




Figura 5.5 – Interface do Matlab – Ilustração do Resultado do Treinamento de 10 amostras do arquivo de características do ECG, cardiopatia IAM.

Após o treinamento da rede, realizamos os testes de validação dos padrões treinados e na Figura 5.6 registramos o exemplo do processamento da rede, com o resultado da simulação com as amostras de treinamento, na qual obtivemos 100% de reconhecimento. A arquitetura utilizada para o exemplo que vemos na Figura 5.6 utilizou seis neurônios de entrada, quatorze neurônios na camada intermediária única e dois neurônios de saída, com a identificação das cardiopatias normais (1, 1), de infarto (-1, -1), de bloqueios (-1, 1) e demais cardiopatias (1, -1).




Figura 5.6 – Interface do Matlab – Resultado da validação da massa de treinamento com 1 ciclo e 10 coeficientes.

5.2.2. Reconhecimento

O reconhecimento das cardiopatias é a segunda fase do experimento. Para sua realização informamos na aplicação os seguintes parâmetros: a opção de operação “Classificação”, a derivação mestre para traçado de gráficos, os parâmetros para o cálculo dos coeficientes AR, as derivações que têm seus coeficientes calculados, o número de ciclos e a amostra selecionada. Os parâmetros utilizados para o cálculo do modelo AR e as derivações que farão parte do experimento devem ser exatamente as mesmas utilizadas na fase de treinamento, conforme vemos na Figura 5.7, onde temos apenas uma amostra selecionada, e seus parâmetros devidamente preenchidos.

Para o reconhecimento das amostras, realizamos testes individuais, criando para cada uma das amostras selecionadas, um arquivo específico para aplicação à

rede neural. Utilizamos este método para os três cenários escolhidos e para os dois tipos de janelamento do ciclo. A identificação de reconhecimento dá-se com 50% de aproximação do resultado alcançado para o valor alvo [ANDRADE, Adriano O; et al. 2005.], ou seja, avaliação dos valores resultantes do reconhecimento pela rede esteja acima ou abaixo do alvo em até 50% do seu valor, caso o resultado esperado para um neurônio for -1. Foram considerados como reconhecimento positivo os resultados compreendidos entre -0,5 e -1,5.

Exemplo: IAM → neurônios de saídas alvo -1, -1.

Amostra 1 → neurônios de saída → -0,86574, - 1,23656

→ reconhecimento OK

Amostra 2 → neurônios de saída → -0,38866, - 1,23776

→ reconhecimento NÃO OK




Figura 5.7 – Interface do aplicativo –Seleção de uma amostra, com um ciclo para reconhecimento pela rede neural, com dez coeficientes.

O teste de reconhecimento foi realizado aplicando cada uma das amostras à rede neural, tendo na Figura 5.8 o exemplo desta aplicação com a função de simulação da rede já treinada, onde em diversas amostras obtivemos resultado positivo de reconhecimento e em outras o reconhecimento não foi alcançado.




Figura 5.8 – Interface Matlab –Reconhecimento de amostras aplicadas à rede neural após o treinamento, amostra com um ciclo e 10 coeficientes.

Os resultados alcançados pelo reconhecimento estão dentro dos padrões encontrados na literatura para este tipo de sinal, que tem como característica amplitudes e formatos muito próximos entre uma cardiopatia e outra. A maior dificuldade no reconhecimento foi entre bloqueio e infarto agudo do miocárdio, pois eles têm características semelhantes em função de ambos causarem algum tipo de atraso na passagem do impulso pelo músculo cardíaco. Na Tabela 5.2 mostramos os resultados obtidos após a fase de reconhecimento com amostras de um ciclo.

O cenário que apresentou pior desempenho foi de ordem oito, que na cardiopatia bloqueio não atingiu o patamar de 80% de reconhecimento, não se mostrando eficaz para o objetivo do modelo, que é alcançar ou melhorar as metas já alcançadas em outras pesquisas semelhantes.

Para o cenário com um ciclo por amostras, o comportamento da rede com modelo AR de ordem seis, alcançou melhores resultados, atingindo 96% de reconhecimento no paciente de controle, e uma média de 93% para todas as amostras, que está na faixa dos índices alcançados em pesquisas na área. As dificuldades encontradas foram à diversidade do sinal de uma cardiopatia para outra, com amplitudes variadas para as mesmas amostras, e em contrapartida, tivemos também dificuldades entre as cardiopatias IAM e bloqueios, pois algumas vezes a área cardíaca afetada é a mesma, tornando o sinal semelhante, impedindo a rede de efetuar o reconhecimento correto. Mesmo com as dificuldades apontadas os índices de reconhecimento estão coerentes com os demais trabalhos pesquisados, para este tipo de sinal.

