

250704-4

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE INFORMÁTICA
CURSO DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

Aprendizagem em Sistemas Híbridos

ALEX GUAZZELLI

Dissertação de Mestrado

Prof. Dr. Dante Augusto Couto Barone
Orientador

Profa. Dra. Beatriz de Faria Leão
Co-orientadora



UFRGS



85231373

SABi

Porto Alegre, junho de 1994

**UFRGS
INSTITUTO DE INFORMÁTICA
BIBLIOTECA**

INSTITUTO DE INFORMÁTICA	UFRGS
BIBLIOTECA	UFRGS
ORIENTADOR	PROF. DR. DANTE AUGUSTO COUTO BARONE
CO-ORIENTADORA	PROFA. DRA. BEATRIZ DE FARIA LEÃO
DATA DE RECEBIMENTO	03/06/94
VALOR	
FORMA	
MUNDO	

CIP - CATALOGAÇÃO NA PUBLICAÇÃO

Guazzelli, Alex

Aprendizagem em sistemas híbridos / Alex Guazzelli. - Porto Alegre: CPGCC da UFRGS, 1994.

131p.: il.

Dissertação (mestrado) - Universidade Federal do Rio Grande do Sul, Curso de Pós-Graduação em Ciência da Computação, Porto Alegre, 1994. Orientador: Barone, Dante Augusto Couto. Co-orientadora: Leão, Beatriz de Faria.

Dissertação: Inteligência Artificial, Sistemas Especialistas, Aprendizado de Máquina, Redes Neurais, Sistemas Híbridos, Informática Aplicada à Medicina, Teoria da Adaptação Ressonante, Sensibilidade, Especificidade e Relevância.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO
Sistema de Biblioteca da UFRGS

30208

681.3.011(043)
G919A

INF
1994/250704-4
1994/10/13

A Deus pelo seu infinito amor.

AGRADECIMENTOS

Este trabalho só foi possível graças à colaboração de várias pessoas. Cada uma em um determinado momento, apoiando, incentivando, dando idéias, discutindo e até mesmo distraíndo. Por isto, desejo expressar a todos o meu mais profundo agradecimento, especialmente:

À Dra. Beatriz de Faria Leão, assessora de informática e líder do grupo de pesquisa em Inteligência Artificial aplicada à Medicina do Instituto de Cardiologia RS, pelo seu brilhantismo, orientação, ensinamentos, amizade, apoio, incentivo, paciência e alegria.

Ao Prof. Dante Augusto Couto Barone, professor adjunto do Instituto de Informática da UFRGS, pelos ensinamentos, irrestrito apoio, exemplo de moral, amizade e incentivo.

Ao Prof. Manoel Luiz Leão pela confiança, apoio e revisão final do texto.

Aos amigos Altino, Eliseo e Eneida, membros do grupo de pesquisa em Inteligência Artificial aplicada à Medicina do ICFUC, pela sincera amizade, incentivo e alegria. Em especial à Eneida pelo auxílio com os procedimentos estatísticos.

Aos amigos da Unidade de Pesquisa: Carmem, Lúcia, Marcos, Miguel, Regina, Rosinha, Rose, Vera e Zezinho pela adorável convivência durante o período em que trabalhei no Instituto de Cardiologia - RS. Em especial, à Rose pelo auxílio na formatação do texto e por ter deixado de fumar por dois meses; bem como à Rosinha pelos importantes fluidos positivos.

Ao Daniel, Dino, Fernando e Rodrigo, colegas de bacharelado e de mestrado, por sua amizade, incentivo e apoio.

Aos colegas de mestrado Álfio, Cláudia, Denise, Ernesto, Elói, Giba, Lú, Marianinha, Martín, Nara, Osório, Otília, Rafael, Renata, Ricardo, Soraia e Uebel, pela amizade, incentivo e alegria.

Aos funcionários do Instituto de Informática da UFRGS, pelo bom-humor, amizade e alegria.

Aos funcionários da biblioteca, pelo auxílio com as referências bibliográficas.

Ao pessoal do Centro de Supercomputação da UFRGS e à Cray Research Inc., pelo incentivo, apoio e confiança.

Aos integrantes do grupo de pesquisa em Computação Cognitiva da Universidade da Califórnia - San Diego, em especial a Rik, Bill e Filipo, por terem feito da minha estadia em San Diego um sucesso.

