

## Sistema Especialista Híbrido: Uma Aplicação para Diagnóstico de Múltiplas Doenças

Jean Rojas<sup>1</sup>, Paulemir Campos<sup>1</sup>, Fábio Ferreira<sup>1</sup>; Lourival Almeida Junior<sup>1</sup>, Igor Cavalcanti<sup>1</sup>,  
Lourdes Brasil<sup>2</sup>, Fernando Azevedo<sup>3</sup>, Mário Brito Filho<sup>1</sup>, Antônio Almeida<sup>4</sup>

<sup>1</sup>Núcleo de Estudos e Tecnologia em Engenharia Biomédica (*NETEB*)  
Mestrado em Engenharia Biomédica  
Universidade Federal da Paraíba (*UFPB*)  
Campus I – Caixa Postal 5095  
Cep: 58051-970, Fone: +55-83-2167067, Fax: +55-83-2167369  
João Pessoa - PB, Brasil

<sup>2</sup>Universidade Católica de Brasília (*UCB*)  
Diretoria do Programa de Tecnologia de Informação e Comunicação  
Campos II – Pós-Graduação, SGAN 916, Módulo B  
Cep: 70790-160, Fone: +55-61-3405550  
Brasília – DF, Brasil

<sup>3</sup>Departamento de Engenharia Elétrica, Instituto de Engenharia Biomédica (*IEB*)  
Universidade Federal de Santa Catarina (*UFSC*)  
Cep: 88040-900, Fone: +55-48-3319594  
Florianópolis - SC, Brasil

<sup>4</sup>Cardio Lógica Métodos Diagnósticos LTDA  
Av: Rui Barbosa, 143, Torre  
Cep: 58040-490, Fone: +55-83-2444878  
João Pessoa - PB, Brasil

E-Mails: [jcabrera@terra.com.br](mailto:jcabrera@terra.com.br), [lmb@ucb.br](mailto:lmb@ucb.br), [azevedo@ieb.ufsc.br](mailto:azevedo@ieb.ufsc.br)

### Abstract

*This work describes the implementation of a Hybrid Expert System (HES) applied to multiple disease diagnosis. The implementation process begins with the Knowledge Acquisition (KA), originated from a series of clinical parameters regarding each specific domain. In the proposed HES, the clinical parameters are used as input data for the Neural Network Based Expert System (NNES), hence, all obtained knowledge is converted to fuzzy rules. The NNES learning process and optimization is performed through the Genetic-Backpropagation Based Learning algorithm (GENBACK). The abstracted NNES knowledge, which is already refined, trained and tested, is used to form the Rule Based Expert System (RBES) knowledge base. The rule extraction algorithm is the Fuzzy Rule Extraction Algorithm (FUZZYRULEXT), and it is used to better explain the answer provided by the connectionist system output. In this context, the HES (v.1.0) has been used in epileptic crisis classification and also in breast cancer. For the first domain, it has presented a hit rate varying*

*from 63,6% to 83,3%, and for the second, the partial tests have showed a variation of hits from 50% to 70%. At the moment, the HES (v.2.0) is also being tested to help defining the therapeutic conduct in coronary.*

### 1. Introdução

O objetivo principal deste trabalho é apresentar um SEH destinado ao diagnóstico de múltiplas doenças. Em sua primeira versão, o sistema foi testado e avaliado com casos clínicos reais referentes ao domínio pertencente à classificação de crises epiléticas [1], como também na classificação de câncer de mama [2].

Atualmente, o sistema encontra-se em sua segunda versão de desenvolvimento, abrangendo também um domínio restrito da cardiologia. Além da inclusão do novo domínio, a nova versão incorpora alguns aperfeiçoamentos, por exemplo, a utilização de um Banco de Dados robusto, migração para linguagens de programação mais poderosas, manipulação do Banco de Dados através da *Internet*, otimização de algoritmos, entre outras.