Tabela 5.2 – Resultados de validação e reconhecimento dos sinais ECG pela rede neural, cenário de um ciclo por amostra selecionada, com três ordens diferentes de análise.

Amostras com 1 ciclo			
Ordem AR	Patologia	Validação do Treino	Reconhecimento
10	ECG Normal	100%	92%
	IAM	100%	86%
	Bloqueio	100%	84%
	Outras	100%	88%
8	ECG Normal	100%	86%
	IAM	100%	78%
	Bloqueio	100%	76%
	Outras	100%	78%
6	ECG Normal	100%	96%
	IAM	100%	91%
	Bloqueio	100%	90%
	Outras	100%	93%

5.3. Cenário 2 – Amostras com dez ciclos de ECG

5.3.1. Treinamento

No segundo cenário temos a utilização de dez ciclos consecutivos e inteiros por amostra selecionada, com as mesmas opções de ordens para geração dos coeficientes. As opções de ordens utilizadas foram: dez, oito e seis.

O processamento deste cenário é semelhante ao primeiro, sendo que a diferença essencial é o parâmetro de número de ciclos que está marcado como 10. Na Figura 5.9 vemos uma parte da *interface* com os parâmetros preenchidos e a opção de número de ciclos informada em 10; os demais parâmetros estão preenchidos da mesma maneira que o primeiro cenário. No gráfico “Derivações do ECG Selecionado” observamos o traçado dos dez ciclos para todas as derivações selecionadas.




Figura 5.9 – Corte da Interface – área de seleção de parâmetros e gráficos de derivações para opção com dez ciclos.

Na Figura 5.10 destacamos o gráfico “AR x Derivação Selecionada” e um zoom do gráfico para mostrar em detalhe a reconstrução da curva, utilizando os coeficientes do modelo AR, sendo o ciclo original em azul e a curva reconstruída em

vermelho, neste gráfico também verificamos a opção dos dez ciclos escolhidos para a representação do sinal e aplicação dos cálculos dos coeficientes AR.




Figura 5.10 – Gráfico em zoom do registro dos coeficientes AR sobre a curva do ciclo original, em vermelho o resultado do cálculo do modelo AR e em azul a curva original de ECG.

Após a geração dos arquivos com os coeficientes e alvos pelo aplicativo, utilizamos o *Matlab* para o treinamento da rede neural. Os mesmos procedimentos de treinamento utilizados no primeiro cenário foram utilizados para o cenário com dez ciclos. O desempenho do treinamento não foi comprometido, pois mesmo com dez ciclos, o volume de dados ainda é bastante reduzido uma vez que utilizamos coeficientes representando o sinal original. Na fase de validação do treinamento da rede neural atingimos 100% de reconhecimento (índice esperado para esta fase).

5.3.2. Reconhecimento

Na fase de reconhecimento adotamos o percentual de 50% de aproximação do resultado alcançado em comparação o valor treinado. A identificação de reconhecimento dá-se com 50% de aproximação do resultado alcançado para o valor alvo. A Figura 5.11 mostra a *interface* do aplicativo com a seleção da amostra

para reconhecimento, a opção de operação selecionada é a “Classificação”, onde temos as amostras sem identificação de cardiopatia e sem a utilização de arquivo de alvos, com o parâmetro de número de ciclos marcado com dez ciclos.




Figura 5.11 – Interface do aplicativo – Seleção de uma amostra, com dez ciclos para reconhecimento pela rede neural, com dez coeficientes.

O teste de reconhecimento foi realizado submetendo cada uma das amostras selecionadas à rede neural e aferido os resultados. Na Figura 5.12 podemos observar o resultado dos experimentos, com a função de simulação da rede já treinada, para amostras formadas por dez ciclos consecutivos.




Figura 5.12– Interface Matlab – Reconhecimento de amostras aplicadas à rede neural após o treinamento, amostra com dez ciclo e dez coeficientes.