Aos amigos da UCSD, Andrea, Sainan, Janine, Renata, Natalie, Maria, Antonio, Paul, Fu-Sheng e Trine, pela sua amizade, incentivo e apoio emocional.

À Sra. Jayne Keller, por toda sua ajuda e incentivo durante o período em que trabalhei no Centro de Supercomputação de San Diego.

Ao Maurício, Carla, Brian, Mary e Curtis por terem sido minha família em San Diego.

Ao Dr. Ricardo Machado pelo apoio, incentivo e inesquecível orientação durante o período em que trabalhei no Centro Científico da IBM - Rio.

Ao Levi, Enéas, Renata e D. Marina pela amizade, incentivo e por todo o apoio e carinho com que fui tratado durante o período em que permaneci no Rio de Janeiro.

Ao Prof. Edson Carvalho Filho, do Departamento de Informática da Universidade Federal de Pernambuco, pelos ensinamentos iniciais sobre ART, e à Prof. Mara Abel, do Instituto de Informática da UFRGS, pelos primeiros ensinamentos sobre sistemas especialistas.

À minha família, em especial ao Nélio, Sirlei, Max e Tânia, pelo seu imenso amor, amizade, paciência, apoio, incentivo, moral, conselhos e compreensão.

LISTA DE ABREVIATURAS

ART	Teoria da Adaptação Ressonante (<i>Adaptive Resonance Theory</i>)
BCH	Base de Conhecimento Híbrida
CHD	Cardiopatias Congênitas (<i>Congenital Heart Diseases</i>)
CPGCC	Curso de Pós-Graduação em Ciências da Computação
CIA	Comunicação Interatrial
CIV	Comunicação Interventricular
DSAV	Defeito Septal Atrioventricular
EC	Engenheiro de Conhecimento
IA	Inteligência Artificial
LTM	Pesos das Conexões entre os Neurônios Artificiais (<i>Long Term Memory</i>)
MLP	Perceptron Multi-Camadas (<i>Multi-Layer Perceptron</i>)
MNC	Modelo Neural Combinatório
RNA	Redes Neurais Artificiais
SMART	<i>Semantic ART</i>
SE	Sistema Especialista
STM	Neurônio Artificial (<i>Short Term Memory</i>)
UFRGS	Universidade Federal do Rio Grande do Sul
WTA	<i>Winner-Take-All</i>

LISTA DE FIGURAS

Figura 1	Arquitetura básica do modelo conexionista híbrido HYCONES	25
Figura 2	Preenchimento dos <i>frames de diagnóstico</i>	28
Figura 3	Topologia do Modelo Neural Combinatório (MNC).....	31
Figura 4	Grafo de Conhecimento.....	40
Figura 5	Arquitetura da rede <i>Fuzzy ARTMAP</i>	44
Figura 6	Arquitetura da rede <i>Fuzzy ART</i>	45
Figura 7	A regra 2/3	47
Figura 8	Arquitetura da rede <i>Simplified Fuzzy ARTMAP</i>	57
Figura 9	Aquisição automática de conhecimento em ART.....	62
Figura 10	O motor de inferência de HYCONES II	63
Figura 11	A hierarquia de <i>frames</i>	66
Figura 12	Construção das versões MNC-CHD e MNC-RENAL.....	70
Figura 13	Construção das 15 versões ART-CHD e das 15 ART-RENAL.....	71
Figura 14	Construção das 15 versões ARTS-CHD e das 15 ARTS-RENAL.....	75
Figura 15	Construção das 15 versões SMART-CHD e das 15 SMART-RENAL.....	78
Figura 16	Grafos de Conhecimento para o diagnóstico de <i>CIA</i>	89
Figura 17	Grafos de Conhecimento para o diagnóstico de <i>CIV</i>	89
Figura 18	Grafo de Conhecimento para o diagnóstico de <i>DSAV</i>	90
Figura 19	Redes MNC mais ativadas para o diagnóstico de <i>CIA</i> , <i>CIV</i> e <i>DSAV</i>	92