O módulo do sistema, que contém o novo domínio, foi denominado de EXPERT CARDIO, e é destinado ao apoio à decisão de uma equipe clínico-cirúrgica na área de cardiologia. Essa equipe é formada por um cardiologista, um hemodinamicista e um cirurgião cardíaco.

O objetivo principal que se espera alcançar com o EXPERT CARDIO é auxiliar o processo de decisão da equipe clínico-cirúrgica podendo, ao final do processamento, inferir por uma conduta clínica, uma angioplastia coronariana ou uma cirurgia de revascularização [3].

Portanto, para que o SEH possa inferir por diagnósticos em cada domínio, é proposta, primeiramente, a implementação de uma Rede Neural Artificial (RNA) *Fuzzy* direta supervisionada de múltiplas camadas, a qual é alimentada por parâmetros clínicos, obtidos junto aos especialistas de domínio.

A primeira etapa do sistema corresponde ao processo de AC. Neste processo é necessária a aplicação das técnicas de Elicitação de Conhecimento (EC), descritas em [4] e [5], mais apropriadas para o cada domínio. Além disso, outro elemento que compõe esta etapa corresponde à análise dos parâmetros clínicos. Os parâmetros clínicos são fornecidos pelos especialistas médicos.

Na segunda etapa é necessária a criação de algumas regras iniciais e um conjunto de exemplos adquiridos na fase de EC a fim de que sejam utilizados para o treinamento da RNA do SERN. É necessário também, após o treinamento da rede, um segundo conjunto de exemplos que é utilizado no refinamento e na validação o SERN.

E, finalmente, com o objetivo de superar a deficiência do SERN em prover meios de explanação aceitáveis, desenvolveu-se aqui uma metodologia de extração de conhecimento do SERN. Isto porque uma das principais causas de rejeição do uso de um SERN, pelos especialistas de domínio, está diretamente associada à capacidade de explicar de maneira clara e objetiva como o sistema chegou a uma determinada conclusão.

Assim, caso se represente este mesmo conhecimento de uma outra maneira, como por exemplo, através de regras de produção do tipo “SE... ENTÃO...”, o sistema torna-se mais aceitável pelos especialistas. Por esse motivo, convencionou-se a adoção dessa metodologia. Dessa forma, o conjunto das regras extraídas do SERN é usado aqui, para formar a Base de Conhecimento (BC) do SEBR.

Portanto, nesta segunda versão do SEH, pretende-se realizar o confronto dos novos resultados com os obtidos nos testes da primeira versão para os domínios de epilepsia e mastologia, bem como avaliar seu desempenho para o novo módulo acoplado.

## 2. Materiais e Métodos

O processo de implementação inicia-se com a AC, proveniente da análise de uma série de parâmetros clínicos, os quais formam os parâmetros de entrada do SERN.

A seguir, todo o conhecimento adquirido é convertido em regras de produção onde as variáveis são padronizadas e as imprecisões são tratadas com o auxílio da lógica *fuzzy* [6]. Através dessas regras é possível realizar o mapeamento do conhecimento em grafos E/OU que inicialmente representam a estrutura do SERN.

Dois conjuntos de exemplos são apresentados ao SERN, formados por sintomas e diagnóstico. O primeiro conjunto de exemplos é usado para treinar o SERN através do algoritmo de aprendizado. O segundo conjunto é usado para refinar e validar o SERN (Figura 1).

O SERN é formado por uma camada de entrada, uma intermediária e uma de saída. Os neurônios da camada de entrada correspondem aos sintomas, em outras palavras, a parte SE das regras *fuzzy*. A camada intermediária, durante o processamento, deverá ser otimizada pelo algoritmo proposto e representa as hipóteses intermediárias, isto é, corresponde às premissas das regras *fuzzy*. O número de neurônios na camada intermediária da RNA *Fuzzy* inicial corresponde à quantidade de regras iniciais obtidas durante a EC. A camada de saída representa os possíveis diagnósticos e correspondem às conclusões, ou seja, a parte ENTÃO das regras *fuzzy* [7], [8].

