



UNIVERSIDADE
ESTADUAL DE LONDRINA

THIAGO REGES PERALES

**UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS NO
DIAGNÓSTICO DE CARDIOPATAS**

Londrina
2011

THIAGO REGES PERALES

**UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS NO
DIAGNÓSTICO DE CARDIOPATAS**

Dissertação submetida ao Departamento de Engenharia Elétrica da Universidade Estadual de Londrina como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Márcio Roberto Covacic.

Londrina
2011

**Catálogo elaborado pela Divisão de Processos Técnicos da Biblioteca Central da
Universidade Estadual de Londrina**

Dados Internacionais de Catalogação-na-Publicação (CIP)

P426u Perales, Thiago Reges.
Utilização de redes neurais artificiais no diagnóstico de cardiopatas / Thiago
Reges Perales. – Londrina, 2011.
150 f. : il.

Orientador: Manuel Simões Filho.
Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual de
Londrina, Centro de Tecnologia e Urbanismo, Programa de Pós-Graduação em
Engenharia Elétrica, 2011.
Inclui bibliografia.

1. Cardiopatas – Diagnósticos – Teses. 2. Redes Neurais artificiais – Teses. 3.
Inteligência artificial – Engenharia – Teses. I. Covacic, Márcio Roberto. II.
Universidade Estadual de Londrina. Centro de Tecnologia e Urbanismo.
Programa de Pós-Graduação em Engenharia Elétrica. III. Título.

CDU 519.683:616

THIAGO REGES PERALES

**UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS NO
DIAGNOSTICO DE CARDIOPATAS**

Dissertação submetida ao Departamento de Engenharia Elétrica da Universidade Estadual de Londrina como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

BANCA EXAMINADORA

Orientador: Prof. Dr. Márcio Roberto Covacic
Universidade Estadual de Londrina – UEL

Prof. Dr. Ernesto Fernando Ferreyra Ramírez
Universidade Estadual de Londrina – UEL

Prof. Dr. Marcos Eduardo Ribeiro do Valle
Universidade Estadual de Londrina – UEL

Londrina, 25 de julho de 2011.

PERALES, Thiago Reges. **Utilização de redes neurais artificiais no diagnóstico de cardiopatas**. 2011. 150 f. Dissertação (mestrado em Engenharia Elétrica) – Universidade Estadual de Londrina, Londrina, 2011.

RESUMO

Este trabalho trata da aplicação de redes neurais artificiais para o diagnóstico de cardiopatias como arritmia e insuficiência cardíaca congestiva. Foram seguidos os passos: Aquisição e condicionamento dos dados para serem aplicados como entrada das redes; Treinamento de diversas redes para escolher a de melhor desempenho. A rede neural artificial para diagnosticar pessoas saudáveis foi a que apresentou melhor desempenho, com 95,93% de acerto. Já o diagnóstico de insuficiência cardíaca congestiva foi de 91,70%, e o de arritmia cardíaca foi de 93,67% de acerto. Assim, pode ser afirmado que as redes neurais artificiais poderão ajudar muito a obter um diagnóstico preciso e rápido. Fica como sugestão de trabalhos futuros realizar o treinamento com um número bem maior de dados para realizar o treinamento e melhorar ainda mais o desempenho da rede.

Palavras-chave: Redes neurais artificiais. Inteligência artificial. Diagnóstico em cardiopatas.

PERALES, Thiago Reges. **Use of artificial neural networks in the diagnosis of c**
Master in Electrical Engineering ardiac. 2011. 150 f. Dissertation (Master in
Electrical Engineering) – Universidade Estadual de Londrina, 2011.

ABSTRACT

This work is about the application of Artificial Neural Networks for the diagnosis of heart disease as arrhythmia and insufficiency heart congestive. The followed steps had been: Acquisition and conditioning of the data to be applied as input of the nets; Training of several nets to choose that with the best performance. The neural network to diagnosis healthy people was what it presented the best performance, with 95,93% of rightness. Already the diagnosis of insufficiency heart congestive it was of 91,70%, and the arrhythmia cardiac it was of 93,67% of rightness. Thus, it can be affirmed that the artificial neural networks will be able to help very to get fast and precise the diagnosis. It is as suggestion to future works to carry through the training with a well bigger number of data to carry through the training and still more improve the performance of the network.

Keywords: Artificial neural network. Artificial intelligence. Diagnostic in heart disease.

LISTA DE FIGURAS

Figura 1	– Modelo de um neurônio	19
Figura 2	– Gráficos das funções de ativação: (a) Função de limiar, (b) Função de limiar por partes e (c) Função sigmoide	21
Figura 3	– A figura (a) representação completa e a (b) representação parcialmente completa	23
Figura 4	– Rede alimentada adiante com camada única	25
Figura 5	– Modelo com uma camada de neurônio oculto e totalmente conectada	26
Figura 6	– Rede recorrente com realimentação normal	27
Figura 7	– Rede recorrente com auto realimentação	27
Figura 8	– Grafo de fluxo de sinal ressaltando detalhes do neurônio de saída	33
Figura 9	– Grafo de fluxo de sinal ressaltando os detalhes do neurônio de saída k conectado ao neurônio oculto j	37
Figura 10	– Eletrocardiograma	46
Figura 11	– Eletrocardiograma mostrando o intervalo RR	47
Figura 12	– Demonstração do código no prompt de comando	48
Figura 13	– Gráfico mostrando o intervalo RR antes e depois de ser filtrado	51
Figura 14	– Gráfico com valores do intervalo RR	52
Figura 15	– Gráfico mostrando como foi feita a reamostragem	52
Figura 16	– Gráfico mostrando como foi feita a reamostragem	55
Figura 17	– Fluxograma de Treinamento para as RNAs	57
Figura 18	– Bloco base para o primeiro modelo	59
Figura 19	– Bloco base para o segundo modelo	59
Figura 20	– Bloco base para o terceiro modelo	60
Figura 21	– Bloco base para o quarto modelo	61
Figura 22	– Bloco base para o quinto modelo	61
Figura 23	– Bloco base para o sexto modelo	62
Figura 24	– Rede completa para o diagnóstico com 3 saídas	62
Figura 25	– Tela de treinamento da RNA utilizando nntool	64
Figura 26	– Gráfico com treinamento e teste da rede 3	68

Figura 27 – Gráfico com treinamento e teste da rede 8.....	69
Figura 28 – Gráfico com treinamento e teste da rede 12.....	70
Figura 29 – Gráfico com treinamento e teste da rede 17.....	70
Figura 30 – Gráfico do treinamento e teste da rede escolhida para diagnosticar Insuficiência Cardíaca Congestiva	72
Figura 31 – Gráfico do treinamento e teste da rede escolhida para diagnosticar Arritmia Cardíaca.....	73
Figura 32 – Rede completa para o diagnóstico	88
Figura 33 – Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 1.....	103
Figura 34 – Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 2.....	103
Figura 35 – Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 4.....	104
Figura 36 – Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 5.....	104
Figura 37 – Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 6.....	105
Figura 38 – Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 7.....	105
Figura 39 – Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 9.....	106
Figura 40 – Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 10.....	106
Figura 41 – Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 1.....	107
Figura 42 – Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 13.....	107
Figura 43 – Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 14.....	108
Figura 44 – Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 15.....	108
Figura 45 – Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 16.....	109

Figura 46 – Treinamento e teste para o diagnóstico de insuficiência cardíaca congestiva, com a rede 3	110
Figura 47 – Treinamento e teste para o diagnóstico de insuficiência cardíaca congestiva, com a rede 8	111
Figura 48 – Treinamento e teste para o diagnóstico de insuficiência cardíaca congestiva, com a rede	111
Figura 49 – Treinamento e teste para o diagnóstico de Arritmia cardíaca, com a rede 3	112
Figura 50 – Treinamento e teste para o diagnóstico de Arritmia cardíaca, com a rede 8	112
Figura 51 – Treinamento e teste para o diagnóstico de Arritmia cardíaca, com a rede 12	113

LISTA DE TABELAS

Tabela 1 – Características da programação convencional e da programação em IA	17
Tabela 2 – Causas de mortes no mundo	42
Tabela 3 – Parâmetros de Treinamento para o Algoritmo LMS.....	65
Tabela 4 – Resultados das redes de 1 a 6	66
Tabela 5 – Resultados das redes de 7 a 12	67
Tabela 6 – Resultados das redes de 13 a 17	67
Tabela 7 – Redes de melhor desempenho	68
Tabela 8 – Dados obtidos com o treinamento para diagnosticar Insuficiência Cardíaca Congestiva.....	71
Tabela 9 – Dados obtidos com o treinamento para diagnosticar Arritmia Cardíaca	73
Tabela 10 – Parâmetros para de treinamento para definição da constante Momento.....	75
Tabela 11 – Tabela com resultados do treinamento para definição da constante momento	75
Tabela 12 – Parâmetros para o primeiro treinamento do algoritmo Backpropagation com 1 camada oculta.....	76
Tabela 13 – Resultado do primeiro treinamento do algoritmo Backpropagation com 1 camada oculta.....	76
Tabela 14 – Resultados do treinamento das melhores redes (1 e 7) em pessoas saudas	77
Tabela 15 – Resultados do treinamento das melhores redes (1 e 7) em pessoas com Insuficiência cardíaca congestiva	78
Tabela 16 – Resultados do treinamento das melhores redes (1 e 7) em pessoas com Arritmia Cardíaca.....	78
Tabela 17 – Parâmetros, das melhores redes, do primeiro treinamento do algoritmo Backpropagation com 2 camadas ocultas.....	80
Tabela 18 – Resultados das melhores redes do primeiro treinamento do algoritmo backpropagation com 2 camadas ocultas	80

Tabela 19 – Parâmetros, das melhores redes, do primeiro treinamento do algoritmo Backpropagation com 2 camadas ocultas com epMax igualado.....	81
Tabela 20 – Melhores resultados do treinamento backpropagation 2 camadas em pessoas saudias.....	81
Tabela 21 – Melhores resultados do treinamento backpropagation 2 camadas em pessoas com insuficiência cardíaca congestiva.....	82
Tabela 22 – Melhores resultados do treinamento backpropagation 2 camadas em pessoas com arritmia cardíaca.....	82
Tabela 23 – Parâmetros para o treinamento da RNA com 1 camada oculta utilizando nntools	83
Tabela 24 – Resultados do treinamento de RNAs de 1 camada oculta e treinadas com nntools.....	84
Tabela 25 – Parâmetros para o treinamento da RNA com 2 camadas ocultas utilizando nntools.....	84
Tabela 26 – Resultados do treinamento de RNAs de 2 camadas ocultas e treinadas com nntools	85
Tabela 27 – Comparação dos Resultados das redes treinadas com o algoritmo desenvolvido e com o nntools.....	86
Tabela 28 – Tabela comparando os erros obtidos no treinamento de cada tipo de rede	87
Tabela 29 – Tabela com parâmetros do teste da variável de momento	114
Tabela 30 – Tabela com parâmetros do teste da variável de momento (cont.).....	115
Tabela 31 – Tabela com os resultados dos treinamentos com os parâmetros da tabela 22.....	116
Tabela 32 – Resultados do treinamento após a escolha da valor da constante de momento	117
Tabela 33 – Resultado do novo teste com as redes 1 e 7.....	118
Tabela 34 – Teste com os dados de insuficiência cardíaca congestiva	119
Tabela 35 – Teste com os dados de arritmia cardíaca	120
Tabela 36 – Parâmetros do primeiro treinamento com o backpropagation de duas camadas	121

Tabela 37 – Parâmetros do primeiro treinamento com o backpropagation de duas camadas (cont...)	122
Tabela 38 – Parâmetros do primeiro treinamento com o backpropagation de duas camadas (cont...)	123
Tabela 39 – Parâmetros do primeiro treinamento com o backpropagation de duas camadas (cont...)	124
Tabela 40 – Resultados do treinamento com os parâmetros da Tabela 28	125
Tabela 41 – Resultados do treinamento com os parâmetros da Tabela 28 (cont...)	126
Tabela 42 – Resultados do treinamento com os parâmetros da Tabela 28 (cont...)	127
Tabela 43 – Resultados do treinamento com os parâmetros da Tabela 28 (cont...)	128
Tabela 44 – Resultados do treinamento com os parâmetros da Tabela 28 (cont...)	129
Tabela 45 – Resultados do treinamento com os parâmetros da Tabela 28 (cont...)	130
Tabela 46 – Resultados do treinamento com os parâmetros da Tabela 28 (cont...)	131
Tabela 47 – Resultados do treinamento com os parâmetros da Tabela 28 (cont...)	132
Tabela 48 – Resultado do novo treinamento com as redes escolhidas e com o epmax igualado	133
Tabela 49 – Resultado do novo treinamento com as redes escolhidas e com o epmax igualado (cont...)	134
Tabela 50 – Resultado do novo treinamento com as redes escolhidas e com o epmax igualado (cont...)	135
Tabela 51 – Resultado do novo treinamento com as redes escolhidas e com o epmax igualado (cont...)	136
Tabela 52 – Resultado do novo treinamento com as redes escolhidas e com o epmax igualado (cont...)	137

Tabela 53 – Resultado do novo treinamento com as redes escolhidas e com o e _{pmax} igualado (cont...)	138
Tabela 54 – Resultados do teste das redes com os dados de insuficiência cardíaca congestiva	139
Tabela 55 – Resultados do teste das redes com os dados de insuficiência cardíaca congestiva (cont...)	140
Tabela 56 – Resultados do teste das redes com os dados de arritmia cardíaca	141
Tabela 57 – Resultados do teste das redes com os dados de arritmia cardíaca (cont...)	142

SUMÁRIO

1 INTRODUÇÃO	15
1.1 OBJETIVO.....	16
2 INTRODUÇÃO A REDES NEURAIS ARTIFICIAIS	17
2.1 INTELIGÊNCIA ARTIFICIAL E REDES NEURAIS	17
2.2 O QUE É UMA REDE NEURAL ARTIFICIAL	18
2.3 MODELO DE UM NEURÔNIO.....	18
2.4 REDES NEURAIS VISTAS COMO GRAFOS ORIENTADOS.....	22
2.5 ARQUITETURAS DE REDES.....	24
2.5.1 Redes Diretas	24
2.5.1.1 Redes progressivas (alimentadas adiante) com camada única.....	24
2.5.1.2 Redes progressivas com múltiplas camadas	25
2.5.2 Redes Recorrentes.....	26
2.6 REPRESENTAÇÃO DO CONHECIMENTO.....	28
3 ALGORITMOS DE TREINAMENTO	29
3.1 ALGORITMO DO MÍNIMO QUADRADO MÉDIO (LMS).....	29
3.1.1 Algoritmo LMS	29
3.1.2 Convergência do Algoritmo LMS	31
3.1.3 Virtudes e Limitações do Algoritmo LMS	31
3.1.3.1 Virtudes.....	31
3.1.3.2 Limitações.....	32
3.1.4 Aprendizagem.....	32
3.2 ALGORITMO BACKPROPAGATION (RETROPROPAGAÇÃO)	33
3.2.1 Algoritmo de Retropopagação	33
3.2.2 Os Dois Passos da Computação	39
3.2.3 Função de Ativação	40
3.2.4 Taxa de Aprendizagem.....	40
4 DOENÇAS CARDÍACAS	42
4.1 O CICLO CARDÍACO	43

4.2	ARRITMIA CARDÍACA	43
4.3	INSUFICIÊNCIA CARDÍACA CONGESTIVA	44
5	METODOLOGIA.....	46
5.1	O INTERVALO RR.....	46
5.2	AQUISIÇÃO DE DADOS	47
5.3	CONDICIONAMENTO DE DADOS	50
5.3.1	Filtragem dos Dados.....	50
5.3.2	Reamostragem	51
5.3.3	Densidade Espectral de Potência (PSD).....	54
5.3.4	Integral.....	54
5.3.5	Bootstrap (Reamostragem).....	56
5.4	APLICANDO A RNA	57
5.4.1	Fluxograma Padrão para Treinamento e Teste	57
5.4.2	Divisão dos Dados.....	58
5.4.3	Modelos para a Solução dos Problemas	58
5.4.3.1	Primeiro modelo.....	58
5.4.3.2	Segundo modelo	59
5.4.3.3	Terceiro modelo	60
5.4.3.4	Quarto modelo	60
5.4.3.5	Quinto modelo.....	61
5.4.3.6	Sexto modelo	62
5.4.3.7	Modelo geral da RNA.....	62
5.4.4	Redes do Matlab Utilizando nntools	63
6	RESULTADOS E DISCUSSÃO	65
6.1	RESULTADOS OBTIDOS COM O ALGORITMO LMS.....	65
6.2	RESULTADOS COM O BACKPROPAGATION	74
6.2.1	Algoritmo Backpropagation com 1 Camada Oculta	74
6.2.2	Algoritmo Backpropagation com 2 Camadas Ocultas.....	79
6.3	RESULTADOS DOS TREINAMENTOS UTILIZANDO NNTOOLS	83
6.3.1	RNA 1 Camada Oculta	83
6.3.2	RNA 2 Camada Oculta	84

7 CONCLUSÕES	87
7.1 CONCLUSÕES DO TRABALHO	87
7.2 SUGESTÕES DE TRABALHOS FUTUROS	88
REFERÊNCIAS	89
APÊNDICES	91
APÊNDICE A – Funções criadas no Matlab para o desenvolvimento deste trabalho	92
Função Início	92
Função Main	93
Função Leitor	94
Função Reamostragem	95
Função PSD	95
Função Integral	96
Função para Normalizar os Dados	98
Algoritmo LMS Utilizado	101
APÊNDICE B – Gráficos gerados nos treinamentos e testes das redes	103
Treinamento para Diagnóstico de Pessoas Saudáveis	103
Treinamento para Diagnóstico de Pessoas com Insuficiência Cardíaca Congestiva	110
Treinamento para Diagnóstico de Pessoas com Arritmia Cardíaca	112
APÊNDICE C – Tabelas geradas nos treinamentos e testes das redes	114
Tabelas do treinamento das redes de 1 camada oculta com algoritmo backpropagation	114
Tabelas do treinamento das redes de 2 camadas ocultas com algoritmo backpropagation	121
APÊNDICE D – Artigo apresentado ao congresso CBIS 2008	143

1 INTRODUÇÃO

As redes neurais artificiais começaram com o trabalho dos pioneiros McCulloch e Pitts em 1943 e, desde então, vem sendo cada vez mais empregadas em diversas áreas, tais como: modelamento, controle, reconhecimento de padrões, análise de séries temporais e processamento de sinais. O principal motivo dessa ampla variedade de aplicações é a habilidade de aprender a partir de dados de entrada (com ou sem supervisão), além de ter raízes em múltiplas disciplinas como neurociência, matemática, estatística, física, ciência da computação e engenharia (HAYKIN, 2001).

Nos dias de hoje, a tecnologia evolui constantemente e o uso de ferramentas computacionais está bastante difundido; por outro lado, o tempo livre é cada vez mais escasso. Então, é necessário que os exames médicos também acompanhem essa evolução. Pode-se utilizar a tecnologia disponível para aumentar a agilidade e a confiabilidade, e ainda, ter uma ferramenta que auxilie nas decisões médicas. Em muitos casos os problemas de diagnóstico médico são devidos às inconsistências, exceções às regras e especificações incompletas, forçando a resolver o problema com conhecimento parcial ou aproximado dos dados (VON ZUBEN, 2003; BARRETO, 2000; BARRETO, 2001).

Em alguns trabalhos são mostradas aplicações para problemas de diagnóstico médico em áreas correlatas, tais como: classificação da apnéia do sono (FONTELLA - ROMERO et al., 2005); detecção da obstrução das vias aéreas superiores (BRIGHT, 1998); ou diagnóstico de doença pulmonar obstrutiva crônica (OLIVEIRA et al, 2006)

Neste trabalho foi realizada a conexão entre redes neurais artificiais e diagnósticos médicos de cardiopatias. As redes foram aplicadas ao diagnóstico de cardiopatias como arritmia e insuficiência cardíaca congestiva (devido à disponibilidade desses dados). Pode ser observado nos resultados obtidos que esta conexão teve um bom resultado. Futuramente, a rede poderá ser integrada em hardware para funcionar como um holter¹ inteligente, que faça o diagnóstico do paciente à medida que for ocorrendo o monitoramento de 24 horas. Assim, o paciente poderá ter seu tratamento prescrito de forma mais eficiente e rápida.

¹ *Holter: aparelho de monitoramento cardíaco.*

Os dados para a realização deste trabalho foram obtidos da internet no site www.physionet.org, onde também é possível encontrar o programa para a conversão dos mesmos.

1.1 OBJETIVO

Este trabalho tem como objetivo desenvolver e treinar um conjunto de redes neurais artificiais que permitirá o auxílio no diagnóstico rápido e confiável de cardiopatias. Assim, o tratamento dos pacientes iniciará-se rapidamente, melhorando com isso a sua eficácia.

2 INTRODUÇÃO A REDES NEURAIS ARTIFICIAIS

2.1 INTELIGÊNCIA ARTIFICIAL E REDES NEURAIS

Inteligência Artificial (IA) é uma área de estudo que abrange diferentes campos da ciência, incluindo lógica nebulosa (*fuzzy logic*), redes neurais artificiais e sistemas especialistas (BLANCHARD et al. 2000). Os programas computacionais de IA são bem diferentes dos programas convencionais, conforme pode ser visto na Tabela 1

Tabela 1 – Características da programação convencional e da programação em IA.

Programação Convencional	Programação em Inteligência Artificial
1.Primariamente processamento numérico	1.Primariamente processamento simbólico
2.Soluções algorítmicas	2.Soluções heurísticas (uso do “bom-senso”)
3.Estruturas de controle e de conhecimento integradas	3.Estrutura de controle separada do domínio de conhecimento
4.Difícil modificação e atualização	4.Fácil modificação e atualização
5.Só a resposta correta interessa	5.Algumas respostas erradas são toleradas
6.Só a melhor solução satisfaz	6.Respostas satisfatórias usualmente são aceitas

Fonte: adaptado de Ribeiro (1987)

Pela Tabela 1 pode-se perceber que a IA será mais adequada para problemas cuja solução não possa ser obtida através do uso de algoritmos (RIBEIRO, 1987). Por isso a IA tem sido muito útil na resolução de alguns tipos específicos de problemas, dentre os quais:

- Processamento de linguagem natural (RIBEIRO, 1987);
- Modelamento e processamento de sinais biológicos (BLANCHARD et al. 2000);
- Base de dados inteligente (BARRETO, 2001);
- Ensino (ALMEIDA, 1999);

- Diagnóstico e auxílio na tomada de decisão (REFENES et al, 1997; FERREYRA RAMIREZ, 2005).

2.2 O QUE É UMA REDE NEURAL ARTIFICIAL?

Rede neural artificial é uma ferramenta computacional utilizada para resolução de problemas, processamento de sinais e de imagens, entre outras aplicações. Ela foi desenvolvida com inspiração no cérebro humano e tem por objetivo obter a rapidez e a precisão de processamento de um cérebro humano, acelerando o processamento dos métodos digitais utilizados hoje em dia, que tem um processamento muito lento, quando comparados com os da rede neural. Essa rede, como no cérebro humano descrito em livros consagrados de fisiologia humana, como Guyton e Hall (2002), também pode ser implementada em blocos específicos para uma determinada função e depois pode ser reagrupada para a resolução de um sistema.

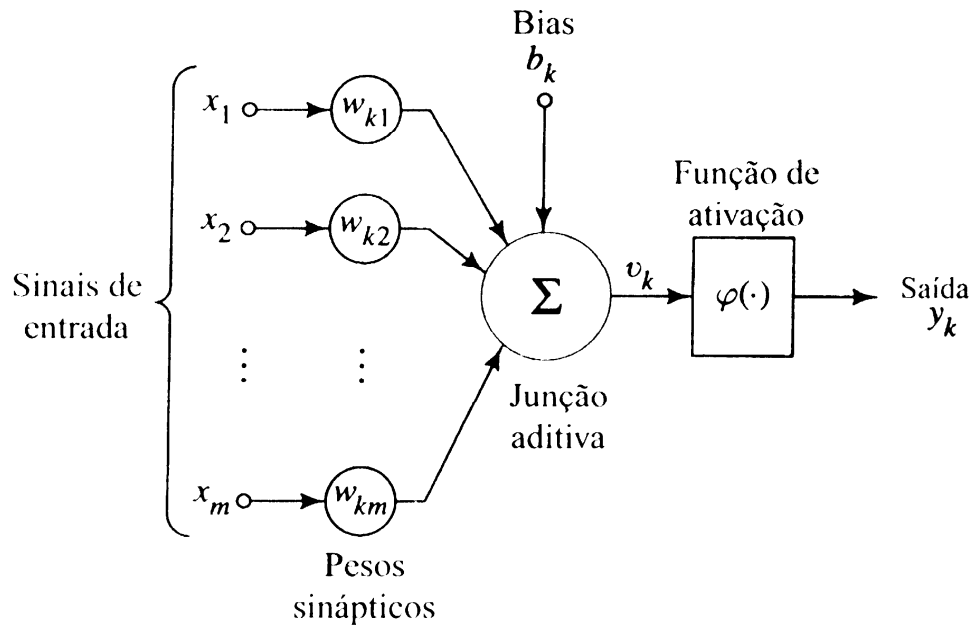
A rede tem por benefício a aprendizagem (supervisionada ou não), que seria o mapeamento de entrada e saída em que se fornecem os pesos sinápticos para adequar as saídas com as entradas. Ela também pode se adaptar com o meio onde ela não foi treinada, mas é necessário tomar cuidado com estas variações para que o sistema possa ignorar variações espúrias.

Os neurônios de uma rede estão interligados uns com os outros, e todos os neurônios são afetados pela atividade da rede. Caso haja problema com um neurônio, este afetará a rede inteira. Porém, ela deve suportá-lo e se auto corrigir.

2.3 MODELO DE UM NEURÔNIO

No modelo da Figura 1, X_j são as entradas do neurônio K , W_{kj} são os pesos sinápticos do neurônio K de cada entrada j , e b_k tem a função de aumentar ou diminuir a entrada líquida da função de ativação mostrada na Equação 1.

Figura 1 – Modelo de um neurônio.



Fonte: Haykin (2001)

$$U_j = \sum_{i=1}^m w_{kj} x_j \text{ e } V_k = U_k + b_k \text{ e } Y_k = \varphi(U_k + b_k) \quad (1)$$

Onde:

X_j = sinal de entrada

w_{kj} = pesos sinápticos

U_j = saída do combinador linear

V_k = campo local induzido do neurônio K

b_k = bias

O neurônio pode ser determinístico ou estocástico dependendo do tipo da função de ativação.

No neurônio determinístico, a função de ativação pode ser uma função de limiar (Equação 2), linear por partes (Equação 3) ou sigmóide (Equação 4):

Função de limiar $\rightarrow \varphi(V) = \begin{cases} 1 & \text{se } V \geq 0 \\ 0 & \text{se } V < 0 \end{cases}$ (2)

O gráfico da função φ apresentado na Equação 2 pode ser visto na figura 2a.


Função de limiar por partes $\rightarrow \varphi(V) = \begin{cases} 1, & \text{se } V \geq \frac{1}{2} \\ V & \text{se } -\frac{1}{2} < V < \frac{1}{2} \\ 0 & \text{se } V \leq -\frac{1}{2} \end{cases}$ (3)

O gráfico da Equação 3 pode ser visto na figura 2b.


Função sigmóide $\rightarrow \varphi(V) = \frac{1}{1 + e^{-aV}}$ (4)

O gráfico da Equação 4 pode ser visto na figura 2c.


Figura 2 – Gráficos das funções de ativação: (a) Função de limiar, (b) Função de limiar por partes e (c) Função sigmóide.



(a)



(b)



(c)

Fonte: Haykin (2001)

Os gráfico das funções de ativação mostrados na Figura 2 são para redes onde as saídas vão de 0 a 1. No caso em que as saídas forem de -1 até 1 temos a função sinal (Equação 5) e a tangente hiperbólica (Equação 6):

$$\text{Função sinal (correspondente ao limiar)} \rightarrow \varphi(V) = \begin{cases} 1 & \text{se } V > 0 \\ 0 & \text{se } V = 0 \\ -1 & \text{se } V < 0 \end{cases} \quad (5)$$

$$\text{Função tangente hiperbólica} \rightarrow \varphi(V) = \tanh(V) \quad (6)$$

Como nem tudo é definido precisamente, é necessário um neurônio estocástico que trabalhe com probabilidade para ser disparado, em


que: $x = \begin{cases} +1 & \text{com probabilidade } p(V) \\ -1 & \text{com probabilidade } 1 - p(V) \end{cases}$ onde $p(V) = \frac{1}{1 + e^{-\frac{V}{T}}}$ e T é a pseudo temperatura para controlar o nível de ruído e, portanto, a incerteza do disparo. Para $T \rightarrow 0$ o neurônio fica sem ruído, tornando-se um neurônio determinístico.

2.4 REDES NEURAIS VISTAS COMO GRAFOS ORIENTADOS


Outro modo de apresentação dos neurônios pode ser feito através de grafos orientados. Essa é a forma mais elegante de retratar o fluxo de sinais na rede, apesar de apresentar algumas limitações para redes não lineares.

Os grafos orientados são divididos em ramos e nós. Os ramos, ou elos, são subdivididos em elos sinápticos (onde é aplicado o peso sináptico ao sinal) e elos de ativação (que é uma relação não linear entre a saída e a entrada). O sinal em um elo flui na direção de indicação deste elo, e nos nós as saídas são as somas das entradas (Figura 3).

Figura 3 – A figura (a) representação completa e a (b) representação parcialmente completa.



(a)



(b)

Fonte: Haykin (2001)

Pode-se representar um neurônio de uma forma não tão completa como na Figura 3b, mas sem extraviar muita informação como na Figura 3a. Esta forma é denominada parcialmente completa ou grafo arquitetural, e se preocupa em mostrar a estrutura dos neurônios escondendo os detalhes como os pesos sinápticos.

A forma parcialmente completa é caracterizada por nós de fonte que fornecem sinais de entrada e saída. O neurônio é representado por um único nó computacional e elos que apenas mostram a direção do fluxo de sinal.

