitar a padronização, os eletrodos correspondentes ao triângulo de Einthoven (figura 2.4) são colocados sobre os pulsos (RA e LA) e no tornozelo esquerdo (LL).




Figura 2.4: Triângulo de Einthoven (BUTTON, 2007).

As 12 derivações clássicas são obtidas através dos sinais captados por nove eletrodos: um na perna esquerda, dois nos braços e seis sobre o peito (apresentados na figura 2.5). Para

reduzir a interferência externa, utiliza-se um eletrodo adicional normalmente colocado na perna direita (RL).




Figura 2.5: Pontos de derivações sobre o peito (BUTTON, 2007).

O sistema padrão de 12 derivações inclui três colocações diferentes de eletrodos: derivação bipolar, aumentada e precordial, como mostrado na tabela 2.1. A primeira coluna da tabela 2.1 representa o tipo de derivação, a segunda representa em que local o eletrodo deve ser usado e a terceira coluna define cada uma das derivações.

Tabela 2.1: As 12 derivações

Tipo de derivação	Eletrodos utilizados	Definição
Bipolar ou derivação de membros (Goldberger)	LA, RA, LL, RL	$I = LA - RA$
		$II = LL - RA$
		$III = LL - LA$
Aumentada ou derivação unipolar de extremidade	LA, RA, LL, RL	$aVR = RA - \frac{1}{2}(LA + LL)$
		$aVL = LA - \frac{1}{2}(LL + RA)$
		$aVF = LL - \frac{1}{2}(LA + RA)$
Unipolares precordias (Wilson)	V1, V2, V3, V4, V5 e	$V1 = v1 - (RA+LA+LL)/3$
	V6 (mais um em cada braço,	$V2 = v2 - (RA+LA+LL)/3$
	um em cada perna, sendo a	$V3 = v3 - (RA+LA+LL)/3$
	direita aterrada; eletrodo	$V4 = v4 - (RA+LA+LL)/3$
	explorador = V_i , com i sendo	$V5 = v5 - (RA+LA+LL)/3$
	entre um e seis, uma das	

posições pré-cordiais)

$$V6 = v6 - (RA+LA+LL)/3$$

Neste trabalho, uma das derivações utilizadas pela base de dados é uma modificação da DII denominada de MLII (modified lead II).

Como foi abordado anteriormente, o eletrocardiograma padrão possui 12 derivações de ondas, porém nesta pesquisa apenas uma derivação foi utilizada, a primeira disponibilizada pela base de dados, pois a base possui apenas duas derivações e as derivações variam entre cada paciente. Esta derivação utilizada já é suficiente para detectar diversas arritmias cardíacas.

A avaliação do sinal de ECG é um assunto bastante explorado pela comunidade científica e por isso, inúmeros trabalhos já foram desenvolvidos. Nesta pesquisa, será utilizada a base *MIT-BH - Arrhythmia Database* (será melhor comentada no capítulo 4), onde a onda R já está “anotada” e o ECG possui apenas duas derivações. Mostra-se um exemplo da base de dados na figura 2.6.




Figura 2.6: Exemplo de ECG da base de dados *MIT-BH* (PHYSIONET, 2007).

A representação deste sinal também pode ser visualizada na tabela 2.2, e esta será a entrada do sistema. Os dados apresentados correspondem ao valor que o sinal de ECG possui

no instante de tempo (referenciado pela primeira coluna da tabela 2.2), nas duas derivações, MLII e V5.

Tabela 2.2: Exemplo dos dados da base *MIT-BH - Arrhythmia Database*.

time	MLII	V5
(sec)	(mV)	(mV)
400.000	-0.335	-0.200
400.003	-0.340	-0.210
400.006	-0.360	-0.205
400.008	-0.350	-0.200
400.011	-0.340	-0.190

A figura 2.7 representa um sinal com arritmia (fibrilação atrial), podendo-se notar uma diferença razoável (indicada pelo retângulo tracejado na figura 2.7) entre o sinal saudável (figura 2.6) e o da figura 2.7. O ECG deixa de ter seu formato padrão (figura 2.6), ficando clara uma disfunção cardíaca.




Figura 2.7: Exemplo de ECG com arritmia da base de dados *MIT-BH - Arrhythmia Database* (PHYSIONET, 2007).

2.3. Arritmia Cardíaca

As arritmias cardíacas são distúrbios ocasionados por alterações na formação e/ou condução do impulso elétrico através do tecido do miocárdio, podendo, assim, modificar a origem e/ou a difusão fisiológica do estímulo elétrico do coração, motivo pelo qual têm no eletrocardiograma o método de escolha para seu estudo e diagnóstico. As alterações na velocidade da propagação do estímulo elétrico, isoladamente, levando a bloqueios dos fascículos ou ramos, não são consideradas arritmias cardíacas (SOCIEDADE BRASILEIRA DE CARDIOLOGIA, 2003).

A frequência normal dos batimentos cardíacos é de 60 até 100 batidas por minuto. Essa frequência tende a ser mais elevada em crianças. As arritmias são alterações do ritmo cardíaco normal (GONÇALVES, 1995). Estas alterações do ritmo e da frequência cardíaca podem ser percebidas e registradas.

As arritmias cardíacas representam um grupo de perturbações do ritmo cardíaco, entre os quais estão incluídas diversas doenças, sendo algumas bastante raras e outras muito comuns. A patologia cardíaca pode afetar indivíduos de qualquer idade, não importando o sexo, etnia e muito menos estar ou não associada a outras doenças cardíacas.

Existem duas categorias para as arritmias: elas podem ser assintomáticas (sem sintomas ou sinais) ou sintomáticas, dependendo de sua intensidade e da situação clínica do indivíduo. Os corações doentes não se portariam bem em caso de uma arritmia, onde provavelmente, seria assintomática para um coração sadio. Por sua vez, as arritmias também são classificadas em relação a outros aspectos, tal como a frequência cardíaca. Em relação à frequência, as arritmias podem ser classificadas em dois grupos:

- Bradicardia: sucede quando a frequência cardíaca é menor que 60 batimentos por segundo (GUYTON; HALL, 2006). No caso de atletas e em algumas pessoas, a bradicardia pode ser considerada como normal. Para o seu tratamento são utilizados marca-passos cardíacos.
- Taquicardia: sucede quando a frequência cardíaca é maior que 100 batimentos por minuto. Ao realizar esforços físicos sua ocorrência é considerada normal, porém após alguns minutos depois do término da atividade física, a frequência cardíaca deve se restabelecer ao nível saudável. Quando isso não acontece ou

se em repouso apresenta-se taquicardia, isto pode indicar a existência de alguma patologia.

Como sintoma as arritmias apresentam comumente a palpitação¹, que pode ocorrer tanto nas taquicardias quanto nas bradicardias. O mal-estar, a falta de ar, a síncope (desmaio) e outros sintomas, dependendo de qual doença o indivíduo possuir, também podem representar sinais da arritmia cardíaca (ARRITMIA, 2007). Em alguns casos de arritmias mais severas, o paciente pode sentir fraqueza, confusão mental, dor no peito (angina), hipotensão (pressão baixa), tratando-se então de uma emergência médica e sendo necessário o tratamento imediato para que não ocorra a morte do enfermo. As figuras 2.8, 2.9 e 2.10 apresentam ECGs que possuem tipos de arritmias distintos, sendo a taquicardia ventricular, fibrilação atrial e o flutter ventricular, respectivamente.




Figura 2.8: Exemplo de ECG com taquicardia ventricular (área tracejada)
(PHYSIONET, 2007).

A Taquicardia ventricular (TV), exemplificada através da figura 2.8, normalmente tem a frequência cardíaca entre 150 a 200 batimentos por minuto (TAQUICARDIA a, 2007). A TV existe quando o nó SA perde o controle de sua função de sinalização, e com isso, uma nova área nos ventrículos assume a tarefa de sinalização. Esta nova sinalização não percorre o músculo cardíaco normalmente, fazendo com que este músculo não se contraia de forma adequada. Sua presença faz com que os batimentos do coração se tornem mais rápidos, portanto, o coração bombeia menor quantidade de sangue a cada contração, pois o tempo é muito curto para o enchimento de sangue do coração entre cada batimento. Com a permanência deste ritmo cardíaco acelerado, a cabeça e o corpo não receberão sangue e oxigenação suficientes. Com isso, a cabeça alertará sobre a necessidade de mais sangue oxigenado gerando sintomas de fraqueza no falar, tontura, escuridão e eventualmente, dor no

¹ Palpitação é a percepção consciente do trabalho cardíaco [PDA07].

coração e a falta de consciência. Geralmente a taquicardia ventricular pode ser tratada ou prevenida através uso de medicamentos (TAQUICARDIA b, 2007).




Figura 2.9: Exemplo de ECG com fibrilação atrial (área tracejada) (PHYSIONET, 2007).

A fibrilação atrial (FA), exemplificada através da figura 2.9, é a arritmia clínica sustentada mais frequentemente encontrada na prática cardiológica, causadora de aproximadamente um terço das hospitalizações por distúrbios do ritmo cardíaco. Ela atinge 0,4% da população geral. A probabilidade de se possuir a FA aumenta com o avanço da idade e, a partir dos 50 anos, duplica a cada década (SOCIEDADE BRASILEIRA DE CARDIOLOGIA, b, 2003).

A fibrilação atrial é caracterizada pela atividade elétrica atrial rápida e desorganizada (RIBEIRO, 2007). A FA consiste em um ritmo secundário à ausência de atividade elétrica atrial organizada, podendo ser visível através do ECG por uma linha de base que pode se apresentar isoelétrica, com irregularidades finas, grosseiras, ou por um misto dessas alterações, as chamadas ondas “F”, apresentadas na figura 2.11. No eletrocardiograma, através das ondas “F”, é possível verificar a atividade elétrica atrial na fibrilação atrial. As ondas “F” possuem frequência entre 450 e 700 ciclos por minuto. A atividade elétrica atrial desorganizada torna as frequências cardíacas irregulares, gerando assim, ciclos RR não constantes (SOCIEDADE BRASILEIRA DE CARDIOLOGIA, 2003).




Figura 2.10: Exemplo de ECG com flutter ventricular (área tracejada) (PHYSIONET, 2007).




Figura 2.11: Exemplo de onda F na fibrilação atrial (área tracejada) (PHYSIONET, 2007).

O Flutter Ventricular (FV), exemplificado através da figura 2.10, não apresenta onda P visível. O complexo QRS e a onda T são fundidos e acabam sendo indistinguíveis. Normalmente a frequência do sinal varia entre 180 e 250 batidas por minuto. O FV é raro de acontecer e normalmente antecede a fibrilação ventricular. Seu ritmo é regular e uniforme.

O FV faz com que as câmaras do coração se contraíam tão rapidamente que existe dificuldade para o sangue encher as câmaras. Neste caso, o coração transporta somente uma pequena quantidade de sangue no corpo, fazendo com que logo o paciente perca a consciência (FLUTTER, 2007).

Existem ainda vários outros tipos de arritmias, em que na maioria deles a anomalia pode ser detectada através do sinal de ECG. Para se fazer a análise do sinal e detectar estas anomalias, deve existir um pré-processamento do sinal para que um sistema digital possa interpretá-lo. Este pré-processamento pode ser realizado de diversas formas e, para sinais que possuem um certo padrão, criar um método de análise de janela variável é uma boa opção prática e eficiente.

2.4. Normalização do Sinal de ECG

A normalização do sinal de ECG consiste em tratar as amostras obtidas do sinal, para gerar a entrada de um sistema inteligente de classificação do sinal de ECG. Esta normalização pode ser realizada através de funções matemáticas. No trabalho (LETTNIN; VARGAS; MACARTHY, 2002) os dados foram normalizados no intervalo de $[0.2, 0.8]$.

Em alguns casos, o método utilizado simplesmente seleciona algumas amostras do sinal e as utiliza como entrada. Os autores do trabalho (OZBAY; KARLIK, 2001) apresentam esta abordagem, utilizando 200 amostras do sinal como entrada para a rede neural utilizada na pesquisa.

Muitos trabalhos não realizam a normalização do sinal, pois efetuam a extração de características do ECG (intervalo RR, frequência cardíaca e outras) e essas características que serão a entrada do sistema. Em outros casos o sinal de ECG é decomposto por transformadas (*Wavelet*, Fourier). No trabalho (PRASAD; SAHAMBI, 2003), os autores utilizam transformadas *Wavelet* para representar o sinal de ECG. Os coeficientes da transformada *Wavelet* discreta (TWD) em conjunto com a informação do intervalo RR formam a entrada para o sistema inteligente.

2.5. Wavelet

Wavelet é uma função capaz de descrever e decompor funções no domínio da frequência, sendo possível a análise em diferentes escalas de tempo e frequência destas funções. A origem da *Wavelet* aconteceu no final dos anos 70 criada por J. Morlet, sendo a base matemática de sua teoria desenvolvida pelo físico teórico Alex Grossmann (DAUBECHIES, 1996).

A decomposição de uma função através da utilização de *Wavelets* é chamada de transformada *Wavelet*. A Transformada *Wavelet* pode ser considerada como uma técnica por

janelas, sendo a dimensão da janela variável, permitindo assim a avaliação do sinal, no espaço tempo x frequência. Também é possível identificar quais componentes espectrais existem em um determinado intervalo de tempo (GRAPS, 1995).

O método de análise por *Wavelets* é baseado na adoção de uma função base *Wavelet*, nomeada de *Wavelets*-mãe, que é utilizada como protótipo para todas as janelas criadas no procedimento. As janelas podem ser transladadas no tempo. Elas são versões comprimidas ou dilatadas da *Wavelet*-mãe (GRAPS, 1995).

Existem dois tipos de transformada *Wavelet*, sendo um a transformada contínua e outro a transformada discreta. Devido à possibilidade da decomposição de funções no domínio do tempo como no de frequência, as funções *Wavelets* possuem uma grande abrangência e poder para a análise e compressão de sinais.

2.5.1. Transformada Wavelet Contínua

A Transformada *Wavelet* Contínua (TWC) é a soma do sinal, multiplicado pela *Wavelet*-mãe em certa escala e deslocada de certa quantidade, no decorrer do tempo. Esta transformada gera coeficientes *Wavelets* que são funções da escala e da posição.

A TWC é usada principalmente em análise e caracterização de detalhes de sinais.

Matematicamente a TWC pode ser definida em $F(a,b)$ como:

$$F(a,b) = \int_{-\infty}^{\infty} f(t)\psi_{a,b}(t)dt \quad (2.1)$$

Na equação 2.2, tem-se como valores reais as variáveis a e b , em que a é um parâmetro de escala (contração ou dilatação) e b é um parâmetro de localização (translação).