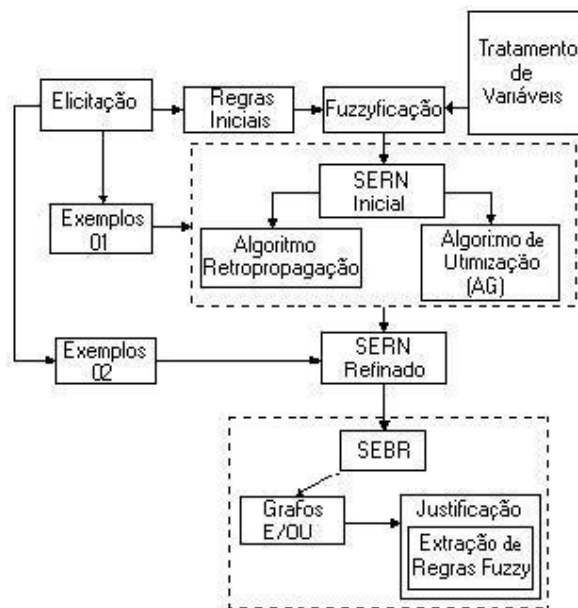


Figura 1 - Diagrama geral do SEH

O conhecimento das regras iniciais somado ao conhecimento oriundo dos conjuntos de exemplos fornecidos pelo especialista, após terem sido treinados, refinados e validados, são representados em um grafo E/OU com a finalidade de facilitar a tarefa de mapeamento destes conhecimentos em um sistema simbólico.

O grafo E/OU indica o número de neurônios nas camadas de entrada, intermediária e saída. O grafo também mostra a existência de conceitos intermediários e suas conexões, que são decodificadas na camada intermediária da RNA. A camada intermediária é

definida como nós E, e a camada de saída como nós OU [7], [8].

A Figura 2 mostra um possível exemplo de uma rede neural *fuzzy* inicial, assim como regras *fuzzy* iniciais que estão sendo usadas para criar a rede.

As variáveis *fuzzy* nas regras *fuzzy* são tratadas da seguinte maneira: os valores em lógica *fuzzy* são representados através de graus de pertinência, no intervalo de [0,1], que são definidos usando-se uma função de pertinência. O método utilizado neste trabalho para tratar a função de pertinência faz uso dos operadores Max/Min [7], [8].

Na Figura 2, algumas regras *fuzzy* iniciais do SERN são apresentadas. É importante lembrar que as variáveis de A a F representam os graus de pertinência, obtidos durante o processo de “fuzzyficação”, enquanto que de X a Z, representam a saída do sistema. Além disso, as regras *fuzzy* iniciais estão padronizadas de acordo com as Cláusulas de Horn, onde cada regra *fuzzy* tem um antecedente consistindo de uma ou mais condições, bem como, um único conseqüente [7], [8].

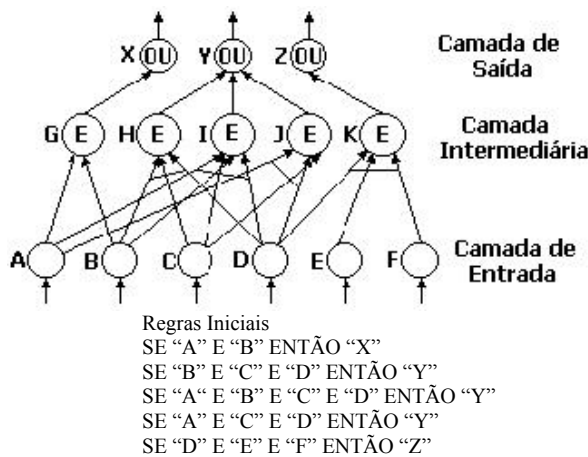


Figura 2 - Regras *fuzzy* iniciais

O aprendizado e a otimização do sistema, no estágio de refinamento, é feito através do algoritmo GENBACK. Esse algoritmo utiliza Algoritmo Genético (AG) como uma ferramenta para auxiliar na determinação da topologia de rede que melhor se adapta ao problema em questão.