LISTA DE TABELAS

Tabela 1	Fatores de relevância, conforme definidos no sistema INTERNIST	30
Tabela 2	Validação das versões MNC-CHD, ART0-CHD, ART7-CHD e ART9-CHD.....	72
Tabela 3	Validação das versões MNC-RENAIS, ART0-RENAIS, ART7-RENAIS e ART9-RENAIS	73
Tabela 4	Número de categorias de reconhecimento das versões ART0-CHD, ART7-CHD e ART9-CHD	74
Tabela 5	Validação das versões MNC-CHD, ARTS0-CHD, ARTS7-CHD e ARTS9-CHD	76
Tabela 6	Validação das versões MNC-RENAIS, ARTS0-RENAIS, ARTS7-RENAIS e ARTS9-RENAIS.....	76
Tabela 7	Validação das versões MNC-CHD, SMART0-CHD, SMART7-CHD e SMART9-CHD com limiar de poda igual a 0,0.....	79
Tabela 8	Validação das versões MNC-CHD, SMART0-CHD, SMART7-CHD e SMART9-CHD com limiar de poda igual a 0,3.....	79
Tabela 9	Validação das versões MNC-CHD, SMART0-CHD, SMART7-CHD e SMART9-CHD com limiar de poda igual a 0,5.....	80
Tabela 10	Validação das versões MNC-CHD, SMART0-CHD, SMART7-CHD e SMART9-CHD com limiar de poda igual a 0,7.....	80
Tabela 11	Número de categorias de reconhecimento das versões SMART0-CHD, SMART7-CHD e SMART9-CHD a partir dos limiares de poda 0,0, 0,3, 0,5 e 0,7.....	81
Tabela 12	Validação das versões MNC-RENAIS, SMART0-RENAIS, SMART7-RENAIS e SMART9-RENAIS com limiar de poda igual a 0,0.....	82
Tabela 13	Validação das versões MNC-RENAIS, SMART0-RENAIS, SMART7-RENAIS e SMART9-RENAIS com limiar de poda igual a 0,3.....	83

Tabela 14	Validação das versões MNC-RENAIS, SMART0-RENAIS, SMART7-RENAIS e SMART9-RENAIS com limiar de poda igual a 0,5.....	84
Tabela 15	Validação das versões MNC-RENAIS, SMART0-RENAIS, SMART7-RENAIS e SMART9-RENAIS com limiar de poda igual a 0,7.....	85
Tabela 16	Número de categorias de reconhecimento das versões SMART0-RENAIS, SMART7-RENAIS e SMART9-RENAIS a partir dos limiares de poda 0,0, 0,3, 0,5 e 0,7.....	86
Tabela 17	Conteúdo dos <i>frames de diagnóstico</i> - CHD.....	91
Tabela 18	Achados e respectivos pesos da parte <i>ligada</i> das categorias de reconhecimento mais ativadas em uma das versões ART0-CHD para os diagnósticos <i>CIA, CIV e DSAV</i>	93
Tabela 19	Achados e respectivos pesos da parte <i>desligada</i> das categorias de reconhecimento mais ativadas em uma das versões ART0-CHD para os diagnósticos <i>CIA, CIV e DSAV</i>	94
Tabela 20	Achados e respectivos pesos das categorias de reconhecimento mais ativadas em uma das versões ARTS0-CHD para os diagnósticos <i>CIA, CIV e DSAV</i> , sem a codificação complementar	97
Tabela 21	Categorias de reconhecimento mais ativadas em uma das versões SMART0-CHD para <i>CIA, CIV e DSAV</i> com limiar de poda igual a 0,3	99
Tabela 22	Categorias de reconhecimento mais ativadas em uma das versões SMART0-CHD para <i>CIA, CIV e DSAV</i> com limiar de poda igual a 0,5	100
Tabela 23	Categorias de reconhecimento mais ativadas em uma das versões SMART0-CHD para <i>CIA, CIV e DSAV</i> com limiar de poda igual a 0,7	100
Tabela 24	Categorias de reconhecimento mais ativadas em uma das versões SMART7-CHD para <i>CIA, CIV e DSAV</i> com limiar de poda igual a 0,3	100