Tem - se três formas de representar uma rede neural (HAYKIN, 2001):

- Diagrama de blocos que expõe uma descrição funcional da rede;
- Grafo de fluxo de sinal, que fornece uma descrição completa do fluxo de sinal da rede;
- Grafo arquitetural, que descreve a topologia da rede.

2.5 ARQUITETURAS DE REDES


Basicamente a estrutura da rede neural pode ser classificada de duas formas fundamentais diferentes: redes diretas e redes recorrentes.

2.5.1 Redes Diretas

2.5.1.1 Redes progressivas (alimentadas adiante) com camada única

É a rede que contém apenas uma camada de neurônios e apresenta o fluxo de sinal em apenas uma direção, como pode ser visto na Figura 4.

Figura 1 – Rede alimentada adiante com camada única.




Fonte: Haykin (2001)

2.5.1.2 Redes progressivas com múltiplas camadas

Esta classe apresenta uma ou mais camadas de neurônios ocultos, que têm a habilidade de extrair estatísticas de ordem elevada quando o número de entrada é grande. Tipicamente, os neurônios em camada da rede têm como entrada as saídas dos neurônios anteriores. Quando cada um dos nós está conectado a todos os nós da camada seguinte, a rede é dita totalmente conectada, caso contrário, é dita parcialmente conectada.

Figura 5 – Modelo com uma camada de neurônio oculto e totalmente conectada.

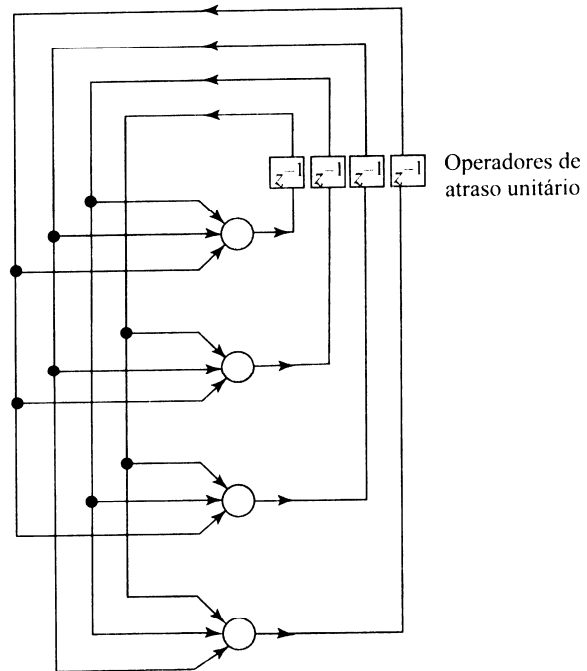


Fonte: Haykin (2001)

2.5.2 Redes Recorrentes

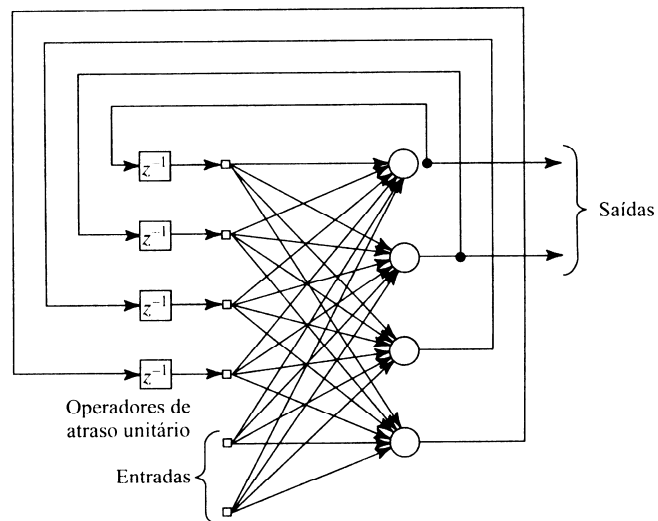
É a classe que representa as redes com realimentação (auto realimentação ou não) e pode conter neurônios ocultos ou não. A realimentação envolve o uso de ramos particulares compostos de elementos de atraso unitário (Z^{-1}), o que pode resultar num comportamento não linear da rede, admitindo-se que a rede contenha unidades não-lineares.

Figura 6 – Rede recorrente com realimentação normal.



Fonte: Haykin (2001)

Figura 2 – Rede recorrente com auto realimentação.



Fonte: Haykin (2001)

2.6 REPRESENTAÇÃO DO CONHECIMENTO

Na representação do conhecimento por redes neurais tem-se basicamente quatro regras (HAYKIN, 2001):

1ª As entradas similares devem produzir representações similares no interior da rede e, portanto, devem ser classificadas como pertencentes à mesma categoria.

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

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

4ª Informação prévia e invariâncias devem ser incorporadas no projeto de uma rede neural, simplificando com isso o projeto da rede por não ter que aprendê-las.

3 ALGORITMOS DE TREINAMENTO

3.1 ALGORITMO DO MÍNIMO QUADRADO MÉDIO (LMS)

3.1.1 Algoritmo LMS

O algoritmo do mínimo quadrado médio (LMS) é baseado na utilização de valores instantâneos para a função de custo (Equação 7).

$$E(w) = \frac{1}{2}e^2(n) \quad (7)$$

Onde:

$e(n)$ = Sinal de erro medido no tempo n .

Diferenciando $E(w)$ em relação ao vetor de peso w , obteve-se a Equação 8.

$$\frac{\partial E(w)}{\partial w} = e(n) \frac{\partial e(n)}{\partial w} \quad (8)$$

Como no caso do filtro dos mínimos quadrados, o algoritmo LMS opera com um neurônio linear de forma que se pode expressar o sinal de erro como na Equação 9

$$e(n) = d(n) - x^T(n)w(n) \quad (9)$$

Onde:

$d(n)$ = Saída desejada da rede.

$x(n)$ = Entrada da rede.

$w(n)$ = Pesos sinápticos da rede.

Com isso,

$$\frac{\partial e(n)}{\partial w(n)} = -x(n) \quad (10)$$

e

$$\frac{\partial E(w)}{\partial w(n)} = -x(n)e(n) \quad (11)$$

Utilizando este último resultado como uma estimativa para o vetor de gradiente, pode-se escrever a Equação 12.

$$g = -x(n)e(n) \quad (12)$$

Finalmente, usando a Equação 12 para o método da descida mais íngreme, pode-se formular o algoritmo LMS como segue na Equação 13.

$$w(n+1) = w(n) + \eta x(n)e(n) \quad (13)$$

Onde:

η = taxa de aprendizagem.

A realimentação mostrada na Equação 13 se comporta como um filtro passa-baixas, que faz com que as componentes de alta frequência do erro sejam atenuadas, fazendo com que só passem as de baixa frequência. A taxa de aprendizagem η fica responsável pela velocidade com que os valores dos pesos sinápticos são corrigidos. Quanto menor a taxa η , mais lentamente o processo progredirá e, conseqüentemente, mais precisa será a correção dos pesos.

À medida que o treinamento vai progredindo em direção ao tempo infinito, a correção fica em uma caminhada assintótica em torno da solução. Por isso quanto menor a taxa de aprendizagem mais próxima estará da solução. Mas, em contrapartida, mais tempo vai demorar para chegar aos valores adequados.

O benefício do LMS é que ele não requer conhecimento das estatísticas do ambiente (BRAGA, et al.,2000).

3.1.2 Convergência do Algoritmo LMS

Da teoria de controle, sabe-se que a estabilidade de um sistema realimentado é determinada pelos parâmetros que constituem seu laço de realimentação. No caso, o algoritmo LMS tem seu comportamento alterado principalmente por dois parâmetros: a taxa de aprendizagem η e o vetor de entrada $x(n)$. Por isso, o comportamento em relação à convergência e à estabilidade do algoritmo LMS é influenciado pelo vetor de entrada $x(n)$ e pela taxa de aprendizagem η . Portanto, deve-se ter cuidado na hora de escolher o vetor de entrada e, principalmente, a taxa de aprendizagem η para garantir que a saída do LMS seja convergente.

Desde que o parâmetro da taxa de aprendizagem η satisfaça a condição da Equação 14, assegura-se também a convergência do LMS (HAYKIN, 2001).

$$0 < \eta < \frac{2}{A} \quad (14)$$

Onde:

A = Soma dos valores médios quadrados das entradas sensoriais.

3.1.3 Virtudes e Limitações do Algoritmo LMS

3.1.3.1 Virtudes

Uma das virtudes do LMS é a sua simplicidade, independente do modelo e conseqüentemente, de sua robustez, o que significa que pequenas incertezas do modelo e pequenas perturbações resultam apenas em pequenos erros de estimativa. Por estas razões o LMS possui a habilidade de funcionar

satisfatoriamente tanto em um ambiente estacionário como em um ambiente não-estacionário.

3.1.3.2 Limitações

As principais limitações do LMS são a sua taxa de convergência lenta e a sua sensibilidade a variações na auto-estrutura da entrada. O LMS requer tipicamente um número de iterações cerca de 10 vezes a dimensionalidade do espaço de entrada para alcançar uma condição de estabilidade (HAYKIN, 2001). A lenta taxa de convergência se torna particularmente séria quando a dimensionalidade do espaço de entrada é alta.

3.1.4 Aprendizagem

O Algoritmo LMS tem como regra de aprendizagem a regra DELTA que leva em conta a diferença, ou erro, entre a resposta desejada e a saída da RNA. Assim, durante o treinamento, é aplicada a seguinte correção aos pesos sinápticos da RNA, Equação 15 (AZEVEDO, et al., 2000).

$$\Delta w_j = \eta e_j x_j = \eta (d_j - o_j) x_j \quad (15)$$

Onde:

Δw_j = variação dos pesos sinápticos

η = taxa de aprendizagem

e_j = erro na saída do neurônio

x_j = entrada da rede

d_j = saída desejada

o_j = saída obtida com a rede

A regra delta é biologicamente plausível por usar apenas informação local da sinapse para o aprendizado. Além disso, ela é útil quando se deseja minimizar o erro médio quadrático durante o treinamento de uma RNA. Entretanto, o

uso da regra delta é limitado a RNA com duas camadas de neurônios (uma de entrada e outra de saída). Quando a regra delta é aplicada a neurônios lineares, minimizará a função custo mostrada na Equação 16.

$$EQM_j = \frac{(e_j)^2}{2} \quad (16)$$


EQM_j = erro médio quadrático na saída do neurônio

e_j = erro na saída do neurônio

3.2 ALGORITMO BACKPROPAGATION (RETROPROPAGAÇÃO)

3.2.1 Algoritmo de Retropropagação

Figura 8—Grafo de fluxo de sinal ressaltando detalhes do neurônio de saída.



Fonte: Haykin (2001)

O sinal de erro na saída do neurônio j , na iteração n é definido por

$$e_j(n) = d_j(n) - y_j(n) \quad (17)$$

Definido o valor instantâneo da energia do erro para o neurônio j como $\frac{1}{2}e_j^2(n)$. Correspondentemente, a energia total do erro é obtida somando-se a energia do erro de todos os neurônios, podendo assim escrever:

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (18)$$

onde o conjunto C inclui todos os neurônios da camada de saída.

A energia média do erro quadrado é obtida por:

$$\varepsilon_{med} = \frac{1}{N} \sum_{n=1}^N \varepsilon(n) \quad (19)$$

A energia instantânea do erro $\varepsilon(n)$, e conseqüentemente a energia média do erro ε_{med} , é uma função de todos os parâmetros livres da rede. Para um dado conjunto de treinamento, ε_{med} representa a função de custo como uma medida do desempenho de aprendizagem. O objetivo do processo de aprendizagem é ajustar os parâmetros livres da rede para minimizar ε_{med} .

O campo local induzido $v_j(n)$ produzido na entrada da função de ativação associada ao neurônio j é portanto:

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (20)$$

onde m é o número total de entradas.

Assim, o sinal funcional $y_j(n)$ que aparece na saída do neurônio j na iteração n é:

$$y_j(n) = \varphi_j(v_j(n)) \quad (21)$$

De uma forma similar ao algoritmo LMS, o backpropagation aplica uma correção $\Delta w_{ji}(n)$ ao peso sináptico $w_{ji}(n)$, que é proporcional a derivada parcial $\partial \varepsilon(n) / \partial w_{ji}(n)$. De acordo com a regra de cadeia do cálculo, pode-se expressar este gradiente como:

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (22)$$

A derivada parcial $\partial \varepsilon(n) / \partial w_{ji}(n)$ representa um fator de sensibilidade, determinando a direção de busca no espaço de pesos, para o peso sináptico w_{ji} .

Diferenciando ambos os lados da equação 18 em relação a $e_j(n)$, obtemos:

$$\frac{\partial \varepsilon(n)}{\partial e_j(n)} = e_j(n) \quad (23)$$

Diferenciando ambos os lados da equação 17 temos:

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (24)$$

Diferenciando a equação 21 obtemos:

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi'_j(v_j(n)) \quad (25)$$

onde o uso do apóstrofe (no lado direito) significa a diferenciação em relação ao argumento.

Finalmente, diferenciando a equação 20 temos:

$$\frac{\partial v_i(n)}{\partial w_{ji}(n)} = y_i(n) \quad (26)$$

O uso das equações 23 a 26 em 22 produz:

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = -e_j(n) \varphi'_j(v_j(n)) y_i(n) \quad (27)$$

A correção $\Delta w_{ji}(n)$ aplicada a $w_{ji}(n)$ é definida pela regra delta:

$$\Delta w_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \quad (28)$$

Onde η é a taxa de aprendizagem e o sinal de negativo indica a descida do gradiente.

O uso da Equação 27 na 28 produz:

$$\Delta w_{ji}(n) = -\eta \delta_j(n) y_j(n) \quad (29)$$

onde o gradiente local $\delta_j(n)$ é definido por:

$$\delta_j(n) = -\frac{\partial \varepsilon(n)}{\partial v_j(n)} = -\frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = e_j(n) \varphi'_j(v_j(n)) \quad (30)$$


O gradiente local aponta para as modificações necessárias nos pesos sinápticos.

Das equações 29 e 30 nota-se que um fator importante envolvido no ajuste dos pesos sinápticos é o sinal de erro na saída do neurônio. Neste contexto pode-se identificar dois casos.

O primeiro caso, mais simples, é quando o neurônio j está localizado na camada de saída da rede, sendo suprido por uma saída desejada particular. Então, podemos utilizar a equação 17 para calcular o sinal de erro $e_j(n)$ do neurônio. Com base neste erro pode-se calcular diretamente o gradiente local $\delta_j(n)$, usando a Equação 30.

O segundo caso, mais complexo, é quando o neurônio j está em uma camada oculta onde não há acesso diretamente ao erro. Portanto, eles compartilham a responsabilidade por qualquer erro cometido na saída, sendo penalizados ou recompensados (atribuição de crédito) pela sua parcela de responsabilidade. Este problema é resolvido de forma elegante retropropagando-se os sinais de erro através da rede.

Figura 9 – Grafo de fluxo de sinal ressaltando os detalhes do neurônio de saída k conectado ao neurônio oculto j .



Fonte: Haykin (2001)

Considere a situação apresentada na Figura 9, que representa o neurônio j oculto na rede. De acordo com a equação 30, pode-se redefinir o gradiente local $\delta_j(n)$ para o neurônio oculto j como:

$$\delta_j(n) = -\frac{\partial \varepsilon(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = -\frac{\partial \varepsilon(n)}{\partial y_j(n)} \varphi'_j(v_j(n)) \quad (31)$$

Da Figura 9 também nota-se que:

$$\varepsilon(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n) \quad (32)$$

Diferenciando a Equação 32 chega-se a Equação 33:

$$\frac{\partial \varepsilon(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_j(n)} \quad (33)$$

A Equação 33 pode ser escrita conforme Equação 34:

$$\frac{\partial \varepsilon(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \quad (34)$$

Entretanto na Figura 9 notamos que:

$$e_k(n) = d_k(n) - y_k(n) = d_k(n) - \varphi'_k(v_k(n)) \quad (35)$$

Assim,

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\varphi'_k(v_k(n)) \quad (36)$$

Da Figura 9 vemos que o campo local induzido é:

$$v_k(n) = \sum_{j=0}^m w_{kj}(n) y_j(n) \quad (37)$$

onde m é o número total de entradas excluindo o bias.

Diferenciando a Equação 37 tem-se:

$$\frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n) \quad (38)$$

Utilizando as equação 36 e 38 em 34, obtemos a derivada parcial desejada:

$$\frac{\partial \varepsilon(n)}{\partial y_j(n)} = -\sum_k e_k(n) \varphi'_k(v_k(n)) w_{kj}(n) = -\sum_k \delta_k(n) w_{kj}(n) \quad (39)$$

Finalmente utilizando a equação 39 em 31, obtemos a fórmula de retropropagação para o gradiente local $\delta_j(n)$ como descrito:

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (40)$$

3.2.2 Os Dois Passos da Computação

No algoritmo de retropropagação existem dois passos distintos de computação a serem seguidos (HAYKIN, 2001).

O primeiro passo é para frente. Os pesos sinápticos se mantêm inalterados em toda a rede e os sinais funcionais são calculados individualmente, neurônio por neurônio. O sinal funcional que aparece na saída do neurônio j é calculada como:

$$y_j(n) = \varphi(v_j(n)) \quad (41)$$

onde:

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) z_i(n) \quad (42)$$

e $z_i(n)$ é o sinal de entrada do neurônio j .

O segundo é o passo de retropropagação. Começa na saída passando-se os sinais de erro para a esquerda através da rede, camada por camada, e recursivamente calculando-se o gradiente de cada neurônio. Este processo recursivo permite que os pesos sinápticos sofram modificações de acordo com a regra delta da Equação 29. Para um neurônio localizado na camada de saída, o δ é simplesmente igual ao sinal de erro daquele neurônio multiplicado pela primeira derivada da sua não-linearidade. Assim, utiliza-se a Equação 29 para calcular as modificações dos pesos de todas as conexões que alimentam a camada de saída. Dados os δ_s para os neurônios da camada de saída, utiliza-se, a seguir, a Equação 40 para calcular os δ_s para todos os neurônios na penúltima camada, e conseqüentemente as modificações dos pesos de todas as conexões que a alimentam. A computação recursiva continua, camada por camada, propagando as modificações para todos os pesos sinápticos da rede.

3.2.3 Função de Ativação

O cálculo do δ para cada neurônio da rede de múltiplas camadas requer o conhecimento da derivada da função de ativação $\varphi(\cdot)$ associada àquele neurônio. Para esta derivação existir, necessitamos que a função $\varphi(\cdot)$ seja contínua. Em termos básicos, a diferenciabilidade é a única exigência que a função de ativação deve satisfazer. Um exemplo de uma função de ativação não-linear, continuamente diferenciável e normalmente utilizada nos perceptrons de múltiplas camadas é a não-linearidade sigmóide. Uma forma desta função é a função tangente hiperbólica, que na sua forma mais geral é definida por:

$$\varphi_j(v_j(n)) = a \tanh(bv_j(n)) \quad (43)$$

onde a e b são constantes maiores que 0.

A sua derivada é dada por:

$$\varphi'_j(v_j(n)) = ab \operatorname{sech}^2(bv_j(n)) = ab(1 - \tanh^2(bv_j(n))) = \frac{b}{a}[a - y_j(n)][a + y_j(n)] \quad (44)$$

O gradiente local, na camada de saída, é:

$$\delta_j(n) = e_j(n)\varphi'_j(v_j(n)) = \frac{b}{a}[d_j(n) - y_j(n)][a - y_j(n)][a + y_j(n)] \quad (45)$$

Para a camada oculta é:

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) = \frac{b}{a}[a - y_j(n)][a + y_j(n)] \sum_k \delta_k(n) w_{kj}(n) \quad (46)$$

3.2.4 Taxa de Aprendizagem

O algoritmo de retropropagação fornece uma aproximação para a trajetória no espaço dos pesos calculada pelo método da descida mais íngreme. Quanto menor for a taxa de aprendizagem η , menor vai ser a variação nos pesos

sinápticos e mais suave será a trajetória no espaço dos pesos, mas esta melhoria causa uma lentidão no processo de aprendizagem. Já para taxas de aprendizagens η maiores, o aprendizado é mais rápido, porém pode causar instabilidade na rede. Um método simples de aumentar a taxa de aprendizagem, evitando o perigo de instabilidade, é modificar a regra delta equação 29 incluindo um termo de momento, como mostrados na equação 47:

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n - 1) + \eta \delta_j(n) y_j(n) \quad (47)$$

onde α é um número positivo chamado de constante de momento.

A incorporação do momento no algoritmo de retropropagação representa uma modificação pequena na atualização dos pesos. Contudo, ela pode ter alguns efeitos benéficos sobre o comportamento de aprendizagem do algoritmo. O termo de momento pode também ter o benefício de evitar que o processo de aprendizagem termine em um mínimo local raso na superfície de erro.

4 DOENÇAS CARDÍACAS

Segundo a Organização Mundial da Saúde (OMS) ou em inglês World Health Organization (WHO), anualmente morrem aproximadamente 57 milhões de pessoas ao redor do mundo. As principais causas de morte são mostradas na Tabela 2.

Tabela 2 – Causas de mortes no mundo.

Causas	%
Guerras e conflitos civis	0,3%
Incêndios	0,3%
Envenenamento	0,4%
Afogamento	0,5%
Problemas Endócrinos	0,6%
Problemas Nutricionais	0,7%
Anomalias congênitas	0,8%
Doenças da infância	0,8%
Quedas	0,9%
Assassinatos	0,9%
Suicídio	1,4%
Malária	1,5%
Outros Acidentes	2,0%
Acidentes de Carro	2,1%
Diabetes Mellitus	2,2%
Problemas Neuropsiquiátricos	2,3%
Tuberculose	2,4%
HIV/AIDS	3,1%
Doenças do Aparelho Digestivo	3,9%
Diarréia	4,3%
Complicações no Parto	4,6%
Doença Cerebrovascular	10,8%
Câncer	13,3%
Infecções e Doenças Respiratórias	13,6%
Doenças Infecciosas e Parasitárias	15,3%
Doenças Cardíacas	19,7%

Fonte: Oms (2008).

Como pode ser visto na Tabela 2, as Doenças Cardíacas estão entre as principais causas de óbitos no mundo, com aproximadamente 20% das mortes registradas em 2008.

Também segundo estudos realizados pelo Incor em 2009, cerca de 212 mil pessoas morrem de morte súbita no Brasil por ano sendo que aproximadamente 90% dessas mortes está relacionado com arritmias cardíacas possíveis de serem tratadas se diagnosticadas e a tempo.

4.1 O CICLO CARDÍACO

O sangue chega ao coração pelas veias cavas proveniente da Grande circulação, entra no átrio direito e rapidamente passa ao ventrículo direito. Deste o sangue venoso é ejetado para a artéria pulmonar que o leva aos pulmões, onde são realizadas as trocas gasosas. O sangue torna-se enriquecido de oxigênio e menos saturado de gás carbônico. O sangue arterial volta ao coração através das veias pulmonares para o átrio esquerdo e vai rapidamente para o ventrículo esquerdo. Em seguida uma nova sístole ventricular é realizada e o sangue arterial é ejetado para o organismo pela artéria aorta.

O sistema de Purkinje é formado por fibras auto excitáveis distribuídas de forma organizada pela massa cardíaca. O nodo sinusal funciona como um marcapasso natural onde os impulsos partem para todo o coração. A função do nodo átrio ventricular é retardar, a passagem do impulso necessária para que o enchimento das câmaras ventriculares ocorra antes da contração das mesmas. No feixe átrio-ventricular o estímulo é transmitido com grande rapidez até um segmento que divide-se em dois ramos do feixe de Hiss . Estes fazem com que as fibras se contraiam e que um considerável volume de sangue seja ejetado do ventrículo direito para a artéria pulmonar e do ventrículo esquerdo para a artéria aorta (GUYTON; HALL, 2002).

4.2 ARRITMIA CARDÍACA

Arritmia é a ausência de ritmo, irregularidades das contrações cardíacas.

As causas das arritmias cardíacas são, em geral, uma (ou a combinação) das seguintes anormalidades no sistema de ritmicidade de condução do coração:

- Ritmicidade anormal do marca-passo;
- Deslocamento do marca-passo do nodo sinusal, para outras áreas do coração;
- Bloqueios em diferentes partes da propagação do impulso pelo coração;
- Vias anormais, para a transmissão do impulso pelo coração;
- Geração espontânea de impulsos anormais em quase todas as áreas do coração.

O eletrocardiograma ECG é o melhor método para diagnóstico.

São consideradas arritmias cardíacas: arritmia sinusal, extra-sístole atrial, flutter atrial, fibrilação atrial, extra-sístole ventricular, taquicardia ventricular e fibrilação ventricular.(GUYTON; HALL., 2002).

4.3 INSUFICIÊNCIA CARDÍACA CONGESTIVA

A insuficiência cardíaca congestiva (insuficiência cardíaca) é uma condição grave na qual a quantidade de sangue bombeada pelo coração a cada minuto (débito cardíaco) é insuficiente para suprir as demandas normais de oxigênio e de nutrientes do organismo. Apesar de algumas pessoas, de modo equivocado, acreditarem que o termo insuficiência cardíaca signifique parada cardíaca, o termo, na realidade, refere-se à diminuição da capacidade do coração suportar a carga de trabalho. Ela é muito mais comum entre os idosos, pelo fato deles apresentarem maior probabilidade de apresentar alguma doença que a desencadeie. Apesar de o quadro apresentar um agravamento no decorrer do tempo, os indivíduos com insuficiência cardíaca podem viver muitos anos (GUYTON; HALL, 2002).

As principais causas de insuficiência cardíaca são:

- Doenças que podem alterar a contractilidade do coração.
- Doenças que exigem um esforço maior do músculo cardíaco (hipertensão arterial ou na estenose (estreitamento) da válvula aórtica, doenças pulmonares)

- Doenças que podem fazer com que uma quantidade maior de sangue retorne ao coração (hipertireoidismo, a anemia severa e as doenças congênitas do coração, insuficiência de válvulas - quando não fecham bem).

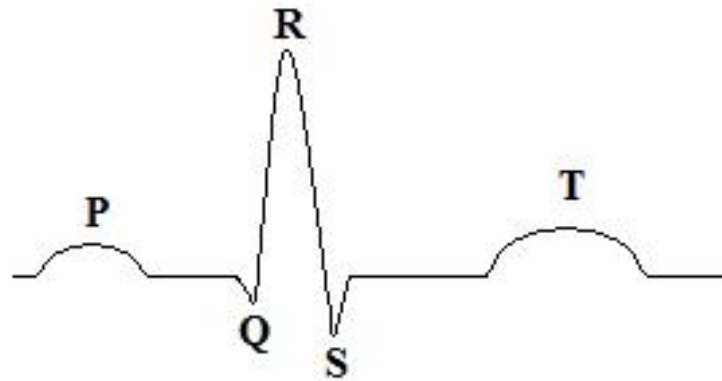
O tratamento pode ser feito para tornar a atividade física mais confortável, para melhorar a qualidade de vida e para prolongar a vida do paciente. No entanto, não existe uma cura para a maioria das pessoas com insuficiência cardíaca.

5 METODOLOGIA

5.1 O INTERVALO RR

Para entender o que seria o intervalo RR é necessário conhecer o eletrocardiograma, que está ilustrado na Figura 10.

Figura 3 – Eletrocardiograma



Fonte: autor

Onde:

P = despolarização dos átrios

QRS = despolarização dos ventrículos


T = onda de repolarização

A onda P é causada pelos potenciais elétricos gerados quando os átrios se despolarizam, antes da contração atrial. O complexo QRS é causado pelos potenciais gerados quando os ventrículos se despolarizam antes da sua contração, isto é, à medida que a onda de despolarização se propaga pelos ventrículos. Por conseguinte, tanto a onda P como os componentes do complexo QRS são ondas de despolarização.

A onda T é causada pelos potenciais gerados quando os ventrículos se recuperam do estado de despolarização. Esse processo ocorre, normalmente, no músculo ventricular, de 0,25 a 0,35s após a despolarização. A onda T é conhecida como onda de repolarização. Dessa forma, o eletrocardiograma é composto por ondas de despolarização e de repolarização (GUYTON et al., 2002).

O intervalo RR é o tempo entre uma onda R e outra, como pode ser visto na Figura 11. Este intervalo traz a duração de cada batimento cardíaco, ou seja, a frequência cardíaca do paciente. Mas ela não traz somente essa informação. Por ser uma medida instantânea, ela também traz informações sobre algumas cardiopatias como arritmia, taquicardia, bradicardia, insuficiência cardíaca congestiva, etc. Porém, neste trabalho será estudado somente arritmia e insuficiência cardíaca congestiva, além de pessoas saudias.

Figura 11 – Eletrocardiograma mostrando o intervalo RR



Fonte: autor

5.2 AQUISIÇÃO DE DADOS

Os dados foram obtidos do site www.physionet.org na seção de banco de dados. Foram coletados em diferentes lugares e de diferentes pacientes, e estão disponíveis para realização de trabalhos e pesquisas que necessitem de uma ampla diversidade de amostras sobre problemas cardíacos.