O GENBACK tem as seguintes características: utiliza AG para ajudar na otimização do número de neurônios da camada intermediária da RNA, trata as variáveis de entrada de rede através da lógica *fuzzy* e no lugar da soma dos pesos, utiliza os conectivos lógicos E/OU.

O GENBACK, em seu primeiro estágio, considera que o SERN já existe. Utiliza um conjunto de exemplos para efetuar mudanças não somente nos pesos das conexões, mas também na estrutura de rede. As conexões podem ser incluídas ou excluídas entre os neurônios, assim como neurônios podem ser incluídos ou excluídos da camada intermediária pela aplicação do AG. Assim, o algoritmo pode produzir novos conceitos que não estavam presentes nas regras iniciais e,

conseqüentemente, pode-se deduzir regras que o especialista teve dificuldade de articular [7], [8].

A avaliação da aptidão de cada rede criada é auxiliada através do processo de treinamento da rede pelo GENBACK para determinar quais redes são mais aptas a sobreviverem. A função de custo, utilizada neste processo, é obtida em função do erro total ocorrido durante o treinamento da rede em questão. Esta função foi obtida de modo a descrever o problema em estudo de duas formas:

$$F1 = NCH/ERRO \quad (1)$$

$$F2 = 1/NCH + ERRO \quad (2)$$

onde NCH corresponde ao número de neurônios da camada intermediária, e ERRO corresponde ao erro na saída do SERN.

A função F1 faz, em geral, que a rede vencedora tenha mais neurônios que a rede inicial, enquanto que na função F2, a rede vencedora passa, em geral, a ter menos neurônios que a rede inicial.

A metodologia utilizada para extração das regras do SERN é baseada no algoritmo FUZZYRULEXT [9][10], conforme descrevemos sucintamente a seguir:

1. Passar como parâmetro de entrada um arquivo contendo os padrões de entrada e saída “fuzzificados”, usado no treinamento da RNA do SERN, e um outro arquivo com informações sobre a topologia da rede e os valores dos pesos da RNA já treinada;
2. Construir um grafo E/OU considerando apenas os pesos positivos entre as camadas da RNA treinada;
3. Determinar os antecedentes das regras através do método decomposicional. Para tanto, deve-se utilizar o grafo E/OU do passo anterior para encontrar caminhos que, partindo da camada de saída, atinja-se a camada de entrada da rede. Feito isso, soma-se os pesos de cada um desses caminhos constituindo assim os pesos acumulados de cada neurônio da camada de entrada. Calculam-se, em seguida, os impactos na rede que cada um desses neurônios de entrada provocará na saída multiplicando cada valor *fuzzy* dos padrões de entrada destes neurônios pelos respectivos pesos acumulados. Os antecedentes que farão parte das regras extraídas serão todos aqueles que obtiverem valor de impacto de rede maior que um valor pré-estabelecido;
4. Aplicar a técnica pedagógica para encontrar os conseqüentes dessas regras. Serão considerados como parte “ENTÃO...” das regras extraídas todos os neurônios de saída que tiverem valor padrão *fuzzy* de saída superior a um determinado valor;
5. “Desfuzzificar” os valores dos neurônios de entrada e saída da rede que serão atribuídos às partes “SE... ENTÃO...” das respectivas regras;
6. Criar essas regras na forma de cláusulas de Horn;
7. E, finalmente, salvar cada uma dessas regras, desde que sejam inéditas, num arquivo. Note que este conjunto de regras representa a BC de um típico SEBR.