Tabela 25	Categorias de reconhecimento mais ativadas em uma das versões SMART7-CHD para <i>CIA</i> , <i>CIV</i> e <i>DSAV</i> com limiar de poda igual a 0,5	101
Tabela 26	Categorias de reconhecimento mais ativadas em uma das versões SMART7-CHD para <i>CIA</i> , <i>CIV</i> e <i>DSAV</i> com limiar de poda igual a 0,7	101
Tabela 27	Categorias de reconhecimento mais ativadas em uma das versões SMART9-CHD para <i>CIA</i> , <i>CIV</i> e <i>DSAV</i> com limiar de poda igual a 0,3	101
Tabela 28	Categorias de reconhecimento mais ativadas em uma das versões SMART9-CHD para <i>CIA</i> , <i>CIV</i> e <i>DSAV</i> com limiar de poda igual a 0,5	102
Tabela 29	Categorias de reconhecimento mais ativadas em uma das versões SMART9-CHD para <i>CIA</i> , <i>CIV</i> e <i>DSAV</i> com limiar de poda igual a 0,7	102

SUMÁRIO

LISTA DE ABREVIATURAS	6
LISTA DE FIGURAS.....	7
LISTA DE TABELAS.....	8
RESUMO	13
ABSTRACT.....	17
1 INTRODUÇÃO	21
1.1 Histórico.....	21
1.2 Os Sistemas Híbridos	22
1.3 HYCONES: Ferramenta para SEs de Arquitetura Híbrida.....	24
1.3.1 A Base de Conhecimento Híbrida	25
1.3.2 A Máquina de Aprendizado	30
1.3.2.1 O Modelo Neural Combinatório.....	31
1.3.2.1.1 O Aprendizado Indutivo.....	33
1.3.2.1.2 O Aprendizado Dedutivo	37
1.3.2.1.3 Os Grafos de Conhecimento.....	39
1.3.3 O Mecanismo de Explicação	40
1.4 A Teoria da Adaptação Ressonante	42
1.4.1 A Rede <i>Fuzzy</i> ARTMAP	43
1.4.1.1 O Módulo <i>Fuzzy</i> ART	44
1.4.1.1.1 A Aprendizagem em <i>Fuzzy</i> ART	47
1.4.1.1.2 A Codificação Complementar	49
1.4.1.2 A Aprendizagem em <i>Fuzzy</i> ARTMAP.....	50
2 OBJETIVOS	54
3 METODOLOGIA	55

3.1	Por que <i>Fuzzy ARTMAP</i> ?	55
3.2	A Rede <i>Simplified Fuzzy ARTMAP</i>	56
3.3	Incorporando Especificidade e Relevância ao ART: A Rede SMART	58
3.4	A Aquisição Automática de Conhecimento	61
3.5	O Motor de Inferência	62
4	IMPLEMENTAÇÃO	64
5	VALIDAÇÃO	69
5.1	As Bases de Casos Utilizadas	69
5.1.1	A Base de Casos de Cardiopatias Congênitas	69
5.1.2	A Base de Casos de Síndromes Renais	69
5.2	MNC e <i>Simplified Fuzzy ARTMAP</i> : Resultados	70
5.3	SMART: Resultados	77
6	DISCUSSÃO	87
6.1	As Bases de Casos	87
6.2	Grafos de Conhecimento para CHD	88
6.3	<i>Frames de Diagnóstico</i> - CHD	90
6.4	Redes MNC-CHD	92
6.5	Categorias <i>Simplified Fuzzy ARTMAP</i> - CHD	92
6.6	Categorias SMART-CHD	98
	BIBLIOGRAFIA	106
	APÊNDICE I	112
	APÊNDICE II	116
	APÊNDICE III	123

RESUMO

O presente trabalho apresenta dois novos modelos conexionistas, baseados na teoria da adaptação ressonante (ART): *Simplified Fuzzy ARTMAP* e *Semantic ART* (SMART). Descreve-se a modelagem, adaptação, implementação e validação destes, enquanto incorporados ao sistema híbrido HYCONES, para resolução de problemas de diagnóstico médico em cardiopatias congênitas e nefrologia. HYCONES é uma ferramenta para a construção de sistemas especialistas híbridos que integra redes neurais com *frames*, assimilando as qualidades inerentes aos dois paradigmas. O mecanismo de *frames* fornece tipos construtores flexíveis para a modelagem do conhecimento do domínio, enquanto as redes neurais, representadas na versão original de HYCONES pelo modelo neural combinatório (MNC), possibilitam tanto a automação da aquisição de conhecimento, a partir de uma base de casos, quanto a implementação de aprendizado indutivo e dedutivo.