Dentre as amostras disponíveis foram escolhidos os seguintes casos:

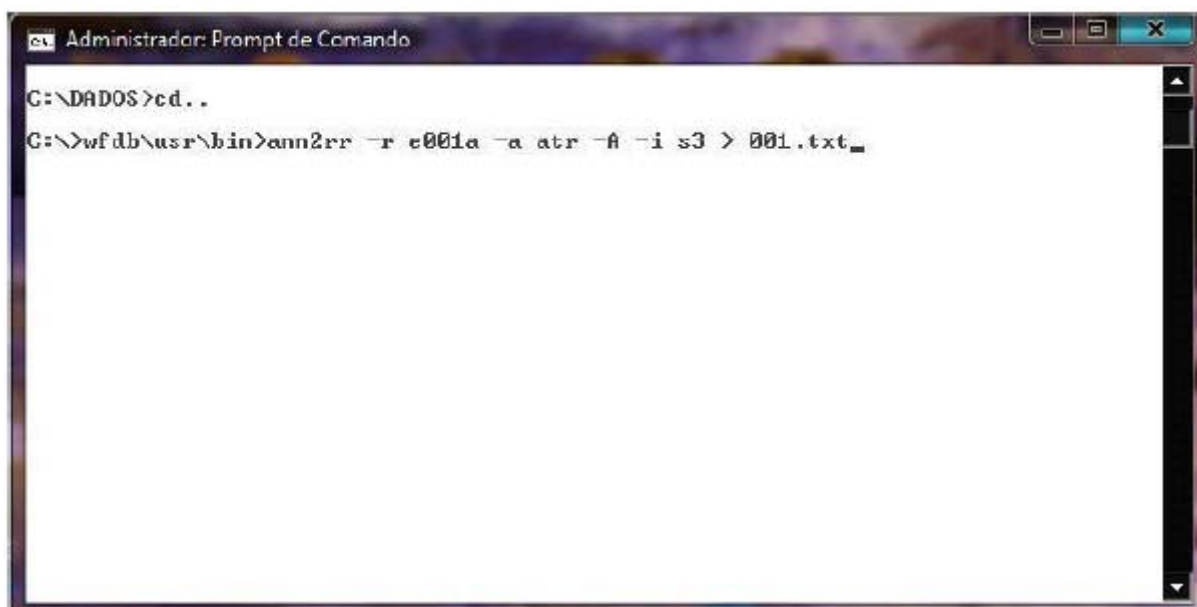
- Pessoas Normais (54 amostras)
- Pessoas com Arritmia (100 amostras)
- Insuficiência Cardíaca Congestiva (29 amostras)

Os arquivos disponíveis estão em formato compactado para que cada arquivo fique com um tamanho menor, ocupe menos espaço na página e que seja baixado mais rapidamente.

Para ter acesso aos dados contidos nos arquivos é necessário fazer o download de um programa também disponível na mesma página, mas no *link Tools*. Depois de baixado é necessário realizar a instalação e, após, já é possível utilizá-lo.

O programa para plataforma Windows é executado apenas no prompt de comando. Depois de aberto é necessário ir para o diretório onde o programa foi instalado e onde devem estar os arquivos a serem convertidos, como pode ser visto na Figura 12:

Figura 12 – Demonstração do código no prompt de comando.



```
Administrador: Prompt de Comando
G:\DADOS>cd ..
G:\>wfidb\usr\bin>ann2rr -r e001a -a atr -A -i s3 > 001.txt
```

Fonte: autor

Após ter feito todo o procedimento descrito anteriormente é necessário digitar o seguinte código para a conversão.

```
ann2rr -r xxx -a yyy -A -i s3 > zzz.www
```

Onde:

xxx = é o nome do arquivo a ser convertido

yyy = é a extensão do arquivo a ser convertido

zzz = é o nome do arquivo de saída onde serão gravados os dados

www = é a extensão do arquivo de saída

Como exemplo para converter o arquivo e001a.atr e gravar no arquivo 001.txt é necessário digitar o seguinte código:

```
ann2rr -r e001a -a atr -A -i s3 > 001.txt
```

O resultado deste código é um arquivo de texto gravado no mesmo diretório onde se encontra o arquivo original, e este arquivo contém os seguintes dados

```
334.837  
0.550  
0.558  
0.462  
0.662  
0.550  
0.558  
0.558  
0.550  
0.558  
0.558  
0.558  
0.558  
0.558  
0.542  
0.558  
0.550  
0.534  
0.582  
0.558  
0.558  
0.558  
0.566  
0.558  
0.375  
0.662  
0.566  
0.478  
0.638  
1.100  
0.558  
0.558  
0.550
```

Essa é uma pequena parte do que foi gerado no arquivo de texto, pois este tem em torno de 110 mil linhas mostrando o valor de cada intervalo RR.

Este valor se deve ao fato de que o período entre cada batida do coração é menor que 1 segundo (o que corresponde a frequência cardíaca de repouso de 60 bpm – batimentos por minuto). Com isso, é gerado um registro no arquivo; então em 24 horas seriam gerados mais de 86.400 registros (= 24Hr x 60minutos x 60 segundos).

Deve-se baixar juntamente um arquivo com extensão **.hea** que contém os dados sobre o paciente, como abaixo.

```
e001a
0 128 0
9:18:00
23/11/1987#
Start time=09:18#
First beat=09:22:58.179#
<age-range>: 60-64,
<sex>: Male,
<medication>: None#
<RR-low-limit(sec)>: 0.476,
<RR-high-limit(sec)>: 1.054#
Note: recording with a timing signal, flutter-compensated
```

Como pode ser observado, este arquivo contém muitas informações.


Porém as mais importantes são o sexo e a idade do paciente.

5.3 CONDICIONAMENTO DE DADOS

5.3.1 Filtragem dos Dados

Os dados estão na forma como eles foram coletados e apresentam erros, o que prejudicaria o desempenho da RNA ou até mesmo levaria a rede a tomar decisões erradas. Por isso, foi realizada uma função em Matlab para filtrar esses valores e colocar o valor médio dos intervalos RR no lugar desses valores espúrios, como pode ser visto na Figura 13 com o intervalo de uma pessoa com arritmia.

Figura 13 – Gráfico mostrando o intervalo RR antes e depois de ser filtrado.




Fonte: autor.

5.3.2 Reamostragem

Os dados foram gerados sem ter um valor fixo de amostragem, pois eles foram gerados de acordo com o valor do intervalo RR. A cada onda R era marcado o tempo que levou para acontecer desde a última onda, como pode ser visto na Figura 14. Com isso, esses dados não podem ser aplicados em algumas partes do condicionamento de sinal ou, mais especificamente, eles não podem ser aplicados como entrada para o cálculo da PSD (densidade espectral de potência).

Figura 14 – Gráfico com valores do intervalo RR.




Fonte: autor

Para resolver esse problema foi desenvolvida uma função (Função reamostragem) em Matlab, que se encontra no apêndice A. Como entrada, tem os dados da saída do filtro e o valor de amostragem desejado que os dados fiquem. A saída é o sinal já reamostrado.

A reamostragem foi feita considerando um sinal linear, ou seja, considerando que de dois em dois pontos eles são interligados por uma reta, como pode ser visto na figura 15.

Figura 15 – Gráfico mostrando como foi feita a reamostragem



Fonte: autor

Baseado na Figura 15 foi realizado o seguinte equacionamento. Primeiramente,

$$a = \frac{X_2 - X_1}{Y_2 - Y_1} \quad (17)$$

e

$$b = X_1 \quad (18)$$

Inicialmente faz-se

$$t = Y_1 \quad (19)$$

E depois se adiciona o valor desejado para a reamostragem em t até que o valor seja maior ou igual a Y_2 e, posteriormente, é alterado os valores de a e b .

$$t = t + passo \quad (20)$$

Em seguida é calculado o valor para X_3 e Y_3 . Após, para X_4 e Y_4 e assim por diante até o fim dos dados, como mostra as Equações 21 e 22.

$$X_3 = a(t - Y_1) + b \quad (21)$$

e

$$Y_3 = t \quad (22)$$

Depois de todo esse equacionamento é que foi desenvolvida a função de reamostragem.

5.3.3 Densidade Espectral de Potência (PSD)

Nesta fase do condicionamento dos dados foi utilizada uma função que já se encontra pronta no próprio matlab.

O único trabalho acrescentado nesta etapa foi retirar os valores de dentro de uma variável objeto que esta função dá como resposta, e acertar os valores dos dados. A resposta não é dada com os valores dos dados certos como é mostrado no gráfico gerado pela função do matlab. Os cálculos de ajuste dos dados foram feitas como mostra a Equação 23.

O eixo X são as frequências e o eixo Y são os dados, portanto a correção foi feita da seguinte maneira:

$$\mathbf{Dados} = \mathbf{Dados}.*\mathbf{Frequência} \quad (23)$$


Onde o operador.* corresponde à multiplicação ponto a ponto entre dois vetores.

Depois de feitos os ajustes foi verificado que a saída desta função apresenta um número bem baixo de pontos e, para resolver este problema, foi feita uma reamostragem para aumentar o número de pontos e a precisão dos dados no próximo passo. Nesta reamostragem foi utilizada a mesma função descrita no item 5.3.2.

5.3.4 Integral

Esta nova função desenvolvida no Matlab também considerou que o sinal entre dois pontos fosse uma reta como mostrado na Figura 16

Figura 16 – Gráfico mostrando como foi feita a reamostragem



Fonte: autor

De acordo com a Figura 16 foi desenvolvido o equacionamento que se encontra na função integral no apêndice A.

Para o cálculo da integral foi calculada a área de cada trapézio e depois, somada à área para cada faixa de frequência. As Equações 24 a 26 fazem o cálculo das áreas.

$$Base = X_2 - X_1 \quad (24)$$

$$Lados = Y_2 + Y_1 \quad (25)$$

$$Área = \frac{Base \cdot Lados}{2} \quad (26)$$

O domínio de frequência da variação do intervalo RR foi computado pela integração sobre seus intervalos de frequência. A potência foi calculada dentro das quatro bandas (ULF - ultra-baixa frequência, VLF - muito baixa frequência, LF - baixa frequência, HF - alta frequência). Depois de calculadas essas quatro bandas pôde ser calculado a TP (potencia total) que é a soma das quatro e a razão LF/HF (BIGGER et al.,1995; GOMES, 2001). A faixa de frequência de cada banda está citada abaixo.

- ULF (<0,0033Hz)
- VLF (0,0033 até 0,04 Hz)
- LF (0,04 até 0,15 Hz)
- HF (0,15 até 0,4 Hz)
- TP (<0,4 Hz)
- LF/HF

Depois de realizada a integral para cada faixa de frequência foi calculado o logaritmo natural de cada faixa. Estes valores são as entradas desta função.

5.3.5 Bootstrap (Reamostragem)

Bootstrap é técnica introduzida por Efron como abordagem ao cálculo de intervalos de confiança de parâmetros. É utilizado quando outras técnicas não são aplicáveis, em particular, no caso em que o número de amostras é reduzido.

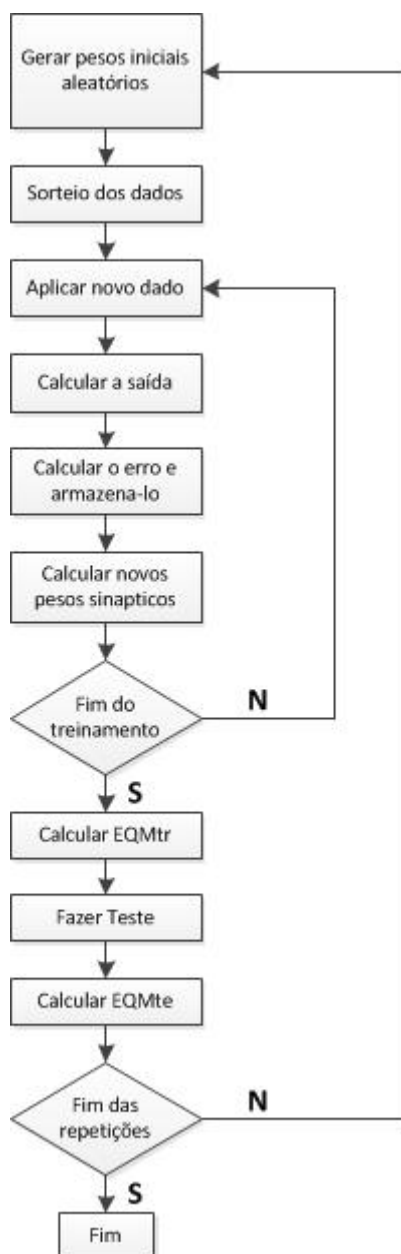
Esta técnica consiste em aumentar o número de amostras (reamostragem) de um experimento de modo que sua estatística não se altere, partindo do princípio de que as amostras iniciais representam fidedignamente toda a população.

Para isso, são geradas cópias das amostras iniciais aleatoriamente para que a média e a variância das amostras continuem representando a população.

5.4 APLICANDO A RNA

5.4.1 Fluxograma Padrão para Treinamento e Teste

Figura 17 – Fluxograma de Treinamento para as RNAs



Fonte: autor

Primeiramente gera-se os pesos sinápticos iniciais aleatoriamente. Em seguida sorteia-se os dados para que eles apareçam em uma ordem diferente em cada repetição. Após o sorteio, coloca-se um dado de treinamento na entrada da

rede onde será calculada a saída e, em seguida, calcula-se o erro da rede. Com este erro, o algoritmo calcula os novos pesos sinápticos e, em seguida, verifica se há mais dados de treinamento. Caso exista, o processo é repetido. Se não houver mais dados de treinamento, ele calcula o EQM de treinamento, faz o teste da rede com os dados de teste e calcula o EQM de teste. Depois de calcular o EQM de teste o algoritmo verifica se o número de repetições chegou ao fim. Caso isso aconteça, ele encerra o treinamento e teste da rede. Caso contrário, ele inicia o processo inteiro novamente.

Os algoritmos das redes LMS e backpropagation estão no anexo A.

5.4.2 Divisão dos Dados


Primeiramente, foram realizados a normalização dos dados e organização dos vetores de saída. Assim, cada vetor ficou responsável por uma cardiopatia. Em seguida, os dados foram divididos por sexo (masculino/feminino) e pela faixa etária (40-44, 45-49, 50-54, 55-59, 60-64, 65-69 anos) (BIGGER, et al., 1995).

Caso com estas divisões os resultados fiquem próximos aos resultados obtidos sem as divisões citadas anteriormente (pesos sinápticos bem baixos tornando a entrada menos significativa), essas divisões serão desconsideradas para que o processamento seja mais rápido.

5.4.3 Modelos para a Solução dos Problemas

5.4.3.1 Primeiro modelo


Utilizando todas as divisões possíveis, teremos 8 entradas e 1 saída, como pode ser visto na Figura 18.

Figura 18 – Bloco base para o primeiro modelo

Fonte: autor.

5.4.3.2 Segundo modelo

Utilizando somente as divisões por sexo, teremos 7 entradas e 1 saída, como pode ser visto na Figura 19.


Figura 19 – Bloco base para o segundo modelo

Fonte: autor.

5.4.3.3 Terceiro modelo

Utilizando somente as divisões por idade, teremos 7 entradas e 1 saída, como pode ser visto na Figura 20.

Figura 4 – Bloco base para o terceiro modelo




Fonte: autor

5.4.3.4 Quarto modelo

Utilizando somente as faixas de frequência, teremos 6 entradas e 1 saída, como pode ser visto na Figura 21.

Figura 21 – Bloco base para o quarto modelo




Fonte: autor.

5.4.3.5 Quinto modelo

Utilizando somente as faixas de frequências, como no quarto modelo, mas utilizando uma rede com uma camada oculta, teremos 6 entradas e 1 saída, como pode ser visto na Figura 22.

Figura 22 – Bloco base para o quinto modelo




Fonte: autor.

5.4.3.6 Sexto modelo

Utilizando somente as faixas de freqüências, como no quarto modelo, mas utilizando uma rede com duas camadas ocultas, teremos 6 entradas e 1 saída, como pode ser visto na Figura 23.

Figura 23 – Bloco base para o sexto modelo

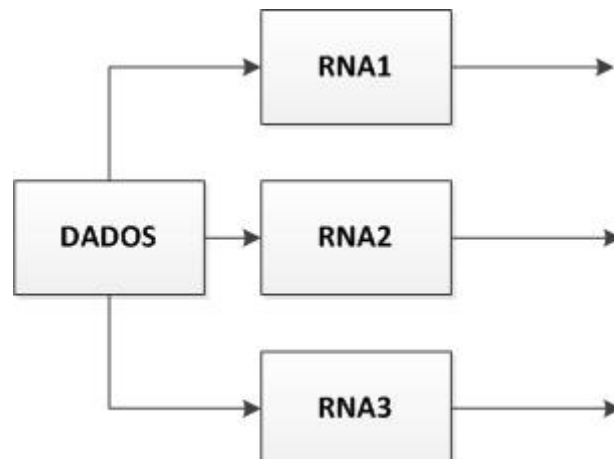


Fonte: autor.

5.4.3.7 Modelo geral da RNA

A rede da Figura 24 é composta por cada bloco base descrito nos itens 5.4.3.1 até 5.4.3.6. Cada bloco corresponde à uma cardiopatia ou ausência de alguma doença, ou seja, a pessoa é sadia.

Figura 24 – Rede completa para o diagnóstico com 3 saídas.



5.4.4 Redes do Matlab Utilizando nntools

Para comparar o desempenho das redes desenvolvidas foram utilizadas RNA prontas com a ferramenta nntool do matlab.

Para utilizar a rede do matlab é utilizado o seguinte comando para configurar a rede.

```
net = newff ([-1 1; -1 1; -1 1; -1 1; -1 1; -1 1], [25 10 1]);
```

como pode ser visto neste exemplo os números entre os primeiros colchetes mostram o intervalo de valor da entrada, os números no segundo colchetes representam o numero de neurônios em cada camada da rede, ou seja, neste exemplo temos 6 entradas que variam de -1 ate 1 e três camadas de neurônios sendo duas ocultas, uma com 25 neurônios e outra com 10, e uma cada de saída composta por 1 neurônio.

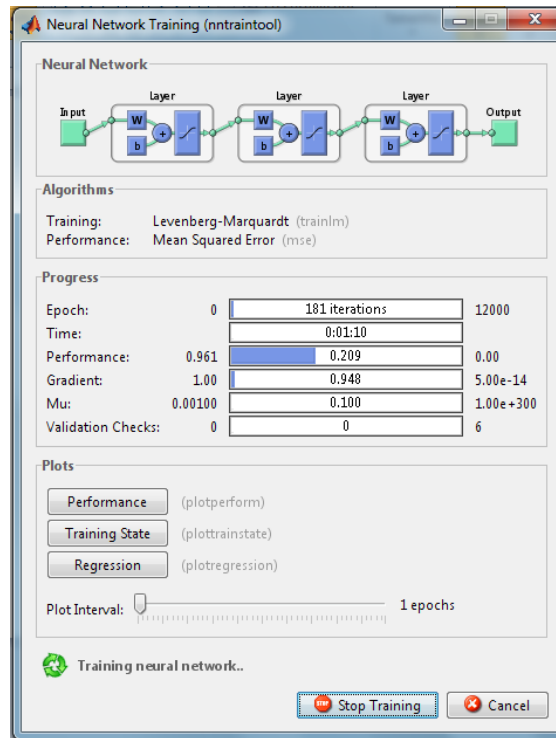
Depois de configurada a rede basta dar o seguinte comando para treinar a rede:

```
[net,tr] = train(net, x.', d');
```

Onde net é a rede que foi configurada, x é a entrada da rede e d é a saída que desejamos que a rede atinja.

Após digitado este comando a seguinte janela, Figura 25, ira abrir mostrando dados sobre o que está acontecendo com o treinamento da rede.

Figura 25 – Tela de treinamento da RNA utilizando nntool.



6 RESULTADOS E DISCUSSÃO

6.1 RESULTADOS OBTIDOS COM O ALGORITMO LMS

Depois de realizado o condicionamento dos dados e feita a normalização, os dados de entrada foram aplicados ao algoritmo LMS. Pode-se observar, após inúmeros tentativas de treinamentos, que a separação dos dados em faixa etária e por sexo fazia com que a rede não convergisse e, em alguns casos, a rede não conseguia realizar cálculo algum.

Portanto, o único modelo que deu resultados foi o quarto modelo proposto no item 5.4.2.4. Então, os resultados que seguem são apenas os resultados obtidos com este modelo.

O treinamento foi realizado com os parâmetros mostrados na Tabela 3.

Tabela 3 – Parâmetros de Treinamento para o Algoritmo LMS

Treinamento	Eta (η)	nRep	epMax
1	$1e^{-5}$	1	10000
2	$1e^{-5}$	1	50000
3	$1e^{-4}$	1	500
4	$1e^{-4}$	20	500
5	$1e^{-4}$	1	2500
6	$1e^{-3}$	5	1000
7	$1e^{-3}$	5	1000
8	$1e^{-3}$	5	1000
9	$1e^{-4}$	10	1000
10	$1e^{-4}$	5	1000
11	$1e^{-4}$	5	3000
12	$1e^{-4}$	5	7000
13	$1e^{-5}$	5	7000
14	$1e^{-5}$	5	15000
15	$1e^{-5}$	2	30000
16	$1e^{-5}$	1	50000
17	$1e^{-4}$	1	20000

Onde:

Treinamento = Indica o número da rede (LMS)

η = valor da taxa de aprendizagem

nRep = número de vezes que é repetido o treinamento

epMax = número máximo de épocas

Foram obtidos os seguintes resultados apresentados nas Tabela 4 a

Tabela 6.

Tabela 4 – Resultados das redes de 1 a 6

RNA		1	2	3	4	5	6
Treinamento	EQM	0,0838	0,082	0,0842	0,0872	0,0826	0,0798
	DP_EQM	0	0	0	0	0	0
	Época	10000	50000	500	500	2500	753
	DP_Época	0	0	0	0	0	128
Teste	Erro	0,4000	0,1667	0,1000	0,3633	0,3333	0,2667
	DP_Erro	0	0	0	1	0	0
	Época	1	73	16	70	1	548
	DP_Época	0	0	0	138	0	328
Duração (s)		671	3332	38	424	105	209

Onde:

EQM = erro quadrático médio

DP_EQM = desvio padrão do EQM

Época = época média onde ocorreu o menor EQM ou Erro

DP_Época = desvio padrão da época que aconteceu o menor EQM

ou Erro

Erro = erro de teste, se multiplicado por 100 torna-se percentagem

de Erro

DP_Erro = desvio padrão do Erro

Tabela 5 – Resultados das redes de 7 a 12

RNA		7	8	9	10	11	12
Treinamento	EQM	0,0820	0,0819	0,0835	0,0836	0,0822	0,0820
	DP_EQM	0	0	0	0	0	0
	Época	957	940	1000	1000	29984	6994
	DP_Época	25	56	0	0	21	5
Teste	Erro	0,3867	0,1667	0,2467	0,2933	0,1800	0,1600
	DP_Erro	0	0	0	0	0	0
	Época	184	213	457	531	24332	2305
	DP_Época	170	62	469	457	548	1297
Duração (s)		220	210	416	202	618	1334

Tabela 6 – Resultados das redes de 13 a 17

RNA		13	14	15	16	17
Treinamento	EQM	0,0860	0,0823	0,0823	0,0820	0,0813
	DP_EQM	0	0	0	0	0
	Época	7000	15000	30000	50000	19992
	DP_Época	0	0	0	0	0
Teste	Erro	0,3333	0,2133	0,1833	0,1667	0,1667
	DP_EQM	0	0	0	0	0
	Época	1	10491	27178	27832	3262
	DP_Epoca	0	5974	1999	0	0
Duração (s)		1319	2799	2241	3336	1255

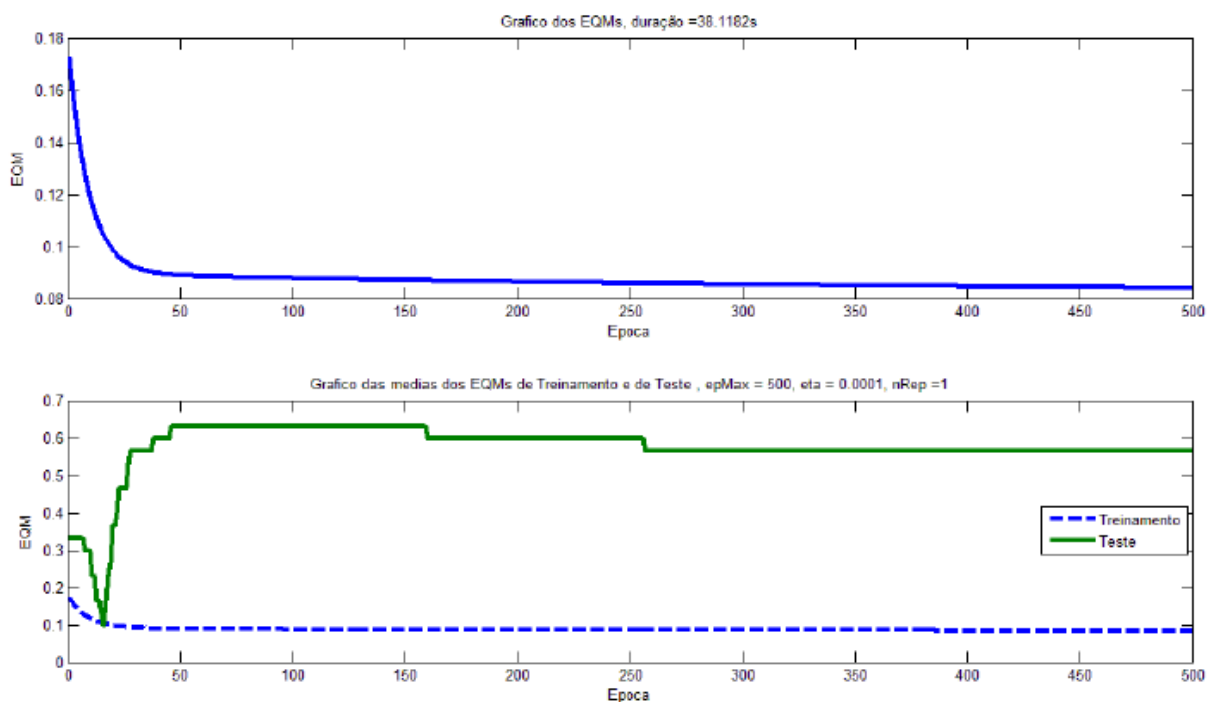
Observando as Tabela 4 a Tabela 6 podemos dizer que as melhores redes são as redes 2, 3, 8, 12, 16 e 17 .

Tabela 7 – Redes de melhor desempenho

RNA		2	3	8	12	16	17
Treinamento	EQM	0,0820	0,0842	0,0819	0,0820	0,0820	0,0813
	DP_EQM	0	0	0	0	0	0
	Época	50000	500	940	6993,6	50000	19992
	DP_Época	0	0	56	5	0	0
Teste	Erro	0,1667	0,1000	0,1667	0,1600	0,1667	0,1667
	DP_EQM	0	0	0	0	0	0
	Época	73	16	213	2305	27832	3262
	DP_Época	0	0	62	1297	0	0
Duração (s)		3332	38	210	1334	3336	1255

Das seis redes da Tabela 7 foram escolhidas quatro. O critério para a eliminação das redes foi o tempo de treinamento, eliminando-se então as redes que demoraram mais para fazer o treinamento. Assim, ficou-se com as redes 3, 8, 12 e 17. Os gráficos de treinamento e teste de cada rede são mostrados nas Figura 26, Figura 27, Figura 5 e Figura 29 respectivamente.

Figura 26 – Gráfico com treinamento e teste da rede 3




Fonte: autor.

Como pode ser visto esta rede chegou rapidamente em um valor aceitável com erro de apenas 10%. Depois ela divergiu, apresentando erro consideravelmente maior que o anterior.

Esta rede poderia ser descartada pela probabilidade de ser uma rede instável. Porém, ela será utilizada para realizar o treinamento para as outras doenças apenas para confirmar a sua não funcionalidade.

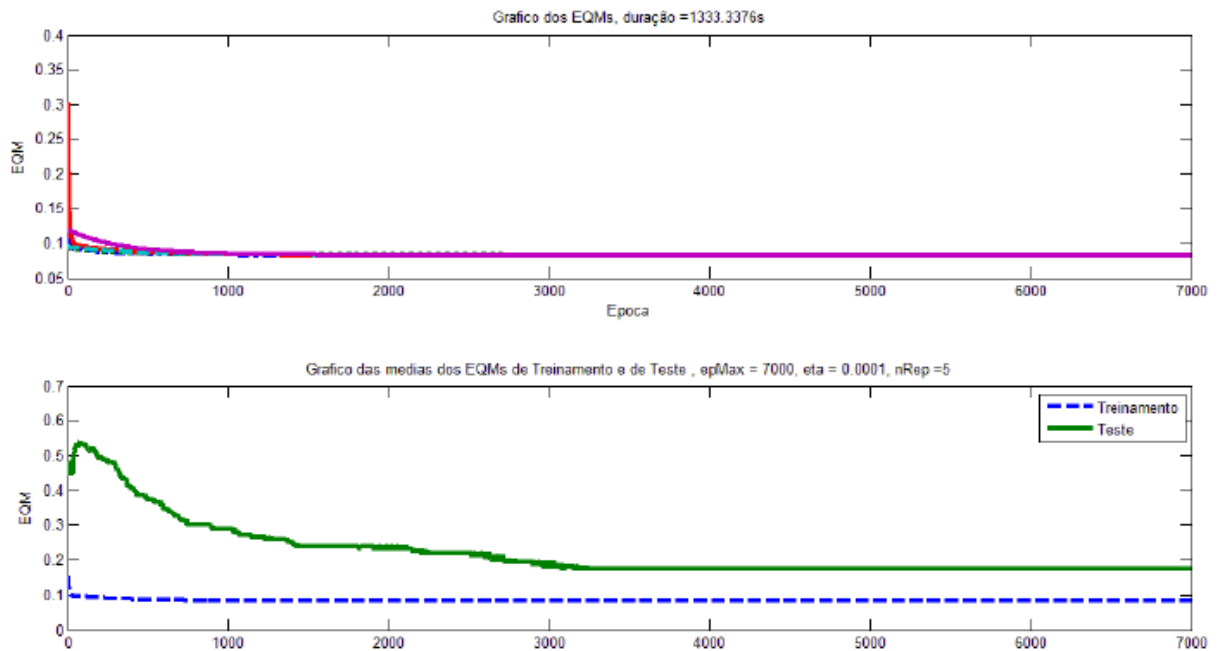
Figura 27 – Gráfico com treinamento e teste da rede 8



Fonte: autor.