A função $\Psi_{a,b}(t)$ é chamada de *Wavelets*-mãe e é definida como:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}}\psi\left(\frac{t-b}{a}\right), \quad a \neq 0, \quad b \in \Re \quad (2.2)$$

O nome *Wavelet* referencia-se a uma "pequena onda finita", e esta é usada como janela de amostragem. A *Wavelet*-mãe é a função-protótipo para gerar várias *Wavelets*, utilizando-se de mudanças de a (escala) e b (translação).

A seguinte propriedade deve ser satisfeita pela *Wavelets*-mãe:

$$\int \psi(t) dt = 0 \quad (2.3)$$

Na TWC a variável translação representa o deslocamento da janela de amostragem ao longo do tempo. A variável de escala é definida como a inversa da frequência, portanto para a possuindo valor menor que 1 a *Wavelet* ψ é uma versão comprimida, com conteúdo de frequência na faixa de altas frequências, correspondendo assim a detalhes contidos no sinal que surgem em um tempo relativamente curto. Conseqüentemente, para a possuindo um valor maior do que um, a *Wavelet* ψ é expandida, ou seja, uma função de baixa frequência, que corresponde a informação global no sinal.

Existem diferentes tipos de *Wavelets*-mãe que podem ser utilizados em uma TWC, sendo cada tipo mais apropriado a um estabelecido sinal. Alguns tipos populares de *Wavelets* são apresentados na figura 2.12.




Figura 2.12: Diferentes famílias de Wavelets: (a) Daubechies; (b) Coiflet; (c) Haar; e, (d) Symmlet (GRAPS, 1995).

2.5.2. Transformada Wavelet Discreta

Na TWC, para se obter os coeficientes *Wavelets*, o cálculo é realizado discretamente nos computadores, gerando assim, uma alta redundância de informação (FIGUEREDO, 2008). Um caminho alternativo é utilizar a transformada *Wavelet* em sua forma matemática discreta, dispensando as fases sensíveis a erros e que são de difícil implementação em tempo real, devido à implementação computacional ser direta. A Transformada *Wavelet* pode ser utilizada sob a forma discreta, sem perder suas qualidades e propriedades, e se portando de maneira numericamente estável (SILVA, 2006).

A TWD é implementada através de filtragens digitais sucessivas sobre o sinal original, onde um par de filtros digitais definidos como filtros em quadratura, conforme um algoritmo conhecido como codificação sub-banda, é descrito pelas funções $h(n)$ e $g(n)$, sendo estas, respectivamente, as funções resposta ao impulso de um filtro passa-baixa e passa-alta, cada um com metade da banda do sinal original (CASTELANO, 2006).

Na TWD o parâmetro de escala a e de deslocamento b descritos na equação 2.2, apresentam apenas valores discretos. Para a variável a escolhe-se valores inteiros (positivos e negativos), potências de um parâmetro fixo a_0 , conforme a equação 2.4. A variável j determina a largura da *Wavelet*.

$$a = a_0^{-j} \quad a_0 > 1 \quad e \quad j \in \mathbb{Z} \quad (2.4)$$

O parâmetro j causa a dependência da discretização de b . As *Wavelets* estreitas, de frequências mais altas, são transladadas por pequenas distâncias com a finalidade de cobrir todo o domínio do tempo, ao passo que as *Wavelets* mais largas, de frequências mais baixas, são transladadas por uma distância maior. Então, b pode ser descrito pela equação 2.5.

$$b = kb_0 a_0^{-j} \quad b_0 > 0, \text{ fixo}, j, k \in \mathbb{Z} \quad (2.5)$$

Portanto, a *Wavelet* discreta é descrita pela equação 2.6.

$$\psi_{j,k}(t) = a_0^{j/2} \psi(a_0^j t - kb_0) \quad (2.6)$$

Com isso, pode-se definir a Transformada *Wavelet* para sinais discretos através da equação 2.7.

$$F_{m,n}(a,b) = a_0^{-j/2} \int f(t) \psi(a_0^{-j}t - nb_0) \quad (2.7)$$

Os blocos G e H (figura 2.13) representam, respectivamente, os filtros passa-alta e passa-baixa. O símbolo ($\downarrow 2$) denota uma operação de decimação² (sub-amostragem), que é utilizada para preservar a dimensão do sinal, e implica em retirar as amostras de índice ímpar do sinal de entrada.




Figura 2.13: Transformada Wavelet Discreta com três níveis (PEREIRA; NABETA, 2007).

Ingrid Daubechies, uma grande pesquisadora sobre *Wavelets*, implementou o que é chamado de "*Wavelet* ortonormal com suporte compacto". Estas *Wavelets* foram pioneiras no sentido de tornar prática a análise discreta. Nas *Wavelets* de Daubechies o número de momentos nulos determina sua numeração. As *Wavelets* de Daubechies são numeradas em função do número de momentos nulos que possuem. O número de coeficientes dos filtros associados corresponde ao índice, que equivale ao número de derivadas nulas do filtro

² É a redução da frequência de amostragem do sinal contínuo.

associado à função escaladora em $\omega=\pi$ (o filtro tem um zero em $\omega=\pi$ de ordem $N-1$). Portanto a Wavelet D4 (Daubechies 4) tem dois momentos nulos, e os filtros associados possuem 4 zeros em $\omega=\pi$ e quatro coeficientes. (FARIA, 1997)

A figura 2.14 apresenta quatro modelos de Wavelets-mães da família Daubechies.




Figura 2.14: Família Daubechies (SILVA, 2006).

As Wavelets de Daubechies são assimétricas, contínuas e quanto maior o número de decaimentos mais suave será a banda de transição (PIFER; CAMPOS; CAMPOS, 2008).

Outras Wavelets ortogonais foram criadas por Daubechies, sendo uma delas as *Symmlets* que possuem características positivas da família das Daubechies. Porém, as *Symmlets* foram implementadas para atender os requisitos de simetria e fase linear, mas não são perfeitamente simétricas, pois o requisito de ortogonalidade não permite que isso seja possível.

Daubechies também construiu as *Coiflets*, que limitam os momentos de decaimento na função *Wavelet* e na função escala (PIFER; CAMPOS; CAMPOS, 2008).

2.6. Redes Neurais Artificiais

As redes neurais artificiais (RNA) procuram implementar o modelo cerebral humano. O método se baseia em simular o neurônio cerebral, que é composto basicamente por dendritos, axônio e corpo celular. Os neurônios são considerados as unidades de processamento das redes neurais e, por isso, são essenciais para o seu funcionamento. A união de bilhões de neurônios constitui o sistema nervoso humano. A forma de conexão entre os vários neurônios formam a topologia da rede neural. A figura 2.15 apresenta a estrutura básica de um neurônio cerebral.




Figura 2.15: Estrutura básica do neurônio cerebral (LINHARES; GEWANDSZNAJDER, 1997).

Na década de 1940, os fisiologistas Warren MacCulloch e Pitts interpretaram o funcionamento de um neurônio semelhante à de um circuito de entradas binárias combinadas por uma soma ponderada, gerando uma entrada efetiva. Eles propuseram o neurônio booleano (*Perceptron*) que teve caráter seminal na área de sistemas conexionistas. Porém, a estrutura proposta podia classificar apenas padrões que pudessem ser linearmente separados. A estrutura do neurônio biológico se relaciona com a de um neurônio artificial e com suas funções da seguinte maneira:

- Entradas / dendritos: recebem os sinais;
- Saída / axônio: saída do sinal;
- Pesos / sinapses: retém o conhecimento;
- Somatório: soma a relação dos sinais de entrada e dos pesos sinápticos;
- Função de Ativação: depende do valor do somatório e do *threshold* (limiar), para ativar ou não a saída. Ex: tangente hiperbólico, sigmóide e linear;




Figura 2.16: Estrutura do neurônio artificial.

A figura 2.16 apresenta a estrutura de um neurônio artificial, onde e são os sinais de entrada e s é o sinal de saída. O neurônio recebe diversos sinais de entrada, e cada sinal é multiplicado por um peso. Após a multiplicação, os sinais são somados e, por fim, a função de ativação transforma a soma das entradas ponderadas em um sinal de saída, em geral limitado (BIANCHINI, 2001).

A rede neural artificial pode possuir uma ou múltiplas camadas. Os neurônios são dispostos nestas camadas que estão organizadas em camada de entrada (as unidades recebem os padrões), camadas ocultas ou intermediárias (realiza o processamento e a extração de características) e camada de saída (conclui e apresenta o resultado final). A camada de entrada não possui neurônios, pois ela recebe os sinais de entrada. O número de neurônios na camada de saída é determinado pelo tamanho do vetor de saída. Portanto, em uma rede neural que possui apenas uma camada oculta (intermediária), somente o número de neurônios desta camada é um parâmetro de projeto. Com o aumento do número de camadas, a rede tem uma melhor capacidade de aprendizado, porém apresenta problemas de generalização.

A capacidade de representação das relações entre o espaço de entrada e de saída é determinada pelo número de camadas da rede neural. Uma característica do modelo *perceptron* é a inexistência da camada intermediária, e isso gera uma rede capaz de representar bem somente relações linearmente independentes. Para solucionar esta restrição, foi apresentado o modelo *Perceptron* de Múltipla Camada (MLP – *Multi Layer Perceptron*) que com a existência de camadas intermediárias elimina a limitação. Uma rede MLP que possui apenas uma camada oculta pode representar qualquer função contínua, por menor que seja o grau de aproximação (BIANCHINI, 2001).

A figura 2.17 apresenta a topologia de uma rede neural com apenas uma camada intermediária.




Figura 2.17: Estrutura de uma rede neural artificial MLP.

A RNA pode ter duas formas de treinamento, o auto-aprendizado ou o aprendizado supervisionado. No treinamento com o auto-aprendizado os padrões são expostos para a rede e ela é responsável por agrupar aqueles que possuem características semelhantes. Já o treinamento supervisionado apresenta um padrão a ser reconhecido e a resposta que a rede deve resultar ao receber novamente o mesmo padrão.

A rede MLP é supervisionada e, por isso, requer uma resposta desejada para ser treinada e seu algoritmo de treinamento normalmente é formado por duas etapas que são descritas a seguir:

- *feedforward*: a camada de entrada é alimentada por um vetor de padrões, e este é propagado pela rede, camada por camada. Com isso, cada neurônio que recebe um sinal, calcula sua função de ativação e encaminha o valor para os

neurônios que se situam na camada seguinte, até atingir os neurônios da camada de saída. Estes últimos calculam suas ativações e geram o resultado de saída da rede neural.

- *backpropagation*: comparando o valor resultante na saída da rede neural com o valor desejado calcula-se o erro de cada um dos neurônios de saída. Esse erro é propagado para as camadas inferiores da rede, baseando-se na ponderação dos erros da camada superior.

Para finalizar o treinamento, esses passos são repetidos até que os erros dos neurônios de saída sejam considerados aceitáveis.

Existem outras formas de treinar uma rede MLP, sendo uma delas a utilização de métodos evolutivos. Neste trabalho, utilizou-se o método do PSO para realizar o treinamento da rede MLP e a descrição de como esse método se configura está apresentada no próximo tópico deste trabalho.

Uma característica das RNAs é ser adequada para realizar o reconhecimento de padrões. As redes neurais podem ter um aprendizado, sendo assim, seu comportamento pode ser modificado diante um conjunto de estímulos de entrada. Isso significa que a rede pode aprender a responder precisamente para um determinado conjunto de estímulos recebidos, através da modificação dos pesos de atuação das entradas. Por isso, as RNAs podem se adaptar para uma resposta a um padrão específico (OSORIO, 1991).

A regra de aprendizado divide as RNAs em duas classes, a com algoritmo competitivo e a com algoritmo por correção de erros. Utilizando-se do algoritmo competitivo, a RNA caracteriza-se pelas conexões laterais dos neurônios com os seus vizinhos, e com isso, gera-se uma competição dos neurônios. As redes de *Kohonen* e *Hopfield* utilizam o algoritmo citado acima. Por sua vez, o algoritmo por correção de erros é caracterizado pelo princípio da adaptação e correção dos pesos de atuação de cada neurônio, até que o neurônio gere a saída desejada.

As redes neurais são utilizadas em diversas áreas de pesquisa, tais como: reconhecimento sonoro, reconhecimento de imagens (assinaturas, impressões digitais), previsão do tempo e memórias associativas.

2.7. Otimização por Nuvem de Partículas (PSO)

Otimização por Nuvem de Partículas, PSO (*Particle Swarm Optimization*), é uma técnica de otimização proposta por James Kennedy e Russel Eberhart em 1995 (KENNEDY; EBERHART, 1995). O método foi criado através da simulação de um modelo social simplificado análogo ao modelo de cardume de peixes ou bando de pássaros à procura de alimento (VESTERSTROM; RIGET, 2002).

Este método é baseado na otimização de uma função objetivo através da troca de informações entre os elementos, que são denominados de partículas, do grupo. Esta otimização resulta em um algoritmo de otimização não determinístico eficiente, robusto e de simples implementação computacional (BISCAIA; SCHWAAB; PINTO, 2004).

O conceito do PSO surgiu baseado em um bando de pássaros a procura do alimento. Os pássaros não sabem onde está o alimento e este é único. Portanto, a idéia consiste em encontrar o melhor comportamento que os pássaros terão que realizar para conseguir alcançar seu objetivo. Eles devem seguir o pássaro que estiver mais próximo do alimento. No início da busca, os pássaros voam sem orientação prévia, e então, eles se aglomeram em bandos, até que um pássaro consiga encontrar o alimento e atrair outros pássaros que estiverem em sua vizinhança.

Comparação, avaliação e imitação são propriedades importantes do comportamento social humano e, portanto, são a base para a nuvem de partículas, que utiliza essas idéias na adaptação a mudanças no ambiente e na resolução de problemas complexos (KENNEDY; EBERHART, 2001). Em uma simulação, o comportamento de cada indivíduo é influenciado pelas experiências dos outros indivíduos.

No PSO a inteligência do bando é coletiva, ou seja, um elemento aprende com o acerto do outro. Por isso, se um pássaro encontrar o alimento a probabilidade de os outros pássaros também encontrarem aumenta consideravelmente (SARAMAGO; PRADO, 2005).

A Otimização por Nuvem de Partículas é uma técnica de Inteligência de Enxames (*Swarm Intelligence*) e tem suas raízes na Vida Artificial e na Computação Evolucionária (CE). Relacionando CE e PSO, verifica-se que as duas técnicas possuem alguns pontos semelhantes. Uma população de indivíduos forma uma nuvem, onde estes indivíduos representam uma solução para um problema de otimização. Realizando modificações probabilísticas e iterativas dessas soluções, busca-se uma solução ótima. A diferença entre os dois conceitos está em como modificar esta população ou nuvem de uma geração para outra.

Na Computação Evolucionária (CE), a mudança de uma geração para a outra é realizada com base nos operadores genéticos de seleção, cruzamento e mutação. Outra diferença da CE é que as espécies morrem e são substituídas a cada geração. Já em Nuvem de Partículas, a iteração entre as gerações é realizada de acordo com as fórmulas de atualização da velocidade e posição, que serão descritas na próxima seção. Na abordagem de Nuvem de Partículas as partículas se movimentam, não existe a morte e nem a substituição de partículas. No PSO o objetivo é alcançado através de uma busca cooperativa, enquanto que em CE ocorre uma busca competitiva (VESTERSTROM; RIGET, 2002).