Semelhantes aos experimentos realizados no primeiro cenário, encontram como maior dificuldade no reconhecimento a diferenciação entre bloqueio e infarto agudo do miocárdio, pois eles têm características semelhantes em função de ambos possuírem algum tipo de atraso na passagem do impulso pelo músculo cardíaco. Na Tabela 5.3 mostramos os resultados obtidos após a fase de reconhecimento com amostras de dez ciclos.

Modelo AR de ordem dez apresentou o pior desempenho, onde observamos que no caso da cardiopatia bloqueio não foi atingido o patamar de 65% de reconhecimento, índices muito baixos para considerarmos como ferramenta eficiente na classificação de cardiopatias.

Para o cenário com dez ciclos por amostras, o comportamento da rede com do modelo AR de ordem oito alcançou melhores resultados, atingindo 85% de

reconhecimento no paciente de controle, e uma média de 80% para todas as amostras. Estes índices estão abaixo da média dos índices alcançados em pesquisas semelhantes. [Hedén,et al., 1997].

Tabela 5.3 – Resultados de validação e reconhecimento dos sinais ECG pela rede neural, cenário de dez ciclos por amostra selecionada.

Amostras com 10 ciclos			
Ordem AR	Patologia	Validação do Treino	Reconhecimento
10	ECG Normal	100%	71%
	IAM	100%	65%
	Bloqueio	100%	64%
	Outras	100%	68%
8	ECG Normal	100%	85%
	IAM	100%	77%
	Bloqueio	100%	76%
	Outras	100%	80%
6	ECG Normal	100%	81%
	IAM	100%	76%
	Bloqueio	100%	75%
	Outras	100%	77%

5.4. Cenário 3 – Amostras com um ciclo de ECG – 4 neurônios de saída

5.4.1. Treinamento

No terceiro cenário, realizamos uma escolha aleatória das amostras, com dez combinações por grupo de amostras para treinamento. As ordens do modelo AR escolhidas foram: dez, oito e seis.

O processamento deste cenário é semelhante ao primeiro, sendo que a diferença essencial é a forma de escolha de amostras para treinamento e a construção da rede neural, onde optamos por diminuir o número de neurônios na camada intermediária, de quatorze para cinco, (um experimento para avaliar o comportamento da rede). Com a base nos cenários anteriores, onde a rede encontrou dificuldade para distinguir as amostras de Bloqueios e IAM, modificamos para este cenário o número de neurônios de saída, de dois para quatro, com o objetivo de distanciar as identificações entre Bloqueios e IAM. A identificação foi experimentada de acordo com a identificação descrita a seguir:

⇒ Pacientes normais	-1, 1, -1, 1;
⇒ IAM	-1, -1, -1, -1;
⇒ Bloqueios	1, 1, 1, 1;
⇒ Demais cardiopatias	1, -1, 1, -1.

Após a geração dos arquivos com os coeficientes e alvos pelo aplicativo, utilizamos o *Matlab* para o treinamento da rede neural. Como nos cenários anteriores, na fase de validação do treinamento da rede neural atingimos 100% de reconhecimento.

5.4.2. Reconhecimento

Na fase de reconhecimento utilizamos o percentual de 50% de aproximação do resultado alcançado em comparação o valor treinado. A identificação de

reconhecimento dá-se com 50% de aproximação do resultado alcançado para o valor alvo. (valor alvo de 1 o reconhecimento está entre -0,5 a 0,5).

O teste de reconhecimento foi realizado submetendo cada uma das amostras selecionadas à rede neural e aferido os resultados.

Para alcançarmos um melhor resultado, reduzimos o número de neurônios na camada intermediária de quatorze para cinco. Aumentamos o número de neurônios de saída de dois para quatro, com o objetivo de distanciar a identificação dos bloqueios e dos infartos. Na Tabela 5.3 mostramos os resultados obtidos após a fase de reconhecimento.

Modelo AR de ordem oito apresentou o pior desempenho, pois na cardiopatia bloqueio não atingiu o patamar de 80% de reconhecimento, índices muito baixos para considerarmos como ferramenta eficiente na classificação de cardiopatias.

Para esse cenário, o comportamento da rede com do modelo AR de ordem seis alcançou melhores resultados, atingindo 97% de reconhecimento no paciente de controle, e um índice mínimo de reconhecimento de 93% para todas as amostras. Estes índices estão na média dos índices alcançados em pesquisas semelhantes. [Hedén, et al., 1997].

Tabela 5.4 – Resultados de validação e reconhecimento dos sinais ECG pela rede neural, cenário de dez ciclos por amostra selecionada.