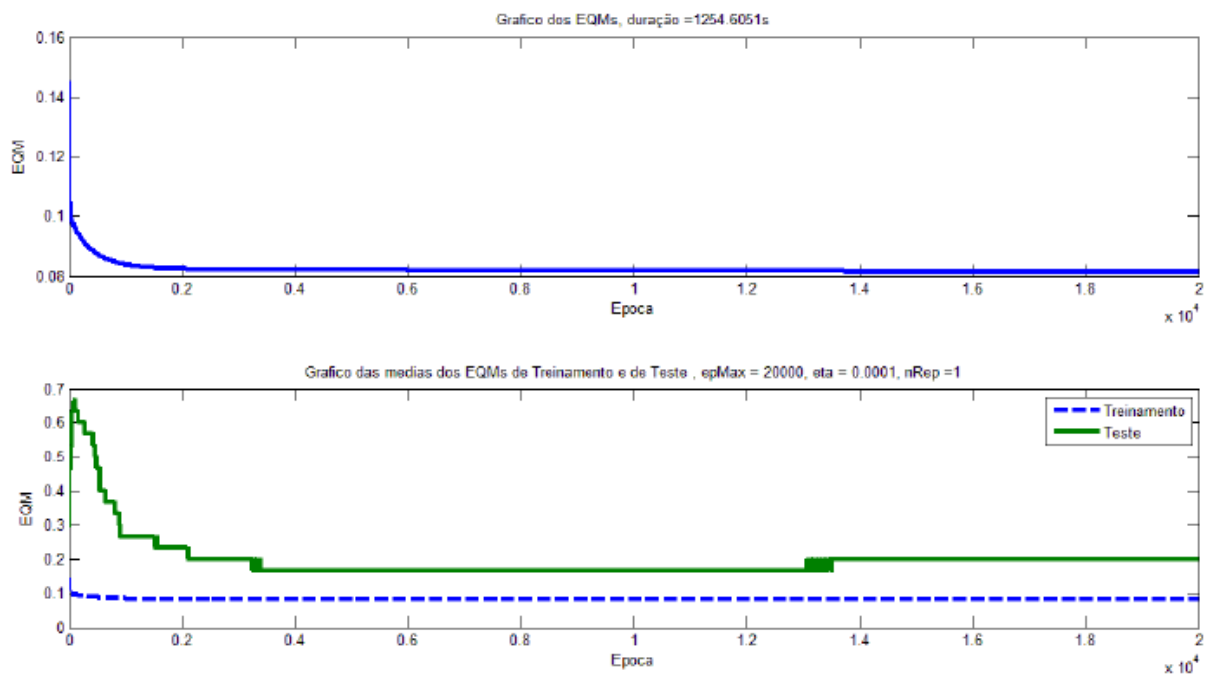
Diferentemente da rede anterior, esta rede convergiu em um tempo relativamente pequeno. Oscilou pouco e teve um desempenho razoável com apenas 16,67% de erro

Figura 5 – Gráfico com treinamento e teste da rede 12



Esta rede foi a segunda que teve o melhor desempenho (16% de erro) e convergiu mostrando ser uma rede adequada para o diagnóstico.

Figura 29 – Gráfico com treinamento e teste da rede 17



A rede 17 teve um bom desempenho com erro de 16,67%, mas, depois de um tempo, subiu para 20% de erro. Porém, isso não faz com que esta rede seja descartada, pois, um desempenho de 16,67% em um pequeno tempo de treinamento, faz com que ela seja uma boa candidata.

O Restante dos gráficos de treinamento para essa doença se encontra no apêndice B.

Para diagnosticar pessoas saudáveis - objetivo de treinamento destas redes - a que teve um melhor desempenho foi com certeza a de número 12, pois apresentou menos oscilações e o menor erro (16%). Por estes motivos ela foi escolhida para este diagnóstico.

Os dados que seguem são do treinamento para diagnosticar insuficiência cardíaca congestiva.

Como foi exposto, as redes que formam parte desse treinamento já foram citadas. São as redes: 3, 8, 12 e 17. Os detalhes destas podem ser vistos na Tabela 3, com algumas diferenças talvez no número de repetições.

Na Tabela 8 estão os resultados obtidos com o treinamento das redes.

Tabela 8 – Dados obtidos com o treinamento para diagnosticar Insuficiência Cardíaca Congestiva


RNA		3	8	12	17
Treinamento	EQM	0,115	0,1027	0,1026	0,1122
	DP_EQM	0,0029	0,0002	0,0003	0,0000
	Época	500	870,4	6990,2	19977
	DP_Época	0	110,45	15,7	0
Teste	EQM	0,3933	0,38	0,3133	0,3333
	DP_EQM	0.1535	0.1043	0,0183	0
	Época	10.6	1	11,2	1
	DP_Época	16,832	0	11,23	0
Duração (s)		65	128	850	506

Como pode ser visualizado (Tabela 8), as redes não conseguiram desempenho significativo ficando com os erros em torno de 35,5%. A rede que obteve o melhor desempenho foi novamente a rede 12 com 31,33% de erro.

Confirmando a suposição de que a rede de número 3 não teria um bom desempenho, com quase 40% de erro, foi a que obteve o pior desempenho.

A Figura 29 mostra o gráfico de treinamento e teste da rede de número 12. Foi a que teve o melhor desempenho (31,33% de erro) e escolhida para diagnosticar insuficiência cardíaca congestiva.

Figura 6 – Gráfico do treinamento e teste da rede escolhida para diagnosticar Insuficiência Cardíaca Congestiva.



Fonte: autor


Agora serão apresentados os dados que faltavam: os dados do treinamento para diagnosticar arritmia cardíaca.

As redes treinadas nesta etapa possuem a mesma estrutura das utilizadas para diagnosticar insuficiência cardíaca congestiva. Os resultados estão na Tabela 9.

Tabela 9 – Dados obtidos com o treinamento para diagnosticar Arritmia Cardíaca

RNA		3	8	12	17
Treinamento	EQM	0,0499	0,049	0,048	0,0489
	DP_EQM	0,0005	0	0	0
	Época	500	628,4	6419	15561
	DP_Época	0	273,94	339,8	0
Teste	EQM	0,2367	0,14	0,14	0,1333
	DP_EQM	0,0399	0,0149	0,014	0
	Época	251,6	190,8	1859,2	2522
	DP_Época	181,02	22,08	0,4877	0
Duração (s)		122	123	887	509

Como pode ser visto na Tabela 9, no diagnóstico de arritmia cardíaca as redes tiveram o melhor desempenho quando comparadas com o desempenho das redes anteriores. O erro médio foi de 16,25%, sendo que a melhor rede teve apenas 13,33% de erro. Por isso, a rede mais adequada para o diagnóstico de arritmia cardíaca é a rede de número 17, onde o seu treinamento e teste pode ser visto na Figura 25.

Figura 31 – Gráfico do treinamento e teste da rede escolhida para diagnosticar Arritmia Cardíaca

Fonte: autor.

Todos os gráficos de treinamento e teste das outras redes que não tiveram seus gráficos mostrados (arritmia cardíaca e insuficiência cardíaca congestiva) estão no Apêndice B.

6.2 RESULTADOS COM O ALGORITMO BACKPROPAGATION

Depois de realizado o condicionamento dos dados e feita a normalização, foi realizado um processo de reamostragem das amostras. Desse modo, elas foram clonadas aleatoriamente fazendo com que todas as doenças ficassem com 100 amostras. Como os dados referentes à idade e sexo causaram instabilidade no algoritmo LMS, eles também não serão utilizados no treinamento das RNAs com o algoritmo backpropagation.

6.2.1 Algoritmo Backpropagation com 1 Camada Oculta.

O algoritmo backpropagation de uma camada oculta necessita dos seguintes parâmetros para o treinamento e teste das RNAs:

a → Constante = 1,7159.

b → Constante = 0,6667.

α → “constante” de momento (inércia).

η → Coeficiente de aprendizagem inicial, para que o treinamento seja mais rápido.

η^2 → Coeficiente de aprendizagem substituto, utilizado no fim do treinamento para refinar a rede.

epMax → número máximo de épocas.

nRep → número máximo de repetições.

m1 → número de neurônios na camada oculta.

pTrei → percentual de dados utilizados no treinamento.

Os testes iniciais da rede são feitos com os dados de pessoas saudáveis, definindo as melhores redes para depois realizar o treinamento com os outros dados.

Primeiramente, foram feitos testes nas redes variando a constante de momento de acordo com a Tabela 10.

Tabela 10 – Parâmetros para de treinamento para definição da constante momento.

Treinamento	α	η	η^2	epMax	nRep	m1	pTrei
1	0,7	0,1	0,01	6000	10	100	80
2	0,7	0,1	0,01	6000	25	50	80
3	0,7	0,1	0,01	6000	10	25	80
11	0,5	0,1	0,01	6000	10	100	80
12	0,5	0,1	0,01	6000	25	50	80
13	0,5	0,1	0,01	6000	10	25	80

Os resultados do treinamento das redes podem ser visto na Tabela 11:

Tabela 11 –Tabela com resultados do treinamento para definição da constante momento.

RNA		1	2	3	11	12	13
Treinamento	EQM	0,0865	0,0834	0,0855	0,0813	0,0862	0,0784
	DP_EQM	0,005	0,0079	0,0031	0,0169	0,0277	0,0194
	Época	2930	3278	2800	4601	4805	4738
	DP_Época	1989	2310	1641	1749	2268	2263
Teste	Erro	0,1815	0,2041	0,1893	0,1861	0,2134	0,2244
	DP_Erro	0,0197	0,0199	0,0162	0,0232	0,0311	0,0262
	Época	2037	1505	1786	1794	2015	2017
	DP_Época	1904	1351	1677	1703	1509	1783
Duração (s)		446	984	409	519	1065	485

A Tabela 11 mostra apenas 6 testes, o restante pode ser visualizado no Anexo C.

Como pode ser observado na Tabela 11 e no Anexo C, o melhor valor entre os dois valores testados é 0,7. Portanto, para os testes seguintes, será utilizado o valor 0,7 para a constante de momento.

Depois de definido o valor da constante momento foram definidos os seguintes parâmetros para o novo treinamento.

Tabela 12 –Parâmetros para o primeiro treinamento do algoritmo Backpropagation com 1 camada oculta.

Treinamento	α	η	η^2	epMax	nRep	m1	pTrei
1	0,7	0,1	0,01	6000	10	100	80
2	0,7	0,1	0,01	6000	50	100	80
3	0,7	0,1	0,01	6000	100	100	80
4	0,7	0,1	0,01	6000	25	50	80
5	0,7	0,1	0,01	6000	50	50	80
6	0,7	0,1	0,01	6000	100	50	80
7	0,7	0,1	0,01	6000	10	25	80
8	0,7	0,1	0,01	6000	50	25	80
9	0,7	0,1	0,01	6000	100	25	80
10	0,7	0,1	0,01	6000	25	100	80
11	0,7	0,1	0,01	6000	75	100	80
12	0,7	0,1	0,01	6000	125	100	80

Depois de definidos os parâmetros do treinamento (Tabela 12), foi realizado o treinamento da rede com o algoritmo Backpropagation.

Tabela 13 – Resultado do primeiro treinamento do algoritmo Backpropagation com 1 camada oculta

	RNA	1	7	4	2	6	9
Treinamento	EQM	0,0724	0,0723	0,072	0,0711	0,0714	0,0713
	DP_EQM	0,0045	0,0111	0,0055	0,0049	0,0071	0,0087
	Época	4841	4874	4797	4996	4939	4861
	DP_Época	1513	2012	1569	1354	1508	1665
Teste	Erro	0,1621	0,1629	0,1686	0,1735	0,1743	0,1781
	DP_Erro	0,0493	0,0494	0,0495	0,0565	0,0567	0,0603
	Época	1131	1475	1019	1245	1163	1246
	DP_Época	1501	1905	1572	1667	1628	3906
Duração (s)		490	341	983	2502	3906	3442

O restante dos resultados pode ser visto no Anexo C

Como pode ser visualizado na Tabela 13, as redes que apresentaram o melhor desempenho neste treinamento (melhor resultado em menor

tempo) foram as redes 1 e 7. Portanto, para os testes seguintes, foram utilizadas somente estas redes.

Após a definição das melhores redes, como visto na Tabela 14, as redes foram submetidas a novos treinamentos. Cada rede foi treinada mais 6 vezes.

Tabela 14 – Resultados do treinamento das melhores redes (1 e 7) em pessoas saudáveis.

RNA		1	7	1	7
Treinamento	EQM	0,0749	0,0761	0,0756	0,0762
	DP_EQM	0,0016	0,0087	0,006	0,0061
	Época	5351	5032	5120	5213
	DP_Época	1110	2060	1361	1372
Teste	Erro	0,0933	0,0933	0,105	0,1066
	DP_Erro	0,0262	0,0378	0,0371	0,0423
	Época	1346	640	711	724
	DP_Época	1852	1131	1401	1421
Duração (s)		486	319	478	335

O restante dos resultados pode ser visto no Anexo C

Como pode ser visualizado na Tabela 14, as redes 1 e 7 realmente apresentaram um bom desempenho e serão utilizadas para o treinamento com as outras doenças.

As duas redes apresentaram o mesmo erro na identificação de pessoas saudáveis. Porém, a rede de melhor desempenho e escolhida para este diagnóstico é a rede 7, pois apresentou o menor tempo de processamento.

Depois do treinamento com os dados de pessoas saudáveis, as redes 1 e 7 foram submetidas a novos treinamentos com os dados de pessoas com insuficiência cardíaca congestiva.

Para o treinamento com dados de pessoas com insuficiência cardíaca congestiva as redes 1 e 7 foram treinadas 10 vezes cada uma dando um total de 20 treinamentos.

Tabela 15 – Resultados do treinamento das melhores redes (1 e 7) em pessoas com Insuficiência cardíaca congestiva.

RNA		1	7	7	1
Treinamento	EQM	0,0875	0,0858	0,0709	0,0787
	DP_EQM	0,0102	0,0142	0,0036	0,0011
	Época	2868	3486	4695	5475
	DP_Época	2626	2486	4695	5475
Teste	Erro	0,1433	0,17	0,1783	0,1783
	DP_Erro	0,014	0,0219	0,0176	0,0176
	Época	2905	1342	1115	1007
	DP_Época	1240	1796	1589	1499
Duração (s)		750	525	505	774

O restante dos resultados pode ser visto no anexo C

Como pode ser visualizado na Tabela 15, o melhor resultado foi obtido com o treinamento da rede 1. Portanto, ela será utilizada para o diagnóstico de insuficiência cardíaca congestiva.

Depois do treinamento com os dados de insuficiência cardíaca, as redes 1 e 7 foram novamente treinadas mas, desta vez, com os dados de pessoas com arritmia. Elas também foram treinadas 10 vezes cada uma, dando um total de 20 treinamentos.

Tabela 16 – Resultados do treinamento das melhores redes (1 e 7) em pessoas com Arritmia Cardíaca.

RNA		7	7	1	7
Treinamento	EQM	0,0746	0,0841	0,0784	0,0737
	DP_EQM	0,0043	0,0137	0,0016	0,0022
	Época	5541	3405	4261	6000
	DP_Época	969	2516	2313	0
Teste	Erro	0,16	0,1733	0,1733	0,175
	DP_Erro	0,021	0,0522	0,021	0,0196
	Época	1351	1503	1027	1440
	DP_Época	1902	1681	1626	1807
Duração (s)		547	535	757	536

O restante dos resultados pode ser visto no anexo C

Como pode ser visualizado na Tabela 16, o melhor resultado foi obtido com o treinamento da rede 7.

Portanto, para identificação de pessoas saudias, a rede de 1 camada oculta que apresentou o melhor desempenho foi a rede 7, pois seu erro foi de 9,33%. Já na identificação de pessoa com insuficiência cardíaca congestiva foi a rede 1, com erro de 14,33%. Finalmente, para a identificação de pessoas com arritmia cardíaca, foi a rede 7 com 16% de erro.

6.2.2 Algoritmo Backpropagation com 2 Camadas Ocultas.

O algoritmo backpropagation de duas camadas ocultas necessita dos seguintes parâmetros para o treinamento e teste das RNAs

a → Constante = 1,7159.

b → Constante = 0,6667.

α → “constante” de momento (inércia).

η → Coeficiente de aprendizagem inicial, para que o treinamento seja mais rápido.

η^2 → Coeficiente de aprendizagem substituto, utilizado no fim do treinamento para refinar a rede.

epMax → número máximo de épocas.

nRep → número máximo de repetições.

m1 → número de neurônios na primeira camada oculta.

m2 → número de neurônios na segunda camada oculta.

pTrei → percentual de dados utilizados no treinamento.

Na Tabela 17 encontram-se os parâmetros das redes que apresentaram os melhores desempenhos. Como foi realizado um grande número de treinamentos, os outros parâmetros juntamente com os resultados estão no Anexo C.

Tabela 17 – Parâmetros, das melhores redes, do primeiro treinamento do algoritmo Backpropagation com 2 camadas ocultas.

Treinamento	α	η_1	η_2	epMax	nRep	m1	pTrei	m2
4	0,7	0,1	0,01	6000	25	50	80	10
7	0,7	0,1	0,01	6000	10	25	80	10
32	0,7	0,1	0,001	12000	50	25	80	10
75	0,7	0,1	0,01	6000	100	100	80	25

Tabela 18 – Resultados das melhores redes do primeiro treinamento do algoritmo backpropagation com 2 camadas ocultas.

RNA		4	7	75	32
Treinamento	EQM	0,0697	0,0745	0,0471	0,0613
	DP_EQM	0,0232	0,0218	0,017	0,0229
	Época	4274	3463	5041	10198
	DP_Época	2005	2308	1095	4320
Teste	Erro	0,09	0,0883	0,1495	0,0883
	DP_Erro	0,0136	0,0176	0,0326	0,0259
	Época	2341	2521	3266	4264
	DP_Época	1858	1571	2049	4629
Duração (s)		3668	1292	20876	12513

A Tabela 18 mostra os resultados dos treinamentos das redes escolhidas para continuar o processo de treinamento e teste com o algoritmo backpropagation em redes com 2 camadas ocultas. As redes 4, 7 e 32 foram escolhidas por apresentarem menor erro. Já a rede de número 75 foi escolhida por ter apresentado o menor EQM de treinamento.

Após definir que os treinamentos seriam realizados com estas redes, o parâmetro epMax das redes 4, 7 e 75 foram alterados para que todas as redes tivessem o mesmo valor da rede 32, ou seja, todas as redes ficaram com epMax = 12000, como pode ser visto na Tabela 19.

Tabela 19 – Parâmetros, das melhores redes, do primeiro treinamento do algoritmo Backpropagation com 2 camadas ocultas com epMax igualado.

Treinamento	α	η	η^2	epMax	nRep	m1	pTrei	m2
4	0,7	0,1	0,01	12000	25	50	80	10
7	0,7	0,1	0,01	12000	10	25	80	10
32	0,7	0,1	0,001	12000	50	25	80	10
75	0,7	0,1	0,01	12000	100	100	80	25

Feitas as alterações nos parâmetros das redes, elas foram submetidas a novos treinamentos com os dados de pessoas saudias, resultando em 110 novos treinamentos.

Tabela 20 – Melhores resultados do treinamento backpropagation 2 camadas em pessoas saudias.

RNA	32	4	7	7	
Treinamento	EQM	0,0781	0,0532	0,0574	0,0646
	DP_EQM	0,0313	0,0208	0,0329	0,0254
	Época	6783	7711	7897	5297
	DP_Época	4575	2828	3487	3926
Teste	Erro	0,0407	0,0513	0,0633	0,0667
	DP_Erro	0,0191	0,022	0,0153	0,0192
	Época	2066	7188	2911	7658
	DP_Época	2947	3031	4179	4119
Duração (s)	12283	6694	2534	2536	

O restante dos resultados pode ser visto no anexo C

Como pode ser visualizado na Tabela, todas as redes tiveram um desempenho excelente, mas a rede 32 foi a que apresentou o melhor desempenho na identificação de pessoas saudias.

Depois do treinamento com os dados de pessoas saudias foi realizado o treinamento das mesmas redes com os dados de pessoas com insuficiência cardíaca congestiva. Para este novo treinamento, cada rede foi submetida a 10 novos treinamentos resultando em 40 novos treinamentos. A Tabela 21 – mostra os melhores resultados deste treinamento.

Tabela 21 – Melhores resultados do treinamento backpropagation 2 camadas em pessoas com insuficiência cardíaca congestiva.

RNA		75	7	32	4
Treinamento	EQM	0,0413	0,0761	0,0643	0,0694
	DP_EQM	0,0205	0,0241	0,017	0,0135
	Época	9814	3703	11110	10507
	DP_Época	2630	2679	2498	3697
Teste	Erro	0,083	0,0967	0,1027	0,108
	DP_Erro	0,0311	0,0483	0,0295	0,0221
	Época	7537	4191	3377	3367
	DP_Época	2919	3150	2558	3022
Duração (s)		37176	2472	12195	7659

Como pode ser observado na Tabela 21 –a rede de melhor desempenho foi a rede de número 75, mas todas apresentaram um bom desempenho.

Posteriormente ao treinamento com os dados de pessoas com insuficiência cardíaca, foram realizados os treinamentos com os dados de pessoa com arritmia cardíaca. Seguiu-se os mesmos critérios do treinamento anterior, ou seja, 10 treinamentos cada, resultando em um universo de 40 treinamentos.

Tabela 22 –Melhores resultados do treinamento backpropagation 2 camadas em pessoas com arritmia cardíaca.

RNA		7	7	32	4
Treinamento	EQM	0,0574	0,0646	0,0682	0,0548
	DP_EQM	0,0329	0,0254	0,0260	0,0245
	Época	7897	5297	5958	6538
	DP_Época	3487	3926	3240	3013
Teste	Erro	0,0633	0,0667	0,0783	0,0893
	DP_Erro	0,0153	0,0192	0,0249	0,0311
	Época	2911	7658	5744	6844
	DP_Época	4179	4119	3133	3113
Duração (s)		2534	2536	12529	6850

A Tabela 22 mostra que novamente as redes escolhidas apresentaram um ótimo desempenho e a que teve o melhor desempenho na identificação de pessoas com arritmia foi a rede de número 7.

Como pode ser observado, no treinamento de rede com duas camadas ocultas utilizando o algoritmo backpropagation, a rede 32 foi a de melhor desempenho na identificação de pessoas sadias com um erro de 4,07%. Para pessoas com insuficiência cardíaca foi a rede 75 com 8,3% e para pessoas com arritmia cardíaca foi a rede de número 7 com um erro de 6,33%.

6.3 RESULTADOS DOS TREINAMENTOS UTILIZANDO NNTTOOLS

6.3.1 RNA 1 Camada Oculta.

Para este treinamento as redes foram configuradas de forma que ficassem similares as redes do treinamento com o algoritmo backpropagation desenvolvido, os parâmetros utilizados pode ser visto na Tabela 23.

Tabela 23 – Parâmetros para o treinamento da RNA com 1 camada oculta utilizando nntools.

Rede	epMax	m1	pTrei
1	6000	25	80
2	6000	50	80
3	6000	100	80

Onde:

epMax → número máximo de épocas.

m1 → número de neurônios na camada oculta.

pTrei → percentual de dados utilizados no treinamento.

Os resultados do treinamento pode ser visto na Tabela 24

Tabela 24 – Resultados do treinamento de RNAs de 1 camada oculta e treinadas com nntools

Doenças	Teste	RNA		
		1	2	3
Sadias	Erro	0,1250	0,065	0,1042
	Epoca	303	789	669
	Duração	10	62	213
Insuficiência Cardíaca Congestiva	Erro	0,1458	0,1250	0,0833
	Epoca	352	555	1199
	Duração	11	45	406
Arritmia	Erro	0,1667	0,1035	0,1043
	Epoca	455	1918	536
	Duração	14	155	190

6.3.2 RNA 2 Camada Oculta.

Para este treinamento as redes foram configuradas de forma que ficassem similares as redes do treinamento com o algoritmo backpropagation desenvolvido, os parâmetros utilizados pode ser visto na Tabela 25.

Tabela 25 – Parâmetros para o treinamento da RNA com 2 camadas ocultas utilizando nntools.

Rede	epMax	m1	m2	pTrei
1	6000	25	10	80
2	6000	50	10	80
3	6000	100	25	80

Onde:

epMax → número máximo de épocas.

m1 → número de neurônios na primeira camada oculta.

m2 → número de neurônios na segunda camada oculta.

pTrei → percentual de dados utilizados no treinamento.

Os resultados do treinamento pode ser visto na Tabela 26

Tabela 26 – Resultados do treinamento de RNAs de 2 camadas ocultas e treinadas com nntools

Doenças	Teste	RNA		
		1	2	3
Sadias	Erro	0,0834	0,1048	0,0405
	Época	1798	2720	7251
	Duração	279	1390	60420
Insuficiencia Cardiaca Congestiva	Erro	0,1250	0,0565	0,0833
	Época	250	2707	3692
	Duração	84	1369	33720
Arritmia	Erro	0,1354	0,0875	0,1041
	Época	6365	1580	4567
	Duração	623	583	42336

Como pode ser observado na Tabela 24 e Tabela 26 os erros de teste das redes treinadas utilizando a ferramenta nntools do Matlab ficaram muito próximos e até em alguns casos melhores do que com os algoritmos desenvolvidos, porém o desempenho em alguns caso foi muito superior pois o tempo de treinamento foi extremamente menor, já que é um algoritmo otimizado e um dos critérios de parada utilizado é o gradiente o que faz com que rede não seja treinada até o fim da épocas estipuladas como acontece nos algoritmos desenvolvidos neste trabalho.

A Tabela 27 mostra a comparação dos melhores resultados obtidos com o treinamento com as redes desenvolvidas e com o resultado atingido com o treinamento utilizando o nntools.

Tabela 27 – Comparação dos Resultados das redes treinadas com o algoritmo desenvolvido e com o nntools.

Doenças	Teste	RNA			
		BP 1 camada	nntools 1 camada	BP 2 camada	nntools 2 Camada
Sadias	Erro	0,0933	0,065	0,0407	0,0405
	Epoca	640	789	2066	7251
	Duração	319	62	12283	60420
Insuficiencia Cardiaca Congestiva	Erro	0,1433	0,0833	0,0830	0,0565
	Epoca	2905	1199	7537	2707
	Duração	750	406	37176	1369
Arritmia	Erro	0,1600	0,1035	0,0633	0,0875
	Epoca	1351	1918	2911	1580
	Duração	547	155	2534	583

7 CONCLUSÕES

7.1 CONCLUSÕES DO TRABALHO

Devido aos resultados mostrados neste trabalho, comprovou-se que as redes neurais artificiais, podem não apenas dar auxílio, mas formar opiniões sobre os diagnósticos dos pacientes. Elas fornecem um diagnóstico relativamente preciso apenas com os dados de um eletrocardiograma de 24 horas e de algum processamento, facilitando e até mesmo apoiando as decisões dos médicos. Isso faz com que os pacientes possam ter um tratamento adequado e imediato.

Como pode ser visto na seção de resultados a melhor rede para o diagnóstico de cardiopatias, dentre as treinadas, é a rede com duas camadas ocultas de neurônios, onde o erro no diagnóstico foi de 4,07% para pessoas saudáveis, 8,3% para insuficiência cardíaca congestiva e 6,33% para arritmia cardíaca. Os resultados das outras redes podem ser comparados na Tabela 28.

Tabela 28 – Tabela comparando os erros obtidos no treinamento de cada tipo de rede.

Algoritmo	Erro		
	Backpropagation		LMS
Rede	2 camadas ocultas	1 camada oculta	1 neurônio
peçoas saudáveis	4,07%	9,33%	16,00%
insuficiência cardíaca	8,30%	14,33%	31,33%
arritmia cardíaca	6,33%	16,00%	13,33%

Para verificar os resultados obtidos, as melhores arquitetura de redes foram testadas utilizando a ferramenta nntools do Matlab. Ao final, foram encontrados resultados similares (erros de classificação na ordem de 4%), apenas com tempos menores de simulação devido ao critério de parada utilizado (gradiente).

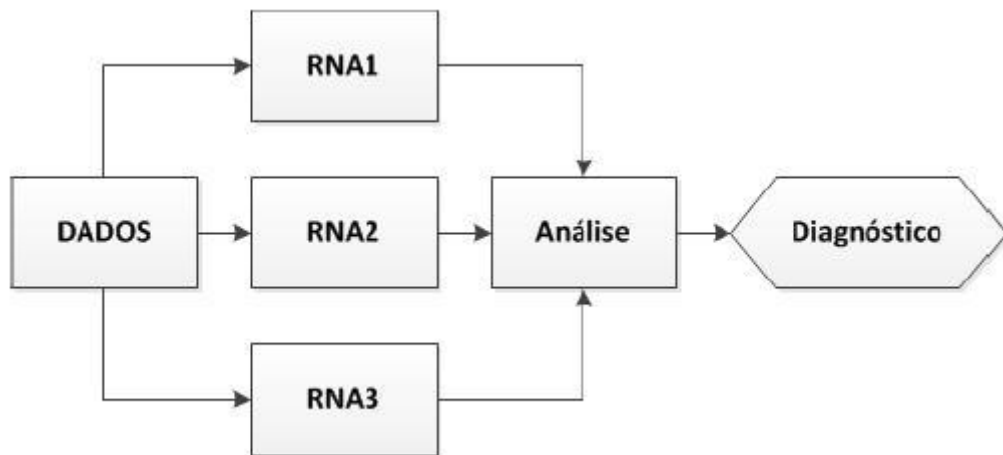
O desempenho global das redes pode ser melhorado se usarmos os resultados das outras redes para ajudar a tomar decisão sobre o diagnóstico, ou seja, não avaliar apenas uma rede e sim o conjunto de resultados levando em consideração a resposta das três redes.

Uma rede neural, por mais precisa que seja, nunca vai ser capaz de determinar todos os casos com extrema exatidão. Então, como já foi dito, essa será mais uma ferramenta à disposição dos especialistas.

7.2 SUGESTÕES DE TRABALHOS FUTUROS

- Fazer uma nova rede para fazer uma análise dos resultados das redes anteriores e dizer diagnóstico final como mostra a Figura 32.