2.8. Algoritmo do PSO

O algoritmo do PSO tem como base o comportamento social de aves, sendo a busca por alimento ou pelo ninho e a interação entre os pássaros ao longo do voo modelados como um mecanismo de otimização. Os pássaros ou partículas fazem uso de suas experiências e da experiência do próprio bando para encontrarem o alimento. Fazendo uma relação do voo dos pássaros com PSO tem-se que a área sobrevoada equivale ao espaço de busca e encontrar o local com comida ou o ninho corresponde a encontrar a solução ótima. Em PSO, a população é denominada nuvem. Uma nuvem é uma quantidade de partículas que se movem em um espaço n-dimensional, dentro de um subespaço de busca. Há um conceito de vizinhança para cada partícula, que consiste no conjunto de todas as partículas vizinhas.

As aplicações presentes na literatura mostram que o algoritmo do PSO possui a capacidade de solucionar diferentes tipos problemas, bem como ressaltam a habilidade de trabalhar com variáveis discretas e contínuas ao mesmo tempo.

Cada partícula, em uma dada iteração, tem uma velocidade e uma posição no espaço. A partícula possui também uma pequena memória que armazena sua melhor posição até então atingida (melhor local), e a melhor posição já alcançada pelos conhecidos da partícula (melhor vizinhança), ou seja, o melhor de todas as partículas pertencentes à vizinhança.

Na inicialização do algoritmo PSO, a nuvem é iniciada aleatoriamente (Figura 2.18). A população de soluções candidatas, ou seja, cada partícula (círculo na Figura 2.18) é inicializada com uma posição e uma velocidade (vetor na Figura 2.18) aleatórias.




Figura 2.18: Inicialização aleatória das partículas no espaço (MEDEIROS, 2005).

Para saber se uma solução é melhor do que outra se utiliza uma função de aptidão, que determina quão boa é a solução para o problema. Como cada posição da partícula representa uma solução candidata para o problema, a aptidão de uma partícula é uma função da posição da partícula. Cada partícula modifica sua velocidade levando em conta a melhor posição de si mesma e a melhor posição do grupo, e ao longo do tempo o grupo acaba alcançando o alimento.

A lista abaixo representa os símbolos que serão utilizados para denominar as variáveis:

- p e i = partículas
- V_MAX = velocidade máxima permitida
- $V(p)$ = vizinhança de p
- t = iteração
- S = espaço
- $\vec{x}(t)$ = vetor de posição
- $\vec{v}(t)$ = vetor de velocidade
- $\vec{p}(t)$ = melhor posição da partícula

- $\vec{g}(t)$ = melhor posição alcançada pela vizinhança
- $a(p)$ = aptidão da partícula
- c_1 = coeficiente que determina a influência do melhor local
- c_2 = coeficiente que determina a influência do melhor global
- w = coeficiente de inércia

É importante ressaltar que os vetores citados anteriormente são n-dimensionais.

A nuvem é iniciada no tempo $t = 0$, distribuindo as partículas aleatoriamente no espaço

S . Determina-se $\vec{p}(0) = \vec{g}(0) = \vec{x}(0)$. Depois disso, inicia-se o processo iterativo.

Através das seguintes fórmulas é possível calcular a velocidade e a posição da partícula na próxima iteração.

$$\vec{v}(t+1) = w\vec{v}(t) + c_1(\vec{p}(t) - \vec{x}(t)) + c_2(\vec{g}(t) - \vec{x}(t)), \quad (2.8)$$

$$\vec{x}(t+1) = \vec{x}(t) + \vec{v}(t+1), \quad (2.9)$$

em que w é a inércia da partícula, ou seja, o quanto sua velocidade anterior influencia na velocidade atual.

A função de aptidão é uma função da posição da partícula, pois é a localização da partícula em S que determina se uma partícula é "melhor" que outra. Por exemplo, para um problema de maximização, em um dado instante t , uma partícula i é melhor que uma partícula j se $a(\vec{x}_i(t)) > a(\vec{x}_j(t))$.

O desempenho do algoritmo depende bastante dos valores de seus parâmetros. Em (TRELEA, 2003) é apresentada uma análise teórica do algoritmo, onde são definidos critérios para uma boa escolha dos parâmetros de busca.

Os parâmetros de confiança e de inércia devem ser ajustados de acordo com o problema. Eles são utilizados para a atualização do vetor velocidade. Após a atualização das velocidades e posições de todas as partículas, $\vec{p}(t+1)$ e $\vec{g}(t+1)$ são calculados e passa-se à próxima iteração ou acaba-se a execução dependendo do critério de parada adotado, que normalmente consiste em um número definido de iterações. (SARAMAGO; PRADO, 2005).

Conforme descrito na equação 2.8, o movimento de cada partícula em cada iteração é correspondente à soma de três termos distintos, sendo o primeiro um termo relativo à inércia da partícula e que representa o modo com que a que a partícula vem se movendo, o segundo é

um termo relativo à atração da partícula a melhor posição que encontrou (melhor local), e o terceiro termo é relativo à atração da partícula a melhor posição de todo o espaço (ou uma parte do espaço) que já encontrou. Na figura 2.19 os vetores de velocidade podem ser visualizados.




Figura 2.19: Vetores de velocidade das partículas (SARAMAGO; PRADO, 2005).

O fluxograma mostrado na Figura 2.20 representa um esboço do algoritmo de PSO.




Figura 2.20: Esboço do algoritmo PSO (ROJAS; VIANA; RADE, 2004).

A seguir é apresentado o pseudo-código do algoritmo:

1. Para cada partícula i da nuvem, faça:
 - a. Inicia $\vec{x}_i$ com uma solução aleatória para o problema.
 - b. Inicia $\vec{v}_i$ com uma velocidade aleatória $< V_MAX$.
 - c. $\vec{p}_i \leftarrow \vec{x}_i$
 - d. $\vec{g}_i \leftarrow \vec{x}_i$
2. Enquanto o critério de parada não for alcançado:
 - a. para cada partícula i da nuvem, faça:
 - i. $\vec{v}_i \leftarrow w.v_{ii} + c_1(\vec{p}_i - \vec{x}_i) + c_2(\vec{g}_i - \vec{x}_i)$
 - ii. $\vec{x}_i \leftarrow \vec{x}_i + \vec{v}_i$
 - iii. $\vec{p}_i \leftarrow \text{melhor entre } \vec{p}_i \text{ e } \vec{x}_i$
 - iv. $\vec{g}_i \leftarrow \text{melhor } (\vec{p}_j), \text{ com } j \in V(i)$
3. Retorna o melhor $\vec{g}$ dentre todas as partículas.

Uma característica muito interessante do PSO é a realização de uma busca global nas iterações iniciais do procedimento de otimização, ocorrendo neste estágio a prospecção de várias regiões do espaço de busca, viabilizando a localização de ótimo(s) global(is). Com o decorrer das iterações a busca passa a ser uma busca local em torno do valor mais promissor, chegando a valores próximos do ponto ótimo. Entretanto, o desempenho do algoritmo é bastante dependente da seleção dos valores de seus parâmetros (BISCAIA; SCHWAAB; PINTO, 2004).

O capítulo apresentou os conceitos teóricos necessários para a compreensão do trabalho realizado, iniciando com uma abordagem simples sobre os ECGs, citando algumas formas utilizadas na literatura de pré-processamento do sinal de ECG, introduzindo o conceito de Wavelets e suas Transformadas e descrevendo algumas anomalias nos sinais de ECG que são consideradas arritmias. Também foi apresentada a base de dados a ser utilizada e como são seus registros de dados. Por fim, as redes neurais artificiais e o algoritmo e conceitos da técnica de otimização por nuvem de partículas foram descritos. Todos estes conceitos explanados neste capítulo serão utilizados para descrever a metodologia que foi aplicada para o desenvolvimento da pesquisa. No próximo capítulo tem-se a revisão da literatura sobre o tema de classificação automática de arritmias cardíacas.

Capítulo 3

Revisão de Literatura

Neste capítulo serão apresentadas as técnicas e abordagens das principais áreas de Inteligência Artificial que foram utilizadas nos últimos anos na literatura para a classificação de sinais de ECG com arritmias, tendo como intuito prover o leitor de informações atualizadas sobre a área.

Em (LETTNIN; VARGAS; MACARTHY, 2002) estudou-se as formas e estruturas das Redes Neurais Artificiais para a tarefa de classificação do Eletrocardiograma (ECG). Este estudo contribuiu para a comunidade científica no *design* de sistemas que auxiliem os médicos na análise de pacientes com arritmias. Muitas vezes estes sinais possuem ruídos que dificultam o diagnóstico de doenças, pois o ruído causa mudanças na forma do sinal. Mas as redes neurais podem ajudar a identificar os padrões dentro dos sinais com ruído. Os atributos são modificados testando o desempenho da rede neural. A abordagem utilizada é a MLP (*Multilayer Perceptron*) e o algoritmo de aprendizagem o *BackPropagation*. Nenhum filtro para remoção de ruído foi utilizado. Os padrões de sinal subamostrados foram normalizados no intervalo de [0.2, 0.8]. Três tipos de sinais foram classificados: Normal, PVC e Flutter. Nesse estudo, os conjuntos foram divididos na seguinte forma: um conjunto de treinamento com 300 padrões e um conjunto de teste com 300 padrões. Cada padrão possui 131 valores, sendo que 130 são amostras que compõem o segmento PQRST e um valor representa o intervalo RR entre o complexo atual e o anterior. A melhor taxa de acerto foi de 80,599% para o treino e 80,102% para o teste.

Em (OZBAY; KARLIK, 2001) foi utilizada RNA para se realizar a classificação de arritmias através do sinal de ECG. A abordagem para a análise do sinal deu-se utilizando o domínio do tempo. Para ser realizada a classificação das arritmias, o intervalo entre dois picos

(intervalo RR) foi normalizado em 200 amostras, sendo estas as 200 entradas da rede neural. O algoritmo de aprendizagem utilizado foi o *back-propagation*. Para se avaliar o método proposto, a classificação de dez arritmias foi estabelecida em duas estruturas da RNA. Na primeira estrutura, foi realizada uma classificação simples através da qual as arritmias foram classificadas separadamente com uma média de acerto de 95,7%. Na segunda, a classificação envolveu todos os tipos de arritmias, e a média dos acertos elevou-se para 97,8%.

Em (PRASAD; SAHAMBI, 2003) um método para classificação de arritmias cardíacas utilizando uma combinação de *Wavelets* e RNAs foi proposto. A transformada *Wavelet* possui a habilidade de decompor um sinal em diversas resoluções, o que permite a detecção e extração de características de sinais não estacionários como o ECG. Os coeficientes da transformada *Wavelet* discreta (TWD) em conjunto com a informação do intervalo RR alimentam a RNA MLP com algoritmo *back-propagation* para classificar as arritmias. Grande parte da informação pertinente ao diagnóstico se encontra nas proximidades do pico R. Por isso, apenas esse trecho é selecionado para o processamento. Se um número excessivo de amostras é selecionado, corre-se o risco de sobrescrever o complexo QRS, implicando em resultados errôneos. Portanto, o segmento de ECG extraído para processamento é 100ms antes e 150ms depois do pico R. Um algoritmo para eliminação dos ruídos foi implementado. O sinal é filtrado por um filtro passa-alta para remover a componente DC. A base utilizada foi a *MIT-BIH Arrhythmia Database*. Este método atingiu uma taxa de acerto de 96,77% sendo capaz de classificar 12 tipos de arritmias e mais o sinal normal.

Em (OSOWSKI; HOAI, 2004) considera-se o problema de otimização para escolher as características que seguem na representação de *Hermite*³ do complexo QRS do ECG para a classificação de arritmias cardíacas. O classificador utilizado foi uma rede *neuro-fuzzy* com uma estrutura modificada e um algoritmo de aprendizagem. Seis tipos de arritmias e o sinal considerado normal foram classificados. Os resultados atingidos estão na Tabela 3.1. A primeira coluna da Tabela 3.1 representa o tipo classificador de RNA, a segunda coluna representa o número de classes (aritmias) que foi utilizada e a última coluna apresenta a taxa de acerto.

³ Polinômios de Hermite ($H_n(x)$) são um conjunto de polinômios ortogonais no domínio $(-\infty, +\infty)$ com função de peso (e^{-x^2}). Esses polinômios podem ser usados para representar outros dados (HERMITE, 2007). Eles permitem a interpolação suave e o cálculo rápido e preciso das derivadas (CASTRO et al., 1999).

Tabela 3.1: Tabela de resultados da classificação dos sinais [adaptada de (OSOWSKI; HOAI, 2004)].

Solução RNA	Número de classes	Taxa de Acerto
TSK+Hermite	7	96,21%
SOM +Hermite	7	96,10%
SOM+Hermite	13	92,88%
MLP+Fourier	3	98,00%
SOM+SVD	4	92,20%
MLP+LVQ	2	96,80%

Em (LIN; GE; TAO, 2005) foi realizado um estudo para determinar a dificuldade de se analisar o ECG como um grande volume de dados e com uma boa eficiência e em tempo-real, usando um algoritmo de classificação de arritmias baseado na análise de agrupamento. Este algoritmo utiliza a similaridade entre os casos da mesma categoria. Ao mesmo tempo, ele incorpora um fator de individualidade para diferenciar os casos. O algoritmo analisa a arritmia através do agrupamento de complexos QRS em conjunto com uma análise de ritmo. O pré-processamento é realizado através de dois filtros e de um detector do complexo QRS. O primeiro filtro é um corta-faixa que elimina a frequência de 60Hz e o segundo é um filtro passa-alta que corta frequências abaixo de 0,5Hz. Para detecção do complexo QRS é utilizada a transformada *Wavelet*. Foram analisados oito registros da base *MIT-BH Arrhythmia Standard Heart Electricity Database*, onde o agrupamento correto teve uma taxa de acerto em torno de 90%.

Em (LEE; PARK; SONG; LEE, 2005) foi realizado um estudo que propôs um método para a realização de classificação de arritmias cardíacas usando RNAs com redução das características de entrada pela análise do discriminante linear. Primeiramente foram extraídas 17 características da entrada que são baseadas nos coeficientes da transformada *Wavelet*. Aplicando a análise do discriminante linear nos dados, reduziu-se a dimensão das características para quatro. Com a estrutura da nova dimensão, o classificador MLP foi treinado para detectar seis tipos de arritmias. A classificação das arritmias obteve um bom resultado e reduziu o tempo e custos computacionais. O algoritmo proposto trabalhou com três tipos de arritmias, Taquicardia Supraventricular, Contração Ventricular Prematura,

Fibrilação Ventricular e o sinal considerado normal, conseguindo como taxa de acerto na detecção das arritmias 99.43%, 98.59%, 99.88% e 99.52%, respectivamente.