Amostras com 1 ciclo			
Ordem AR	Patologia	Validação do Treino	Reconhecimento
10	ECG Normal	100%	93%
	IAM	100%	89%
	Bloqueio	100%	89%
	Demais Cardiatias	100%	89%
8	ECG Normal	100%	92%
	IAM	100%	81%
	Bloqueio	100%	79%
	Demais Cardiatias	100%	83%
6	ECG Normal	100%	97%
	IAM	100%	94%
	Bloqueio	100%	93%
	Demais Cardiatias	100%	95%

5.5. Conclusão

Para esse trabalho, experimentamos três cenários para as análises, o primeiro onde foi utilizado um ciclo selecionado aleatoriamente de cada amostra e o segundo com dez ciclos consecutivos por amostra (com uma rede configurada com dois neurônios de saída) e o terceiro com um ciclo por amostras, e o treinamento realizado com dez combinações de amostras, selecionadas aleatoriamente (com a rede configurada com quatro neurônios de saída). Foram utilizados modelo AR de ordens diferentes, sendo ordem dez, oito e seis. Os treinos e testes foram realizados utilizando seis derivações, selecionadas entre as de melhor índice de acerto,

segundo relatório de desempenho obtido no trabalho de Rangel, 2006. Para cada um dos cenários, foram treinadas na rede amostras com as características de ciclos de ECG's normais e patológicos apresentando as cardiopatias IAM, Bloqueios e demais cardiopatias.

A combinação mais eficiente encontrada em nossos testes foi com a utilização do modelo AR de ordem seis com um ciclo por amostra, numa rede neural configurada com cinco neurônios na camada intermediária e quatro neurônios de saída, alcançando o patamar de 97% para pacientes do grupo de controle e 93% de mínimo no reconhecimento nos três grupos. O resultado de pior desempenho foi o de ordem dez com dez ciclos por amostra. A grande dificuldade encontrada nos experimentos é a semelhança de algumas amostras das cardiopatias IAM e bloqueio, em função da área cardíaca acometida pela enfermidade, mas essa dificuldade foi atenuada quando utilizamos uma rede neural artificial com quatro neurônios de saída.

Entendemos que o método utilizado para reconhecimento do sinal ECG mostrou-se aderente ao objetivo do modelo proposto para a classificação de Cardiopatias através da análise do sinal ECG.

No próximo capítulo, apresentaremos nossas conclusões sobre o estudo, e analisamos as possibilidades de melhorias do modelo, bem como trabalhos futuros relacionados à nossa pesquisa.

Capítulo 6

Conclusão e Trabalhos Futuros

6.1. Conclusões Gerais

Neste trabalho, desenvolvemos um modelo capaz de classificar Cardiopatias através da análise de sinais ECG digitais. Para esse desenvolvimento utilizamos a extração de características do sinal ECG com o uso do modelo AR com LMS modificado, descrito por Soares e Andrade [SOARES, Alcimar Barbosa; et al. 2003.], sendo tais características classificadas por uma RNA.

A escolha do modelo AR mostrou-se capaz de representar o sinal ECG com vantagens sobre o uso do sinal original, tais como:

- Redução de informações redundantes ao sistema de classificação;
- Agilidade e simplicidade no processo de cálculo.

Para o estabelecimento da ordem e da constante de convergência, apoiamos-nos em trabalhos já desenvolvidos [ANDRADE, Adriano de Oliveira. 2000.] [SOARES, Alcimar Barbosa; et al. 2002.] [SOARES, Alcimar Barbosa; et al. 2003.] e

realizamos numerosos testes para chegarmos aos valores de melhor desempenho para este tipo de sinal.

Para a etapa de classificação utilizamos as redes neurais artificiais, com topologia MLP e como algoritmo de treinamento o *backpropagation*. Os coeficientes extraídos pelo modelo AR foram utilizados como informações de entrada da rede, fator que contribuiu para que a RNA não se tornasse pesada, permitindo assim alcançarmos bons resultados com agilidade e pequeno esforço computacional. Uma dificuldade encontrada na utilização da rede neural foi a determinação do melhor número de neurônios das camadas intermediárias e saída. Nesse trabalho experimentamos quatorze e cinco neurônios para camada intermediária, dois e quatro neurônios para camada de saída. Estabelecemos as quantidades de neurônios aproveitamos a experiência de outras pesquisas semelhantes encontradas na literatura [HEDEN, Bo; et al., em 1997].