A teoria da adaptação ressonante é caracterizada, principalmente, pela manutenção do equilíbrio entre as propriedades de plasticidade e estabilidade durante o processo de aprendizagem. ART inclui vários modelos conexionistas, tais como: *Fuzzy ARTMAP*, *Fuzzy ART*, ART 1, ART 2 e ART 3. Dentre estes, a rede neural *Fuzzy ARTMAP* destaca-se por possibilitar o tratamento de padrões analógicos a partir de dois módulos ART básicos.

O modelo *Simplified Fuzzy ARTMAP*, como o próprio nome o diz, é uma simplificação da rede neural *Fuzzy ARTMAP*. Ao contrário desta, o novo modelo possibilita o tratamento de padrões analógicos, a partir de apenas um módulo ART, responsável pelo tratamento dos padrões de entrada, adicionado de uma camada, responsável pelos padrões alvo. Mesmo com apenas um módulo ART, o modelo *Simplified Fuzzy ARTMAP* é capaz de reter o mesmo nível de desempenho obtido com a rede neural *Fuzzy ARTMAP* pois, continua a garantir, conjuntamente, a maximização da generalização e a minimização do erro preditivo, através da execução da estratégia *match-tracking*.

Para a construção da base de casos de cardiopatias congênitas, 66 prontuários médicos, das três cardiopatias congênitas mais frequentes, foram extraídos do banco de dados de pacientes submetidos à cirurgia cardíaca no Instituto de Cardiologia RS (ICFUC-RS). Tais prontuários abrangem o período de janeiro de 1986 a dezembro de 1990 e reportam 22 casos de *Comunicação Interatrial (CIA)*, 29

de *Comunicação Interventricular (CIV)* e 15 de *Defeito Septal Atrioventricular (DSAV)*. Para a análise de desempenho do sistema, 33 casos adicionais, do referido período, foram extraídos aleatoriamente do banco de dados do ICFUC-RS. Destes 33 casos, 13 apresentam *CIA*, 10 *CIV* e 10 *DSAV*.

Para a construção da base de casos de síndromes renais, 381 prontuários do banco de dados de síndromes renais da Escola Paulista de Medicina foram analisados e 58 evidências, correspondentes a dados de história clínica e exame físico dos pacientes, foram extraídas semi-automaticamente. Do total de casos selecionados, 136 apresentam *Uremia*, 85 *Nefrite*, 100 *Hipertensão* e 60 *Litíase*. Dos 381 casos analisados, 254 foram escolhidos aleatoriamente para a composição do conjunto de treinamento, enquanto que os demais foram utilizados para a elaboração do conjunto de testes.

Para que HYCONES II fosse validado, foram construídas 46 versões da base de conhecimento híbrida (BCH) para o domínio de cardiopatias congênitas e 46 versões da BCH para o de nefrologia. Em ambos os domínios médicos as respectivas bases de conhecimento foram construídas, automaticamente, a partir das respectivas bases de casos de treinamento. Das 46 versões geradas para cada grupo, uma representa o modelo MNC e 45 os modelos ART. As versões ART dividem-se em grupos de 3: 15 versões foram formadas a partir do modelo *Simplified Fuzzy ARTMAP*; 15 a partir deste mesmo modelo, sem que os padrões de entrada fossem normalizados; e, finalmente, 15 para o modelo *Semantic ART*.

Na base de testes CHD, o desempenho da versão HYCONES II - *Simplified Fuzzy ARTMAP* foi semelhante ao da versão MNC. A primeira acertou 29 dos 33 diagnósticos (87,9%), enquanto a segunda apontou corretamente 31 dos 33 diagnósticos apresentados (93,9%).

Na base de testes de síndromes renais, o desempenho de HYCONES II - *Simplified Fuzzy ARTMAP* foi superior ao da versão MNC ($p < 0,05$). Ambas acertaram, respectivamente, 108 (85%) e 95 (74,8%) diagnósticos, em 127 casos submetidos.