Em (JIANG; KONG; PETERSON, 2006) é apresentado uma monitoração dos batimentos cardíacos usando redes neurais baseada em blocos (BbNNs). Um algoritmo evolucionário é usado para otimizar a estrutura e os pesos da BbNN simultaneamente. A BbNN é treinada com os coeficientes da transformada de *Hermite* e um intervalo de tempo entre dois vizinhos de pico R do sinal de ECG. BbNNs reconfiguram a estrutura e os pesos internos para competir com as diferenças individuais e as mudanças das condições físicas. Resultados simulados usando a base MIT-BIH *Arrhythmia Database* demonstram a alta eficiência de 98,7% de média para a classificação da Ventricular Ectopic Beats (VEBs), existindo um acréscimo substancial sobre as técnicas convencionais.

Em (AL-FAHOUM; KHADRA, 2005) uma nova forma é abordada. É utilizada uma técnica baseada na transformada de Fourier (*Bispectrum*). A classificação quantitativa da ocorrência de arritmias cardíacas é uma importante ferramenta em UTIs. Em geral, as arritmias fatais são a fibrilação atrial, taquicardia ventricular e fibrilação ventricular. Todas elas podem ser detectadas por algoritmos especiais. Neste artigo, um algoritmo de classificação baseado em transformada de Fourier é apresentado para classificar sinais de ECG em: sinal normal, fibrilação atrial, taquicardia ventricular e fibrilação ventricular. A proposta obteve resultados com uma taxa de acerto em torno de 93,6%.

Em (RODRIGUEZ et al., 2005) é proposto um sistema com potencial comercial. Os avanços nas tecnologias de sensores, PDAs e comunicações *wireless* favoreceram o desenvolvimento de novos tipos de sistemas de monitoração. Particularmente, foram desenvolvidos vários sistemas de monitoração projetados para pessoas que sofrem de arritmias do coração, devido ao número crescente de pessoas com doenças cardiovasculares. Entre esses sistemas, está o MOLEC, onde um sinal de ECG adquirido a 360 Hz é pré-processado com a ferramenta ECGPUWAVE e processado por classificadores em tempo-real, que detectam batimentos fora de compasso. Alarmes são enviados a um hospital em até 6,66 segundos, caso seja detectada uma arritmia. O MOLEC possui uma taxa de acerto de 100% para classificar sinais que possuem arritmias consideradas de alto risco (Flutter Ventricular, Ritmo Idioventricular), onde o paciente precisa de assistência médica em menos de três minutos. Para a detecção da Taquicardia Ventricular a taxa de acerto diminui para 95%. Para classificar sinais saudáveis o sistema alcançou somente a taxa de acerto de 67,35%.

Em (JUNG; TOMPKINS, 2003) foi apresentado um algoritmo baseado em *Wavelets* capaz de detectar e classificar quatro tipos de arritmias ventriculares, que são: Fibrilação Ventricular, Taquicardia Ventricular, Taquicardia Supraventricular e Flutter Ventricular. Quatro tipos de *Wavelets* foram testados, e seus resultados comparados, sendo que a *Wavelet* de Daubechies de comprimento quatro apresentou os melhores resultados. Neste trabalho é utilizado um algoritmo que inicialmente verifica se o sinal é fibrilação/flutter ventricular através dos coeficientes *Wavelets* e análise no domínio da frequência. Em caso positivo, o algoritmo separa o flutter da fibrilação através da distribuição de energia no domínio da frequência. Em caso negativo, o algoritmo passa para as próximas verificações através da detecção do QRS. Esta separação inicial do sinal entre flutter/fibrilação ventricular e os demais sinais, foi criada devido à frequência dos picos do sinal, pois o flutter e a fibrilação apresentam uma frequência maior do que os demais sinais, facilitando, assim, a classificação destes. O uso de *Wavelets* reduziu o número de dados utilizados no processamento do algoritmo em dez vezes. O método obteve uma taxa média de sensibilidade de 92,3%.

Em (TSIPOURAS; VOGLIS; FOTIADIS, 2007) é apresentada uma metodologia de desenvolvimento automático de sistemas especialista *fuzzy*. Inicialmente, regras *fuzzy* foram determinadas por cardiologistas especialistas. Essas regras foram instaladas em um sistema especialista, que processou as bases de dados *MIT-BIH Arrhythmia Database* e *European ST-T*. Durante o processamento, as regras foram otimizadas automaticamente, provando que a abordagem pode render frutos no futuro. A proposta obteve um excelente resultado, atingindo uma taxa de acerto de 96,43%.

O artigo (MEYER; GAVELA; HARRIS, 2006) apresenta uma abordagem combinada de algoritmos para identificar os picos R em sinais de ECG. Esta é uma das principais etapas em qualquer tipo de análise automática do ECG. Os autores utilizaram vários algoritmos, incluindo filtros, limites por cortes, *Wavelets*, redes neurais, entre outros. Foi calculada uma média ponderada, onde a contribuição de cada algoritmo apresentou um peso diferente. Os testes foram realizados sobre a base *MIT-BIH Arrhythmia Database*, superando, com 99,43% de acerto, os resultados individuais dos algoritmos utilizados.

O artigo (INAN; GIOVANGRANDI; KOVACS, 2006) apresenta outro método de classificação de batimentos cardíacos. Nesse caso, transformadas *Wavelet* foram utilizadas em conjunto com informações temporais. A classificação foi realizada por uma RNA e a base

utilizada foi a MIT-BIH *Arrhythmia Database*. Dessa forma, o algoritmo apresentou uma acurácia de mais de 95%, tendo sido processados mais de 93.000 batimentos.

O artigo (KARIMIFARD et al., 2006) apresenta uma técnica de detecção de arritmia baseada na morfologia do sinal. O pré-processamento foi baseado no modelo de *Hermite*. No caso, utilizaram-se classificadores kNN (k vizinhos mais próximos), obtendo-se a sensibilidade de 99% e uma especificidade de 99,84%. O algoritmo foi testado sobre a base MIT-BIH *Arrhythmia Database*, sendo capaz de detectar as arritmias em 0,6 segundos.

Em (ROGAL et al., 2008) se trabalhou a classificação de arritmias cardíacas utilizando a transformada de Wavelet em conjunto com RNAs auto-organizáveis. Com essa estrutura é possível adicionar outros grupos de arritmias sem a necessidade de realizar uma nova fase de treinamento. Neste trabalho, uma RNA ART2 foi utilizada para detectar batimentos normais, contração prematura atrial, e contração prematura ventricular, obtendo como taxa de acerto, respectivamente, 82%, 83% e 94%.

Existem trabalhos que utilizam o PSO como técnica principal, nas mais diversas áreas, tais como: resolução de problemas MiniMax, otimização da utilização de reatores de energia, controle de tensão em sistemas de potência. Em (MAMMEN; JACOB; KÓKAI, 2005) o PSO é utilizado para auxiliar na construção de estruturas tridimensionais no espaço contínuo. Também existem outras abordagens ou variações do PSO, como por exemplo, o MOPSO (*Multiple Objective Particle Swarm Optimization*). Em (RIBEIRO; SCHLANSKER, 2006) o PSO é utilizado para formar a RNA, substituindo a técnica de *back-propagation*. Um *software* denominado *Themis*, implementado em Java, foi desenvolvido nesta pesquisa. A aplicação inicializa uma nuvem PSO, sendo cada partícula da nuvem uma rede neural com valores aleatórios dos pesos. Em cada iteração, o *software* analisa a aptidão, que é baseado nos erros obtidos pela rede utilizando a base de treino, de cada rede neural. A rede que apresentar o melhor valor de aptidão será considerada a melhor global. As outras redes neurais terão seus pesos atualizados baseados na posição da melhor global, atualizando sua posição e velocidade no espaço do PSO. Caso a rede obtenha um erro menor do que o erro exigido, salva-se os pesos da RNA e encerra-se a aplicação. Poucos trabalhos utilizam a combinação de métodos de treinamento com a otimização de topologia de redes e funções de ativação. O trabalho discute o uso do PSO para otimizar as entradas, topologia e função de ativação da RNA para a resolução do problema do controle de reatores de energia.

Existem muitos trabalhos na área de detecção automática de arritmia analisando o ECG no domínio do tempo. As pesquisas mais recentes indicam a utilização de *Wavelets*, onde a análise do ECG é realizada através do domínio do tempo e frequência. Porém, em nenhuma pesquisa foi utilizada a normalização proposta e técnicas de classificação baseadas em RNAs e *Swarm*. O capítulo seguinte mostrará a metodologia que será abordada na implementação do trabalho.

Capítulo 4

Metodologia

Neste capítulo será apresentada a metodologia adotada para o desenvolvimento da pesquisa.

4.1. Panorama Geral

Utilizando *Wavelets*, RNA e PSO, analisou-se o sinal de ECG classificando-o em quatro tipos de sinal: Taquicardia Ventricular, Fibrilação Atrial, Flutter Ventricular e Sinal Normal. A fibrilação atrial foi escolhida por ser a mais freqüente arritmia paroxística (SOCIEDADE BRASILEIRA DE CARDIOLOGIA, b, 2003). O Flutter Ventricular foi selecionado por ser mais raro, anteceder a Fibrilação Ventricular, que pode causar a morte e por ter seu ritmo regular e uniforme. A Taquicardia Ventricular foi escolhida por apresentar particularidades e diferenças no formato do sinal de ECG, com relação às outras duas arritmias em questão. Sendo assim, o método utilizado terá três tipos bem distintos de sinal com arritmia para classificar.

Na figura 4.1 podem ser visualizados os passos realizados na pesquisa. Cada um deles será descrito nos tópicos posteriores com um grau de detalhamento maior.




Figura 4.1: Visão geral.

Estas etapas apresentadas na figura 4.1 são realizadas duas vezes no trabalho, uma para separar o flutter dos outros sinais e outra para classificar os três tipos de sinais restantes: fibrilação atrial, taquicardia ventricular e o sinal normal.




Figura 4.2: Primeira abordagem de classificação dos sinais.

Duas abordagens foram implementadas e comparadas neste trabalho. A figura 4.2 apresenta a primeira abordagem. Esta abordagem utiliza apenas uma rede neural que classifica o sinal em quatro categorias.

Na figura 4.3, a segunda abordagem da estrutura da classificação dos sinais é apresentada. A rede neural 1 separa o flutter ventricular dos demais sinais e a rede neural 2 é utilizada para classificar os outros sinais abordados. A diferença entre as redes neurais é que a rede neural 1 apresenta apenas dois neurônios na camada de saída, enquanto a segunda rede apresenta três neurônios.




Figura 4.3: Segunda abordagem de classificação dos sinais.

Para a conclusão dos objetivos foi implementado um software em Java que recebe como entrada uma base de treinamento, base de teste, base de validação, número de neurônios e parâmetros do PSO. Para a implementação do algoritmo PSO foi usada a JSwarm-PSO (JSWARM-PSO, 2007). A aplicação criada gera uma rede neural treinada para classificar os sinais de ECG para cada classe do problema, indicando o seu desempenho.

4.1.1. Base de Dados

Conforme visto no capítulo 2, a entrada do sistema é composta pelos sinais de ECG da *MIT-BH Arrhythmia Database*. Esta base foi escolhida devido aos inúmeros trabalhos científicos na área de ECG que a utilizam e por ser uma base com credibilidade. Sendo assim, a pesquisa realizada pode ter seus resultados comparados a diversas outras pesquisas que também utilizaram a base de dados selecionada. A *MIT-BH Arrhythmia Database* teve seu início a partir das pesquisas realizadas pelo *Boston's Beth Israel Hospital* (BIH) e pelo *Massachusetts Institute of Technology* (MIT) sobre arritmias cardíacas. Esta pesquisa sobre arritmias aconteceu entre os anos de 1975 e 1979, porém só foi publicada em 1980. Os dados coletados da pesquisa foram de 47 pacientes que foram monitorados e avaliados pelo BIH *Arrhythmia Laboratory*, o que ocasionou 48 horas e meia de registros de ECG. Desses registros, 23 foram coletados de um conjunto de 4000 exames de 24 horas, sendo 60% de pacientes internos e 40% de pacientes externos do *Boston's Beth Israel Hospital*. Os 25 registros restantes foram selecionados para representar arritmias importantes, porém, que existiam com pouca frequência. Todos os registros foram digitalizados com uma taxa de amostragem de 360Hz, usando 11 bits para representar 10mV. Cardiologistas avaliaram cada um dos batimentos cardíacos dos exames, informando a ocorrência de uma arritmia ou não, gerando um total de 110.000 anotações de batimentos cardíacos (PHYSIONET, 2007).

O eletrocardiograma padrão possui 12 derivações de ondas, porém a base de dados só disponibiliza duas dessas derivações, sendo que para cada paciente as derivações podem variar entre as 12 derivações padrão. Por isso, apenas a primeira derivação do sinal disponibilizada na base de dados é avaliada nesta pesquisa.

A representação do sinal de ECG da base de dados *MIT-BH* pode ser visualizada na tabela 4.1, que descreve o valor das duas derivações do sinal em cada instante de tempo representado na primeira coluna.

Tabela 4.1: Exemplo dos dados da base *MIT-BH - Arrhythmia Database*.

time	MLII	V5
(sec)	(mV)	(mV)
400.000	-0.335	-0.200
400.003	-0.340	-0.210
400.006	-0.360	-0.205
400.008	-0.350	-0.200
400.011	-0.340	-0.190

A base de dados também fornece um arquivo de anotações do sinal. As siglas utilizadas no arquivo de anotações estão descritas na tabela 4.2. Um exemplo do arquivo de anotações pode ser visualizado na tabela 4.3.

Tabela 4.2: Siglas do arquivo de anotações dos dados da base *MIT-BH - Arrhythmia Database*.

Sigla	Significado
N	Batida Normal
A	Batida Atrial Prematura
V	Contração Ventricular Prematura
Q	Batida sem Classificação
?	Batida não classificada durante o aprendizado
+	Mudança de ritmo
(SVTA	Taquiarritmia Supraventricular
(AFIB	Fibrilação Atrial
(VFL	Flutter Ventricular
(VT	Taquicardia Ventricular

Tabela 4.3: Exemplo das anotações dos dados da base MIT-BH - Arrhythmia Database.

Time	Sample #	Type	Sub	Chan	Num	Aux
7:09.086	154471	N	0	0	0	
7:09.980	154793	N	0	0	0	
7:10.863	155111	N	0	0	0	
7:11.038	155174	+	0	0	0	(SVTA
7:11.408	155307	A	0	0	0	
7:11.813	155453	A	0	0	0	
7:12.458	155685	A	0	0	0	
7:13.294	155986	+	0	0	0	(N
7:13.536	156073	N	0	0	0	
7:14.483	156414	N	0	0	0	

Analisando o arquivo de anotações é possível descobrir os picos existentes no sinal, assim como a arritmia em que o sinal se classifica.