Figura 32 – Rede completa para o diagnóstico



- Fazer o treinamento das redes com um número bem maior de dados e de cardiopatias.
- Desenvolver uma função para calcular a Densidade Espectral de Potência (PSD) dos dados de entrada, já que neste trabalho foi utilizado uma função interna do Matlab. Este, por não possuir código aberto, não permite acesso ao processamento que ela realiza. Seria interessante ter acesso a algumas etapas, como definir os números de elementos na saída.
- Desenvolver um hardware que fizesse a captura dos dados e tivesse como saída, além do ECG, o diagnóstico (ou seja, a saída da RNA).
- Fazer o treinamento com dados de ECG de 5 min para comparar os resultados e definir se é uma alternativa válida.

REFERÊNCIAS

- ALMEIDA, M. A. F. *Aprender atividade inteligente: e se esta inteligência for parcialmente artificial?*. 1999. 102 f. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Santa Catarina, Florianópolis, 1999.
- AZEVEDO, F. M.; BRASIL, L. M.; OLIVEIRA, R. C. *Redes neurais*. Florianópolis: Visual Books, 2000.
- BARRETO, J. M. Inteligência artificial e engenharia biomédica: casamento perfeito ou amantes eternos? .In: CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA, 17. *Anais...*, 2000.
- BARRETO, J. M. *Inteligência artificial no limiar do século XXI*. 3. ed. Florianópolis: ppp Edições, 2001.
- BIGGER, J. T.; FLEISS, J. L.; STEINMAN, R. C. RR variability in healthy, middle-aged persons compared with patients with chronic coronary heart disease or recent acute myocardial infarction. *Circulation*, v. 91, n. 7, p.1936-1943, 1995.
- BLANCHARD, S. M. Anatomy and physiology .In: J. ENDERLE; S. M. BLANCHARD; J. D. BRONZINO (Org.). *Introduction to biomedical engineering*. San Diego: Academic Press, 2000, p. 29-78.
- BLANCHARD, S. M.; LUCAS, C.; WRIGHT. S. Biosignal processing .In: J. ENDERLE; S.M. BLANCHARD; J.D. BRONZINO (Org.). *Introduction to biomedical engineering*. San Diego: Academic Press, 2000, p. 233-278.
- BRAGA, A. D.; CARVALHO, A. P.; LUDERMIR, T. B. *Redes neurais artificiais, teorema e aplicações*. Rio de Janeiro: LTC, 2000.
- BRIGHT, P.; MILLER M. R.; FRANKLYN, J. A.; SHEPPARD, M. C. The use of a neural network to detect upper airway obstruction caused by goiter. *American Journal of Respiratory Critical Care in Medicine*. v. 157, n. 6, p.1885-1891, 1998.
- FERREYRA RAMIREZ, E. F. *Modelo conexionista para avaliação de propostas para aquisição de equipamentos médico-hospitalares*. 2005. 267f. Tese (Doutorado em Engenharia Elétrica) – Universidade Estadual de Campinas, Campinas, 2005.
- FONTENLA - Romero, O. ET AL. A new method for sleep apnea classification using wavelets and feedforward neural networks. *Artificial Intelligence in Medicine*. v. 34, n. 1, p.65-76, 2005
- GOMES, M. E. D. *Técnicas de sistemas dinâmicos não lineares na análise da modulação autonômica da variabilidade da frequência cardíaca*. 2001. 268f. Tese (Doutorado em Engenharia Elétrica) – Universidade Federal de Minas Gerais, Belo Horizonte, 2001.
- GUYTON, A. C.; HALL, J. E. *Tratado de fisiologia médica*. 10. ed. Rio de Janeiro: Guanabara Koogan S.A. 2002.

HAYKIN, S. *Redes neurais: princípios e prática*. 2. ed. Porto Alegre: Bookman, 2001.

OLIVEIRA, C.; CAMARGO-BRUNETTO, M. A. O.; FERREYRA RAMÍREZ, E. F.; BRUNETTO, A. F. Identificação de doença pulmonar obstrutiva crônica através de redes neurais artificiais. In: CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA, 10. *Anais...*, CONGRESSO BRASILEIRO DE ENGENHARIA CLÍNICA, 2. ,2006.

REFENES, A. P. N.; BURGESS, A. N.; BENTZ, Y. Neural networks in financial engineering: a study in methodology. *IEEE Transactions on Neural Networks*, v. 8, n.6, p.1222-1267. 1997.

RIBEIRO, H. C. S., *Introdução aos sistemas especialistas*. Rio de Janeiro: Livros Técnicos e Científicos, 1987, 142 p.

VON ZUBEN, F. J. Uma caricatura funcional de redes neurais artificiais. In: CONGRESSO BRASILEIRO DE REDES NEURAS, 6., *Anais...* v. 1, n. 2, p. 66-76, 2003.

APÊNDICES

APÊNDICE A – Funções criadas no Matlab para o desenvolvimento deste trabalho.

Função Início

```

disp(          ' #####')
disp(          ' #      Programa para realizar o processamento      #')
disp(          ' #      do intervalo RR que, posteriormente,          #')
disp(          ' #      será aplicado como entrada da                          #')
disp(          ' #      rede neural.                                           #')
disp(          ' #####')
disp('      ')
arquivo = input (' Digite o número de arquivos a serem processados :');
filtro  = input (' Digite o valor máximo do intervalo RR :');
Linha   = input (' Digite o número de linhas do cabeçalho :');
Amost   = input (' Digite o valor para a reamostragem do intervalo RR :');
disp('      ')
tic
for i=1:1:arquivo

[ln_ulf,ln_vlf,ln_lf,ln_hf,ln_tp,ln_raz,dados,freq,tipo,sexo,idade1,idade2]
= main(filtro,i,Linha,Amost);
    RR_temp = fopen('saida.txt','a+');          %Abre o arquivo para gravação.
    fprintf(RR_temp,'%1f  %1f  %1f  %1f  %1f  %1f  %1f  %1f  %1f
%1f\n',ln_ulf,ln_vlf,ln_lf,ln_hf,ln_tp,ln_raz,tipo,sexo,idade1,idade2');
    %Grava o valor RR no arquivo.
    fclose(RR_temp);                          %Fecha o arquivo de gravação.
end
toc

```

Função Main

```

function
[ln_ulf,ln_vlf,ln_lf,ln_hf,ln_tp,ln_raz,dados,freq,tipo,sexo,idade1,idade2]
= main(filtro,arquivo,Linha,Amost)
%Programa principal
%filtro = 2;          %Valor maximo do intervalo RR
%arquivo = 1;        %Número do paciente
%Linha = 5;          %Linha inicial dos dados
%Amost = 0.1;        %Valor para reamostragem
[x,media,horas,total,tipo,sexo,idade1,idade2]=leitor(filtro,arquivo,Linha);
[z,cont]=reamost(Amost,x,Linha,total);
[dados,freq] = fazpsd(Amost,z,Linha);
temp(:,2) = freq;
temp(:,1) = dados;
[w,cont]=reamost(0.001,temp,1,max(freq));
[ln_ulf,ln_vlf,ln_lf,ln_hf,ln_tp,ln_raz] = integral(w(:,1),w(:,2),arquivo);
end

```

Função Leitor

```

function [RR,media,horas,total,tip,sex,idade1,idade2] =
leitor(Lim,Num,Linha)
%Leitor e condicionador de dados do intervalo RR
%Atualizado em: 24/08/2007
%Versão:1.0

%*****DADOS*****
%Lim ==> Valor de corte das amostras
%Num ==> Numero do paciente
%Linha ==> Numero de linhas do cabeçario

%figure
str = [num2str(Num) '.txt'];
str
RR=textread(str); %Carrega o arquivo de texto para a
matrix RR.
str = ['h' num2str(Num) '.txt'];
str
RR_h=textread(str); %Carrega o arquivo de texto para
a matrix RR.

%subplot(2,1,1);plot(RR(Linha:size(RR,1),1));
%title('Grafico dos Intervalos RR');
%xlabel('Tempo(s)');
%ylabel('Valor do Intervalo(s)');

total=0; %zera a variavel total.
media=mean(RR(Linha:size(RR,1))); %Calcula a média do intervalo RR.
for i=Linha:size(RR,1); % Retira Valores de intervalo RR,
if RR(i,1)>Lim; %maiores que 2 segundos, da matriz
RR.
RR(i,1)=media;
end
total=total+RR(i,1); %Soma os Intervalos RR.
RR(i,2)= total;
end
horas=total/3600; %Calcula o tempo Total do exame.

%subplot(2,1,2);plot(RR(Linha:size(RR,1),2),RR(Linha:size(RR,1),1),'b. ');
%title('Grafico dos Intervalos RR filtrados');
%xlabel('Tempo(s)');
%ylabel('Valor do Intervalo(s)');

idade1= RR_h(1);
idade2= RR_h(2);
if RR_h(3) == 1;
sexo='Masculino';
else;
sexo='Feminino';
end;

```

```

tip = RR_h(4);
sex = RR_h(3);
if RR_h(4) == 0;
    tipo='Normal';
end;
if RR_h(4) == 1;
    tipo='Arritmia';
end;
if RR_h(4) == 2;
    tipo='Congestive';
end;

mimRR=min(RR(Linha:size(RR,1)-Linha+1,1));
maxRR=max(RR(Linha:size(RR,1)-Linha+1,1));

texto= ['----- Dados do Intervalo RR ' num2str(Num) ' -----'];
disp(texto);
texto= ['                Media: ' num2str(media) ' Segundos'];
disp(texto);
texto= ['                Amostras: ' num2str(size(RR,1)-Linha+1) '
Intervalos'];
disp(texto);
texto= ['                Idade: ' num2str(idade1) num2str(idade2) '
Anos'];
disp(texto);
texto= ['                Sexo: ' num2str(sexo)];
disp(texto);
texto= [' Intervalo Minimo: ' num2str(mimRR) ' Segundos'];
disp(texto);
texto= [' Intervalo Maximo: ' num2str(maxRR) ' Segundos'];
disp(texto);
texto= ['                Doença: ' num2str(tipo) ];
disp(texto);
disp('-----');
disp(' ');

end

```

Função Reamostragem

```

function [z,cont] = reamost(amost,x,Linha,total)
%amost = 0.7;
t = x(Linha,2);
cont = 1;
z(1,1)=x(Linha,1);
z(1,2)=x(Linha,2);
tudo = round(total/amost);
z(tudo-20,1)=0;
for i=Linha:1:(size(x,1)-1)

    a = (x(i+1,1)-x(i,1))/(x(i+1,2)-x(i,2)) ;
    b = x(i,1);
    while t+amost < x(i+1,2)

```

```

        cont = cont + 1;
        t = t + amost;
        z(cont,1)= a*(t-x(i,2)) + b;
        z(cont,2)= t;

    end
end
%plot(z(:,1))
end

```

Função PSD

```

function [dat,freq] = fazpsd(amost,z,Linha)
    Fs = 1/amost;
    h = spectrum.welch;
    Hpsd = psd(h,z(Linha:size(z,1),1),'Fs',Fs);
    dat = Hpsd.data;
    dat = dat.*freq;
    freq = Hpsd.frequencies;
    %figure;
    %plot(freq,dat)
end

```

Função Integral

```

function
[ln_ulf,ln_vlf,ln_lf,ln_hf,ln_tp,ln_raz]=integral(dados,freq,arquivo)
ulf = 0;
vlf = 0;
lf = 0;
hf = 0;
j=1;
while freq(j)<0.5

    base = freq(j+1)-freq(j);
    lados = dados(j+1)+dados(j);
    if freq(j)<0.0033
        ulf = ulf + (base*lados/2);
    else
        if freq(j)<0.04
            vlf = vlf + (base*lados/2);
        else
            if freq(j)<0.15
                lf = lf + (base*lados/2);
            else
                if freq(j)<0.4
                    hf = hf + (base*lados/2);
                end
            end
        end
    end
end
end

```

```

j = j+1;

end
tp = ulf + vlf + lf + hf;
raz = lf/hf;
ln_ulf = log(ulf);
ln_vlf = log(vlf);
ln_lf = log(lf);
ln_hf = log(hf);
ln_tp = log(tp);
ln_raz = log(raz);
texto= ['----- Saída do Intervalo RR ' num2str(arquivo) ' -----'];
disp(texto);
texto= ['          ULF = ' num2str(ln_ulf) ];
disp(texto);
texto= ['          VLF = ' num2str(ln_vlf) ];
disp(texto);
texto= ['          LF = ' num2str(ln_lf) ];
disp(texto);
texto= ['          HF = ' num2str(ln_hf) ];
disp(texto);
texto= ['          TP = ' num2str(ln_tp) ];
disp(texto);
texto= ['          LF/HF = ' num2str(ln_raz) ];
disp(texto);
disp('-----');
disp(' ');

```

Função para Normalizar os Dados

```

clear all

x = textread('saida.txt'); %le as entradas para rede Neural Que
foram geradas pelo condicionador de sinais.
for i=1:1:size(x,1)
    x(i,7) = x(i,7) + 1; %Arruma os dados sobre a doença para
tirar o zero causado pelo condicionador.
    %----- Arruma o sexo (1)Masculino (-1)Feminino -----
    %if x(i,8) == 0
        %x(i,8)= -1;
    %end
    %-----
    %----- Coloca as saidas de cada rede em colunas separadas -----
    if x(i,7) == 1
        x(i,8) = 1;
    else
        x(i,8) = 0;
    end
    if x(i,7) == 2
        x(i,9) = 1;
    else

```

```

        x(i,9) = 0;
    end
    if x(i,7) == 3
        x(i,10) = 1;
    else
        x(i,10) = 0;
    end
end
%-----
end
for i=1:1:size(x,1)          %Coloca a entrada de bias
    x(i,7) = x(i,6);
    x(i,6) = x(i,5);
    x(i,5) = x(i,4);
    x(i,4) = x(i,3);
    x(i,3) = x(i,2);
    x(i,2) = x(i,1);
    x(i,1) = 1;
end
%----- Calcula o quanto tem de cada Doença para fazer o teste com o
%numero iguais de paciente para cada doença.
N = 0;
A = 0;
C = 0;
for i=1:1:size(x,1)
    if x(i,8) == 1
        N = N + 1;
    end
    if x(i,9) == 1
        A = A + 1;
    end
    if x(i,10) == 1
        C = C + 1;
    end
end
%-----
%----- Normaliza os dados -----
for i=2:1:7
    x(:,i) = x(:,i)/max(abs(x(:,i)));
end
%----- Divide os dados para treinamento (Y) e teste (Y_t)-----
cont = 0;
cont1 = 0;
for i=1:1:size(x,1)
    if i <= A - 10
        cont = cont + 1;
        Y(cont,:) = x(i,:);
    elseif i <= A
        cont1 = cont1 + 1;
        Y_t(cont1,:) = x(i,:);
    elseif i <= A + C - 10
        cont = cont + 1;
        Y(cont,:) = x(i,:);
    elseif i <= A + C
        cont1 = cont1 + 1;
        Y_t(cont1,:) = x(i,:);
    elseif i <= A + C + N - 10

```

```

        cont = cont + 1;
        Y(cont,:) = x(i,:);
elseif i <= A + C + N
        cont1 = cont1 + 1;
        Y_t(cont1,:) = x(i,:);
end
end
%-----

```

Algoritmo LMS Utilizado

```

clear all

Normaliza

tic
eta = 0.0001           %coef. de aprendizagem
epMax = 20000         %numero de epocas maximo
nRep = 1              %numero de repeticoes
nAmos = 100          %numero de amostras
nTrei = size(Y,1)    %numero de elementos de treinamento
nTeste = nTrei+1     %numero onde inicia os elementos para o teste

for j= 1:nRep

    disp(j);
    %gerando o w inicial aleatoriamente

    w = (rand(1,7)-0.5) *0.5;

    Wd = w;           %carrega o valor do w aleatorio para o Wd que sera carregado
no Wa
    for k=1:epMax

        rv=rand(1,size(Y,1));           %gera o vetor para ser ordenado

        Y1=Y;
        for var=1:size(Y,1)             %codigo para embaralhar a matriz com
os valores de entrada
            for tes=1:size(Y,1)-1
                if rv(tes)>rv(tes+1)     %testa o elemento do vetor aleatorio
para a ordenação deste
                    %em ordem crescente e embaralhar as
saidas
                        gd=rv(tes+1);
                        gdm=Y1(tes+1,:);
                        rv(tes+1)=rv(tes);
                        Y1(tes+1,:)=Y1(tes,:);
                        rv(tes)=gd;
                        Y1(tes,:)=gdm(1,:);

```

```

        end
    end
end %fim do codigo de embaralhamento

for i=1:nTrei
    Wa = Wd;
    x=Y1(i,1:7); %vetor de entrada
    y=x*Wa'; %calculo da saida
    e=Y1(i,10)-y; %calculo do erro
    Wd=Wa+eta*e.*x; %calculo do novo valor de W
    E(i)=e; %Vetor que armazena os erros

end

EQM(j,k)=(E*E')/(2*size(E,2)); %calculo do erro
quadratico medio da epoca de treinamento
x=Y_t(:,1:7); %carregando a matriz
para realizar o teste %calculando o vetor de
saida
y=x*Wa';
y=sign(1+(sign(y-0.2)));

E=abs(Y_t(:,10)-y)'; %calculo do vetor
de erro do teste
% EQMtteste(j,k) = E*E'/(2*size(E,2)); %calculo do erro
quadratico medio do teste para a epoca
EQMtteste(j,k) = mean(E);

if k==1
    mEQMtteste(j)=EQMtteste(j,k); %armazena o menor erro
da epoca caso seja o primeiro
    Wme(j,1:7)=Wa(1,1:7); %armazena o w que
causou o menor erro
    mnep(j)=k; %armazena a repeti;ao
que ocorreu o menor EQM
else
    if mEQMtteste(j)>EQMtteste(j,k); %armazena o menor erro
da epoca
        Wme(j,1:7)=Wa(1,1:7); %armazena o w que
causou o menor erro
        mnep(j)=k; %armazena a repeti;ao
que ocorreu o menor EQM
    end
end
end
end

disp('*****Resultados Finais*****');

[a b] = min(EQM,[],2);
disp('***Treinamento***');
disp('EQM - Media Desvio-Padrao');

```

```

disp([mean(a) std(a)]);
disp('Epoca - Media      Desvio-Padrao');
disp([mean(b)          std(b)]);

[c d] = min(EQMteste,[],2);
disp('***Teste***');
disp('EQM - Media      Desvio-Padrao');
disp([mean(c) std(c)]);
disp('Epoca - Media      Desvio-Padrao');
disp([mean(d) std(d)]);

[EQMme posx] = min(mEQMteste);
menorW=Wme(posx,:);
%disp('menor EQM de teste = '); disp(a);
%disp('W que causou o menor EQM de teste = '); disp(Wme(b,:));
%disp('epoca onde ocorreu o menor EQM = '); disp(mnep(b));
%disp('repeticao onde ocorreu o menor EQM = '); disp(b);
duracao = toc
RR_temp = fopen('saida_LMS.txt','a');          %Abre o arquivo para gravação.
fprintf(RR_temp,'%1f      %1f      %1f      %1f      %1f\n',eta,epMax,nRep,duracao,EQMme,menorW);          %Grava o valor RR no
arquivo.
fclose(RR_temp);          %Fecha o arquivo de gravação.

figure();
subplot(2,1,1);plot(EQM');
title(['Grafico dos EQMs, duração =',num2str(duracao),'s']);
xlabel('Epoca');
ylabel('EQM');
%legend('Rep=1','Rep=2','Rep=3','Rep=4','Rep=5','Rep=6','Rep=7','Rep=8','Re
p=9','Rep=10');

subplot(2,1,2);plot([mean(EQM,1);mean(EQMteste,1)]');
title(['Grafico das medias dos EQMs de Treinamento e de Teste , epMax =
',num2str(epMax),' , eta = ',num2str(eta),' , nRep = ',num2str(nRep)]);
xlabel('Epoca');
ylabel('EQM');
legend('Treinamento','Teste');

%subplot(2,2,4);plot()
%title('Grafico da media dos EQMs de Teste');
%xlabel('Epoca');
%ylabel('EQMteste medio');

```

Algoritmo backpropagation Utilizado

```

function [EQM,EQM_t] =
back(arquivo,alfa,a,b,eta,epMax,repMax,m1,pTrei,n_saidas)
%Back_Lebres_australianas
str = [arquivo '.txt']; %Junta o nome do arquivo com o Formato
Dados = textread(str)'; %Carrega os dados do arquivo na variavel dados
nTrei = round((pTrei/100)*size(Dados,2)); %calcula o numero de dados para
o grupo de Treinamento
nTest = size(Dados,2)-nTrei; %calcula o numero de dados para o grupo de
Teste
EQM_min = 9999;
%Normalizacao dos dados
[Max] = max(Dados,[],2); %Armazena os maximos para desnormalizacao

for i=1:size(Dados,1)
    Dados(i,:) = Dados(i,+)/Max(i,:);%Normaliza os dados da Entrada
end

for rep = 1:repMax,
tempo = toc;
disp([num2str(rep) ' --> Tempo = ' num2str(tempo) ' segundos']);
[Dados]=embaralha(Dados); % Embaralha os dados para nao viciar a rede
x = [ones(1,nTrei); Dados(1:(size(Dados,1)-n_saidas),1:nTrei)]; %Coloca as
entradas de Treinamento na variavel x
x_t = [ones(1,nTest); Dados(1:(size(Dados,1)-
n_saidas),nTrei+1:size(Dados,2))];%Coloca as entradas de Teste na variavel
x_t
d = Dados((size(Dados,1)-n_saidas+1):size(Dados,1),1:nTrei); %Coloca as
saidas desejadas de Treinamento na variavel d
d_t = Dados((size(Dados,1)-
n_saidas+1):size(Dados,1),nTrei+1:size(Dados,2));%Coloca as saidas
desejadas de Teste na variavel d_t

W1_d= 0.5*rand(m1,size(x,1))-0.25;%Calculo aleatorio do W1 inicial da
repeticao
W2_d= 0.5*rand(size(d,1),m1+1)-0.25;%Calculo aleatorio do W2 inicial da
repeticao

for ep=1:epMax
    W1_a = W1_d;
    W2_a = W2_d;

    for i=1:size(x,2),
        v1 = W1_d*x(:,i); %Calculo das entradas dos neuronios da Camada
oculta 1
        Y1(2:m1+1,i)=((a*tanh(b*v1))/2)+0.5); %Calculo das saidas dos
neuronios da Camada oculta 1
        Y1(1,i)=1;

```

```

        v2 = W2_d*Y1(:,i); %Calculo da entrada do neuronio da Camada de
saida
        Y(i) = ((a*tanh(b*v2))/2)+0.5); %Calculo da saida do neuronio da
Camada de saida
        e(i) = d(i)-Y(i); %Calculo do erro de treinamento (desejado -
obtido)
        delta2 = e(i)*(b/a)*(a-Y(i))*(a+Y(i));
        delta1 = (b/a)*((a-
Y1(2:m1+1,i)).*(a+Y1(2:m1+1,i))).*(W2_d(2:m1+1))'*delta2);

        W1_a2 = W1_a; %guarda os pesos da camada oculta 1 da epoca
anterior
        W1_a = W1_d; %guarda os pesos da camada oculta 1 desta epoca
        W2_a2 = W2_a; %guarda os pesos da camada de saida da epoca
anterior
        W2_a = W2_d; %guarda os pesos da camada de saida desta epoca
        W1_d = W1_a + (alfa*(W1_a-W1_a2)) + (eta*(delta1*x(:,i)'));
%Calcula os pesos da camada oculta 1 para a proxima epoca
        W2_d = W2_a + (alfa*(W2_a-W2_a2)) + (eta*(delta2*Y1(:,i)'));
%Calcula os pesos da camada de saida para a proxima epoca

    end

    EQM(rep,ep) = (e*e')/(2*size(e,2)); %Calculo do EQM de treinamento
    for i=1:size(x_t,2),
        v1 = W1_d*x_t(:,i); %Calculo das entradas dos neuronios da Camada
oculta 1
        Y1(2:m1+1,i) = ((a*tanh(b*v1))/2)+0.5); %Calculo das saidas dos
neuronios da Camada oculta 1
        Y1(1,i)=1;
        v2 = W2_d*Y1(:,i); %Calculo da entrada do neuronio da Camada de
saida
        Y(i) = ((a*tanh(b*v2))/2)+0.5); %Calculo da saida do neuronio
da Camada de saida
        e_t(i) = d_t(i)-Y(i); %Calculo do erro de teste (desejado -
obtido)
    end
    EQM_t(rep,ep) = (e_t*e_t')/(2*size(e_t,2)); %Calculo do EQM de TESTE
    if EQM_min > EQM_t(rep,ep)
        EQM_min = EQM_t(rep,ep); %armazena o menor EQM de Teste
        W1_f = W1_d;%W1rep(:, :, ep); %armazena os pesos da camada oculta 1
que teve o menor EQM
        W2_f = W2_d;%W2rep(ep, :); %armazena os pesos da camada de saida que
teve o menor EQM
    end
end
end
end

```

APÊNDICE B – Gráficos Gerados nos Treinamentos e Testes das Redes




Figura 33: Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 1




Figura 34: Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 2




Figura 35: Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 4

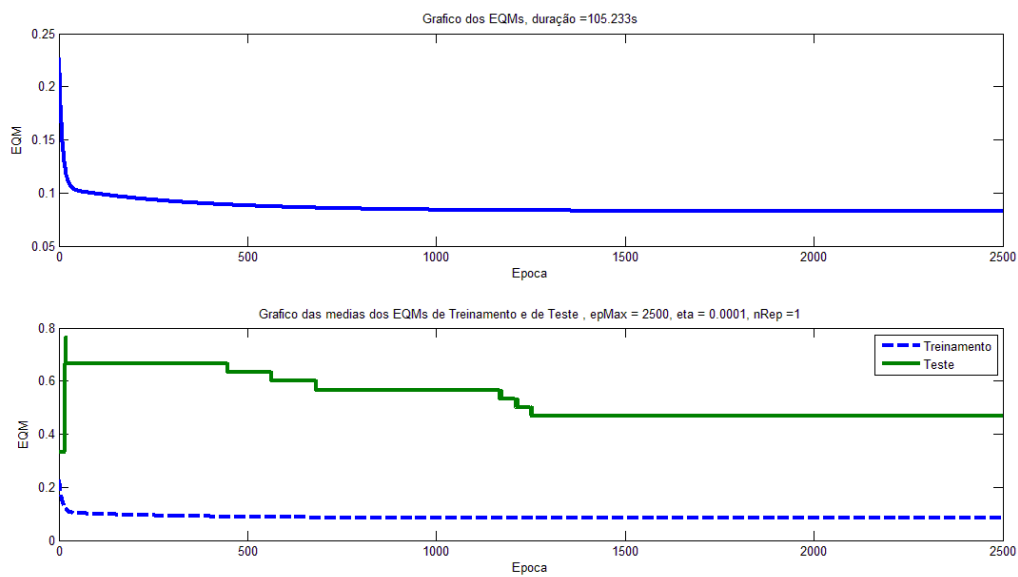


Figura 36: Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 5




Figura 37: Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 6




Figura 38: Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 7




Figura 39: Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 9




Figura 40: Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 10




Figura 41: Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 11




Figura 42: Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 13




Figura 43: Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 14




Figura 44: Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 15




Figura 45: Treinamento e teste para o diagnóstico de pessoas saudáveis, com a rede 16

Treinamento para Diagnóstico de Pessoas com Insuficiência Cardíaca Congestiva.

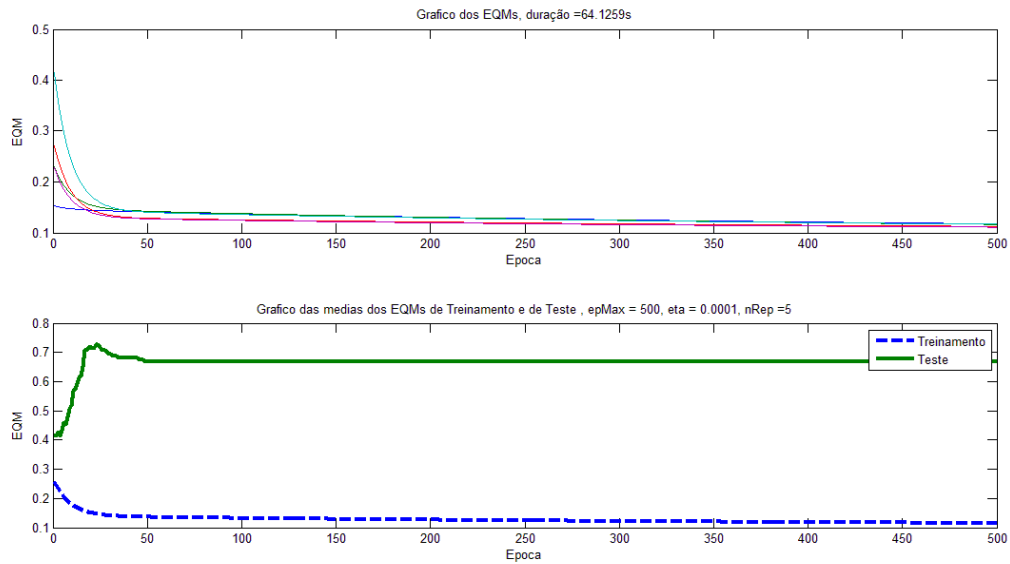


Figura 46: Treinamento e teste para o diagnóstico de insuficiência cardíaca congestiva, com a rede 3




Figura 47: Treinamento e teste para o diagnóstico de insuficiência cardíaca congestiva, com a rede 8




Figura 48: Treinamento e teste para o diagnóstico de insuficiência cardíaca congestiva, com a rede 17

Treinamento para Diagnóstico de Pessoas com Arritmia Cardíaca.




Figura 49: Treinamento e teste para o diagnóstico de Arritmia cardíaca, com a rede 3




Figura 50: Treinamento e teste para o diagnóstico de Arritmia cardíaca, com a rede 8




Figura 51: Treinamento e teste para o diagnóstico de Arritmia cardíaca, com a rede 12.