Ainda que o desempenho da versão HYCONES II - *Simplified Fuzzy ARTMAP* se revelasse promissor, ao se examinar o conteúdo das redes geradas por este modelo, pode-se observar que estas divergiam completamente daquelas obtidas pelo

MNC. As redes que levaram à conclusão diagnóstica, na versão HYCONES - MNC, possuíam conteúdo praticamente igual aos grafos de conhecimento, elicitados de especialistas em cardiopatias congênitas. Já, as redes ativadas na versão HYCONES II - *Simplified Fuzzy ARTMAP*, além de representarem número bem maior de evidências que as redes MNC, a grande maioria destas últimas representam a negação do padrão de entrada. Este fato deve-se a um processo de normalização, inerente ao modelo *Simplified Fuzzy ARTMAP*, no qual cada padrão de entrada é duplicado. Nesta duplicação, são representadas as evidências presentes em cada caso e, ao mesmo tempo, complementarmente, as evidências ausentes, em relação ao total geral das mesmas na base de casos. Esta codificação inviabiliza o mecanismo de explanação do sistema HYCONES, pois, na área médica, os diagnósticos costumam ser feitos a partir de um conjunto de evidências presentes e, não, pela ausência delas.

Tentou-se, então, melhorar o conteúdo semântico das redes *Simplified Fuzzy ARTMAP*. Para tal, o processo de normalização ou codificação complementar da implementação do modelo foi retirado, validando-o novamente, contra o mesma base de testes.

Na base de testes CHD, o desempenho de HYCONES II - *Simplified Fuzzy ARTMAP*, sem a codificação complementar, foi inferior ao da versão MNC ($p < 0,05$). A primeira acertou 25 dos 33 diagnósticos (75,8%), enquanto a segunda apontou corretamente 31 dos mesmos (93,9%).

Na base de testes renais, o desempenho da versão HYCONES II - *Simplified Fuzzy ARTMAP*, sem a codificação complementar, foi semelhante ao da versão MNC. Dos 127 casos apresentados, a primeira acertou 98 diagnósticos (77,2%), contra 95 da segunda (74,8%).

Constatou-se, ainda, que as categorias de reconhecimento formadas pelo modelo *Simplified Fuzzy ARTMAP* continuavam a apresentar diferenças marcantes quanto ao seu conteúdo, quando comparadas às redes MNC ou aos grafos de conhecimento elicitados de especialistas.

O modelo *Semantic ART* foi, então, proposto, na tentativa de se melhorar o conteúdo semântico das redes ART. Modificou-se, então, o algoritmo de aprendizado do modelo *Simplified Fuzzy ARTMAP*, introduzindo-se o mecanismo de aprendizado

indutivo do modelo MNC, i.e., o algoritmo de punições e recompensas, associado ao de poda e normalização. Nova validação com a mesma base de testes foi realizada.

Para a base de testes de CHD, o desempenho de HYCONES II - SMART foi semelhante ao da versão *Simplified Fuzzy ARTMAP* e da versão MNC. A primeira e a segunda acertaram 29 dos 33 diagnósticos (87,9%), enquanto a versão MNC apontou corretamente 31 dos 33 diagnósticos apresentados (93,9%).

Na base de testes de síndromes renais, o desempenho de HYCONES II - SMART foi superior ao da versão MNC ($p < 0,05$) e igual ao da versão *Simplified Fuzzy ARTMAP*. A primeira e a última acertaram 108 dos 127 diagnósticos (85%), enquanto a segunda apontou corretamente 95 dos mesmos (74,8%).

Desta feita, observou-se que as redes neurais geradas por HYCONES II - SMART eram semelhantes em conteúdo às redes MNC e aos grafos de conhecimento elicitados de múltiplos especialistas.

As principais contribuições desta dissertação são: o projeto, implementação e validação dos modelos *Simplified Fuzzy ARTMAP* e SMART. Destaca-se, porém, o modelo SMART, que apresentou maior valor semântico nas categorias de reconhecimento do que o observado nos modelos ART convencionais, graças à incorporação dos conceitos de especificidade e relevância.

Esta dissertação, entretanto, representa não só a modelagem e validação de dois novos modelos neurais, mas sim, o enriquecimento do sistema HYCONES, a partir da continuação de dissertação de mestrado previamente defendida. A partir do presente trabalho, portanto, é dada a possibilidade de escolha, ao engenheiro de conhecimento, de um entre três modelos neurais: o MNC, o *Semantic ART* e o *Simplified Fuzzy ARTMAP* que, sem exceção, apresentam bom desempenho. Os dois primeiros destacam-se, contudo, por suportarem semanticamente o contexto.