O processo desenvolvido nesta solução pode ser resumido nas seguintes etapas:

- Captação do ciclo cardíaco separado utilizando o *software* de localização de ciclo cardíaco desenvolvido por Rangel, UFU, 2006;
- Selecionar a opção para processamento dos dados de treinamento ou reconhecimento do sinal;
- Extrair as características através do modelo AR, com LMS modificado, utilizando o *software* desenvolvido, com os parâmetros de entrada (janelamento do ciclo, ordem do modelo AR, constante de convergência e erro) para o cálculo.

- Gerar um arquivo com a base de dados no formato esperado pelo *Matlab*, para aplicação das características na Rede Neural, para treinamento ou reconhecimento;
- Processamento da Rede Neural *MLP*, com algoritmo de treinamento *backpropagation*, dos dados selecionados;
- Apuração e análise dos resultados de reconhecimento.

Os resultados alcançados mostraram-se aderentes ao objetivo do modelo proposto, sendo:

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

Realizamos os treinamentos com 80 amostras, selecionadas em três grupos de diferentes cardiopatias, sendo o primeiro grupo o de controle, com pessoas saudáveis, infarto agudo do miocárdio, bloqueios e outras cardiopatias agrupadas. Os experimentos foram realizados, considerando três cenários distintos: o primeiro com apenas um ciclo de cada amostra, o segundo com dez ciclos consecutivos para cada amostra e o terceiro, foi utilizada a metodologia de escolha aleatória das amostras e realizado o treinamento com os dez conjuntos previamente escolhidos, foi realizado também a redução do número de neurônios da camada intermediária e

aumento da camada de saída. No primeiro cenário, utilizamos dois tipos de janelamento do sinal, um abrangendo todo o ciclo e o outro utilizando um trecho menor buscando o complexo QRS e adjacências, para o segundo cenário utilizamos o ciclo completo. Para todos os cenários, processamos as análises com ordens do modelo AR, sendo: dez, oito e seis.

As maiores dificuldades no reconhecimento devem-se à presença dos seguintes fatores:

- Sinais muito diferenciados entre as derivações para a mesma cardiopatia;
- Sinais semelhantes para cardiopatias diferentes, em função de a área cardíaca afetada ser a mesma, ocasionando o mesmo efeito no curso do sinal através do músculo cardíaco.

Essas dificuldades não chegaram a comprometer o resultado final.

Podemos concluir que o modelo proposto para a classificação de cardiopatias cardíacas executa seu papel de acordo com o objetivo inicial e poderá ser utilizado como base em aplicações visando o suporte ao diagnóstico baseado em sinais ECG. Alcançamos um índice de reconhecimento em torno de 97%, com a utilização de ordem seis no cenário de um ciclo. O modelo AR de ordem dez com dez ciclos de análise foi o cenário de pior desempenho, com o menor índice de reconhecimento, 64% para a cardiopatia bloqueio. O melhor desempenho foi alcançado no cenário com modelo AR de ordem seis, com um ciclo de análise, para pacientes normais, atingindo 97% de reconhecimento das amostras.

Acreditamos que sua utilização futura possa contribuir para a agilidade e eficiência na sugestão de diagnóstico de cardiopatias através do ECG.

6.2. Trabalhos Futuros

Aprimoramento do modelo

O modelo poderá ser utilizado como programa de sugestão de diagnóstico, simplificando e agilizando a análise dos especialistas em Cardiologia, principalmente em situações de emergência, para tal sugerimos evoluções no modelo:

- Testar novas técnicas de extração de características do sinal como transformadas *wavelets*, que já estão sendo utilizadas em pesquisas mais recentes, podendo também apresentar excelentes resultados [LI, C; ZHENG, et al. 2000.];
- O aprimoramento do método de identificação automatizando a utilização de redes neurais para possibilitar o reconhecimento tempo real.

Trabalhos futuros

Entendemos como possíveis trabalhos futuros para a continuidade das pesquisas as seguintes sugestões:

- Criação de um sistema de alarme para utilização em cardiologia de monitoramento, onde o modelo acionaria um alarme na detecção de

alguma alteração no padrão de normalidade do paciente, com a utilização do modelo apresentado.

- Desenvolvimento de um protótipo em conjunto com programas de eletrocardiógrafos para teste do modelo em tempo real.