A análise estatística da base de dados pode ser verificada em (PHYSIONET, 2008).

Utilizando estas informações, foi possível executar a próxima etapa, que é a segmentação da base, ou seja, escolha das amostras que serão utilizadas através do conceito de janela fixa.

4.1.2. Segmentação

O sinal da base de dados foi segmentado em duas bases utilizando um algoritmo implementado em Java.

A primeira segmentação realizada consiste em retirar 121 amostras de cada pico do sinal, ou seja, o pico, 60 amostras anteriores ao pico e 60 amostras posteriores ao pico. Esta segmentação foi aplicada para que em sinais de alta frequência não sejam utilizadas amostras que possuem dois picos, além de ser uma tentativa de melhorar os resultados obtidos em comparação a segmentação proposta a seguir.

Os trabalhos (OZBAY; KARLIK, 2001) (LETTNIN; VARGAS; MACARTHY, 2002) utilizaram 50 amostras anteriores ao pico e 50 amostras posteriores, justamente para evitar que cada janela não possua amostras do próximo batimento. Por isso, a segunda base criada consiste na segmentação dos dados, semelhante à segmentação anterior, porém com 50

amostras anteriores e 50 amostras posteriores ao pico, para que com isso os resultados sejam comparados. Portanto, deve-se considerar que os processos descritos realizados neste capítulo que utilizaram 121 amostras, também foram realizados com janelas de 101 amostras.

Na figura 4.4 pode ser visualizada a janela fixa em relação ao pico e de onde serão retiradas as 60 amostras anteriores e as 60 posteriores ao pico. As amostras coletadas são as amostras delimitadas pelas linhas mais aparentes.




Figura 4.4: ECG analisado com janela fixa.

Para localizar os picos do sinal não foi necessário realizar a detecção dos mesmos, pois conforme visto no tópico anterior, o arquivo de anotações da base informa qual amostra é o pico. As amostras selecionadas contêm as partes principais do ECG, que são o complexo QRS, a onda P e onda T.

As 121 amostras foram utilizadas para gerar os 120 coeficientes *Wavelet*, através da aplicação da Transformada *Wavelet* Discreta.

4.1.3. Aplicação da Transformada Wavelet

A geração dos coeficientes *Wavelet* foi realizada para as duas bases de dados, formadas com janelas de 101 e 121 amostras, aplicando a Transformada *Wavelet* Discreta. Ao final desta etapa formaram-se duas bases com os coeficientes *Wavelet*, uma com 100 coeficientes e outra com 120 coeficientes. Cada janela de coeficientes é o vetor de entrada da rede neural.

A *Wavelet Coiflet-8* foi utilizada para gerar os coeficientes que são a entrada da rede neural 1 aplicada na segunda abordagem da metodologia realizada. Esta rede, conforme visto anteriormente separará o flutter dos demais sinais. A *Coiflet-8* foi selecionada para gerar os

coeficientes, pois utilizando esta *Wavelet* a rede neural obteve um maior acerto na classificação do flutter ventricular.

Para gerar os coeficientes *Wavelets* utilizados como entrada da rede neural 2 selecionou-se a utilização da Daubechies. Esta *Wavelet* apresentou os melhores resultados no trabalho (JUNG; TOMPKINS, 2003).

4.1.4. Formação dos Grupos e dos Conjuntos

Com os coeficientes gerados pela Transformada *Wavelet*, foram criados 10 grupos da base de dados. Estes grupos foram gerados através da randomização da base de coeficientes e sua divisão em 10 partes de tamanhos iguais, conforme apresentados na figura 4.1.

Utilizando os 10 grupos, criou-se 10 conjuntos, sendo que cada conjunto possui 10 grupos, e, portanto, os grupos são repetidos 10 vezes. Esta formação de conjuntos é justificada pela pequena quantidade de exemplos do Flutter e da Taquicardia Ventricular para realizar o treinamento, o teste e a validação. O método utilizado é o de Validação Cruzada, e por isso, os conjuntos foram criados.

A estrutura dos conjuntos é baseada em nove grupos para realizar o treinamento e um grupo para o teste, conforme apresentado pela figura 4.1.

4.1.5. RNA

Para a criação e treinamento da rede neural foi implementada a aplicação citada no início deste capítulo utilizando a plataforma Java. Este software recebe um conjunto de treinamento, um conjunto de teste, um conjunto de validação, quantidade de neurônios de entrada, escondidos e de saída, e três parâmetros do PSO. O módulo Jswarm-PSO (JSWARM-PSO, 2007) foi integrado ao software para realizar as funções relacionadas ao PSO. A interface do software pode ser visualizada na figura 4.6. (falar que os softwares estão dentro)




Figura 4.6: Aplicação Implementada para Formar a Rede Neural Evoluída através do PSO.

A aplicação implementa uma rede neural MLP de três camadas. Com este *software*, foram criadas três redes neurais citadas no início deste capítulo devido às duas abordagens de classificação. A quantidade de neurônios de entrada das redes é 120, pois existem 120 coeficientes *Wavelet* em cada janela. A camada de saída da primeira rede possui dois neurônios, pois esta rede dividirá os sinais em flutter ou em demais sinais. A segunda rede possui três neurônios na camada de saída devido aos demais sinais serem: fibrilação atrial, taquicardia ventricular e sinal normal. Na terceira rede, utilizada na primeira abordagem, existem quatro neurônios na camada de saída, visto que ela classificará os quatro tipos de

sinais abordados neste trabalho. A quantidade de neurônios escondidos foi variada nos testes, com os valores de 50, 100 e 150 neurônios.

Para a melhor compreensão das redes neurais treinadas e testadas na metodologia, a tabela 4.4 descreve o nome do experimento da rede (identificação utilizada no próximo capítulo), a quantidade de redes, a quantidade de neurônios de cada rede e a função da rede neural. O nome do experimento é determinado pela quantidade de neurônios de entrada, quantidade de neurônios na camada intermediária, quantidade de neurônios de saída e a abordagem a qual a rede pertence.

Tabela 4.4: Redes neurais implementadas e testadas no trabalho.

Experimento	Neurônios de Entrada	Neurônios Escondidos	Neurônios de Saída	Função
120-50-4-a1	120	50	4	Classificar os quatro tipos de sinais utilizando apenas uma rede neural. (primeira abordagem)
120-100-4-a1		100		
120-150-4-a1		150		
120-50-3-a2	120	50	3	Classificar os demais tipos de sinais, sendo a segunda rede neural. (segunda abordagem)
120-100-3-a2		100		
120-150-3-a2		150		
120-50-2-a2	120	50	2	Separar o flutter ventricular dos demais tipos de sinais. (segunda abordagem)
120-100-2-a2		100		
120-150-2-a2		150		
100-50-4-a1	100	50	4	Classificar os quatro tipos de sinais utilizando apenas uma rede neural. (primeira abordagem)
100-100-4-a1		100		
100-150-4-a1		150		
100-50-3-a2	100	50	3	Classificar os demais tipos de sinais, sendo a segunda rede neural. (segunda abordagem)
100-100-3-a2		100		
100-150-3-a2		150		
100-50-2-a2	100	50	2	Separar o flutter ventricular dos demais tipos de sinais. (segunda abordagem)
100-100-2-a2		100		
100-150-2-a2		150		

Com os valores de entrada definidos, a rede é inicializada, e, com isso, uma nuvem PSO é criada.

4.1.6 Algoritmo PSO

A implementação do PSO foi realizada em Java e a API utilizada foi a JSwarm-PSO. A JSwarm-PSO foi integrada com o software criado nesta pesquisa.

Conforme já visto no capítulo dois, existem algumas nomenclaturas utilizadas no algoritmo PSO. Para facilitar a compreensão, a seguir listam-se as nomenclaturas utilizadas neste capítulo:

- Partícula (p) = Uma rede neural
- Coeficiente que determina a influência do melhor local (c_1)
- Coeficiente que determina a influência do melhor global (c_2)
- Coeficiente de inércia (w)

No software implementado, deve-se preencher como entrada três variáveis para a nuvem do PSO, o c_1 (incremento local), c_2 (incremento global) e w (inércia). Este *software* permite que os coeficientes de entrada do PSO sejam alterados no decorrer das iterações, porém esta funcionalidade não foi utilizada para realizar as evoluções das redes neurais.

Inicialmente são geradas 50 partículas aleatoriamente. Foram adotados os coeficientes $c_1 = c_2 = 2$ e $w = 1$, que são valores adotados normalmente na literatura (SARAMAGO; PRADO, 2005)(RIBEIRO; SCHLANSKER, 2006).

A função de aptidão (*fitness*) é calculada através do Vp (verdadeiro positivo), pois ele indicará se uma rede possui mais acertos do que outra. A taxa de Vp é calculada através da fórmula:

$$\frac{Vp}{Vp+Fn} \times 100\% \quad (4.1)$$

Na equação 4.1 o Fn representa os falsos negativos, com isso, o denominador da equação é a quantidade total de classificações.

Na nuvem iniciada pelo *software*, cada indivíduo é uma rede neural e em cada iteração, cada rede é avaliada individualmente com a taxa de Vp.

Conforme a figura 4.7, a aplicação criada possui um campo de resultados, onde são apresentados os valores de aptidão e a matriz de confusão do treinamento e dos testes para cada iteração.

The image shows a software window titled "JSwarmNet". It contains several input fields for configuration and a large text area for results.

Configuration Fields:

- Arquivo de Padrões de Treinamento: s:\new_patterns\all_60_base_train_0.pat [Selecionar]
- Arquivo de Padrões de Teste: s:\new_patterns\all_60_base_test_0.pat [Selecionar]
- Arquivo de Padrões de Validação: r:\patterns\all_60_base_validation_0.pat [Selecionar]
- Neurônios de Entrada: 120
- Neurônios Escondidos: 50
- Neurônios de Saída: 4
- Incremento Local: 2
- Incremento Global: 2
- Inércia: 1

Results Field:

Resultados:

```
Iteração 1
*****
Incremento local: 2.0
Incremento global: 2.0
Inércia: 1.0
*****
Treinamento: 382.0
195 0 0 26
14 0 1 207
45 1 0 162
9 0 0 187
*****
Teste: 122
42 0 0 4
2 2 0 52
12 0 0 48
2 0 0 78
*****
Validação: 61
21 0 0 2
```

Control Buttons:

[Iniciar] [Pausar] [Salvar]

Figura 4.7: Aplicação com o campo de resultados.

A busca pela melhor rede é realizada através do PSO. A cada iteração, o PSO evolui os pesos de cada partícula (rede neural) e avalia seu desempenho através da função de aptidão. A função de aptidão calcula a taxa de acerto da rede em relação à base selecionada na entrada do software. O número de atributos de cada partícula depende do número de neurônios da rede neural. Para redes com 120 neurônios de entrada, 50 neurônios na camada intermediária e três neurônios de saída, existem 18000 atributos (pesos). Para encontrar o valor de atributos da partícula, basta multiplicar a quantidade de neurônios de cada camada da rede neural.

O critério de parada para cada evolução é quando $V_p = 100\%$ ou após 100 iterações.

Ao final da evolução realizada pela aplicação criada neste trabalho, os atributos da melhor rede podem ser salvos em formato texto, utilizando o botão salvar da interface e selecionando o nome e o local em que o arquivo será salvo. A matriz de confusão e a aptidão podem ser visualizadas conforme a figura 4.5.

Os resultados foram comparados com os de outros métodos de detecção automática de arritmias no próximo capítulo. A métrica de comparação é a taxa de acerto, devido aos outros trabalhos científicos da área utilizarem esta métrica.

4.1.7. Validação

A validação dos resultados é realizada através da taxa de acerto da rede neural em relação aos conjuntos citados no tópico 4.1.4, alcançadas pela técnica proposta em relação à base de dados *MIT-BH Arrhythmia Database*. Estes resultados são comparados com os de outros métodos de detecção automática de arritmias existentes na literatura.

A tabela 4.5 apresenta os trabalhos, taxa de acerto e quantidade de arritmias classificadas, que foram comparados com os resultados desta pesquisa.

Tabela 4.5: Trabalhos comparados com as taxas de acerto deste trabalho.

Pesquisa	Taxa de Acerto	Número de Arritmias Classificadas
OK01	97,80%	10
LVM02	80%	2
PS03	96,70%	12
JT03	91,10%	4
LPSL05	99,48%	3

AK05	93,60%	3
IGK 06	95,2%	1
JKP06	98,72%	1
TVF06	96,43%	3

Neste capítulo apresentou-se a metodologia que foi utilizada para a implementação do trabalho. Os resultados obtidos nos experimentos são descritos no próximo capítulo.

Capítulo 5

Resultados e Discussão

Este capítulo apresenta os resultados obtidos a partir dos experimentos realizados através da metodologia proposta no capítulo anterior.

O trabalho foi avaliado através de uma métrica principal: a taxa de acerto. Os resultados obtidos foram comparados com as classificações originais da base *MIT-BH Arrhythmia Database*, feitas por especialistas. Essa comparação gerou uma matriz de confusão. A taxa de acerto do modelo proposto foi comparada com as taxas de trabalhos de outros autores, já comentados na revisão da literatura.

Os resultados apresentados nas tabelas 5.1, 5.2 e 5.3 mostram a taxa de acerto no alcançada no conjunto de validação e desvio padrão em cada etapa da validação cruzada das redes neurais. A diferença básica das redes é o número de neurônios em cada uma das camadas.

A tabela 5.1 apresenta os resultados das redes formuladas na primeira abordagem utilizando 120 neurônios de entrada, que classificam os sinais em normal, taquicardia ventricular, fibrilação atrial e flutter ventricular.

Tabela 5.1: Resultados obtidos das RNAs 120-50-4-a1, 120-100-4-a1 e 120-150-4-a1.

120-50-4-a1			120-100-4-a1			120-150-4-a1		
Conj.	Validação	Desvio Padrão	Conj.	Validação	Desvio Padrão	Conj.	Validação	Desvio Padrão
1	80,99%	3,22	1	73,55%	6,86	1	80,17%	2,15
2	83,47%	5,70	2	86,78%	6,36	2	83,47%	1,16
3	69,42%	8,35	3	83,47%	3,06	3	89,26%	6,94
4	85,95%	8,18	4	80,17%	0,25	4	81,82%	0,50
5	72,73%	5,04	5	92,56%	12,15	5	91,74%	9,42
6	85,12%	7,36	6	72,73%	7,69	6	71,07%	11,24

7	80,17%	2,40	7	69,42%	10,99	7	79,34%	2,98
8	73,55%	4,21	8	71,90%	8,51	8	78,51%	3,80
9	72,73%	5,04	9	88,43%	8,02	9	93,39%	11,07
10	73,55%	4,21	10	85,12%	4,71	10	74,38%	7,93
Média	77,77%		Média	80,41%		Média	82,31%	

Neste caso, o melhor resultado foi obtido pela rede com 150 neurônios na camada intermediária.