APÊNDICE C – Tabelas Geradas nos Treinamentos e Testes das Redes

Tabelas do treinamento das redes de 1 camada oculta com algoritmo backpropagation

Tabela 29: Tabela com parâmetros do teste da variável de momento

Treinamento	α	η	η^2	$epMa_x$	nRep	m1	pTrei
1	0.7	0.1	0.01	6000	10	100	80
2	0.7	0.1	0.01	6000	25	50	80
3	0.7	0.1	0.01	6000	10	25	80
4	0.7	0.1	0.01	6000	25	100	80
5	0.7	0.1	0.001	6000	10	100	80
6	0.7	0.1	0.01	6000	10	100	80
7	0.7	0.1	0.01	6000	25	50	80
8	0.7	0.1	0.01	6000	10	25	80
9	0.7	0.1	0.01	6000	25	100	80
10	0.7	0.1	0.001	6000	10	100	80
11	0.5	0.1	0.01	6000	10	100	80
12	0.5	0.1	0.01	6000	25	50	80
13	0.5	0.1	0.01	6000	10	25	80
14	0.5	0.1	0.01	6000	25	100	80

Tabela 30:Tabela com parâmetros do teste da variável de momento (cont...)

Treinamento	α	η	η^2	$\frac{epMa}{x}$	nRep	m1	pTrei
15	0.5	0.1	0.001	6000	10	100	80
16	0.5	0.1	0.01	6000	10	100	80
17	0.5	0.1	0.01	6000	25	50	80
18	0.5	0.1	0.01	6000	10	25	80
19	0.5	0.1	0.01	6000	25	100	80
20	0.5	0.1	0.001	6000	10	1000	80

Tabela 31: Tabela com os resultados dos treinamentos com os parâmetros da tabela 22

Treinamento	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
1	0,086509	0,005075	2930	1989	0,069679	0,011875	2400	2367	18,1554	1,19765	2037	1904	446
2	0,083408	0,007924	3278	2310	0,084352	0,019801	1913	1945	20,4153	1,995948	1505	1351	984
3	0,085551	0,003182	2800	1641	0,073083	0,016235	2165	2070	18,9318	1,629864	1786	1677	409
4	0,085013	0,008409	2657	2398	0,084006	0,019176	1831	2082	20,3182	1,934418	1425	1265	1340
5	0,088608	0,006923	3901	1943	0,082663	0,034898	3408	2217	21,7561	3,503646	2973	2843	452
6	0,084996	0,004982	2682	2457	0,084478	0,020852	2902	2368	20,533	2,095164	2491	2328	451
7	0,088417	0,007709	2584	2150	0,076871	0,022319	2655	2244	19,919	2,247318	2257	2113	890
8	0,085223	0,007346	2649	1913	0,086738	0,01815	2829	2461	20,4888	1,829692	2419	2292	303
9	0,08705	0,007578	3055	2306	0,082373	0,019466	1815	1922	20,1839	1,961756	1411	1258	1122
10	0,087245	0,008111	2638	2614	0,083358	0,018071	1885	2344	20,1429	1,823322	1482	1308	448
11	0,081323	0,01695	4601	1749	0,090413	0,012694	2274	2092	18,61152	2,327757	1794	1703	519
12	0,086214	0,027725	4805	2268	0,103675	0,016847	1699	1495	21,34325	3,113276	2015	1509	1065
13	0,078407	0,019417	4738	2263	0,106908	0,016678	1993	1804	22,44892	2,6202	2017	1783	485
14	0,087773	0,027585	4614	2133	0,099382	0,017136	1633	1430	20,7337	3,274759	1818	1418	1421
15	0,085247	0,041821	4817	2394	0,111894	0,022421	3195	2977	25,60189	4,638989	1766	2338	539
16	0,082276	0,025834	4649	2137	0,101889	0,017033	2728	2523	21,62276	3,560063	1982	1978	534
17	0,086062	0,030028	4609	1907	0,108039	0,016906	2481	2282	25,30545	3,410448	2192	2009	970
18	0,086008	0,025496	4488	2316	0,105135	0,017495	2665	2460	21,71344	3,037388	1990	2042	385
19	0,086941	0,027044	4680	2169	0,101254	0,016798	1604	1402	21,73432	3,499528	2015	1435	1202
20	0,087571	0,026182	5143	1916	0,112322	0,022286	1717	1515	21,26827	2,924809	1595	1344	529

Tabela 32: Resultados do treinamento após a escolha da valor da constante de momento

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
1	0,072463	0,004537	4841	1513	0,067401	0,011506	3789	1749	16,21622	4,934437	1131	1501	490
2	0,071173	0,00496	4996	1354	0,073941	0,014867	3904	2268	17,35135	5,650537	1245	1667	2502
3	0,070366	0,004496	4954	1343	0,0768	0,015054	3647	2263	19,18919	5,586642	1470	1889	4883
4	0,072043	0,00556	4797	1569	0,068946	0,015218	3840	2133	16,86487	4,951678	1019	1572	983
5	0,070955	0,007716	5158	1446	0,074032	0,018931	3269	2394	18,5946	6,701706	1118	1833	1971
6	0,071401	0,007105	4939	1508	0,071993	0,014948	3494	2137	17,43243	5,676716	1163	1628	3906
7	0,072312	0,011196	4874	2012	0,073249	0,014674	2298	1907	16,2907	4,949111	1475	1905	341
8	0,070644	0,008481	4771	1775	0,073775	0,01568	3188	2316	18,05405	5,815651	1352	1792	1710
9	0,071316	0,008749	4861	1665	0,071552	0,014851	3735	2169	17,81081	6,03848	1246	1612	3442
10	0,071785	0,005741	5331	957	0,071364	0,020479	4065	1916	17,62162	7,688861	724	1380	1226
11	0,071349	0,004194	5148	1221	0,072125	0,013633	3999	2103	17,94595	5,507437	1050	1681	3670
12	0,071591	0,005848	4879	1466	0,07448	0,015923	3595	2271	18,57297	6,197196	1280	1857	6135

Tabela 33: Resultado do novo teste com as redes 1 e 7

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
1	0,07498	0,001699	5351	1110	0,051063	0,003945	4100	2117	9,333333	2,629369	1346	1852	486
7	0,076963	0,007759	5190	1449	0,051137	0,006707	3831	2257	10,66667	3,688556	645	1314	350
1	0,075646	0,006082	5120	1361	0,050371	0,006113	4355	1923	10,5	3,711692	711	1401	478
7	0,074815	0,005825	4920	1363	0,052348	0,009985	4211	1900	10,66667	5,853141	707	1508	328
1	0,077194	0,008038	4762	1601	0,050931	0,009825	4239	1845	11,53333	5,602478	667	1391	482
7	0,075654	0,006498	4771	1716	0,051114	0,008541	4082	1911	10,93333	3,966187	696	1500	324
1	0,080447	0,012314	4218	2046	0,054085	0,014934	3334	2211	13,73333	7,726622	812	1602	497
7	0,076174	0,00879	5032	2060	0,048302	0,00426	3709	1889	9,333333	3,784308	640	1131	319
1	0,076464	0,008474	4414	1765	0,050391	0,014945	3801	1987	11,23333	6,643985	550	1211	480
7	0,076191	0,005407	4921	1662	0,047894	0,00211	4020	2317	10,66667	2,721655	557	1000	343
1	0,07646	0,007877	5029	1482	0,051599	0,010504	4412	1931	11,28889	4,710646	689	1424	476
7	0,076251	0,006111	5213	1372	0,050359	0,007194	4578	1728	10,66667	4,233338	724	1421	335

Tabela 34: Teste com os dados de insuficiência cardíaca congestiva

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
1	0,083352	0,006661	3489	2332	0,065929	0,001924	3988	2341	18,5	1,229775	47	87	789,8504
7	0,077098	0,010425	4280	2137	0,064631	0,00407	4088	2461	17,83333	0,805076	1142	1766	544,8664
1	0,084377	0,010544	4259	2556	0,072344	0,012791	3535	2459	19,16667	4,859127	1265	1936	830,8575
7	0,085844	0,014222	3486	2614	0,065618	0,003614	2882	2198	17	2,194269	1342	1796	525,6434
1	0,078751	0,00113	5475	1406	0,070956	0,00259	5447	1205	17,83333	1,765583	1007	1499	774,1401
7	0,076297	0,003417	4895	1783	0,070794	0,004101	4377	2034	18,66667	1,314684	1689	2390	524,9726
1	0,076818	0,001366	4233	2089	0,08098	0,001894	1131	930	22,33333	2,249829	871	1227	761,5222
7	0,07246	0,002381	5382	981	0,072745	0,005081	3033	1889	18,83333	4,377975	2429	1991	514,6723
1	0,07135	0,003878	2378	1679	0,090284	0,002767	651	1672	26,66667	1,756821	897	1220	763,0554
7	0,0679	0,003207	5070	1668	0,089672	0,003098	1407	1271	25,16667	2,881401	1002	744	538,9125
1	0,072977	0,003376	4904	2157	0,08468	0,003301	2719	2218	21,83333	2,144473	852	1694	753,323
7	0,069645	0,002324	5185	1743	0,084228	0,005503	2695	2163	22,66667	2,509242	865	1820	509,2615
1	0,087545	0,010291	2868	2626	0,061246	0,005363	1895	1891	14,33333	1,405457	2905	1240	750,513
7	0,090034	0,013994	3260	2717	0,065905	0,011438	1317	1780	18,66667	7,149204	924	1829	504,2001
1	0,077399	0,001693	5386	1463	0,078035	0,001354	1689	2015	19,5	2,229156	364	846	748,6872
7	0,070961	0,003673	4695	1700	0,077525	0,00245	1523	1183	17,83333	1,765583	1115	1589	505,6778
1	0,075022	0,004976	4157	2412	0,076791	0,002817	2363	2257	20,83333	2,256677	840	1310	758,1181
7	0,07044	0,002149	5687	730	0,073775	0,002288	2786	2026	19,16667	1,416394	1305	1716	510,0202
1	0,077074	0,002701	3017	2318	0,076527	0,003703	2082	2090	21,33333	1,721326	373	564	755,8123
7	0,072205	0,002572	4411	1844	0,072565	0,002584	3949	2038	18,66667	0,702728	1425	1051	510,95

Tabela 35: Teste com os dados de arritmia cardíaca

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
1	0,08664	0,009851	3309	2563	0,067438	0,008766	3430	2855	20,16667	4,871814	577	835	762,9675
7	0,08413	0,013681	3405	2516	0,064334	0,013448	1996	1649	17,33333	5,223404	1503	1681	535,4805
1	0,078338	0,00124	2598	2379	0,075079	0,004269	4853	1710	19,5	1,581139	1641	2235	759,4803
7	0,074569	0,004317	5541	969	0,06932	0,003897	4794	1829	16	2,108185	1351	1902	547,4947
1	0,067128	0,004862	4136	1830	0,089588	0,002005	647	1294	22	4,288946	1169	2026	765,5262
7	0,066507	0,002506	3900	1648	0,091674	0,00206	1070	2030	21,83333	4,808044	330	902	515,7372
1	0,076306	0,001043	4324	1948	0,081939	0,000945	300	876	23,16667	1,459325	277	420	759,0662
7	0,070848	0,003605	5084	1045	0,080273	0,00388	1464	2186	21,66667	2,222222	1070	1418	514,3622
1	0,073305	0,002938	4317	1986	0,084439	0,007049	2431	2694	22,16667	1,932503	951	1755	760,385
7	0,071623	0,004291	5010	1585	0,081555	0,005128	2205	2655	21	1,165343	1019	1202	510,2719
1	0,080152	0,008598	3724	2424	0,074465	0,004805	2114	2057	18,83333	2,838231	739	1245	760,4189
7	0,076395	0,009025	5403	1887	0,072465	0,007532	2627	1777	18,66667	4,430534	560	1365	513,6025
1	0,078446	0,001558	4261	2313	0,07596	0,003809	1130	1675	17,33333	2,108185	1027	1636	757,3689
7	0,073684	0,002242	6000	0	0,071939	0,001562	4590	2042	17,5	1,964186	1440	1807	536,2496
1	0,072888	0,001384	4015	2347	0,094771	0,002234	2593	2614	26,83333	0,946077	597	794	763,9899
7	0,070198	0,001553	6000	0	0,091429	0,003461	3880	2777	25,16667	1,229775	1194	1325	515,5171
1	0,075051	0,002919	4807	1818	0,080759	0,005215	3981	2074	21,83333	3,804643	1123	1772	765,4191
7	0,072335	0,002489	4770	1921	0,077704	0,004894	4506	2271	19,33333	3,063122	1059	1781	513,7587
1	0,072074	0,004096	5003	1450	0,077475	0,002035	1763	2380	20,66667	2,108185	640	921	766,7901
7	0,068988	0,003288	4902	1730	0,077635	0,004929	1612	1874	20	2,721655	273	585	518,7255

Tabelas do treinamento das redes de 2 camadas ocultas com algoritmo backpropagation

Tabela 36: Parâmetros do primeiro treinamento com o backpropagation de duas camadas

Treinamento				epMax	nRep	m1	pTrei	m2
1	0.7	0.1	0.01	6000	10	100	80	10
2	0.7	0.1	0.01	6000	50	100	80	10
3	0.7	0.1	0.01	6000	100	100	80	10
4	0.7	0.1	0.01	6000	25	50	80	10
5	0.7	0.1	0.01	6000	50	50	80	10
6	0.7	0.1	0.01	6000	100	50	80	10
7	0.7	0.1	0.01	6000	10	25	80	10
8	0.7	0.1	0.01	6000	50	25	80	10
9	0.7	0.1	0.01	6000	100	25	80	10
10	0.7	0.1	0.01	6000	25	100	80	10
11	0.7	0.1	0.01	6000	75	100	80	10
12	0.7	0.1	0.01	6000	125	100	80	10
13	0.7	0.1	0.001	6000	10	100	80	10
14	0.7	0.1	0.001	6000	50	100	80	10
15	0.7	0.1	0.001	6000	100	100	80	10
16	0.7	0.1	0.001	6000	25	50	80	10
17	0.7	0.1	0.001	6000	50	50	80	10

Tabela 37: Parâmetros do primeiro treinamento com o backpropagation de duas camadas(cont...)

Treinamento				epMax	nRep	m1	pTrei	m2
18	0.7	0.1	0.001	6000	100	50	80	10
19	0.7	0.1	0.001	6000	10	25	80	10
20	0.7	0.1	0.001	6000	50	25	80	10
21	0.7	0.1	0.001	6000	100	25	80	10
22	0.7	0.1	0.001	6000	25	100	80	10
23	0.7	0.1	0.001	6000	75	100	80	10
24	0.7	0.1	0.001	6000	125	100	80	10
32	0.7	0.1	0.001	12000	50	25	80	10
33	0.7	0.1	0.001	12000	100	25	80	10
34	0.7	0.1	0.001	12000	25	100	80	10
35	0.7	0.1	0.001	12000	75	100	80	10
73	0.7	0.1	0.01	6000	10	100	80	25
74	0.7	0.1	0.01	6000	50	100	80	25
75	0.7	0.1	0.01	6000	100	100	80	25
76	0.7	0.1	0.01	6000	25	50	80	25
77	0.7	0.1	0.01	6000	50	50	80	25
78	0.7	0.1	0.01	6000	100	50	80	25
79	0.7	0.1	0.01	6000	10	25	80	25
80	0.7	0.1	0.01	6000	50	25	80	25
81	0.7	0.1	0.01	6000	100	25	80	25
82	0.7	0.1	0.01	6000	25	100	80	25

Tabela 38: Parâmetros do primeiro treinamento com o backpropagation de duas camadas(cont...)

Treinamento				epMax	nRep	m1	pTrei	m2
83	0.7	0.1	0.01	6000	75	100	80	25
84	0.7	0.1	0.01	6000	125	100	80	25
85	0.7	0.1	0.001	6000	10	100	80	25
86	0.7	0.1	0.001	6000	50	100	80	25
87	0.7	0.1	0.001	6000	100	100	80	25
88	0.7	0.1	0.001	6000	25	50	80	25
89	0.7	0.1	0.001	6000	50	50	80	25
90	0.7	0.1	0.001	6000	100	50	80	25
91	0.7	0.1	0.001	6000	10	25	80	25
92	0.7	0.1	0.001	6000	50	25	80	25
93	0.7	0.1	0.001	6000	100	25	80	25
94	0.7	0.1	0.001	6000	25	100	80	25
95	0.7	0.1	0.001	6000	75	100	80	25
145	0.7	0.1	0.01	6000	10	100	80	50
146	0.7	0.1	0.01	6000	50	100	80	50
147	0.7	0.1	0.01	6000	100	100	80	50
148	0.7	0.1	0.01	6000	25	50	80	50
149	0.7	0.1	0.01	6000	50	50	80	50
150	0.7	0.1	0.01	6000	100	50	80	50
151	0.7	0.1	0.01	6000	10	25	80	50
152	0.7	0.1	0.01	6000	50	25	80	50

Tabela 39: Parâmetros do primeiro treinamento com o backpropagation de duas camadas(cont...)

Treinamento				epMax	nRep	m1	pTrei	m2
153	0.7	0.1	0.01	6000	100	25	80	50
154	0.7	0.1	0.01	6000	25	100	80	50
155	0.7	0.1	0.01	6000	75	100	80	50
156	0.7	0.1	0.01	6000	125	100	80	50
157	0.7	0.1	0.001	6000	10	100	80	50
158	0.7	0.1	0.001	6000	50	100	80	50
159	0.7	0.1	0.001	6000	100	100	80	50
160	0.7	0.1	0.001	6000	25	50	80	50
161	0.7	0.1	0.001	6000	50	50	80	50
162	0.7	0.1	0.001	6000	100	50	80	50
163	0.7	0.1	0.001	6000	10	25	80	50
164	0.7	0.1	0.001	6000	50	25	80	50
165	0.7	0.1	0.001	6000	100	25	80	50
166	0.7	0.1	0.001	6000	25	100	80	50
167	0.7	0.1	0.001	6000	75	100	80	50
168	0.7	0.1	0.001	6000	125	100	80	50

Tabela 40: Resultados do treinamento com os parâmetros da Tabela 28

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
1	0,069509	0,017955	4249	1948	0,050809	0,007716	3683	2051	9,166667	1,964186	2702	2241	1614,18
2	0,06258	0,017361	4734	1568	0,050339	0,009382	3945	1531	9,566667	2,177237	2420	1743	8091,331
3	0,069379	0,019068	4067	1752	0,050005	0,007573	3829	1802	9,316667	1,608322	2333	1749	16058,48
4	0,069781	0,023242	4274	2005	0,046933	0,004843	3957	1719	9	1,360828	2341	1858	3668,428
5	0,065884	0,022997	3892	1981	0,050575	0,01249	4005	1846	9,466667	3,166577	1977	1837	6964,869
6	0,068383	0,022984	3913	1957	0,049078	0,008169	3808	1894	9,25	1,57803	2309	1870	13843,01
7	0,074524	0,021887	3463	2308	0,050675	0,012904	3502	1832	8,833333	1,765583	2521	1571	1292,384
8	0,067885	0,023413	3977	1862	0,049125	0,006782	3480	1860	9	1,874764	2538	1972	6455,107
9	0,074661	0,022436	3577	2037	0,05163	0,012696	3563	2137	9,916667	3,344887	2148	1955	12892,74
10	0,069719	0,01888	3740	1643	0,04889	0,005752	3873	1983	9,2	1,674979	2766	1999	4085,92
11	0,067318	0,019786	4221	1618	0,049746	0,010757	3951	1802	9,377778	3,13334	2620	1947	12149,28
12	0,068877	0,019329	3962	1667	0,050274	0,009789	3842	1749	9,333333	2,116669	2427	1767	20160,76
1	0,054665	0,016058	4821	1134	0,05324	0,009731	3942	2116	11,66667	3,513642	4175	2048	1611,645
2	0,061044	0,018876	4035	1881	0,058746	0,010307	4266	1556	12,4	3,452956	3181	1874	8295,52
3	0,059601	0,017357	4268	1561	0,058741	0,011269	3925	1467	12,5	3,896097	3527	1629	17767,15
4	0,067541	0,022824	4555	1557	0,063678	0,00971	3310	1683	13,66667	3,90868	3539	1748	3810,368
5	0,060927	0,020457	4297	1722	0,0567	0,007895	4184	1336	12,03333	3,054494	3508	1601	7652,034
6	0,055499	0,016843	4470	1391	0,059153	0,009825	4268	1578	12,71667	3,727947	3550	1954	15021,54
7	0,076392	0,026637	3301	2102	0,064819	0,008676	3260	1957	13,16667	2,881401	2958	1701	1285,343
73	0,061828	0,020969	5542	622	0,05058	0,009969	4312	1511	10,66667	3,784308	3454	1574	1941,77
74	0,061298	0,016443	4635	1470	0,054664	0,009721	4356	1505	11,76667	3,254336	3468	1737	9478,371

Tabela 41: Resultados do treinamento com os parâmetros da Tabela 28 (cont...)

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
75	0,061323	0,019307	4952	1097	0,053899	0,010534	4416	1506	11,76667	3,480102	3657	1741	19109,06
76	0,061789	0,019216	4324	1898	0,055466	0,012446	4188	1534	12,4	3,602982	3472	1887	3832,148
77	0,061554	0,020147	4782	1592	0,055241	0,010077	4149	1671	11,8	3,464102	3174	1949	7628,179
78	0,062758	0,020007	4569	1849	0,054069	0,009607	4065	1629	11,86667	3,027002	3068	1882	15213,75
79	0,068071	0,022262	3829	2148	0,058053	0,012205	3433	2138	12,33333	4,458312	3153	2239	1340,672
80	0,06741	0,022151	4345	2058	0,05621	0,011383	4075	1861	12,2	3,617794	3272	1960	6735,419
81	0,068006	0,022526	3869	2151	0,056135	0,01211	3734	1812	11,91667	4,008794	2919	1805	13548,87
82	0,060851	0,018231	5284	953	0,054156	0,010325	4351	1643	11,93333	3,391165	3415	1763	4751,35
83	0,064004	0,018597	4809	1469	0,055696	0,012064	4138	1702	12,35556	3,583971	3219	1873	14358,62
84	0,061412	0,016994	4788	1530	0,05589	0,010813	4391	1583	12,34667	2,99414	3370	1789	24367,2
73	0,053634	0,007241	5160	836	0,066659	0,00485	4330	1756	14,83333	2,772217	3719	1938	2087,139
74	0,053092	0,022886	5144	1253	0,066703	0,008081	3804	1745	15,43333	3,34708	3016	2030	10394,27
75	0,047154	0,017052	5041	1095	0,066779	0,008846	3729	1927	14,95	3,269206	3266	2049	20875,86
76	0,054913	0,022519	5284	1224	0,068508	0,009609	3467	1883	15,73333	3,33611	3122	2051	4068,952
77	0,053377	0,019477	4628	1527	0,068019	0,009318	3888	1825	15,7	4,027823	2654	2177	7643,297
145	0,062792	0,021377	4755	1603	0,059938	0,003322	3806	1681	14,83333	1,834175	2824	1395	2325,284
146	0,059325	0,023632	4303	1829	0,057092	0,008766	3632	1870	13,3	2,392591	3086	2132	11590,86
147	0,059356	0,023603	4678	1672	0,057652	0,008083	4051	1779	13,31667	2,857394	3349	2102	23331,71
148	0,052119	0,018662	5108	1286	0,056817	0,007388	4471	1473	14,2	3,159348	2904	2288	4427,875
149	0,057418	0,024092	4741	1618	0,057189	0,00975	4360	1565	13,26667	2,585499	3334	2029	8825,929
150	0,057337	0,024853	4817	1789	0,056578	0,008648	3855	1713	13,26667	2,594131	2836	2122	17586,01

Tabela 42: Resultados do treinamento com os parâmetros da Tabela 28 (cont...)

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
151	0,047527	0,011329	5120	962	0,054274	0,007546	3863	2011	13,33333	2,078699	3875	1621	1471,847
152	0,071343	0,028478	3372	2397	0,058504	0,009979	3593	1867	13,03333	2,94873	2827	1995	7432,354
153	0,060201	0,026456	4214	1982	0,057841	0,008786	4049	1750	13,38333	2,523237	2914	1887	14954,85
154	0,048493	0,019622	5184	1321	0,05524	0,010146	4408	1273	12,53333	2,851251	3174	1779	5791,022
155	0,059171	0,021361	4863	1340	0,05749	0,008527	4018	1614	13,57778	2,735779	2937	1899	17562,88
156	0,058213	0,023202	4768	1587	0,056951	0,008909	3766	1690	13,41333	3,036929	3132	2023	31670,72
145	0,064472	0,026653	3920	2214	0,057577	0,010954	2523	2084	11,5	2,539807	2316	1591	2580,376
146	0,062928	0,023594	4198	1720	0,053463	0,00671	3373	1528	10,8	2,656443	1705	1610	12412,46
13	0,063841	0,025719	4885	1804	0,058667	0,00681	3697	1809	14,16667	1,800206	1737	2068	1572,369
14	0,061789	0,01992	5041	1358	0,060548	0,005231	4050	1883	15,2	2,119984	1721	1969	8004,804
15	0,06198	0,018053	4958	1695	0,060668	0,004764	3547	1708	15,25	2,313468	1946	1936	16040,56
16	0,071492	0,021076	4684	2020	0,061675	0,004655	3607	1828	14,93333	2,229848	2209	2176	3504,363
17	0,065785	0,023284	4605	2140	0,061792	0,008433	3453	1857	15,3	2,770307	2168	1999	6893,936
18	0,064381	0,022615	5086	1534	0,059253	0,007166	3621	1894	14,53333	2,853316	1993	1962	13812,83
19	0,052237	0,019303	5590	723	0,05615	0,005916	3857	1180	13,16667	3,282012	3031	1911	1264,44
20	0,072793	0,020498	4652	1912	0,060724	0,004427	3311	1745	15,2	2,809927	1674	1912	6301,558
21	0,065356	0,020719	4708	1877	0,060622	0,006578	2833	2038	14,7	2,65253	1550	1607	12607,46
22	0,063355	0,020605	5251	1684	0,060097	0,00764	3931	1619	14,8	2,649249	1884	2011	4010,215
23	0,060623	0,019813	5231	1401	0,060617	0,006275	3246	1810	15,24444	2,134609	2246	1992	12008,65
24	0,062029	0,01988	5173	1503	0,059553	0,006338	3782	1817	15,22667	2,696938	1861	1897	19785,32
13	0,069487	0,02738	5657	344	0,052218	0,002817	3848	1832	11,5	1,229775	1856	1343	1593,476

Tabela 43: Resultados do treinamento com os parâmetros da Tabela 28 (cont...)

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
14	0,0701	0,021667	4686	1972	0,052283	0,008828	3595	1862	11,23333	2,470001	2163	1864	8392,831
15	0,069853	0,023616	4829	1715	0,050441	0,007692	3994	1712	10,98333	2,223421	2238	1944	15873,72
16	0,07564	0,022047	4110	2386	0,053213	0,006375	3533	2177	12,26667	3,076193	2120	1966	3320,608
17	0,073388	0,024832	4646	2022	0,050648	0,011401	3150	1924	11,06667	4,037242	1948	1852	6631,331
18	0,065828	0,024186	4901	1885	0,048965	0,006359	3714	2013	10,66667	2,518172	2489	2031	13284,06
19	0,084529	0,016923	3694	2148	0,050385	0,006466	2192	1832	12,16667	3,04797	851	1297	1209,789
20	0,078775	0,026474	3511	2518	0,050422	0,007064	3016	2017	10,93333	2,545727	2012	1761	6097,506
21	0,08122	0,022859	3392	2421	0,050647	0,012036	3131	2084	10,9	3,785939	1970	1788	12426,95
22	0,069665	0,022666	4422	2100	0,04945	0,007984	4287	1535	11	2,590939	2858	2050	3866,343
23	0,070545	0,02318	4537	1911	0,05126	0,008829	3708	1798	11,46667	2,820453	2344	1835	11559,05
24	0,068751	0,023383	4762	1768	0,051622	0,008673	3896	1858	11,10667	2,521805	2281	1878	20087,61
13	0,068714	0,019172	4753	1919	0,056996	0,007221	3579	1499	12,5	2,965855	2419	1367	1552,06
14	0,066258	0,018056	5350	1424	0,056031	0,006885	4216	1816	13,13333	3,310123	2830	1851	7749,791
15	0,069972	0,02151	4638	1995	0,05805	0,010799	4051	1727	13,75	3,361622	3134	1768	15435,72
16	0,072762	0,019279	4314	2394	0,05747	0,006566	4093	1840	14	3,435921	3361	1765	3319,081
17	0,066017	0,020348	4745	1980	0,055034	0,010472	4338	1750	13,2	4,243709	3303	1803	6642,786
18	0,067792	0,021713	4802	1967	0,055317	0,010396	4289	1647	12,4	3,555871	3576	1833	13311,51
19	0,080098	0,021205	2664	2720	0,059114	0,013	3136	2045	14,33333	4,021547	2642	2126	1295,21
20	0,074818	0,018848	4357	2368	0,063047	0,0154	3829	2065	15,33333	4,467063	2634	2027	6105,013
21	0,072985	0,020937	4344	2192	0,059707	0,011331	3742	1977	14,48333	4,052787	2785	1911	12203,87
22	0,071641	0,017608	4427	2180	0,055926	0,005406	4111	1396	12,86667	2,82679	3055	1517	3846,792

Tabela 44: Resultados do treinamento com os parâmetros da Tabela 28 (cont...)