Este procedimento foi implementado através da linguagem de programação procedural *Object Pascal* [11]. Porém, com o intuito de se obter uma melhor

performance durante a etapa de explanação de uma dada saída apresentada pelo SERN em resposta aos dados de entrada passados ao sistema, utilizamos a linguagem de programação declarativa *Visual Prolog*.

A utilização do *Visual Prolog*, deve-se ao seu mecanismo de *backtracking*, o que aumenta em muito a performance de análise de várias possibilidades de saída em relação ao que poderia ser feito por uma outra linguagem de programação procedural qualquer.

O processo de explanação funciona da seguinte forma:

1. Desenvolveu-se uma máquina de inferência com o *Visual Prolog* como uma DLL (*Dinamic Link Library*) para servir de interface entre a aplicação feita no DELPHI. Sempre que é requerida uma explanação pelo usuário, essa DDL *Visual Prolog* é acionada pelo sistema em DELPHI;
2. Além disso, foi necessário também implementar uma DLL no DELPHI, que é acionada pela DDL *Visual Prolog* para poder receber os dados de entrada, por exemplo, sintomas de uma doença de um dado paciente, para ser analisado pela máquina de inferência;
3. Esta máquina de inferência confronta esses dados com as regras que foram extraídas da RNA para poder chegar numa dada explanação;
4. Por fim, a DLL *Visual Prolog* retorna para a aplicação em DELPHI, a explanação mais adequada que encontrou para a saída fornecida pelo SERN de acordo com os dados de entrada e com as regras que foram previamente extraídas.

### 3. Resultados

Em sua versão 1.0, a metodologia de desenvolvimento do SEH foi testada para casos reais relacionados à classificação de crises epiléticas, bem como na classificação de câncer de mama.

A complexidade de estrutura de rede, na classificação de crises epiléticas, é composta por 32 neurônios na camada de entrada (sintomas), 11 neurônios na camada intermediária e 4 neurônios na camada de saída (diagnósticos).

No geral, observou-se que a taxa de acerto, para o referido domínio, variou na faixa de 63,6% a 83,3%. Abaixo relacionamos os resultados obtidos para o referido domínio.

#### Resultados do SERN

Os *Dados* da Tabela 1 e Tabela 2 correspondem aos resultados obtidos em algumas simulações para casos clínicos de classificação de crises epiléticas.

Tabela 1 - Dados das simulações <sup>a</sup>

Dados										
S	NG	IP	CR	MR	T	$\alpha$	$\beta$	NE	Nhlw	F
1	5	8	0.6	0.1	0.01	0.1	0.05	250	15	1.45
2	5	8	0.6	0.1	0.01	0.1	0.05	1,000	16	1.78
3	5	8	0.6	0.1	0.01	0.3	0.7	1,250	16	1.65
4	5	20	0.6	0.1	0.01	0.1	0.05	1,500	16	1.79

<sup>a</sup> S - simulações; NG – número de gerações; IP - população inicial; CR – taxa de *crossover*; MR – taxa de mutação; T – tolerância;  $\alpha$  - taxa de aprendizado;  $\beta$  - momento; NE – número de épocas; Nh/w – número de neurônios da camada intermediária da rede vencedora; F – aptidão

Tabela 2 – Reconhecimento de padrões <sup>b</sup>

Quantidade de padrões de teste		
S	NH	PH (%)
1	9	81.8
2	7	63.6
3	7	63.6
4	8	72.7

<sup>b</sup> S - simulações; NH – número de acertos; PH – porcentagem de acertos.

#### Resultados do SEBR

A Tabela 3 mostra os resultados de simulações para casos clínicos de classificação de crise epilética.