A tabela 5.2 apresenta os resultados da segunda abordagem, da segunda rede, que classifica os demais sinais em normal, taquicardia ventricular e fibrilação atrial.

Tabela 5.2: Resultados obtidos das RNAs 120-50-3-a2, 120-100-3-a2 e 120-150-3-a2.

120-50-3-a2			120-100-3-a2			120-150-3-a2		
Conj.	Validação	Desvio Padrão	Conj.	Validação	Desvio Padrão	Conj.	Validação	Desvio Padrão
1	95,60%	0,99	1	98,90%	1,87	1	93,41%	2,97
2	98,90%	2,31	2	98,90%	1,87	2	98,90%	2,53
3	96,70%	0,11	3	98,90%	1,87	3	96,70%	0,33
4	95,60%	0,99	4	97,80%	0,77	4	96,70%	0,33
5	92,31%	4,29	5	95,60%	1,43	5	96,70%	0,33
6	97,80%	1,21	6	95,60%	1,43	6	97,80%	1,43
7	95,60%	0,99	7	94,51%	2,53	7	95,60%	0,77
8	95,60%	0,99	8	95,60%	1,43	8	94,51%	1,87
9	98,90%	2,31	9	95,60%	1,43	9	95,60%	0,77
10	98,90%	2,31	10	98,90%	1,87	10	97,80%	1,43
Média	96,59%		Média	97,03%		Média	96,37%	

Com os resultados das tabelas 5.1 e 5.2, fica evidente que com a adição do flutter ventricular para a classificação, a taxa de acerto cai consideravelmente. Isso ocorre devido à alta frequência do sinal do flutter ventricular, fazendo com que a rede não consiga classificar de forma correta utilizando a janela fixa, pois o padrão do flutter é “confundido” com os outros padrões, principalmente com o sinal normal e a taquicardia ventricular. Essa queda na taxa de acerto justifica a segunda abordagem utilizada no trabalho. A rede que apresentou o melhor resultado para a classificação dos quatro sinais utilizou 150 neurônios na camada intermediária.

Tabela 5.3: Resultados obtidos da RNA 120-50-2-a2, 120-100-2-a2 e 120-150-2-a2.

120-50-2-a2			120-100-2-a2			120-150-2-a2		
Conj.	Validação	Desvio Padrão	Conj.	Validação	Desvio Padrão	Conj.	Validação	Desvio Padrão
1	81,67%	3,67	1	81,67%	3,83	1	81,67%	6,17
2	93,33%	8,00	2	95,00%	9,50	2	93,33%	5,50
3	78,33%	7,00	3	76,67%	8,83	3	83,33%	4,50
4	91,67%	6,33	4	91,67%	6,17	4	91,67%	3,83
5	75,00%	10,33	5	81,67%	3,83	5	81,67%	6,17
6	85,00%	0,33	6	85,00%	0,50	6	91,67%	3,83
7	86,67%	1,33	7	80,00%	5,50	7	95,00%	7,17
8	90,00%	4,67	8	91,67%	6,17	8	90,00%	2,17
9	81,67%	3,67	9	85,00%	0,50	9	83,33%	4,50
10	90,00%	4,67	10	86,67%	1,17	10	86,67%	1,17
Média	85,33%		Média	85,50%		Média	87,83%	

A tabela 5.3 apresenta os resultados obtidos na separação do flutter ventricular dos demais sinais trabalhados (primeira rede neural da segunda abordagem).

Realizando a multiplicação dos resultados da melhor rede da tabela 5.2 e melhor rede da tabela 5.3 chega-se aos melhores resultados obtidos na segunda abordagem citada no trabalho e que podem ser visualizados na tabela 5.4.

Tabela 5.4: Resultados obtidos da 120-100-3-a2 X 120-150-2-a2.

Conj.	Validação	Desvio Padrão
1	80,77%	4,44
2	92,31%	7,10
3	82,42%	2,79
4	89,65%	4,45
5	78,08%	7,13
6	87,64%	2,43
7	89,78%	4,57
8	86,04%	0,84
9	79,67%	5,54
10	85,71%	0,51
Média	85,21%	

Os resultados mostrados pela tabela 5.4 descrevem que a segunda abordagem citada no trabalho possui uma melhor taxa de acerto sob a primeira abordagem. No trabalho (JUNG; TOMPKINS, 2003) a separação do flutter é realizada no começo da análise.

As tabelas 5.5, 5.6, 5.7 e 5.8, se assemelham respectivamente às tabelas 5.1, 5.2, 5.3 e 5.4, porém com a diferença de que as redes neurais utilizaram apenas 100 neurônios na camada de entrada.

Tabela 5.5: Resultados obtidos das RNAs 100-50-4-a1, 100-100-4-a1 e 100-150-4-a1.

100-50-4-a1			100-100-4-a1			100-150-4-a1		
Conj.	Validação	Desvio Padrão	Conj.	Validação	Desvio Padrão	Conj.	Validação	Desvio Padrão
1	61,16%	13,39	1	69,42%	9,26	1	60,33%	15,70
2	81,82%	7,27	2	66,94%	11,74	2	89,26%	13,22
3	73,55%	0,99	3	71,07%	7,60	3	85,12%	9,09
4	72,73%	1,82	4	87,60%	8,93	4	87,60%	11,57
5	85,12%	10,58	5	88,43%	9,75	5	88,43%	12,40
6	66,12%	8,43	6	70,25%	8,43	6	65,29%	10,74
7	76,86%	2,31	7	81,82%	3,14	7	85,95%	9,92
8	66,12%	8,43	8	81,82%	3,14	8	70,25%	5,79
9	85,12%	10,58	9	85,12%	6,45	9	65,29%	10,74
10	76,86%	2,31	10	84,30%	5,62	10	62,81%	13,22
Média	74,55%		Média	78,68%		Média	76,03%	

Tabela 5.6: Resultados obtidos das RNAs 100-50-3-a2, 100-100-3-a2 e 100-150-3-a2.

100-50-3-a2			100-100-3-a2			100-150-3-a2		
Conj.	Validação	Desvio Padrão	Conj.	Validação	Desvio Padrão	Conj.	Validação	Desvio Padrão
1	96,70%	1,76	1	95,60%	0,66	1	97,80%	0,88
2	94,51%	0,44	2	97,80%	1,54	2	98,90%	1,98
3	93,41%	1,54	3	94,51%	1,76	3	96,70%	0,22
4	93,41%	1,54	4	97,80%	1,54	4	95,60%	1,32
5	94,51%	0,44	5	96,70%	0,44	5	96,70%	0,22
6	96,70%	1,76	6	98,90%	2,64	6	98,90%	1,98
7	94,51%	0,44	7	95,60%	0,66	7	97,80%	0,88
8	96,70%	1,76	8	95,60%	0,66	8	97,80%	0,88
9	95,60%	0,66	9	95,60%	0,66	9	95,60%	1,32
10	93,41%	1,54	10	94,51%	1,76	10	93,41%	3,52
Média	94,95%		Média	96,26%		Média	96,92%	

Tabela 5.7: Resultados obtidos das RNAs 100-50-2-a2, 100-100-2-a2 e 100-150-2-a2.

100-50-2-a2			100-100-2-a2			100-150-2-a2		
Conj.	Validação	Desvio Padrão	Conj.	Validação	Desvio Padrão	Conj.	Validação	Desvio Padrão
1	85,00%	1,33	1	88,33%	1,00	1	90,00%	2,83

2	91,67%	6,33	2	96,67%	7,33	2	91,67%	4,50
3	80,00%	5,33	3	81,67%	7,67	3	80,00%	7,17
4	81,67%	3,67	4	90,00%	0,67	4	85,00%	2,17
5	88,33%	3,00	5	88,33%	1,00	5	88,33%	1,17
6	88,33%	3,00	6	90,00%	0,67	6	90,00%	2,83
7	78,33%	7,00	7	83,33%	6,00	7	80,00%	7,17
8	88,33%	3,00	8	90,00%	0,67	8	86,67%	0,50
9	90,00%	4,67	9	93,33%	4,00	9	85,00%	2,17
10	91,67%	6,33	10	91,67%	2,33	10	95,00%	7,83
Média	86,33%		Média	89,33%		Média	87,17%	

Tabela 5.8: Resultados obtidos da RNA 100-150-3-a2 X RNA 100-100-2-a2.

Conj.	Validação	Desvio Padrão
1	86,39%	1,18
2	95,60%	10,40
3	78,97%	6,23
4	86,04%	0,84
5	85,42%	0,21
6	89,01%	3,80
7	81,50%	3,71
8	88,02%	2,82
9	89,23%	4,02
10	85,62%	0,42
Média	86,58%	

Comparando os resultados apresentados nas tabelas acima, verifica-se que a utilização de janelas com 101 amostras, gera melhores resultados do que utilizar 121 amostras em cada janela para detectar as arritmias propostas com o método utilizado. Na separação do flutter ventricular a utilização de janelas com 121 amostras obteve um melhor resultado, porém com uma diferença de 0,11% em relação à melhor rede que utilizou janelas com 101 amostras. Isso comprova que para a separação do flutter ventricular o acréscimo de amostras em cada janela não surtiu efeito no resultado. Na classificação através da primeira abordagem a utilização de janelas com 121 amostras apresentaram melhores resultados, atingindo 82,31%.

Nas tabelas 5.9, 5.10, 5.11 e 5.12 são apresentadas as taxas de acertos, assim como o desvio padrão, em cada um dos conjuntos, na etapa de validação para cada tipo de sinal.

A tabela 5.9 apresenta os resultados obtidos por tipo de sinal pela RNA 120-150-3-a2. A rede com 120 neurônios de entrada que gerou os melhores resultados, utilizou-se de 150 neurônios na camada intermediária.

Tabela 5.9: Resultados obtidos por tipo de sinal da RNA 120-150-3-a2.

Etapas da Validação Cruzada	Fibrilação Atrial		Taquicardia Ventricular		Normal	
	Validação	Desvio Padrão	Validação	Desvio Padrão	Validação	Desvio Padrão
1	100,00%	1,14	97,06%	0,51	100,00%	5,62
2	100,00%	1,14	100,00%	2,43	97,14%	2,76
3	96,88%	1,99	100,00%	2,43	100,00%	5,62
4	100,00%	1,14	94,12%	3,45	100,00%	5,62
5	97,44%	1,43	100,00%	2,43	85,71%	8,67
6	100,00%	1,14	96,97%	0,60	90,91%	3,47
7	97,44%	1,43	96,77%	0,79	85,71%	8,67
8	96,88%	1,99	97,14%	0,42	91,67%	2,72
9	100,00%	1,14	96,55%	1,02	92,68%	1,70
10	100,00%	1,14	97,06%	0,51	100,00%	5,62
Taxa de Classificação Correta	98,86%		97,57%		94,38%	

A tabela 5.10 apresenta os resultados obtidos por tipo de sinal para a classificação direta das quatro categorias realizada pela RNA 120-150-4-a2. A rede com 120 neurônios de entrada que gerou os melhores resultados, utilizou-se de 150 neurônios na camada intermediária.

Tabela 5.10: Resultados obtidos por tipo de sinal da RNA 120-150-4-a1.

Etapas da Validação Cruzada	Fibrilação Atrial		Flutter Ventricular		Taquicardia Ventricular		Normal	
	Validação	Desvio Padrão	Validação	Desvio Padrão	Validação	Desvio Padrão	Validação	Desvio Padrão
1	95,65%	2,25	85,71%	19,97	46,67%	24,36	92,50%	1,99
2	100,00%	2,10	52,00%	13,75	80,65%	9,62	92,31%	2,18
3	100,00%	2,10	74,07%	8,33	91,18%	20,15	92,50%	1,99
4	97,30%	0,60	37,93%	27,82	90,00%	18,97	100,00%	5,51
5	92,31%	5,59	91,18%	25,43	91,18%	20,15	92,59%	1,90

6	100,00%	2,10	11,76%	53,98	80,00%	8,97	100,00%	5,51
7	97,44%	0,46	56,25%	9,50	76,67%	5,64	85,00%	9,49
8	96,30%	1,60	60,00%	5,75	70,59%	0,44	90,00%	4,49
9	100,00%	2,10	88,57%	22,82	83,33%	12,31	100,00%	5,51
10	100,00%	2,10	100,00%	34,25	0,00%	71,03	100,00%	5,51
Taxa de Classificação Correta	97,90%		65,75%		71,03%		94,49%	

A tabela 5.11 apresenta os resultados obtidos por tipo de sinal pela RNA 100-150-3-a2. A rede com 100 neurônios de entrada que obteve os melhores resultados, utilizou-se de 150 neurônios na camada intermediária.

Tabela 5.11: Resultados obtidos por tipo de sinal da RNA 100-150-3-a2.

Etapas da Validação Cruzada	Fibrilação Atrial		Taquicardia Ventricular		Normal	
	Validação	Desvio Padrão	Validação	Desvio Padrão	Validação	Desvio Padrão
1	100,00%	1,30	93,94%	3,60	100,00%	5,39
2	100,00%	1,30	96,55%	0,99	100,00%	5,39
3	96,88%	1,82	100,00%	2,46	92,31%	2,30
4	100,00%	1,30	95,12%	2,42	91,30%	3,31
5	96,00%	2,70	100,00%	2,46	95,00%	0,39
6	97,22%	1,48	100,00%	2,46	100,00%	5,39
7	100,00%	1,30	96,30%	1,25	96,67%	2,05
8	100,00%	1,30	100,00%	2,46	93,55%	1,06
9	100,00%	1,30	96,55%	0,99	92,68%	1,93
10	96,88%	1,82	96,97%	0,57	84,62%	10,00
Taxa de Classificação Correta	98,70%		97,54%		94,61%	

A tabela 5.12 apresenta os resultados obtidos por tipo de sinal para a classificação direta das quatro categorias realizada pela RNA 100-100-4-a1. A rede com 100 neurônios de entrada que gerou os melhores resultados, utilizou-se de 100 neurônios na camada intermediária.

Tabela 5.12: Resultados obtidos por tipo de sinal da RNA 100-100-4-a1.