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
23	0,0698	0,020375	4686	2126	0,057721	0,009111	4269	1412	13,42222	3,613178	3004	1740	11895,33
24	0,065428	0,019385	5043	1713	0,056164	0,008554	4106	1721	13,38667	3,503301	2933	1831	19596,67
32	0,061335	0,022964	10198	4320	0,063706	0,010167	5764	4279	8,833333	2,598769	4264	4629	12513,94
33	0,064656	0,022872	8667	4651	0,067543	0,018107	7621	3621	18,89107	4,696371	5024	4387	12484,64
34	0,05516	0,02833	9511	3436	0,071227	0,023612	7271	3728	18,17852	3,111342	3984	4001	12525,75
35	0,078718	0,007454	11424	1478	0,065915	0,025051	7423	3338	25,01582	2,241392	5483	3785	12571,88
32	0,064213	0,043963	9179	4371	0,065289	0,02352	5769	4279	10,76434	2,601326	4226	4778	12513,94
33	0,073556	0,031282	8975	4239	0,066879	0,025284	7580	3621	19,07721	4,696355	5005	4714	12484,64
34	0,075081	0,02213	9159	3428	0,066361	0,030208	7270	3728	17,69581	3,107155	3965	4175	12525,75
35	0,084618	0,015805	11424	1572	0,068368	0,028063	7432	3338	25,56383	2,243924	5505	3837	12571,88
85	0,057642	0,008784	6000	0	0,06094	0,002766	4319	1797	16,16667	1,932503	891	914	1913,165
86	0,059822	0,014887	5596	1039	0,061104	0,006439	3381	2110	15,63333	2,448795	1392	1844	9644,06
87	0,05864	0,01867	5425	1263	0,061344	0,009883	3502	1892	15,78333	2,757044	1532	1871	19406,11
88	0,057025	0,022262	5286	1431	0,060337	0,005578	3589	1985	14,73333	1,964971	2004	2104	3879,057
89	0,059544	0,020858	5177	1661	0,059966	0,005323	3198	2035	15,1	2,595347	1266	1568	7793,821
90	0,060311	0,022072	5050	1787	0,060456	0,006423	2975	2026	14,9	2,821077	1576	1802	15420,72
91	0,07106	0,02736	3640	2898	0,060665	0,005696	2558	2220	14,33333	1,791613	1725	1916	1361,422
92	0,065379	0,024008	4456	2300	0,060258	0,00811	3244	1987	14,8	3,060983	1782	2010	6823,074
93	0,066075	0,022876	4811	1918	0,061655	0,005484	2757	1908	15,13333	2,728657	1473	1720	13731,44
94	0,059318	0,018652	5279	1187	0,060448	0,004632	3732	1804	15,13333	2,0367	1307	1769	4845,51
95	0,056732	0,017534	5632	880	0,060733	0,005845	3112	1832	15,37778	2,549412	1578	1991	14332,7

Tabela 45: Resultados do treinamento com os parâmetros da Tabela 28 (cont...)

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
96	0,060145	0,017794	5344	1400	0,061211	0,005466	3438	1941	15,53333	2,353218	1381	1817	24464,66
85	0,057042	0,008635	5868	416	0,078486	0,006573	3143	2011	22,16667	3,244178	2061	2365	2017,406
86	0,056347	0,008479	5864	392	0,074993	0,006817	4582	1595	21,43333	3,176765	1950	2173	9350,923
87	0,053661	0,013928	5716	733	0,073075	0,009184	4412	1779	20,55	3,812783	2508	2131	18677,21
88	0,058484	0,020803	5416	1654	0,073398	0,009581	4588	1637	19,73333	4,185513	2297	2115	3731,904
89	0,057425	0,017459	5649	1243	0,07464	0,008061	4356	1924	20,4	3,817848	2234	2112	7472,871
90	0,058303	0,018976	5354	1456	0,073879	0,008132	4116	1904	20,31667	3,919039	1999	2118	15264,06
91	0,062152	0,004659	5788	672	0,079402	0,004531	3848	2176	24,33333	1,791613	367	867	1328,233
92	0,061925	0,016221	5408	1375	0,076437	0,007849	4132	2115	21,1	3,773791	1737	1781	6618,536
93	0,061215	0,016441	5178	1539	0,076285	0,007274	3728	2151	21,05	3,510886	1744	2090	13600,59
94	0,055707	0,012393	5721	666	0,07566	0,011355	4754	1604	21,8	3,260311	2411	2214	4975,62
95	0,058528	0,015111	5463	1310	0,074435	0,008964	4448	1828	20,93333	3,658057	2337	2145	14186,38
96	0,056028	0,011598	5686	912	0,075133	0,007116	4293	1895	21,08	3,105493	2324	2184	23377,38
85	0,059331	0,00722	5659	759	0,074196	0,003716	5334	1112	18,66667	2,581989	3552	1652	1877,404
86	0,059709	0,015966	5408	1338	0,073875	0,006379	4913	1254	18,36667	2,618831	3307	1714	9365,403
87	0,058726	0,01482	5506	1182	0,073285	0,006721	4802	1402	18,2	2,718354	2986	1653	18804,34
88	0,060815	0,019529	5192	2004	0,077368	0,006277	4528	1857	19,53333	2,701166	3359	1918	3723,69
89	0,061672	0,014866	5292	1703	0,074334	0,005937	4978	1577	19,16667	2,239868	3165	1834	7656,403
90	0,063113	0,020419	5018	1932	0,076399	0,009729	4591	1769	18,83333	2,695759	3039	1669	15424,32
91	0,059901	0,006218	5502	838	0,075651	0,004476	3943	1996	18,16667	2,539807	2194	1240	1335,979
92	0,062341	0,010089	5423	1348	0,076031	0,006125	4639	1641	19,16667	2,31455	3042	1336	6645,312

Tabela 46: Resultados do treinamento com os parâmetros da Tabela 28 (cont...)

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
93	0,064403	0,014069	5169	1653	0,075991	0,006246	4922	1578	19	2,392469	3300	1686	13146,29
94	0,060421	0,012819	5546	1198	0,075139	0,006917	5042	1407	18,66667	2,886751	3564	1950	4615,642
95	0,05999	0,012233	5572	1134	0,07497	0,00689	4786	1585	18,82222	2,723126	2990	1713	13817,93
96	0,05638	0,013052	5618	1081	0,074012	0,006295	4784	1543	18,50667	2,830517	3139	1727	23248,56
157	0,06826	0,016742	4727	1799	0,062626	0,00305	4314	1096	16,16667	2,363561	1413	1306	2336,956
158	0,063201	0,021645	5012	1920	0,060711	0,007726	2610	1930	15,26667	2,459652	1776	1988	11886,42
159	0,062462	0,021664	5098	1731	0,061737	0,005122	3180	2161	15,38333	2,448745	1610	1801	23647,29
160	0,056394	0,017425	5671	1008	0,061091	0,005276	3364	2100	15,53333	2,392117	1353	2016	4555,181
161	0,061564	0,021631	5153	1649	0,061106	0,008223	3642	2025	14,66667	2,404644	1910	2033	9025,14
162	0,062394	0,021698	5005	1846	0,061044	0,006331	3290	1886	15,06667	2,35607	1591	1874	18103,1
163	0,056036	0,008989	5592	1255	0,059921	0,005558	2720	1709	15,66667	2,744242	444	618	1516,841
164	0,074675	0,024914	3730	2606	0,062062	0,006603	2928	1850	14,56667	2,537921	1987	1941	7472,102
165	0,06433	0,02435	4598	2140	0,061652	0,007521	3343	1920	14,93333	2,658236	1747	1842	14800,93
166	0,055211	0,017844	5553	1383	0,058418	0,006359	3515	2165	15,13333	2,353091	1625	1902	5844,007
167	0,063124	0,019055	5380	1301	0,061502	0,006337	3084	1931	15,53333	2,327535	1684	1926	17984,33
168	0,061562	0,020757	5233	1602	0,060668	0,006523	3256	1894	15,46667	2,390993	1526	1778	28650
157	0,068259	0,02477	4657	2298	0,05914	0,010177	2355	2355	12,33333	2,960647	1360	1388	2257,118
158	0,06556	0,02215	4714	1908	0,056673	0,006978	2782	2005	11,7	2,8069	1563	1775	11279,36
159	0,066308	0,020512	5106	1551	0,057909	0,006912	2669	1848	11,86667	2,755262	1689	1682	22852,78
160	0,066663	0,026572	4640	1946	0,053438	0,00816	2210	1869	11,06667	2,585573	1030	1142	4331,71
161	0,06415	0,019737	5179	1518	0,059339	0,007995	2834	1975	13,03333	3,864044	1491	1694	8731,062

Tabela 47: Resultados do treinamento com os parâmetros da Tabela 28 (cont...)

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
162	0,062513	0,02173	5130	1560	0,057687	0,007483	2217	1864	11,95	2,701529	1286	1541	18188,04
163	0,066077	0,019751	4852	1987	0,064447	0,018774	3632	2338	12,83333	2,727319	2613	2417	1448,561
164	0,067901	0,024255	4392	2240	0,059262	0,0089	2405	2059	12,4	2,779908	1507	1708	7209,491
165	0,069344	0,025698	4304	2335	0,05852	0,008445	2292	1906	11,9	2,842874	1617	1733	14420,58
166	0,068746	0,021129	4891	1500	0,056798	0,006606	2621	1757	11,53333	2,303379	1853	1639	5685,95
167	0,059116	0,018721	5337	1381	0,057859	0,006064	2405	1843	12	2,209045	1412	1624	17090,84
168	0,061154	0,018569	5347	1534	0,058322	0,008257	2635	2098	11,88	2,30878	1293	1465	28452,02
157	0,062864	0,007954	5867	354	0,068761	0,005687	3846	2303	17,5	1,964186	2664	1923	2338,697
158	0,058353	0,011996	5433	1206	0,070759	0,005348	3483	1979	17,36667	2,131983	2238	2099	11765,02
159	0,062677	0,015106	5416	1271	0,071059	0,006429	3585	1903	17,3	2,168285	1808	1673	22478,44
160	0,063409	0,017355	5301	1790	0,070602	0,005495	3503	1934	17,46667	1,870829	2122	1821	4300,499
161	0,059902	0,013773	5572	1207	0,070283	0,007591	3397	1761	17,23333	2,577814	1816	1526	8602,124
162	0,060828	0,017017	5378	1480	0,06913	0,00797	3648	1851	16,4	2,424158	2259	1653	17509,64
163	0,060521	0,022532	5405	1861	0,069808	0,013128	4584	1928	16,66667	4,230985	2452	2273	1423,493
164	0,064218	0,015214	5304	1552	0,07122	0,006164	3634	1943	17,6	2,567899	2141	1955	7130,057
165	0,06706	0,018582	4709	2101	0,072326	0,007475	2917	1869	16,85	2,449203	2208	1661	14277,23
166	0,062849	0,015568	5237	1603	0,07055	0,007352	3508	1764	16,66667	2,590939	1766	1364	5559,541
167	0,065131	0,014655	5367	1679	0,072232	0,010548	3784	2022	17,11111	1,904896	2367	1841	16753,84
168	0,06097	0,014475	5517	1212	0,070794	0,008109	3730	1956	17,13333	2,123009	2067	1707	27848,3

Tabela 48: Resultado do novo treinamento com as redes escolhidas e com o epmax igualado

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
7	0,064375	0,023654	5669	3471	0,062094	0,014723	6646	3909	12,66667	4,594683	5049	3662	2550,253
7	0,046318	0,005187	8371	3325	0,056668	0,006717	7791	2060	12,83333	1,932503	6972	3290	2620,374
7	0,04829	0,016583	6694	3205	0,069275	0,007201	8707	2895	16,33333	2,91865	8205	3501	2719,651
7	0,05323	0,017292	7590	3356	0,06028	0,007639	8432	2929	14	2,249829	5277	2282	2731,306
7	0,060595	0,016698	4834	3648	0,068653	0,010781	4969	3462	16	4,021547	4764	3545	2689,454
7	0,052887	0,01602	7038	3065	0,05453	0,006848	7196	3067	11,33333	2,91865	6699	2851	2516,846
7	0,041814	0,007191	8185	3016	0,048975	0,005166	8818	2581	9,333333	1,956313	8642	2667	2511,485
7	0,059336	0,021925	6355	3678	0,0647	0,008719	8071	2528	14,33333	2,854496	5969	2585	2490,888
7	0,063311	0,024664	6003	2315	0,056414	0,006875	7253	3648	11,83333	1,995365	4660	3276	2494,634
7	0,049265	0,023833	7096	3464	0,056469	0,010176	8673	2137	11,5	2,658552	7987	3114	2499,826
7	0,043026	0,010099	5924	3320	0,05787	0,00511	7178	2654	12,33333	2,108185	6462	2602	2501,606
7	0,076143	0,02406	3703	2679	0,05184	0,014574	4819	3201	9,666667	4,830459	4191	3150	2471,899
7	0,052885	0,017273	7164	3243	0,056118	0,009405	8400	3963	11,5	4,116363	7384	3930	2504,332
7	0,072444	0,02271	5251	4727	0,069286	0,014124	5712	4751	16,83333	4,611446	5770	5184	2470,528
7	0,063079	0,021467	6277	2983	0,054687	0,010026	7361	3233	11,66667	3,928371	5732	3158	2496,627
7	0,053935	0,021632	6569	3692	0,069467	0,013282	8848	3360	16,16667	4,086261	6164	3965	2486,888
7	0,062441	0,025353	6569	2347	0,054874	0,005728	7988	2691	12,5	1,800206	5676	3162	2496,848
7	0,049632	0,008501	6765	2876	0,061061	0,006698	7237	2318	14,83333	2,881401	5686	3153	2489,239
7	0,052326	0,019363	5425	3001	0,063169	0,016003	6803	3469	14	5,282162	5501	3524	2492,487
7	0,05991	0,018521	8053	3120	0,056099	0,00867	6377	2489	13	2,581989	6050	3568	2494,272
7	0,051562	0,014323	6944	2039	0,063262	0,008754	7580	3911	13,16667	3,282012	6416	3238	2491,65

Tabela 49:Resultado do novo treinamento com as redes escolhidas e com o epmax igualado(cont...)

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
7	0,053886	0,02363	6764	2638	0,049706	0,012249	8532	3036	9,666667	2,69888	6538	2494	2495,737
7	0,053436	0,016717	7044	3543	0,055425	0,010017	7027	3467	12,16667	3,244178	6222	2937	2498,775
7	0,051754	0,019176	6326	2215	0,061175	0,007137	7796	3747	13,66667	2,330686	7829	3997	2496,356
7	0,06823	0,026023	5958	3240	0,044192	0,007913	7598	2938	7,833333	2,490724	5744	3133	2505,746
7	0,067827	0,028363	5161	3232	0,059459	0,01013	6332	4364	13	3,406602	4119	3863	2537,327
7	0,04943	0,016886	8229	2428	0,067537	0,008156	8316	2946	14,83333	1,995365	7344	2954	2581,543
7	0,052326	0,008421	7579	3403	0,067187	0,009283	7839	2991	14,5	3,689324	7189	3202	2531,911
7	0,047311	0,010568	7043	3460	0,072424	0,007958	7921	4084	18,33333	3,333333	6542	4487	2527,273
7	0,064636	0,025353	5297	3926	0,045312	0,012013	8355	3790	6,666667	1,924501	7658	4119	2535,588
7	0,048861	0,017364	6006	3284	0,076204	0,011785	7237	3934	19,5	3,429178	6081	3070	2530,8
7	0,057377	0,032928	7897	3487	0,040816	0,011425	4368	4102	6,333333	1,531561	2911	4179	2533,996
7	0,063432	0,031866	4986	3516	0,06372	0,016327	7036	4264	15,66667	6,344046	5325	3975	2522,147
7	0,064132	0,015614	8182	4452	0,072874	0,012376	5906	4038	16,5	5,238155	5834	4334	2518,031
7	0,055992	0,015752	6827	3362	0,060416	0,008106	6144	2749	13,16667	1,657382	5924	3181	2535,211
7	0,068774	0,019642	5746	3565	0,050541	0,00593	7733	4081	10	2,078699	5562	4079	2572,264
7	0,064951	0,022707	8429	2705	0,053225	0,014901	7601	3266	10,66667	3,531166	7085	3887	2572,737
7	0,059273	0,023498	5389	3825	0,070627	0,01453	5682	3451	16,66667	4,648111	5640	3171	2598,62
7	0,070523	0,026901	6173	4499	0,050124	0,00903	6432	4021	10,33333	2,69888	5982	3317	2590,718
7	0,067625	0,030304	5243	4117	0,060891	0,012271	5672	3632	13,83333	5,094781	3505	3116	2669,008
4	0,050884	0,012433	6727	3692	0,056431	0,006681	7618	2942	12,26667	2,145193	6237	3267	6863,647
4	0,045179	0,01692	7199	3045	0,069391	0,009406	8691	2628	16,66667	3,042903	7354	3022	6810,585

Tabela 50:Resultado do novo treinamento com as redes escolhidas e com o epxmax igualado(cont...)

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
4	0,054763	0,024489	6538	3013	0,047516	0,011466	6810	3117	8,933333	3,11359	6844	3113	6850,319
4	0,046142	0,01878	6344	3421	0,078286	0,009309	6789	3400	18,66667	3,469443	5820	3047	6851,804
4	0,049387	0,016847	5987	3387	0,066265	0,008665	8200	3038	15,2	2,605194	7066	2597	6950,125
4	0,054719	0,019466	6937	2852	0,049196	0,010973	8650	2897	10	2,886751	5374	3648	7028,453
4	0,047975	0,020971	7105	2905	0,051086	0,007759	7320	4069	10,53333	2,392117	6971	4191	6723,526
4	0,059084	0,018286	6507	3092	0,050366	0,009265	8749	2401	10,2	2,605194	6736	2974	6680,754
4	0,051777	0,02138	6629	3043	0,045122	0,006376	7036	2883	9,266667	1,868352	6826	2981	6720,094
4	0,057805	0,02456	5914	3543	0,044792	0,011136	6672	3344	9	3,080705	5147	3863	6709,249
4	0,061414	0,027122	5886	3304	0,057835	0,015995	7076	4113	11,33333	4,538926	6268	3757	6790,911
4	0,061572	0,023305	6310	3570	0,056988	0,010121	6583	3331	12,13333	3,281542	5511	3193	6838,44
4	0,055283	0,026665	7987	3338	0,057404	0,007844	7980	3313	12,26667	2,585573	6529	3671	6917,236
4	0,056043	0,020757	5787	2867	0,049007	0,011912	7002	3439	9,866667	2,923405	5904	2683	6925,185
4	0,053418	0,022731	7346	3225	0,055057	0,007805	7227	3240	12,06667	2,937623	5539	3188	6875,923
4	0,052568	0,020513	6957	3500	0,048074	0,00581	7022	3407	8,733333	1,542605	5085	3606	6868,087
4	0,063522	0,030466	6292	3592	0,051673	0,007554	6410	3096	10,53333	2,440021	5658	3573	6761,476
4	0,057537	0,022592	7764	3425	0,043122	0,008115	8098	2885	8,333333	2,635231	5832	4037	6790,629
4	0,055735	0,023657	7108	3332	0,048358	0,008108	7830	3267	9,666667	2,678792	7088	2990	6835,67
4	0,054021	0,020943	7971	2823	0,05161	0,016779	6948	3955	10,46667	3,982601	4998	4157	6795,483
4	0,054281	0,021237	7203	3303	0,057336	0,005049	8049	2959	10,86667	2,048034	6527	3386	6755,269
4	0,053509	0,019284	6917	3490	0,0688	0,014927	6819	3310	15,73333	4,411685	6147	3495	6725,67
4	0,053212	0,014031	6818	2958	0,050624	0,005933	7415	2519	9,933333	1,699673	6493	3225	6792,617

Tabela 51:Resultado do novo treinamento com as redes escolhidas e com o epxmax igualado(cont...)

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
4	0,049323	0,016579	7068	3310	0,077043	0,009719	8017	2934	17,8	3,107637	5323	3489	6779,948
4	0,05409	0,017464	6714	3057	0,05706	0,008311	7050	3206	12,2	2,752104	6674	3154	6753,086
4	0,050534	0,012624	6706	2486	0,04898	0,005426	7219	2365	9,2	2,211083	7008	2996	6677,858
4	0,05317	0,019945	6894	3132	0,055334	0,007826	7987	3325	12,133333	2,125681	6625	3419	6652,467
4	0,052617	0,018616	7592	3335	0,05277	0,009241	6896	3384	11,66667	2,763854	6317	3408	6657,526
4	0,052181	0,017083	7976	2870	0,060333	0,010582	7794	3336	12,933333	3,44534	6312	2860	6675,041
4	0,063931	0,028898	6504	3480	0,057736	0,009554	8176	3001	12	2,405626	6676	3197	6646,306
4	0,050382	0,018477	6894	3386	0,06507	0,011536	6951	3034	14,533333	4,652757	5636	3592	6648,339
4	0,048972	0,020338	7396	2751	0,057765	0,007043	8069	3013	11,933333	2,621139	6243	3892	6671,742
4	0,061917	0,019651	5865	3946	0,064603	0,012625	7010	3902	14,6	4,621808	5450	3921	6609,355
4	0,071118	0,027171	5651	3257	0,04556	0,014268	6597	3661	9,333333	3,298428	5076	3376	6657,597
4	0,059149	0,026058	7874	3462	0,056141	0,010953	7473	2978	10,733333	3,045944	6251	3754	6689,235
4	0,054102	0,020303	6408	3663	0,064882	0,010464	7308	3423	15,2	3,610684	6816	3188	6611,709
4	0,05577	0,025688	6810	3414	0,053575	0,008668	7256	3093	10	2,5	7275	3453	6654,186
4	0,064235	0,024306	6753	3929	0,056239	0,00864	6551	3538	10,8	2,596294	5902	3243	6629,849
4	0,053152	0,020786	7711	2828	0,034286	0,008453	8777	2341	5,133333	2,200589	7188	3031	6694,216
4	0,052336	0,02235	6605	3250	0,056722	0,009789	7413	3230	12,26667	2,585573	7044	3282	6651,385
75	0,039759	0,014787	10229	2151	0,063847	0,014339	9610	2418	15,083333	5,077265	8744	2949	37110,78
75	0,042735	0,027764	9329	2615	0,045356	0,011114	6663	3643	8,433333	3,919934	4478	3816	37094,96
75	0,042328	0,015968	10550	1890	0,059505	0,010806	9330	2681	13,55	3,868308	8713	2822	37033,04
75	0,038947	0,023006	9413	2876	0,052533	0,007229	7853	3502	9,733333	1,977993	5992	3726	36729,56

Tabela 52:Resultado do novo treinamento com as redes escolhidas e com o epmax igualado(cont...)

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
75	0,039593	0,021633	9400	2634	0,04866	0,010304	7433	3307	10,05	3,110886	7399	2995	37862,51
75	0,037992	0,016197	10514	1482	0,065439	0,009404	8967	2708	13,93333	3,801471	7750	3159	39151,36
75	0,050729	0,022669	9435	3199	0,05183	0,012066	8936	3074	10,96667	3,879353	8001	3236	38523,63
75	0,038782	0,023555	9888	2756	0,053969	0,008133	8561	2787	11,08333	2,511198	7202	3203	38760,78
75	0,035853	0,013349	9856	2188	0,06328	0,010427	9396	2286	13,38333	3,44473	8158	2955	37753,67
75	0,038552	0,019159	10142	2420	0,051227	0,009099	9675	2156	10,88333	3,226008	7992	3033	37589,64
75	0,041018	0,015919	9964	2184	0,057445	0,011991	9400	2671	12,65	4,342873	8672	2726	38318,67
32	0,062105	0,029267	8105	4351	0,057948	0,008724	6794	4396	13,03333	2,749768	4878	4040	12367,13
32	0,066135	0,026781	9064	3654	0,055936	0,009084	5338	4000	11,83333	2,289927	3865	4384	12389,79
32	0,061324	0,022963	9197	4031	0,065097	0,006812	5332	4253	14,46667	2,596003	4353	4421	12390,04
32	0,063565	0,022782	8766	4165	0,069509	0,008915	7156	3574	17,66667	4,689932	5163	4134	12361,03
32	0,055061	0,01933	9915	3382	0,067719	0,009222	6927	3697	16,8	3,101459	4137	3715	12401,74
32	0,048608	0,005854	11244	1434	0,094261	0,00584	7275	3316	24,03333	2,235814	5683	3453	12447,41
32	0,060473	0,017917	9990	3637	0,060586	0,007181	7479	3835	13,5	2,67791	5456	3823	12386,59
32	0,05903	0,021502	8918	4027	0,062698	0,010169	7792	4154	15,7	3,720538	5584	4174	12379,82
32	0,060568	0,021332	8835	4144	0,060197	0,010917	6049	3766	15,43333	3,995604	5227	3470	12278,82
32	0,054486	0,025074	9966	2724	0,05639	0,007132	6296	3982	13,06667	3,288129	5132	4210	12294,48
32	0,055599	0,025131	9397	3453	0,057227	0,008373	7066	3536	13,06667	3,373231	4790	3854	12296,4
32	0,078088	0,0313	6783	4575	0,030788	0,009904	4241	3781	4,066667	1,909518	2066	2947	12283,46
32	0,054071	0,013805	10150	3255	0,080862	0,00796	8521	3408	18,26667	2,934663	5866	3365	12315,39
32	0,060977	0,02481	8745	4234	0,054793	0,009572	4536	3864	11,3	3,199525	3047	3549	12716,29

Tabela 53:Resultado do novo treinamento com as redes escolhidas e com o epmax igualado(cont...)

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
32	0,061181	0,016278	10088	3290	0,068493	0,011764	7906	3893	18,2	4,577872	5611	3765	12803,75
32	0,065262	0,02397	8351	4157	0,06809	0,009418	5779	4142	16,233333	3,981391	3806	4134	12834,97
32	0,075375	0,028443	7363	4908	0,048791	0,008865	5566	3826	9,4333333	2,664327	4003	3595	13008,17
32	0,049199	0,019438	10665	2418	0,071581	0,008621	4669	4188	17	4,096345	4176	3775	12814,13
32	0,061224	0,025424	9305	4165	0,052879	0,008891	5858	3669	9,8	2,686153	4025	3170	12738,55

Tabela 54: Resultados do teste das redes com os dados de insuficiência cardíaca congestiva

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
4	0,05537	0,023717	7648	2992	0,05217	0,008441	7219	3315	11,8	2,401774	5727	3489	6670,501
4	0,046279	0,020321	6742	3130	0,061268	0,005427	7697	2921	12,8	1,782113	4517	3327	6689,696
4	0,046333	0,013485	7676	3107	0,065895	0,010299	8676	2051	14,8	3,674235	6444	3690	6645,05
4	0,048378	0,015523	7399	3551	0,06822	0,007583	8310	3052	15,4	2,219443	7886	3354	7135,233
4	0,056813	0,020835	6463	3310	0,069102	0,007249	6390	3657	15,06667	3,485419	5245	3902	7185,74
4	0,069361	0,013478	10507	3697	0,04795	0,005378	7392	4264	10,8	2,211083	3367	3022	7659,399
4	0,061	0,001683	11889	555	0,076555	0,002572	10154	3547	19,33333	1,360828	4555	4198	7680,06
4	0,062951	0,012391	11803	518	0,053091	0,003505	9413	2953	11,53333	2,84312	6378	3353	7800,762
4	0,061847	0,003505	11950	248	0,066508	0,004791	8823	3479	19,06667	3,007706	3573	3644	7698,774
4	0,062738	0,00246	11538	1067	0,068824	0,001815	5101	3330	18,46667	0,952579	1042	1322	7666,365
7	0,057231	0,027519	5463	3388	0,052409	0,01082	6142	4002	11,83333	3,186585	4068	3795	2439,072
7	0,051745	0,017223	7649	3593	0,070488	0,011865	7830	2387	16,83333	3,963569	7081	2913	2449,09
7	0,063422	0,021317	7288	3032	0,059116	0,010927	5720	2871	13,33333	4,006168	5098	4019	2457,355
7	0,063801	0,023048	6500	4074	0,055437	0,017609	6358	3405	11,16667	5,094781	7375	3242	2447,411
7	0,056379	0,020696	5843	2571	0,070255	0,011521	7391	3919	16,33333	4,956602	5998	3209	2448,176
7	0,043026	0,010099	5924	3320	0,05787	0,00511	7178	2654	12,33333	2,108185	6462	2602	2501,606
7	0,076143	0,02406	3703	2679	0,05184	0,014574	4819	3201	9,666667	4,830459	4191	3150	2471,899
7	0,052885	0,017273	7164	3243	0,056118	0,009405	8400	3963	11,5	4,116363	7384	3930	2504,332
7	0,072444	0,02271	5251	4727	0,069286	0,014124	5712	4751	16,83333	4,611446	5770	5184	2470,528

Tabela 55 Resultados do teste das redes com os dados de insuficiência cardíaca congestiva (cont...)