Tabela 3 - Classificação de crise epilética <sup>c</sup>

S	NIL	NHL	NOL	DST	NRR	NRW	NH	PH (%)
1	6	4	3	6	8	7	5	83.3
2	6	10	3	6	23	12	5	83.3
3	6	10	3	6	30	13	5	83.3
4	32	13	4	9	43	27	7	77.8

<sup>c</sup> S- simulação; NIL – número de neurônios na camada de entrada; NHL – número de neurônios na camada intermediária; NOL – número de neurônios na camada de saída; DST – número de casos testados; NRR – número de regras redundantes geradas; NRW – número de regras sem redundância geradas; NH – número de acertos; PH – porcentagem de acertos

Os casos clínicos utilizados para a classificação de crise epilética foram obtidos junto ao Hospital Universitário (HU) da Universidade Federal de Santa Catarina (UFSC), Brasil [1], [7].

Para o domínio da mastologia, cuja complexidade de estrutura de rede é composta por 9 neurônios na camada de entrada; 5, 10 ou 15 neurônios na camada intermediária e 2 neurônios na camada de saída, os testes no SERN mostram que a taxa de acerto varia na faixa de 50% a 70%, conforme Tabela 4 e Tabela 5. Os testes do SEBR encontram-se em andamento.

Os casos clínicos utilizados para a classificação de câncer de mama foram obtidos junto ao Hospital da Universidade de Wisconsin (Madison-USA).

Tabela 4.- Dados das simulações <sup>a</sup>

Dados										
S	NG	IP	CR	MR	T	$\alpha$	$\beta$	NE	Nhlw	F
1	3	6	0.6	0.1	0.1	0.4	0.1	2000	4	0.10
2	3	6	0.6	0.1	0.1	0.4	0.1	2000	4	0.12
3	3	6	0.6	0.1	0.1	0.4	0.1	2000	13	3.09
4	3	6	0.6	0.1	0.1	0.1	0.1	2000	20	2.64

Tabela 5 – Reconhecimento de padrões<sup>b</sup>

Quantidade de padrões de teste		
S	NH	PH (%)
1	5	50.0
2	6	60.0
3	7	70.0
4	8	53.3

#### 4. Discussão e Conclusões

Atualmente pode-se afirmar que o hibridismo entre as técnicas utilizadas pelo SERN e pelo SEBR é o mais adequado para alcançar o objetivo de nosso trabalho - obter um SEH que responda, com um certo grau de confiança, o conhecimento elicitado de um especialista de domínio médico para uma determinada tarefa – considerando que no domínio médico freqüentemente as informações não são determinísticas e o tratamento de incertezas e imprecisões é essencial.

No momento, o EXPERT CARDIO encontra-se em fase de ajustes e sendo testado com casos clínicos retrospectivos, previamente selecionados, obtidos junto às clínicas Cardio Lógica Métodos Diagnósticos LTDA e o Centro Neuro Vascular e do Coração (CINVASCOR), ambas situadas na cidade de João Pessoa, Paraíba, Brasil. Sua complexidade de rede é composta por 70 neurônios na camada de entrada, 12 na intermediária e 3 na de saída. Contudo, por se tratar praticamente da mesma metodologia testada na versão 1.0 do SEH, espera-se que os resultados alcançados sejam igualmente satisfatórios.

Outro aspecto relevante na nova versão do SEH, diz respeito à utilização do Sistema Gerenciador de Banco de Dados (SGBD) *SQL Server* 2000 [12]. Através dessa arquitetura (Cliente/Servidor), todas as informações contidas no Prontuário Eletrônico do Paciente (PEP) são armazenadas nas Bases de Dados do SEH e, conseqüentemente, podem ser acessadas e manipuladas através da *Internet*, pelos especialistas de domínio, cada qual com suas restrições de acesso.