REFERÊNCIAS BIBLIOGRÁFICAS

AFONSO, VX; TOMPKINS, WJ; et al. **ECG beat detection using filter banks**. 1999. IEEE Trans Biomed Eng. 46(2):192-202. PMID: 9932341. Pubmed.

ANDRADE, Adriano de Oliveira. **Metodologia para Classificação de Sinais EMG no Controle de Membros Artificiais**. Uberlândia, 2000. Dissertação de Mestrado, Departamento de Engenharia Elétrica da Universidade Federal de Uberlândia - UFU, Brasil. 2000.

ANDRADE, Adriano O; NASUTO, Slowamir J.; KYBERD, Peter. **The GTM classifier and its application to the classification of motor unit action potentials**. 2005. 4th IEEE EMBSS UK and republic Ireland Postgraduate Conference in Biomedical Engineering and Medical Physics. University of Reading, Reading, UK. IEEE Press, pp.9-10.2005.

BAXT, WG; SHOFRER, FS; SITES, FD, et.al. **A neural computational aid to the diagnosis of acute myocardial infarction**. Department of Emergency Medicine, Hospital of the University of Pennsylvania, Philadelphia, PA 19104-4283, USA.

BINTZ, Jacques; et al. **Book Memorializing the scientists**. 1997. Foto de Augustus Desiré Waller. Biografia. Disponível em: <http://chem.ch.huji.ac.il/~eugeniik/history/waller.html>. Acessado em 14 jun 2006. [1].

BINTZ, Jacques; et al. **Book Memorializing the scientists**. 1997. Foto de Willem Einthoven. Biografia. Disponível em: <http://chem.ch.huji.ac.il/~eugeniik/history/einthoven.html>. Acessado em 14 jun 2006. [2].

BITTENCOURT, Murilo Guérios. **Noções de Eletrocardiografia**. Apostila da Universidade Federal do Paraná. 2001.

BOYLER, JOSEPH III. **Apostila de Fisiologia Cardiovascular**. 3ª edição. Editora Guanabara Koogan – 1998.

CHAZAL, P; CELLER, B. **Improving ECG diagnostic classification by combining multiple neural networks**. 1997. Computers in Cardiology. Vol 24. IEEE.

DECCACHE, Waldemar; CASTRO, Maria do Carmo V. de. **Eletrocardiograma**. Livraria e Editora Revinter Ltda, RJ – 1993.

DOUGLAS, Carlos Roberto. **Tratado de Fisiologia, aplicada à ciência da saúde**. 4ª edição. Probel Editorial. 2000.

EKG Measurements. 2004. Disponível em http://www.long-qt-syndrome.com/images/ekg_measurements_large.gif. Acessado em 12/06/2006.

FELDMAN, Henry. The **Precordial Leads in 3D. ER Club EKG Interpretation.** Disponível em <http://students.med.nyu.edu/erclub/ekgexpl2.html>. Acessado em 26/06/06.

GAMLYN, L.; NEEDHAM, P.; et al. **The Development of a Neural Network-Based Ambulatory ECG Monitor.** Springer London, Volume 8, Number 3, pp.273-278. ISSN: 0941-0642. 1999.

GE, Dingfei; SRINIVISAN, Narayanan; KRISHNAM, Shankar M. **BioMedical Engeneering OnLine.** Vol. 1, PUBMED record, artigo. 2002.

HALLAKE, José. **Eletrocardiografia.** Medsi Ed. Médica e Científica Ltda – 1994.

HEALTH, Heart. **This is the equipment used to record an ECG** (electrocardiogram). 2000. Disponível em <http://www.healthyheart.nhs.uk/about/about.shtml>. acessado em 13/08/2006.

HEDEN, Bo; OHLIN, Hans; et al. **Acute Myocardial Infarction Detected in the 12-Lead ECG by Artificial Neural Networks.** 1997. American Heart Association. Circulation. 1997;96:1798-1802.

HOLST, Holger; OHLSSON, Mattias; PETERSON Carsten; et. al. **A confident decision support system for interpreting electrocardiograms**. 1999. Clinical Physiologic & Func. In, vol. 19, issue 5, pp. 410-418.

JENKINS, Dean. **A (not so) brief history of electrocardiography**. ECG Library contents. 2002. Disponível em: www.ecglibrary.com/ecghist.html. Acessado em 21 mar 2005.

LEE, Dennis. **Illustration Heart Attack**.