Etapas da Validação Cruzada	Fibrilação Atrial		Flutter Ventricular		Taquicardia Ventricular		Normal	
	Validação	Desvio Padrão	Validação	Desvio Padrão	Validação	Desvio Padrão	Validação	Desvio Padrão
1	100,00%	13,39	94,44%	14,95	69,57%	6,91	0,00%	84,14
2	0,00%	86,61	59,26%	20,23	94,12%	31,46	100,00%	15,86
3	90,91%	4,30	84,00%	4,51	23,53%	39,13	92,50%	8,36
4	96,67%	10,05	76,67%	2,82	80,00%	17,34	100,00%	15,86
5	91,18%	4,56	80,65%	1,15	83,33%	20,67	96,88%	12,74
6	96,15%	9,54	100,00%	20,51	0,00%	62,66	96,77%	12,64
7	97,30%	10,69	76,67%	2,82	51,72%	10,93	100,00%	15,86
8	96,77%	10,16	50,00%	29,49	96,00%	33,34	87,88%	3,74
9	97,14%	10,53	97,22%	17,73	47,83%	14,83	85,19%	1,05
10	100,00%	13,39	76,00%	3,49	80,49%	17,83	82,14%	1,99
Taxa de Classificação Correta	86,61%		79,49%		62,66%		84,14%	

A maior parte das redes neurais que obtiveram os melhores resultados possuía 150 neurônios na camada intermediária. Em apenas dois casos as RNAs com 100 neurônios na camada intermediária obtiveram os melhores resultados. As RNAs com 50 neurônios na camada intermediária atingiram as menores taxas de acerto em todos os casos, exceto na rede 120-50-3-a2.

A quantidade de iterações realizadas para a evolução das redes através do PSO poderia ser menor, visto que normalmente a partir da iteração 70 o resultado da aptidão sofria pouca variação. Nas redes que utilizam 150 neurônios na camada intermediária, esse número de iterações pode ser menor, pois a evolução ocorre de forma mais rápida. Isso comprova a viabilidade de se utilizar o PSO para treinamento de redes neurais. O tempo gasto para cada iteração na evolução da rede 120-50-4-a2 foi de um segundo. O computador utilizado para realizar a evolução com o PSO possui um processador de 2GHz com dois núcleos.

Os resultados avaliados utilizando o flutter ventricular e sem o flutter, mostraram que a metodologia funcionou muito bem para a classificação dos sinais, excluindo-se o flutter ventricular. Para a classificação do flutter, a metodologia realizada não obteve bons resultados, demonstrando que outra técnica ou outra abordagem deve ser utilizada para detecção desta arritmia.

A tabela 5.13 compara os resultados de outros trabalhos citados na pesquisa, que também classificam o flutter, com o resultado obtido pelo trabalho realizado.

Tabela 5.13: Resultados obtidos por trabalhos da área que classificam também o flutter ventricular.

Pesquisa	Taxa de Acerto	Número de Arritmias Classificadas	Tipos de Sinais Classificados
(LETTNIN; VARGAS; MACARTHY, 2002)	80%	2	Normal, Contração Ventricular Prematura e Flutter Ventricular
(PRASAD; SAHAMBI, 2003)	96,70%	12	Normal, Left Bundle Branch Block, Right Bundle Branch Block, Abberated atrial premature beat, Ventricular premature beat, Fusion of ventricular and normal beat, Nodal (junctional) premature beat, Atrial premature beat, Ventricular escape beat, Nodal (junctional) escape beat, Paced beat, Ventricular flutter wave, Fusion of paced and normal beat
(JUNG; TOMPKINS, 2003)	91,10%	4	Taquicardia Ventricular, Taquicardia Supraventricular, Flutter Ventricular e Fibrilação Ventricular
Trabalho Realizado	86,58%	3	Normal, Taquicardia Ventricular, Fibrilação Atrial e Flutter Ventricular

Conforme visto na tabela 5.13, existe uma diferença grande entre a taxa de acertos dos trabalhos citados. Em (PRASAD; SAHAMBI, 2003) a quantidade de batimentos normais é muito maior do que a quantidade de batimentos das outras arritmias, fazendo com que a média da taxa de acertos se eleve. Já no trabalho realizado, a quantidade de batimentos é praticamente a mesma para cada tipo de sinal. O trabalho (JUNG; TOMPKINS, 2003) não

utiliza redes neurais, ele utiliza um algoritmo que analisa as ondas e intervalos do batimento. O primeiro passo do algoritmo verifica se o sinal é flutter ou fibrilação ventricular.

A tabela 5.14 apresenta os resultados obtidos em trabalhos relacionados à detecção automática de arritmias cardíacas através do ECG. O resultado obtido com a metodologia proposta está similar aos resultados encontrados por outros trabalhos, garantindo assim a validade do método proposto.

Tabela 5.14: Resultados obtidos por trabalhos da área que classificam arritmias exceto o flutter ventricular.

Pesquisa	Taxa de Acerto	Número de Arritmias Classificadas	Tipos de Sinais Classificados
(OZBAY; KARLIK, 2001)	97,80%	10	Normal, Sinus bradycardia, Ventricular tachycardia, Sinus arrhythmia, Atrial premature contraction, Paced beat, Right bundle branch block, Left bundle branch block, Atrial fibrillation e Atrial flutter
(LEE; PARK; SONG; LEE, 2005)	99,48%	3	Normal, Fibrilação Ventricular, Taquicardia Supraventricular e Contração Ventricular Prematura
(AL-FAHOUM; KHADRA, 2005)	93,60%	3	Normal, Fibrilação Atrial, Taquicardia Ventricular e Fibrilação Ventricular
(INAN; GIOVANGRANDI; KOVACS, 2006)	95,2%	1	Normal, Contração Prematura Ventricular e Outros
(JIANG; KONG; PETERSON, 2006)	98,72%	1	Ventricular ectopic beats e não Ventricular ectopic beats
(TSIPOURAS; VOGLIS; FOTIADIS, 2007)	96,43%	3	Normal, Ventricular flutter/fibrillation, Premature ventricular contractions e 2o heart block
(ROGAL et al., 2008)	86,33%	2	Normal, contração prematura

			atrial e contração prematura ventricular
Trabalho Realizado	97,03%	2	Normal, Taquicardia Ventricular, Fibrilação Atrial e Flutter Ventricular

A metodologia proposta apresenta uma facilidade para a adição da classificação de novas arritmias. Para adicionar uma nova arritmia é necessário segmentar o sinal de ECG e aplicar a transformada *Wavelet* discreta, gerando a base de entrada do software implementado. Com isso, determinam-se os argumentos de entrada do software e este evoluirá as redes neurais utilizando o PSO, até encontrar a melhor rede ou acabar o número de iterações.

Para a utilização de técnica apresentada neste trabalho em uma aplicação prática, utilizando apenas o sinal de ECG, é necessário um algoritmo de detecção do complexo QRS. Existem vários trabalhos na literatura sobre o assunto e que atingem taxas de 99% de eficiência.

5.1. Teste T de Student

O objetivo da análise de T de *Student* é descobrir se a diferença estatística entre dois conjuntos é significativa.

Neste trabalho foi utilizada esta análise para verificar a validade dos resultados obtidos. As tabelas 5.15, 5.16 e 5.17 apresentam os valores do teste T de *Student* para as RNAs que obtiveram os melhores resultados, comparando as duas abordagens utilizadas pelo trabalho e comparando também os resultados obtidos utilizando 121 e 101 amostras.

Tabela 5.15: Resultados obtidos com o teste T de Student comparando as abordagens.

Conj.	Primeira abordagem com 121 amostras	Segunda abordagem com 121 amostras	Diferença entre medidas
1	80,17%	80,77%	-1%
2	83,47%	92,31%	-9%
3	89,26%	82,42%	7%
4	81,82%	89,65%	-8%
5	91,74%	78,08%	14%
6	71,07%	87,64%	-17%
7	79,34%	89,78%	-10%

8	78,51%	86,04%	-8%
9	93,39%	79,67%	14%
10	74,38%	85,71%	-11%
Média	82,31%	85,21%	-2,89%
Desvio padrão	0,072906533	0,047949532	0,1078158
T de Student	-0,8485013		

Conj.	Primeira abordagem com 101 amostras	Segunda abordagem com 101 amostras	Diferença entre medidas
1	69,42%	86,39%	-17%
2	66,94%	95,60%	-29%
3	71,07%	78,97%	-8%
4	87,60%	86,04%	2%
5	88,43%	85,42%	3%
6	70,25%	89,01%	-19%
7	81,82%	81,50%	0%
8	81,82%	88,02%	-6%
9	85,12%	89,23%	-4%
10	84,30%	85,62%	-1%
Média	78,68%	86,58%	-7,90%
Desvio padrão	0,082992839	0,045051901	0,1036997
T de Student	-2,410513746		

Tabela 5.16: Resultados obtidos com o teste T de Student utilizando quantidade diferente de amostras.

Conj.	Primeira abordagem com 121 amostras	Primeira abordagem com 101 amostras	Diferença entre medidas
1	80,17%	69,42%	11%
2	83,47%	66,94%	17%
3	89,26%	71,07%	18%
4	81,82%	87,60%	-6%
5	91,74%	88,43%	3%
6	71,07%	70,25%	1%
7	79,34%	81,82%	-2%
8	78,51%	81,82%	-3%
9	93,39%	85,12%	8%

10	74,38%	84,30%	-10%
Média	82,31%	78,68%	3,64%
Desvio padrão	0,072906533	0,082992839	0,0952069
T de Student	1,207811148		
Conj.	Segunda abordagem com 121 amostras	Segunda abordagem com 101 amostras	Diferença entre medidas
1	80,77%	86,39%	-6%
2	92,31%	95,60%	-3%
3	82,42%	78,97%	3%
4	89,65%	86,04%	4%
5	78,08%	85,42%	-7%
6	87,64%	89,01%	-1%
7	89,78%	81,50%	8%
8	86,04%	88,02%	-2%
9	79,67%	89,23%	-10%
10	85,71%	85,62%	0%
Média	85,21%	86,58%	-1,38%
Desvio padrão	0,047949532	0,045051901	0,0545811
T de Student	-0,796902068		

Tabela 5.17: Resultados obtidos com o teste T de Student utilizando quantidade de amostras diferentes na primeira abordagem para cada sinal.

Etapas da Validação Cruzada	Fibrilação Atrial		Diferença entre as medidas	Taquicardia Ventricular		Diferença entre as medidas
	101 amostras	121 amostras		101 amostras	121 amostras	
1	100,00%	95,65%	4,35%	69,57%	46,67%	-15,48%
2	0,00%	100,00%	-100,00%	94,12%	80,65%	-48,50%
3	90,91%	100,00%	-9,09%	23,53%	91,18%	12,15%
4	96,67%	97,30%	-0,63%	80,00%	90,00%	1,07%
5	91,18%	92,31%	-1,13%	83,33%	91,18%	7,43%
6	96,15%	100,00%	-3,85%	0,00%	80,00%	19,13%
7	97,30%	97,44%	-0,14%	51,72%	76,67%	-64,59%
8	96,77%	96,30%	0,48%	96,00%	70,59%	24,92%
9	97,14%	100,00%	-2,86%	47,83%	83,33%	25,81%
10	100,00%	100,00%	0,00%	80,49%	0,00%	-20,98%
Média	86,61%	97,90%	-11,29%	62,66%	71,03%	-5,90%
Desvio padrão	0,30587	0,02615	0,31363	0,31608	0,28219	0,31113
T de Student	-1,1381			-0,6001		

Etapas da Validação Cruzada	Normal		Diferença entre as medidas	Flutter		Diferença entre as medidas
	101 amostras	121 amostras		101 amostras	121 amostras	
1	0,00%	92,50%	-92,50%	94,44%	85,71%	-15,48%
2	100,00%	92,31%	7,69%	59,26%	52,00%	-48,50%
3	92,50%	92,50%	0,00%	84,00%	74,07%	12,15%
4	100,00%	100,00%	0,00%	76,67%	37,93%	1,07%
5	96,88%	92,59%	4,28%	80,65%	91,18%	7,43%
6	96,77%	100,00%	-3,23%	100,00%	11,76%	19,13%
7	100,00%	85,00%	15,00%	76,67%	56,25%	-64,59%
8	87,88%	90,00%	-2,12%	50,00%	60,00%	24,92%
9	85,19%	100,00%	-14,81%	97,22%	88,57%	25,81%
10	82,14%	100,00%	-17,86%	76,00%	100,00%	-20,98%
Média	84,14%	94,49%	-10,35%	79,49%	65,75%	-5,90%
Desvio padrão	0,30267	0,05249	0,30441	0,15942	0,27505	0,31113
T de Student	-1,0756			-0,6001		

Utilizando um grau de confiança de 95% na tabela de distribuição T de *Student*, chega-se ao valor 2,262. Esse limiar foi ultrapassado na comparação entre os resultados da primeira e segunda abordagem utilizando 101 amostras em cada janela. Isso significa que existe uma diferença estatisticamente significativa entre as duas abordagens, sugerindo assim que a segunda abordagem apresentada pelo trabalho é mais adequada para a resolução do problema trabalhado.

As demais comparações não ultrapassaram o limiar. Portanto, confirma-se que nos valores obtidos não existe diferença significativa entre os resultados alcançados utilizando 121 e 101 amostras.

5.2. Conclusão

Este capítulo apresentou os resultados obtidos através da metodologia proposta. No capítulo seguinte será apresentada a conclusão do trabalho.

Capítulo 6

Conclusão

Este estudo apresentou informações referentes ao ECG e sua análise, as arritmias cardíacas, as *Wavelets*, redes neurais, o princípio do PSO e o funcionamento de seu algoritmo. Foi apresentado também o princípio do funcionamento da detecção automática de arritmias, utilizando como exemplos trabalhos científicos realizados nesta área. Nesta pesquisa foi abordada a utilização do PSO para a evolução dos pesos de uma RNA MLP de três camadas para realizar a classificação dos sinais de ECG com arritmia.

Os resultados obtidos na primeira e segunda abordagem utilizando 101 amostras em cada janela mostram que, a segunda abordagem é mais adequada para fazer a detecção automática de arritmias cardíacas em relação à primeira abordagem, quando um dos sinais classificados é o flutter ventricular, justificando a utilização da segunda abordagem neste trabalho.

A metodologia funcionou bem para a classificação dos sinais excluindo-se o flutter ventricular. Porém, constatou-se que para classificar o flutter e outras arritmias utilizando a rede neural artificial proposta (primeira abordagem), a metodologia trabalhada não é sugerida, devido aos resultados obtidos, demonstrando que outra técnica ou outra abordagem deve ser utilizada para detecção desta arritmia.

As redes neurais que possuíam 150 neurônios na camada intermediária, em geral, obtiveram um melhor resultado. A quantidade de iterações realizadas para a evolução das redes neurais utilizando o PSO poderia ser reduzida, devido ao fato de que normalmente, a partir da iteração 70, a aptidão atingida sofre pouca alteração até a iteração 100 (critério de parada). Isso fica mais evidente nas redes que utilizam 150 neurônios na camada intermediária, pois essa quantidade de iterações poderia ser menor ainda, devido à aptidão

aumentar mais rapidamente. Isso comprova a viabilidade de se utilizar o PSO para treinamento de redes neurais para realizar a classificação de sinais de ECG.