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
7	0,063079	0,021467	6277	2983	0,054687	0,010026	7361	3233	11,66667	3,928371	5732	3158	2496,627
75	0,044401	0,02166	9804	2591	0,049579	0,010273	8489	2984	10,81667	3,52556	7748	3347	37708,46
75	0,041306	0,020466	9814	2630	0,045853	0,009778	9020	2505	8,3	3,106598	7537	2919	37175,6
75	0,064375	0,023654	5669	3471	0,062094	0,014723	6646	3909	12,66667	4,594683	5049	3662	37550,25
75	0,046318	0,005187	8371	3325	0,056668	0,006717	7791	2060	12,83333	1,932503	6972	3290	36620,37
75	0,04829	0,016583	6694	3205	0,069275	0,007201	8707	2895	16,33333	2,91865	8205	3501	38719,65
75	0,062302	0,001828	11576	997	0,073027	0,004285	9462	3434	19,13333	1,604392	4501	4198	36529,48
75	0,06217	0,002498	11917	388	0,067423	0,002152	8406	3086	18,66667	1,98373	2912	3188	37528,93
75	0,065151	0,004039	11974	128	0,062728	0,001784	4885	3871	15,6	1,433721	864	1944	37498,37
75	0,06087	0,003524	11733	990	0,071209	0,00201	9115	3309	18	1,272938	2404	3179	37527,89
75	0,063505	0,002123	12000	0	0,064849	0,00332	10673	1795	19,86667	2,200589	5280	3651	37527,09
32	0,058667	0,00208	11901	363	0,085375	0,004785	9348	3617	24,26667	2,311405	2629	2977	12120,65
32	0,065525	0,002968	11889	326	0,058058	0,003404	9097	3743	14	1,360828	4684	3425	11902,22
32	0,058431	0,002245	11406	1223	0,083043	0,002377	3809	3904	22,13333	2,013841	3209	3907	11889,41
32	0,060573	0,001121	11828	478	0,078371	0,00256	9988	2673	22,93333	1,298147	2094	2677	11985,5
32	0,063796	0,00327	11792	671	0,065587	0,004531	8811	3470	19,73333	1,779513	1978	3035	11879,22
32	0,065666	0,003677	11936	229	0,054811	0,002668	9349	3260	13,86667	1,5	5277	3456	12144,14
32	0,064273	0,016996	11110	2498	0,048301	0,009452	7521	3561	10,26667	2,953341	3377	2558	12195,16
32	0,06313	0,002242	11841	420	0,066503	0,002327	10051	3198	17,8	1,045272	3853	2412	12197,71
32	0,067869	0,007447	11301	2571	0,056136	0,007328	10414	3132	15,13333	1,436946	2497	3562	12182,7
32	0,056481	0,002683	11499	1151	0,090177	0,003454	8411	3083	25,93333	2,503701	2770	3893	12015

Tabela 56:Retultados do teste das redes com os dados de arritmia cardíaca

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
4	0,050884	0,012433	6727	3692	0,056431	0,006681	7618	2942	12,26667	2,145193	6237	3267	6863,647
4	0,045179	0,01692	7199	3045	0,069391	0,009406	8691	2628	16,66667	3,042903	7354	3022	6810,585
4	0,054763	0,024489	6538	3013	0,047516	0,011466	6810	3117	8,933333	3,11359	6844	3113	6850,319
4	0,046142	0,01878	6344	3421	0,078286	0,009309	6789	3400	18,66667	3,469443	5820	3047	6851,804
4	0,062539	0,002206	11952	129	0,062423	0,005341	4894	3548	14,13333	1,604392	1079	2486	6609,228
4	0,064138	0,004307	11981	77	0,058712	0,003529	10604	1982	15,4	2,857738	5864	3258	6716,062
4	0,0614	0,002409	11624	650	0,070316	0,002363	8609	3060	15,6	1,855921	5897	3419	6804,746
4	0,062122	0,005914	11818	545	0,062569	0,003298	6469	3993	14,86667	0,822147	891	2404	6789,732
4	0,06501	0,004119	11779	729	0,053818	0,004062	6639	3144	12,53333	1,530553	2160	2987	6693,486
4	0,061102	0,002578	11845	475	0,063591	0,003612	4425	2827	16,06667	1,792474	3430	3034	6364,704
7	0,052326	0,008421	7579	3403	0,067187	0,009283	7839	2991	14,5	3,689324	7189	3202	2531,911
7	0,047311	0,010568	7043	3460	0,072424	0,007958	7921	4084	18,33333	3,333333	6542	4487	2527,273
7	0,064636	0,025353	5297	3926	0,045312	0,012013	8355	3790	6,666667	1,924501	7658	4119	2535,588
7	0,048861	0,017364	6006	3284	0,076204	0,011785	7237	3934	19,5	3,429178	6081	3070	2530,8
7	0,057377	0,032928	7897	3487	0,040816	0,011425	4368	4102	6,333333	1,531561	2911	4179	2533,996
7	0,063432	0,031866	4986	3516	0,06372	0,016327	7036	4264	15,66667	6,344046	5325	3975	2522,147
7	0,064132	0,015614	8182	4452	0,072874	0,012376	5906	4038	16,5	5,238155	5834	4334	2518,031
7	0,055992	0,015752	6827	3362	0,060416	0,008106	6144	2749	13,16667	1,657382	5924	3181	2535,211
7	0,068774	0,019642	5746	3565	0,050541	0,00593	7733	4081	10	2,078699	5562	4079	2572,264

Tabela 57: Retultados do teste das redes com os dados de arritmia cardíaca (cont...)

Rede	Treinamento				Teste								Tempo
	EQM		REP		EQM		REP		%Erro		REP		
	média	σ	média	σ	média	σ	média	σ	média	σ	média	σ	
7	0,041814	0,007191	8185	3016	0,048975	0,005166	8818	2581	9,333333	1,956313	8642	2667	2511,485
75	0,05323	0,017292	7590	3356	0,06028	0,007639	8432	2929	14	2,249829	5277	2282	38238,28
75	0,060595	0,016698	4834	3648	0,068653	0,010781	4969	3462	16	4,021547	4764	3545	37652,35
75	0,052887	0,01602	7038	3065	0,05453	0,006848	7196	3067	11,33333	2,91865	6699	2851	37752,68
75	0,059336	0,021925	6355	3678	0,0647	0,008719	8071	2528	14,33333	2,854496	5969	2585	37363,32
75	0,063311	0,024664	6003	2315	0,056414	0,006875	7253	3648	11,83333	1,995365	4660	3276	37419,5
75	0,049265	0,023833	7096	3464	0,056469	0,010176	8673	2137	11,5	2,658552	7987	3114	37497,39
75	0,053935	0,021632	6569	3692	0,069467	0,013282	8848	3360	16,16667	4,086261	6164	3965	37303,32
75	0,062441	0,025353	6569	2347	0,054874	0,005728	7988	2691	12,5	1,800206	5676	3162	37452,72
75	0,049632	0,008501	6765	2876	0,061061	0,006698	7237	2318	14,83333	2,881401	5686	3153	37338,58
75	0,052326	0,019363	5425	3001	0,063169	0,016003	6803	3469	14	5,282162	5501	3524	37387,31
32	0,05991	0,018521	8053	3120	0,056099	0,00867	6377	2489	13	2,581989	6050	3568	12471,36
32	0,051562	0,014323	6944	2039	0,063262	0,008754	7580	3911	13,16667	3,282012	6416	3238	12458,25
32	0,053886	0,02363	6764	2638	0,049706	0,012249	8532	3036	9,66667	2,69888	6538	2494	12478,69
32	0,053436	0,016717	7044	3543	0,055425	0,010017	7027	3467	12,16667	3,244178	6222	2937	12493,87
32	0,051754	0,019176	6326	2215	0,061175	0,007137	7796	3747	13,66667	2,330686	7829	3997	12481,78
32	0,06823	0,026023	5958	3240	0,044192	0,007913	7598	2938	7,833333	2,490724	5744	3133	12528,73
32	0,067827	0,028363	5161	3232	0,059459	0,01013	6332	4364	13	3,406602	4119	3863	12686,63
32	0,04943	0,016886	8229	2428	0,067537	0,008156	8316	2946	14,83333	1,995365	7344	2954	12907,72
32	0,062356	0,003478	11850	432	0,063591	0,003089	4002	4285	15,66667	2,151657	2814	3476	12490,03
32	0,060992	0,003235	11461	1047	0,066947	0,001891	6252	2907	16,93333	1,040833	1677	1800	12493,79

APÊNDICE D – Artigo Apresentado ao congresso CBIS 2008

Diagnóstico de Cardiopatias Usando Redes Neurais Artificiais LMS

Thiago R. Perales¹, Ernesto F. Ferreyra Ramirez¹, Márcio R. Covacic¹

¹Departamento de Engenharia Elétrica (DEEL), Centro de Tecnologia e Urbanismo (CTU)
Universidade Estadual de Londrina (UEL), Brasil

Resumo - Este trabalho trata da aplicação de redes neurais artificiais para o diagnóstico de cardiopatias como arritmia e insuficiência cardíaca congestiva. Para isso, foram seguidos os passos: (i) Aquisição e condicionamento dos dados para serem aplicados como entrada das redes; (ii) Treinamento de diversas redes para escolher a de melhor desempenho. O treinamento para diagnosticar arritmia cardíaca foi o que apresentou melhor desempenho, com cerca de 86% de acerto. Já para o diagnóstico de insuficiência cardíaca congestiva foi de 68%, e para o de pessoas saudáveis foi de 84% de acerto. Assim, pode ser afirmado que as redes neurais artificiais auxiliam o diagnóstico preciso e rápido de cardiopatias. Fica como sugestão para trabalhos futuros, o treinamento com um número bem maior de dados para melhorar ainda mais o desempenho da rede.

Palavras-chave: Inteligência Artificial; Redes Neurais Artificiais; Diagnóstico de Arritmias Cardíacas.

Abstract - This work shows the application of Artificial Neural Networks (ANN) for the diagnosis of Congestive Heart Failure and Spontaneous Ventricular Tachyarrhythmia. The following steps were performed: (i) Acquisition and conditioning of the data to be applied as inputs; (ii) Training of diverse types of ANN to choose the best performance. The diagnostics rightness rate for Spontaneous Ventricular Tachyarrhythmia, Congestive Heart Failure, and healthy people were greater than 86%, 68% and 84% respectively. Thus, using ANN will permit a faster and precise diagnosis. In future works, the training of ANN will be carried through with more data to improve the quality of the diagnostic.

Key-words: Artificial Intelligence; Artificial Neural Networks; Cardiac Arrhythmia Diagnosis.

Introdução

As redes neurais começaram com o trabalho dos pioneiros McCulloch e Pitts em 1943 e, desde então, vêm sendo cada vez mais empregadas nas mais diversas áreas como modelagem, análise de séries temporais, reconhecimento de padrões, processamento de sinais e controle. O principal motivo dessa ampla variedade de aplicações é a habilidade de aprender a partir de dados de entrada, com ou sem supervisão, além de ter raízes em múltiplas disciplinas como neurociência, matemática, estatística, física, ciência da computação e engenharia [1].

Nos dias de hoje em que a tecnologia evolui constantemente, e o uso de ferramentas computacionais está bastante difundido, pode-se utilizar o paradigma do conexionismo. Este é o caso dos problemas de diagnóstico médico [2, 3], devido às inconsistências, exceções às regras e especificações incompletas, que obrigam a resolver o problema com conhecimento parcial ou aproximado dos dados [4]. Assim, o paciente

poderá ter seu tratamento prescrito mais rapidamente e, de modo, mais eficiente.

Em alguns trabalhos são mostrados aplicações para problemas de diagnóstico médico em áreas correlatas, tais como: classificação da apnéia do sono [5]; detecção da obstrução das vias aéreas superiores [6]; ou diagnóstico de doença pulmonar obstrutiva crônica [7]. Neste trabalho é mostrada a aplicação de redes neurais artificiais ao diagnóstico de cardiopatias como arritmia e insuficiência cardíaca congestiva.

Futuramente, a rede poderá ser integrada em *hardware* para funcionar como um *holter* inteligente que faça o diagnóstico do paciente à medida que for fazendo o monitoramento de 24 horas.

Metodologia

Para o desenvolvimento deste trabalho foram implementados os passos descritos a seguir.

Aquisição dos dados – Os dados foram obtidos do site www.physionet.org na seção de banco de dados. Foram coletados em diferentes

lugares e de diferentes pacientes, e estão disponíveis para realização de trabalhos e pesquisas que necessitem de uma ampla diversidade de amostras sobre problemas cardíacos.

Dentre as amostras disponíveis foram escolhidos os seguintes casos:

- Pessoas normais (54 amostras);
- Pessoas com arritmia ventricular (100 amostras);
- Insuficiência cardíaca congestiva (29 amostras).

Os arquivos disponíveis estão em formato compactado para diminuir o seu tamanho e agilizar o seu *download*.

Para ter acesso aos dados contidos nos arquivos é necessário fazer o *download* e a instalação de um programa também disponível na mesma página.

O programa para plataforma *Windows* é executado no prompt de comando, onde é feita a conversão dos arquivos desejados para o formato texto.

Cada arquivo de texto gerado possui em torno de 110 mil linhas mostrando o valor de cada intervalo RR.

Condicionamento dos dados – Os dados estão dispostos na forma como eles foram coletados e apresentam alguns erros, devido a descontinuidades (representadas por valores espúrios) durante a aquisição dos mesmos. Por isso, o uso desses dados sem um pré-processamento prejudicaria o desempenho da RNA ou até mesmo levaria a rede a tomar decisões erradas. Assim, foi desenvolvida e implementada uma função na ferramenta computacional *MatLab*® para que fossem filtrados esses valores e se colocasse o valor médio dos intervalos RR no lugar desses valores espúrios.

Os dados foram gerados sem ter um valor fixo de amostragem, pois eles foram gerados de acordo com o valor do intervalo RR. A cada onda R era marcado o tempo que levou para acontecer desde a última onda, como pode ser visto na Figura 1. Com isso, esses dados não podem ser aplicados em algumas partes do condicionamento de sinal ou, mais especificamente, eles não podem ser aplicados como entrada para o cálculo da PSD (densidade espectral de potência).

Para resolver esse problema foi desenvolvida outra função em *MatLab*®, que tem como entrada os dados da saída do filtro e o valor de amostragem

desejado. A saída desta função é o sinal já reamostrado.

A reamostragem foi feita usando interpolação linear, ou seja, considerando que de dois em dois pontos eles são interligados por uma reta.




Figura 1: Gráfico com valores do intervalo RR.

Para o cálculo da densidade espectral de potência foi utilizada uma função que já se encontra pronta no próprio *MatLab*®.

O único trabalho acrescentado nesta etapa foi retirar os valores de dentro de uma variável objeto que esta função dá como resposta, e ajustar os valores para que fiquem na forma correta. Os cálculos de ajuste dos dados foram feitas como mostra a Equação 1.

O eixo X são as frequências e o eixo Y são os dados, portanto a correção foi feita da seguinte maneira:

$$Dados = Dados .* Frequencia \quad (1)$$

onde o operador “.*” corresponde à multiplicação ponto a ponto dos vetores de entrada.

Depois de feitos os ajustes foi verificado que a saída desta função apresenta um número bem baixo de pontos e, para resolver este problema, foi feita uma reamostragem para aumentar o número de pontos e a precisão dos dados no próximo passo.

Após o cálculo da PSD, o domínio de frequência da variação do intervalo RR foi computado pela integração sobre seus intervalos de frequência. A potência foi calculada dentro das quatro bandas (ULF - ultra-baixa frequência, VLF - muito baixa frequência, LF - baixa frequência, HF - alta frequência). Depois de calculadas essas quatro bandas pôde ser calculado a TP (potência total) que é a soma das quatro e a razão LF/HF [8, 9]. A faixa de frequência de cada banda é mostrada na Tabela 1.

Tabela 1: Faixa de frequência de cada banda.

Nome da banda	Faixa de Frequência (Hz)
ULF	0,0000 a 0,0033
VLF	0,0033 a 0,0400
LF	0,0400 a 0,1500
HF	0,1500 a 0,4000
TP	0,0000 a 0,4000

Treinamento das Redes Neurais Artificiais

– Para fazer o algoritmo LMS primeiramente foram realizadas a normalização dos dados e a reorganização dos vetores de saída, para que cada vetor ficasse responsável por cada cardiopatia. A Figura 2 mostra como foi desenvolvido o algoritmo.

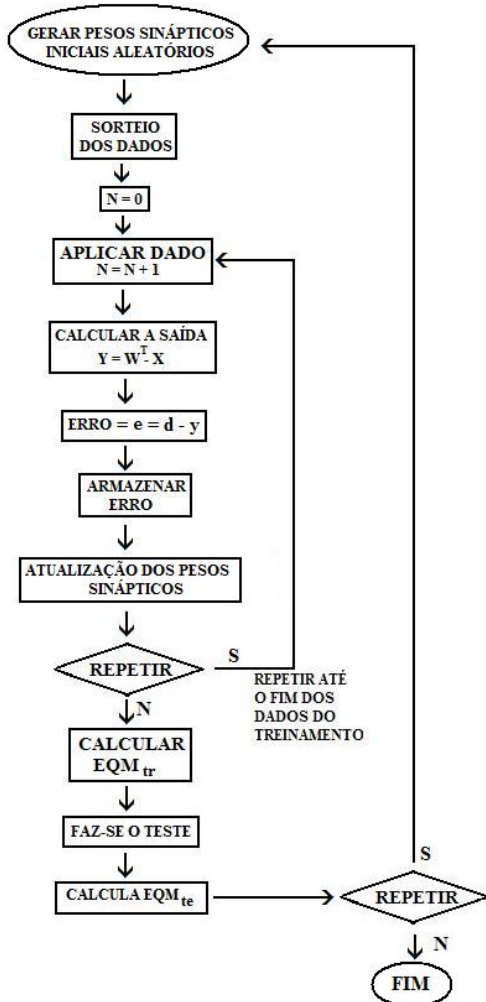


Figura 2: Fluxograma do algoritmo LMS.

Para a realização deste trabalho foram propostos dois modelos de RNA usando as seguintes divisões:

- Divisão dos dados por sexo (masculino/feminino);
- Divisão dos dados pela faixa etária (40-44, 45-49, 50-54, 55-59, 60-64, 65-69 anos).

Este procedimento procurou a aproximação com os modelos citados na literatura [8]. Entretanto, caso os resultados utilizando todos os dados fossem similares aos obtidos com as divisões sugeridas, então elas seriam desconsideradas para que o processamento ficasse mais rápido.

O primeiro modelo utilizou todas as divisões possíveis, ou seja, possuía 8 entradas e 1 saída, como pode ser visto na Figura 3.




Figura 3: Bloco base para o primeiro modelo.

O segundo modelo utilizou somente as divisões por sexo, ficando assim com 7 entradas e 1 saída, como pode ser visto na Figura 4.




Figura 4: Bloco base para o segundo modelo.

Da mesma forma o terceiro modelo que utilizou somente as divisões por idade, ficou com 7 entradas e 1 saída, como pode ser visto na Figura 5.




Figura 5: Bloco base para o terceiro modelo

Finalmente, o quarto modelo, que possuía somente as faixas de freqüência, foi composto por 6 entradas e 1 saída, como pode ser visto na Figura 6.




Figura 6: Bloco base para o quarto modelo.

O modelo geral da rede neural artificial com o algoritmo LMS (RNA/LMS) é mostrado na Figura 7. Cada bloco corresponde à uma cardiopatia ou à ausência de alguma doença cardíaca (a pessoa é sadia). Cada bloco base é descrito da maneira mais adequada entre os modelos descritos nas Figuras 3 a 6.




Figura 7: Rede completa para o diagnóstico.

Resultados

Depois de realizados o condicionamento dos dados e a normalização, os dados de entrada foram aplicados ao algoritmo LMS, onde foi visto que com a separação dos dados em faixa etária e por sexo fazia com que a rede não convergisse e, em alguns

casos, a rede não conseguia realizar cálculo algum. Portanto, o único modelo que deu resultados foi o quarto. Então, os resultados que seguem são apenas os resultados obtidos com este modelo.

O treinamento foi realizado com variações nos parâmetros da rede, resultando no teste de 17 modelos diferentes. Na Tabela 2 são mostrados os parâmetros utilizados nas redes neurais que obtiveram melhor desempenho. Na Tabela 3 são mostradas os melhores resultados das redes neurais treinadas com os parâmetros da Tabela 1.

Após determinadas as melhores redes para diagnóstico de pessoas saudáveis, estas foram aplicadas para diagnosticar insuficiência cardíaca congestiva e arritmia cardíaca, cujos resultados podem ser vistos nas Tabelas 4 e 5 respectivamente.

Tabela 2: Parâmetros dos melhores modelos de RNA.

Modelo utilizado	Taxa de aprendizagem	Repetições do treinamento	Número de épocas
8	10^{-3}	5	1.000
12	10^{-4}	5	7.000
17	10^{-4}	1	20.000

Tabela 3: Resultados no diagnóstico de pessoas sadias.

Modelo de RNA utilizado	8	12	17
Erro de Classificação (%)	6,67	6,00	6,67

Tabela 4: Resultados no diagnóstico de insuficiência cardíaca.

Modelo de RNA utilizado	8	12	17
Erro de Classificação (%)	8,00	1,33	3,33

Tabela 5: Resultados no diagnóstico de arritmia cardíaca.

Modelo de RNA utilizado	8	12	17
Erro de Classificação (%)	4,00	4,00	3,33

Discussão e Conclusões

Para diagnosticar pessoas saudáveis, a RNA 12 apresentou menos oscilações e o menor erro (16%). Por estes motivos este modelo foi escolhido para este diagnóstico.

Como pode ser visto na Tabela 4, as redes não conseguiram um desempenho muito bom apresentando um erro em torno de 35,5%. A rede neural que obteve o melhor desempenho no diagnóstico de insuficiência cardíaca congestiva foi novamente a RNA 12 com 31,33% de erro de classificação.

Como pode ser visto na Tabela 5, para o diagnóstico de arritmia cardíaca as redes neurais tiveram o melhor desempenho de todos os treinamentos, sendo a RNA 17 aquela que apresentou o menor erro (13,33%).

Devido aos resultados mostrados neste trabalho, comprovou-se que redes neurais artificiais, neste caso treinadas com o algoritmo LMS, podem não apenas dar auxílio, mas formar opiniões sobre os diagnósticos dos pacientes apenas com os dados de um eletrocardiograma de 24 Horas e de algum processamento, dando apoio às decisões dos médicos.

Os resultados também mostraram que quanto maior o número de dados que disponibilizamos para a rede analisar em seu treinamento, mais precisa é a decisão da mesma. Pode-se observar o fato no treinamento de insuficiência cardíaca congestiva, que teve apenas 19 exemplos para treinamento e 10 para teste, sendo que seu melhor desempenho teve um erro próximo de 31%. Já para arritmia cardíaca que teve 90 exemplos para treinamento e 10 para teste, o melhor desempenho da rede ficou em 14% de erro de classificação.

Uma rede neural, por mais precisa que seja, nunca vai ser capaz de fazer um diagnóstico correto para todos os casos apresentados, visto que na área médica, durante um diagnóstico, é possível investigar aspectos adicionais do paciente: resultados de exames complementares; histórico familiar; e hábitos de vida. Estes aspectos podem ser considerados como questões ligadas a exceções, incertezas, contradições e intuições presentes na mente do especialista, cujo conhecimento se está querendo adquirir [10]. Então, o *software* desenvolvido neste trabalho é apenas mais uma ferramenta à disposição dos especialistas.

Futuramente, a rede neural artificial poderá ser integrada em *hardware* para funcionar como um *holter* inteligente que faça o diagnóstico do paciente

à medida que estiver fazendo o monitoramento de 24 horas.

Agradecimentos

Os autores agradecem o apoio financeiro recebido da CAPES.

Referências

- [1] Haykin S. Redes Neurais: Princípios e Prática,-- trad. PM Engel, 2.ed., Porto Alegre (Brasil): Bookman, 2001.
- [2] Von Zuben FJ. Uma Caricatura Funcional de Redes Neurais Artificiais. Curso A. Anais do VI Congresso Brasileiro de Redes Neurais / VII Escola de Redes Neurais; 2-5 de junho de 2003, São Paulo.
- [3] Barreto JM. Inteligência Artificial e Engenharia Biomédica: Casamento Perfeito ou Amantes Eternos? Anais do XVII Congresso Brasileiro de Engenharia Biomédica; 11-13 de setembro de 2000, Florianópolis.
- [4] Barreto JM. Inteligência Artificial no Limiar do Século XXI, 3.ed., Florianópolis (Brasil): ppp Edições, 2001.
- [5] Fontenla-Romero O, Guizarro-Berdinãs B, Alonso-Betanzos A, Moret-Bonillo V. A New Method for Sleep Apnea Classification Using Wavelets and FeedForward Neural Networks. Artificial Intelligence in Medicine, 2005 34: 65-76.
- [6] Bright P, Miller MR, Franklyn JÁ, Sheppard MC. The Use of a Neural Network to Detect Upper Airway Obstruction Caused by Goiter. American Journal of Respiratory Critical Care in Medicine, 1998 157: 1885-1891.
- [7] Oliveira C, Camargo-Brunetto MAO, Ferreyra Ramirez EF, Brunetto AF. Identificação de Doença Pulmonar Obstrutiva Crônica Através de Redes Neurais Artificiais. Anais do XX Congresso Brasileiro de Engenharia Biomédica / II Congresso Brasileiro de Engenharia Clínica; 2006, São Pedro. p. 262-265.
- [8] Bigger JT, Fleiss JL, Steinman RC. RR Variability in Healthy, Middle-Aged Persons Compared With Patients With Chronic Coronary Heart Disease or Recent Acute Myocardial Infarction. Circulation 1995 91: 1936-1943.
- [9] Gomes MED. Técnicas de Sistemas Dinâmicos Não Lineares na Análise da Modulação Autônoma da Variabilidade da Frequência Cardíaca. [tese]. Belo Horizonte (MG): Comissão de Pós-Graduação da Faculdade de Engenharia

Elétrica da Universidade Federal de Minas Gerais,
CPG / FEE / UFMG; 2001.

[10] Bittencourt G. Inteligência Artificial:
Ferramentas e Teorias. 3.ed. Florianópolis (Brasil):
Editora UFSC, 2006.

Contato

Thiago Reges Perales

E-mail: thiagorperales@yahoo.com.br

Ernesto Fernando Ferreyra Ramírez

E-mail: ferreyra@uel.br

Márcio Roberto Covacic

E-mail: marciocovacic@uel.br

Endereço para contato:

Universidade Estadual de Londrina

Depto. de Engenharia Elétrica (DEEL/CTU)

Caixa Postal 6001

CEP: 86.051-990 / Londrina – PR

Algoritmo backpropagation Utilizado

```

function [EQM,EQM_t] =
back(arquivo,alfa,a,b,eta,epMax,repMax,m1,pTrei,n_saidas)
%Back_Lebres_australianas
str = [arquivo '.txt']; %Junta o nome do arquivo com o Formato
Dados = textread(str)'; %Carrega os dados do arquivo na variavel dados
nTrei = round((pTrei/100)*size(Dados,2)); %calcula o numero de dados para
o grupo de Treinamento
nTest = size(Dados,2)-nTrei; %calcula o numero de dados para o grupo de
Teste
EQM_min = 9999;
%Normalizacao dos dados
[Max] = max(Dados,[],2); %Armazena os maximos para desnormalizacao

for i=1:size(Dados,1)
    Dados(i,:) = Dados(i,+)/Max(i,:);%Normaliza os dados da Entrada
end

for rep = 1:repMax,
tempo = toc;
disp([num2str(rep) ' --> Tempo = ' num2str(tempo) ' segundos']);
[Dados]=embaralha(Dados); % Embaralha os dados para nao viciar a rede
x = [ones(1,nTrei); Dados(1:(size(Dados,1)-n_saidas),1:nTrei)]; %Coloca as
entradas de Treinamento na variavel x
x_t = [ones(1,nTest); Dados(1:(size(Dados,1)-
n_saidas),nTrei+1:size(Dados,2))];%Coloca as entradas de Teste na variavel
x_t
d = Dados((size(Dados,1)-n_saidas+1):size(Dados,1),1:nTrei); %Coloca as
saidas desejadas de Treinamento na variavel d
d_t = Dados((size(Dados,1)-
n_saidas+1):size(Dados,1),nTrei+1:size(Dados,2));%Coloca as saidas
desejadas de Teste na variavel d_t

W1_d= 0.5*rand(m1,size(x,1))-0.25;%Calculo aleatorio do W1 inicial da
repeticao
W2_d= 0.5*rand(size(d,1),m1+1)-0.25;%Calculo aleatorio do W2 inicial da
repeticao

for ep=1:epMax
    W1_a = W1_d;
    W2_a = W2_d;

    for i=1:size(x,2),
        v1 = W1_d*x(:,i); %Calculo das entradas dos neuronios da Camada
oculta 1
        Y1(2:m1+1,i)=(((a*tanh(b*v1))/2)+0.5); %Calculo das saidas dos
neuronios da Camada oculta 1
        Y1(1,i)=1;
    end
end

```

```

        v2 = W2_d*Y1(:,i); %Calculo da entrada do neuronio da Camada de
saida
        Y(i) = ((a*tanh(b*v2))/2)+0.5); %Calculo da saida do neuronio da
Camada de saida
        e(i) = d(i)-Y(i); %Calculo do erro de treinamento (desejado -
obtido)
        delta2 = e(i)*(b/a)*(a-Y(i))*(a+Y(i));
        delta1 = (b/a)*((a-
Y1(2:m1+1,i)).*(a+Y1(2:m1+1,i))).*(W2_d(2:m1+1)')*delta2);

        W1_a2 = W1_a; %guarda os pesos da camada oculta 1 da epoca
anterior
        W1_a = W1_d; %guarda os pesos da camada oculta 1 desta epoca
        W2_a2 = W2_a; %guarda os pesos da camada de saida da epoca
anterior
        W2_a = W2_d; %guarda os pesos da camada de saida desta epoca
        W1_d = W1_a + (alfa*(W1_a-W1_a2)) + (eta*(delta1*x(:,i)'));
%Calcula os pesos da camada oculta 1 para a proxima epoca
        W2_d = W2_a + (alfa*(W2_a-W2_a2)) + (eta*(delta2*Y1(:,i)'));
%Calcula os pesos da camada de saida para a proxima epoca

    end

    EQM(rep,ep) = (e*e')/(2*size(e,2)); %Calculo do EQM de treinamento
    for i=1:size(x_t,2),
        v1 = W1_d*x_t(:,i); %Calculo das entradas dos neuronios da Camada
oculta 1
        Y1(2:m1+1,i) = ((a*tanh(b*v1))/2)+0.5); %Calculo das saidas dos
neuronios da Camada oculta 1
        Y1(1,i)=1;
        v2 = W2_d*Y1(:,i); %Calculo da entrada do neuronio da Camada de
saida
        Y(i) = ((a*tanh(b*v2))/2)+0.5); %Calculo da saida do neuronio
da Camada de saida
        e_t(i) = d_t(i)-Y(i); %Calculo do erro de teste (desejado -
obtido)
    end
    EQM_t(rep,ep) = (e_t*e_t')/(2*size(e_t,2)); %Calculo do EQM de TESTE
    if EQM_min > EQM_t(rep,ep)
        EQM_min = EQM_t(rep,ep); %armazena o menor EQM de Teste
        W1_f = W1_d;%W1rep(:, :, ep); %armazena os pesos da camada oculta 1
que teve o menor EQM
        W2_f = W2_d;%W2rep(ep, :); %armazena os pesos da camada de saida que
teve o menor EQM
    end
end
end
end

```