#### Agradecimentos

Manifestamos nossos agradecimentos às seguintes instituições: ao Hospital Universitário da Universidade Federal de Santa Catarina, Brasil, especificamente ao Prof. Dr. Paulo C.T. Bittencourt e ao Dr. Li Shin Min pelas informações para classificação de crises epiléticas; ao Hospital da Universidade de Wisconsin (Madison-USA) pelo banco de dados sobre câncer de mama cedido pelo Dr. William H. Wolberg; os cinco primeiros autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), ao Programa Institucional de Bolsas de Iniciação Científica (PIBIC), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro para o desenvolvimento deste trabalho.

#### Referências

- [1] Brasil, L.M., de Azevedo, F.M., Barreto, J.M. (2000), "A hybrid expert system for the diagnosis of epileptic crisis", *Special Issue in Artificial Intelligence in Medicine (AIM)*, ISSN 0933-3657/00, Amsterdam, Holland, v.1-3, no. 21, p. 227-233.
- [2] Silva, I.G.L. da, Amorim, B.P., Campos, P. G., Brasil, L.M. (2002), "Integration of data mining and hybrid expert system", *Proceedings of the Special Track on Integrated Intelligent Systems (FLAIRS-2002)*, Florida, USA, May 16-18.
- [3] Rojas, J.C.C., Silva, I.G.L., Campos, P.G., Batista, C.E., Amorim, B.P., Brasil, L.M., de Azevedo F.M., Filho, M.T.B., de Almeida, A.E.M. (2002) "Sistema Especialista Híbrido Aplicado à Área Médica", CD-ROM *Anais do Congresso Brasileiro de Informática em Saúde, CBIS2002*, Natal, Brasil
- [4] Brasil, L.M. (1994), *Aquisição de Conhecimento Aplicada ao Diagnóstico de Epilepsia*, Dissertação de Mestrado em Engenharia Elétrica, Área de concentração em Engenharia Biomédica, IEB/UFSC, Florianópolis, Brasil.
- [5] Brasil, L.M., de Azevedo, F.M., Bittencourt, P.C.T., Min, L.S. (2000), "Técnicas para a extração do conhecimento a serem utilizadas para sistemas especialistas", *XVII Congresso Brasileiro de Engenharia Biomédica (CBEB'2000)*, Florianópolis, SC, p. 824-829, 11-13 Setembro.
- [6] Zimmermann, H.J. (1991), "Fuzzy set theory – and its applications", Kluwer Academic Publishes, Norwell, Massachusetts.
- [7] Brasil, L.M. (1999), *Proposta de Arquitetura para Sistema Especialista Híbrido e a Correspondente Metodologia de Aquisição do Conhecimento*, Tese de Doutorado em Engenharia Elétrica, Área de concentração em Engenharia Biomédica, IEB/UFSC, Florianópolis, Brasil.
- [8] Azevedo, F.M. de, Brasil, L.M., Limão, R.C.O. (2000), *Redes Neurais com Aplicações em Controle e em Sistemas Especialistas*, ISBN 85-7502-005-6, Bookstore Livraria Ltda. Florianópolis, Brasil, 2000.
- [9] Amorim, B.P., Brasil, L.M., Rojas, J.C.C., Silva, I.G.L., Filho, M.T.B., de Azevedo, F.M., Almeida, A.E.M. (2001), "Extraction of fuzzy rules for and/or fuzzy artificial neural networks", *Proceedings of the First Vietnam-Japan Bilateral Symposium on Biomedical Imaging/Medical Informatics and Applications (VJMEDI-MAG'2001)*, Hanoi, Vietnam, p. 108-114, 24-25 November.
- [10] Brasil, L.M., de Azevedo, F.M. (2003) "Técnica de extração de regras para sistemas especialistas conexionistas". *Revista Brasileira de Engenharia - RBE - Journal of Biomedical Engineering*, Rio de Janeiro, Brasil, (In Press).
- [11] Borland Delphi 5 for Windows 98, Windows 95 & Windows NT, Quick Start. Inprise Corporation, 1999.
- [12] Microsoft SQL Server 2000, SQL Server Books on line, Microsoft Corporation, 2000.