Les dérivations d' un électrocardiogramme. 2000. Disponível em <http://foulon.chez-alice.fr/Alie%202.000/DATAS/MODULE1/derivECG.htm>. Acessado em 15/06/2006.

LI, C; ZHENG, C; TAI, C. **Detection of ECG characteristic points using wavelet transforms**. Biomedical Engineering Institute, Xi'an Jiaotong University, Shaanxi, P. R. China. 2000. PMID: 7851927 [PubMed - indexed for MEDLINE].

LIN, Kang-Ping; CHANG, W.H. **QRS feature extraction using linear prediction**. **Biomedical Engineering**. IEEE Transactions. V.36. p. 1050-1055. ISSN: 0018-9294. 1989.

LINDER, Udo K.; DUBIN, Dale B. **Interpretação Fácil do ECG**. - 6ª Ed. Editora: Livraria e Editora REVINTER Ltda. 1999.

MANDARIM, Carlos Alberto. **Anatomia do Coração – Clínica e Cirúrgica**. 1ª edição. Livraria e Editora REVINTER Ltda – 1990.

MENNA, Carlos. **Entrevista sobre Eletrocardiografia**. Médico Cardiologista da Rede Foccus de Diagnóstico – DixAmico, Grupo Amil. Realizada em 02 abr 2005.

NEVILLER, Conway. **Atlas de Cardiologia**. 2ª edição. Editora Maltese, Livraria Editora Santos– 1987.

OEFF, Michael. Base de Dados de Sinais de ECG. Physikalisch – Technische Bundesanstalt, PhysioNet-MIT Room E25-505A. USA. 2006. Disponível em: www.physionet.org/physiobank/database/ptbdb.

OHLSSON, E; et. al. **Neural network – a diagnostic tool in acute myocardial Infarction with concomitant left bundle branch block**. 2002. Clinical Physiologic & Func. In, vol. 22, pp. 295-299.

RANGEL, Hélio A. L. **Metodologia para localização de ciclo cardíaco a partir do sinal eletrocardiográfico**. 2006. Dissertação de mestrado. UFU – Universidade Federal de Uberlândia – MG – Brasil.

REBROVA, O. Yu; MAXIMOVA M. Yu; PIRADOV M.A. **The neural network algorithm for diagnosis of ischemic stroke pathogenetic subtypes**. Rússia.

2004. National Association of Russian Federation, anuário 2005, Maisons des Sciences de l'Homme, vol 0, fasc. 12. PUBMED; PMID (15628583).

RIBEIRO, Antonio Luiz Pinho. **Redefinindo o Infarto Agudo do Miocárdio**. 2002. eHealth Latin América. Disponível em: <http://www.bibliomed.com.br/lib/ShowDoc.cfm?LibDocID=12688&ReturnCatID=1815>. Acessado em 17 abr 2005.

SILVA, Mauricio R. **Fisiocardiopatia da Circulação**. 1ª Ed. Editora Atheneu. 2000.

SOARES, Alcimar Barbosa; ANDRADE, Adriano O; LAMOUNIER, Edgard; et al. **The Development of a Virtual Myoelectric Prothesis Controlled by EMG Pattern Recognition System Based on Neural Network**. Journal of Intelligent Information System, 21:2, 127-141, 2003.

SOARES, Alcimar Barbosa; VEIGA, Antonio C. P.; ANDRADE, Adriano O.; et al. **Functional Languages in Signal Processing Applied to Prosthetic Limb Control**. SAMS, 2002, vol. 42, 2002, pp1377-1389.

STANTON, Kathleen M. Circulatory System – image. 2005. School of Public Health and Health professions. University at Buffalo, State University of New York. Disponível em: http://agingresearch.buffalo.edu/assets/images/chf_circulatory_system.jpg. Acessado em 10-jun-2006.

TATIBEANO, Cássia Y; KAETSU, Deise Y. Redes Neurais. Disponível em <http://www.din.uem.br/ia/neurais/#links>. Acessado em 12-mai-2006.

TU, C; ZENG, Y; YANG, X. **Nonlinear processing and analysis of ECG data.** Biomechanics & Medical Information Institute, Beijing Polytechnic University, P.R.China 100022. 2004. PMID: 15096682 [PubMed - indexed for MEDLINE].

Universal Medical Center. The Ohio State University Medical Center. Imagem - Electrical System of the Heart. Disponível em http://medicalcenter.osu.edu/images/greystone/ei_0018.jpg. Acessado em 12/06/2006.