O trabalho realizado neste estudo levantou a hipótese de que uma rede neural, treinada através do PSO, utilizando como entrada os coeficientes gerados pela transformada *Wavelet* pode analisar o sinal de ECG, classificando-o em arritmias. Esta hipótese foi comprovada através da metodologia proposta, que buscou em duas abordagens utilizar conceitos do PSO para otimização da rede neural MLP para que esta realize a classificação do sinal de ECG. Demonstrou-se que a transformada *Wavelet* é um recurso recomendável para a extração de características do sinal de ECG, representando o sinal no domínio do tempo-frequência. Provou-se que o PSO pode otimizar uma rede neural MLP de três camadas sem um gasto computacional excessivo, conseguindo em poucas iterações chegar a resultados satisfatórios. Também se provou a deficiência do método proposto para classificar a arritmia flutter ventricular, pois devido à alta frequência do sinal a classificação é prejudicada.

O *Swarm* pode ter um futuro promissor dentro da área pesquisada, visto que poucos trabalhos utilizam *Swarm* para resolução deste tipo de problema. Com isso, novas questões podem ser levantadas a cerca do assunto:

- Quais outras *Wavelets* podem ser utilizadas para a extração de características?
- Quais outros métodos de segmentação do sinal podem ser utilizados?
- Quais outros parâmetros da RNA podem ser utilizados?
- Quais outros parâmetros do PSO e atributos de suas partículas podem ser utilizados?
- Quais outras arritmias podem ser classificadas utilizando este método?
- Em quais áreas a metodologia proposta poderia ser aplicada?

Portanto, para trabalhos futuros podem-se vislumbrar as seguintes etapas:

- Realizar testes mais profundos sobre a utilização de diferentes famílias de *Wavelets*, visto que nesta pesquisa foram utilizadas duas famílias, a *Coiflet* e a *Daubechies*;
- Segmentar o sinal de ECG através de outro método, como por exemplo, o método de janela variável ou mesmo utilizar o mesmo método, porém com janelas de tamanhos diferentes;
- Extrair outras características do sinal para auxiliar na classificação, tais como frequência e intervalos;

- Adicionar novas arritmias, treinando a rede neural classificadora através do mesmo método;
- Alterar parâmetros das RNAs e do PSO a fim de comparar o efeito de cada parâmetro no resultado final da detecção;
- Otimizar utilizando o PSO, além dos pesos da RNA, a topologia da rede, assim como as funções de ativação;

Sendo assim, a conclusão deste trabalho incita o início de novas pesquisas com a utilização do PSO evoluindo toda a estrutura de uma RNA MLP para realizar a classificação de diferentes tipos de sinais.

Referências

AL-FAHOUM, A.; KHADRA, L. Combined Bispectral and Bicoherency approach for Catastrophic Arrhythmia Classification. Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference Shanghai, China, September 1-4, 2005 Page(s): 332 – 336.

ARRITMIA CARDÍACA, In: Boa Saúde. Disponível em: <http://boasaude.uol.com.br/lib/ShowDoc.cfm?LibDocID=4825&ReturnCatID=357#Tipos%20de%20arritmia%20cardíaca>. Acesso em: 10 de março de 2007.

BIANCHINI, A. R. Arquitetura de Redes Neurais para o Reconhecimento Facial Baseado no Neocognitron. Dissertação - Universidade Federal de São Carlos – 2001.

BISCAIA, E. C. Jr.; SCHWAAB, M.; PINTO, J. C. Um Novo Enfoque do Método de Enxame de Partículas. NanoBio 2004, Rio de Janeiro, Março de 2004.

BUTTON, V. L. S. N. Apresentação – Eletrocardiógrafo e Monitor Cardíaco. DEB/FEEC/UNICAMP. Slide 4. Disponível em: <http://www.fee.unicamp.br/deb/vera/ecg.pdf>. Acesso em: 10 de janeiro de 2007.

CASTELANO, C. R. Estudo comparativo da Transformada Wavelet no Reconhecimento de Padrões da Íris Humana. Dissertação - Universidade de São Paulo - Escola de Engenharia de São Carlos. 2006.

CASTRO, L. N. de; IYODA E. M.; PINHEIRO E.; ZUBEN F. V. Redes Neurais Construtivas: Uma Abordagem Comparativa. Proceedings of the IV Brazilian Conference on Neural Networks - IV Congresso Brasileiro de Redes Neurais. Pages: 102 – 107, July, 1999 - ITA, São José dos Campos - SP – Brazil.

CHAVES, P. C; MOREIRA, A. L. ELECTROCARDIOGRAFIA - Texto de Apoio. Faculdade de Medicina do Porto, 2001. Disponível em: http://fisiologia.med.up.pt/Textos_Apoio/cardiaco/ECG.pdf. Acesso em: 19 de março de 2007

DAUBECHIES, I. Where Do Wavelets Come From? – A Personal Point of View. Proceedings of the IEEE, Vol. 84, No.4, pages: 510-513, April 1996.

ECG. Disponível em: www.cvphysiology.com/Arrhythmias/A009.htm. Acessado em 15 de janeiro de 2007.

ELECTROCARDIOGRAMA - Faculdade de Medicina do Porto - Serviço de Fisiologia. Disponível em: www.cristina.prof.ufsc.br/cardiovascular/fisiologia_med_up_pt_ecg.pdf. Acessado em 15 de janeiro de 2007.

FARIA, R. R. A. Aplicação de Wavelets na Análise de Gestos Musicais em Timbres de Instrumentos Acústicos Tradicionais. Dissertação – USP – 1997.

FELDMAN, J.; GOLDWASSER, G. P. Eletrocardiograma: recomendações para a sua interpretação. UFRJ - Revista da SOCERJ – Out/Nov/Dez 2004, 251-256.

FIGUEREDO, M. V. M. Uso de Transformadas Wavelet e Redes Neurais Artificiais na Compressão do Eletrocardiograma. Curitiba – PUCPR –Dissertação de Mestrado - 2008.

FLUTTER VENTRICULAR. Disponível em: <http://www.biotronik.de/sixcms/detail.php/688>. Acessado em 05 de janeiro de 2007.

GONÇALVES, M. A. B. Noções Básicas de Eletrocardiograma e Arritmias. Publicado por Senac, 1995.

GUYTON, A. C.; HALL, J. E. Textbook of Medical Physiology - 11ª Edition. 2006, Elsevier Saunders.

GRAY, HENRY. Gray Anatomia, Volume 2, 35ª ed., Ed. Guanabara Koogan, 1979.

GRAPS, A. An Introduction to Wavelets, IEEE Computational Science and Engineering. 1995. vol 2, no 2. Pages: 50-61.

HERMITE POLYNOMIAL. Disponível em:
<http://mathworld.wolfram.com/HermitePolynomial.html>. Acessado em 27 de Agosto de 2007.

INAN, O. T.; GIOVANGRANDI, L.; KOVACS, G. T. A. Robust Neural-Network-Based Classification of Premature Ventricular Contractions Using Wavelet Transform and Timing Interval Features. *IEEE Transactions on Biomedical Engineering*, VOL. 53, NO. 12, DECEMBER 2006. Pages: 2507 – 2515

JIANG, W.; KONG, S. G.; PETERSON, G. D. Continuous Heartbeat Monitoring Using Evolvable Block-based Neural Networks. *2006 International Joint Conference on Neural Networks*, Canadá, July 2006. Pages: 1950-1957.

JSWARM-PSO. Particle swarm optimization package written in Java. Disponível em:
<http://jswarm-pso.sourceforge.net/>. Acesso em 10 de dezembro de 2006.

JUNG, Y.; TOMPKINS, W. J. Detecting and Classifying Life-threatening ECG Ventricular Arrhythmias using Wavelet Decomposition. *Proceedings of the 25a Annual International Conference of the IEEE EMBS Cancun*, Mexico September 17-21,2003. Page(s): 2390 – 2393

KARIMIFARD, S.; AHMADIAN, A.; KHOSHNEVISAN, M.; NAMBAKHSH, M. S. Morphological Heart Arrhythmia Detection Using Hermitian Basis Functions and kNN Classifier. *Proceedings of the 28th IEEE EMBS Annual International Conference 2006*. Pages: 1367 – 1370

KENNEDY, J.; EBERHART, R. C. Swarm Intelligence. *Academic Press*. 2001, Pages: 286 – 289.

KENNEDY, J.; EBERHART, R. C. Particle Swarm Optimization. *Proceedings of the 1995 IEEE International Conference on Neural Networks*, v. 4, Pages: 1492-1948.

LINHARES, S.; GEWANDSZNAJDER, F. *Biologia Hoje*. Ed.Ática, 1997.

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

LEE J.; PARK, K. L.; SONG, M. H.; LEE, K. J. Arrhythmia Classification with Reduced Features by Linear Discriminant Analysis. *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the* , vol., no.pp. 1142-1144, 01-04 Sept. 2005.

LETTNIN, D. V.; VARGAS, F.; MACARTHY, M. Estudo de um Sistema para Classificação de Batimentos Cardíacos Utilizando Redes Neurais. *VIII IberChip*, México, Abril de 2002. Poster 8.

MEDEIROS, J. A. C. C. Enxame de Partículas como Ferramenta de Otimização em Problemas Complexos de Engenharia Nuclear. Tese UFRJ. Junho 2005. Capítulo 2, Página 14.

MEYER, C.; GAVELA, J. F.; HARRIS, M. Combining Algorithms in Automatic Detection of QRS Complexes in ECG Signals. *IEEE Transactions on Information Technology in Biomedicine*, VOL. 10, NO. 3, JULY 2006. Pages: 468 – 475.

MAMMEN, S. von; JACOB, C.; KÓKAI, G. Evolving Swarms that Build 3D Structures. *IEEE Congress on Evolutionary Computation*, UK, September 2005. Pages: 1434 – 1441.

OSOWSKI, S.; HOAI, L. T. Analysis of Features for Efficient ECG Signal Classification Using Neuro-fuzzy Network. *Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on* Volume 3, 25-29 July 2004 Page(s):2443 - 2448 vol.3.

OZBAY, Y.; KARLIK, B. A Recognition of Ecg Arrhythmias Using Artificial Neural Networks. *Engineering in Medicine and Biology Society, 2001. Proceedings of the 23rd Annual International Conference of the IEEE*. Volume 2, 25-28 Oct. 2001 Page(s):1680 - 1683 vol.2.

OSORIO, F. S. Um Estudo sobre Reconhecimento Visual de Caracteres Através de Redes Neurais. Porto Alegre: CPGCC, 1991. Dissertação de Mestrado.

PIFER, A. C.; CAMPOS, C. F. P. de S.; CAMPOS, A. L. P. de S. Aplicação de Wavelets para Remoção de Ruídos em Sinais Unidimensionais. *Holos*, Ano 24, Vol. 1. 2008.

PDAMED – Dicionário Digital de Termos Médicos 2007, Disponível em: http://www.pdamed.com.br/diciomed/pdamed_0001_aa.php . Acesso em: 17 de março de 2007

PHYSIONET. PhysioBank. MIT-BIH Arrhythmia Database. Disponível em: <http://www.physionet.org/physiobank/database/mitdb>. Acesso em: 14 de fevereiro de 2007.

PHYSIONET. PhysioBank. MIT-BIH Arrhythmia Database Directory. Disponível em: <http://www.physionet.org/physiobank/database/html/mitdbdir/tables.htm#allbeats>

PEREIRA, F. H.; NABETA, S. I. Uma Nova Abordagem Baseada em Wavelets para o Método Multigrid Algébrico: Parte I – Algoritmo Sequencial. *XXX CNMAC 2007*, Florianópolis.

PRASAD, G. K.; SAHAMBI, J. S. Classification of ECG Arrhythmias Using Multi-resolution Analysis and Neural Networks. *TENCON 2003. Conference on Convergent Technologies for Asia-Pacific Region* , vol.1, no.pp. 227- 231 Vol.1, 15-17 Oct. 2003.

RODRIGUEZ, J.; GOÑI, A.; DRANCA, L.; BURGOS, A.; ILLARRAMENDI, A. MOLEC: Anywhere and at Any Time Arrhythmia Classification. *Computers in Cardiology 2005*; Page(s): 607–610.

RIBEIRO, A. L. P. Fibrilação e Flutter Atrial. Fonte: Bibliomed. Disponível em: http://www.espacorealmedico.com.br/index_internas.htm?sUrl=http://www.espacorealmedico.com.br/informacoes/artigos/cardiologia/artigos/tpl_Artigo_log2178.shtm. Acesso em: 15 de Fevereiro de 2007.

RIBEIRO, P. F.; SCHLANSKER, W. K. A Hybrid Particle Swarm and Neural Network Approach for Reactive Power Control. Member IEEE. 2006. Disponível em: cpansearch.perl.org/src/KYLESCH/AI-PSO-0.81/ReactivePower-PSO-wks.pdf

ROJAS, J. E.; VIANA, F.A.C.; RADE, D. A. Force identification of mechanical systems by using particle swarm optimization. *In Proceedings of the 10th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference*, Albany, New York, Aug 30-01 Sept 2004.

SILVA, C. Y. V. W. Extração de Características de Imagens Médicas Utilizando Wavelets para Mineração de Imagens e Auxílio ao Diagnóstico. Dissertação - Universidade Federal de São Carlos. 2007.

SOCIEDADE BRASILEIRA DE CARDIOLOGIA Diretriz de Interpretação de Eletrocardiograma de Repouso. Arq Bras Cardiol Volume 80, (suplemento II), 2003.

SOCIEDADE BRASILEIRA DE CARDIOLOGIA Diretriz de Fibrilação Atrial. Arq Bras Cardiol Volume 81, (suplemento VI), 2003.

SARAMAGO, S. de F. P.; PRADO, J. R. do. Otimização por Colônia de Partículas. *Famat Em Revista*, UFU, v. 04, p. 87-103, 2005.

TAQUICARDIA VENTRICULAR, In: Intox. Disponível em: http://www.intox.org/databank/documents/treat/treatp/trt26_p.htm. Acesso em 15 de fevereiro de 2007.

TAQUICARDIA VENTRICULAR, In: Incor – Instituto do Coração. Disponível em: http://www.incor.usp.br/marcapasso/orientacao_cdi.html#1. Acesso em 08 de fevereiro de 2007.

TRELEA, I.C. The Particle Swarm Optimization Algorithm: Convergence Analysis and Parameter Selection. *Information Processing Letters* 85 (2003) 317-325.

TSIPOURAS, M. G.; VOGLIS, C.; FOTIADIS, D. I. A Framework for Fuzzy Expert System Creation – Application to Cardiovascular Diseases. *IEEE Transactions on Biomedical Engineering*, Vol 54, Issue 8, 2007.

VESTERSTROM, J.; RIGET, J. Particle Swarms. Extensions for Improved Local, Multimodal, Dynamic Search in Numerical Optimization. *Master's thesis, Department of Computer Science, University of Aarhus*, Dinamarca, 2002.

WORLD HEART FEDERATION, Relatório Anual de 2002 Page: 4. Disponível em: http://www.world-heart-federation.org/fileadmin/user_upload/documents/About-annual-report-2002.pdf. Acesso em 20 de outubro de 2006.