PALAVRAS-CHAVE: Inteligência Artificial, Sistemas Especialistas, Aprendizado de Máquina, Redes Neurais, Sistemas Híbridos, Informática aplicada à Medicina, Teoria da Adaptação Ressonante, Sensibilidade, Especificidade e Relevância.

TITLE: Learning in Hybrid Systems**ABSTRACT**

This dissertation presents two new connectionist models based on the adaptive resonance theory (ART): Simplified Fuzzy ARTMAP and Semantic ART (SMART). The modeling, adaptation, implementation and validation of these models are described, in their association to HYCONES, a hybrid connectionist expert system to solve classification problems. HYCONES integrates the knowledge representation mechanism of frames with neural networks, incorporating the inherent qualities of the two paradigms. While the frames mechanism provides flexible constructs for modeling the domain knowledge, neural networks, implemented in HYCONES' first version by the combinatorial neuron model (CNM), provide the means for automatic knowledge acquisition from a case database, enabling, as well, the implementation of deductive and inductive learning.

The Adaptive Resonance Theory (ART) deals with a system involving self-stabilizing input patterns into recognition categories, while maintaining a balance between the properties of plasticity and stability. ART includes a series of different connectionist models: Fuzzy ARTMAP, Fuzzy ART, ART 1, ART 2, and ART 3. Among them, the Fuzzy ARTMAP one stands out for being capable of learning analogical patterns, using two basic ART modules.

The Simplified Fuzzy ARTMAP model is a simplification of the Fuzzy ARTMAP neural network. Constrating the first model, the new one is capable of learning analogical patterns using only one ART module. This module is responsible for the categorization of the input patterns. However, it has one more layer, which is responsible for receiving and propagating the target patterns through the network. The presence of a single ART module does not hamper the Simplified Fuzzy ARTMAP model. The same performance levels are attained when the latter one runs without the second ART module. This is certified by the match-tracking strategy, that conjointly maximizes generalization and minimizes predictive error.

Two medical domains were chosen to validate HYCONES performance: congenital heart diseases (CHD) and renal syndromes. To build up the CHD case base, 66 medical records were extracted from the cardiac surgery database of the Institute of Cardiology RS (ICFUC-RS). These records cover the period from January

1986 to December 1990 and describe 22 cases of *Atrial Septal Defect (ASD)*, 29 of *Ventricular Septal Defect (VSD)*, and 15 of *Atrial-Ventricular Septal Defect (AVSD)*, the three most frequent congenital heart diseases. For validation purposes, 33 additional cases, from the same database and period mentioned above, were also extracted. From these cases, 13 report *ASD*, 10 *VSD* and 10 *AVSD*.

To build the renal syndromes case base, 381 medical records from the database of the *Escola Paulista de Medicina* were analyzed and 58 evidences, covering the patients' clinical history and physical examination data, were semi-automatically extracted. From the total number of selected cases, 136 exhibit *Uremia*, 85 *Nephritis*, 100 *Hypertension*, and 60 *Calculosis*. From the 381 cases analyzed, 245 were randomly chosen to build the training set, while the remaining ones were used to build the testing set.

To validate HYCONES II, 46 versions of the hybrid knowledge base (HKB) with congenital heart diseases were built; for the renal domain, another set of 46 HKB versions were constructed. For both medical domains, the HKBs were automatically generated from the training databases. From these 46 versions, one operates with the CNM model and the other 45 deals with two ART models. These ART versions are divided in three groups: 15 versions were built using the Simplified Fuzzy ARTMAP model; 15 used the Simplified Fuzzy ARTMAP model without the normalization of the input patterns, and 15 used the Semantic ART model.

HYCONES II - Simplified Fuzzy ARTMAP and HYCONES - CNM performed similarly for the CHD domain. The first one pointed out correctly to 29 of the 33 testing cases (87,9%), while the second one indicated correctly 31 of the same cases (93,9%).

In the renal syndromes domain, however, the performance of HYCONES II - Simplified Fuzzy ARTMAP was superior to the one exhibited by CNM ($p < 0,05$). Both versions pointed out correctly, respectively, 108 (85%) and 95 (74.8%) diagnoses of the 127 testing cases presented to the system.

HYCONES II - Simplified Fuzzy ARTMAP, therefore, displayed a satisfactory performance. However, the semantic contents of the neural nets it generated were completely different from the ones stemming from the CNM version. The networks that pointed out the final diagnosis in HYCONES - CNM were very similar to the knowledge graphs elicited from experts in congenital heart diseases. On the other

hand, the networks activated in HYCONES II - Simplified Fuzzy ARTMAP operated with far more evidences than the CNM version. Besides this quantitative difference, there was a striking qualitative discrepancy among these two models. The Simplified Fuzzy ARTMAP version, even though pointing out to the correct diagnoses, used evidences that represented the complementary coding of the input pattern. This coding, inherent to the Simplified Fuzzy ARTMAP model, duplicates the input pattern, generating a new one depicting the evidence observed (*on-cell*) and, at the same time, the absent evidence, in relation to the total evidence employed to represent the input cases (*off-cell*). This coding shuts out the HYCONES explanation mechanism, since medical doctors usually reach a diagnostic conclusion rather from a set of observed evidences than from their absence.

The next step taken was to improve the semantic contents of the Simplified Fuzzy ARTMAP model. To achieve this, the complement coding process was removed and the modified model was, then, revalidated, through the same testing sets as above described.

In the CHD domain, the performance of HYCONES II - *Simplified Fuzzy ARTMAP*, without complementary coding, proved to be inferior to the one presented by CNM ($p < 0,05$). The first model singled out correctly 25 out of the 33 testing cases (75,8%), while the second one singled out correctly 31 out of the same 33 cases (93,9%).

In the renal syndromes domain, the performances of HYCONES II - Simplified Fuzzy ARTMAP, without complementary coding, and HYCONES - CNM were similar. The first pointed out correctly to 98 of the 127 testing cases (77,2%), while the second one pointed out correctly to 95 of the same cases (74.8%).

However, the recognition categories formed by this modified Simplified Fuzzy ARTMAP still presented quantitative and qualitative differences in their contents, when compared to the networks activated by CNM and to the knowledge graphs elicited from experts. This discrepancy, although smaller than the one observed in the original Fuzzy ARTMAP model, still restrained HYCONES explanation mechanism.

The Semantic ART model (SMART) was, then, proposed. Its goal was to improve the semantic contents of ART recognition categories. To build this new model, the Simplified Fuzzy ARTMAP architecture was preserved, while its learning algorithm was replaced by the CNM inductive learning mechanism (the punishments

and rewards algorithm, associated with the pruning and normalization mechanisms). A new validation phase was, then, performed over the same testing sets.

For the CHD domain, the performance comparison among SMART, Simplified Fuzzy ARTMAP, and CNM versions showed similar results. The first and the second versions pointed out correctly to 29 of the 33 testing cases (87,9%), while the third one singled out correctly 31 of the same testing cases (93,9%).

For the renal syndromes domain, the performance of HYCONES II - SMART was superior to the one presented by the CNM version ($p < 0,05$), and equal to the performance presented by the Simplified Fuzzy ARTMAP version. SMART and Simplified Fuzzy ARTMAP singled out correctly 108 of the 127 testing cases (85%), while the CNM version pointed out correctly 95 of the same 127 testing cases (74.8%).

Finally, it was observed that the neural networks generated by HYCONES II - SMART had a similar content to the networks generated by CNM and to the knowledge graphs elicited from multiple experts.

The main contributions of this dissertation are: the design, implementation and validation of the Simplified Fuzzy ARTMAP and SMART models. The latter one, however, stands out for its learning mechanism, which provides a higher semantic value to the recognition categories, when compared to the categories formed by conventional ART models. This important enhancement is obtained by incorporating specificity and relevance concepts to ART's dynamics.

This dissertation, however, represents not only the design and validation of two new connectionist models, but also, the enrichment of HYCONES. This is obtained through the continuation of a previous MSc dissertation, under the same supervision. From the present work, therefore, it is given to the knowledge engineering, the choice among three different neural networks: CNM, Semantic ART and Simplified Fuzzy ARTMAP, all of which, display good performance. Indeed, the first and second models, in contrast to the third, support the context in a semantic way.

KEYWORDS: Artificial Intelligence, Expert Systems, Machine Learning, Neural Networks, Hybrid Systems, Computer Science applied to Medicine, Adaptive Resonance Theory, Sensibility, Specificity and Relevance.

1 INTRODUÇÃO

Neste capítulo, descreve-se, inicialmente, breve histórico sobre o presente trabalho. A seguir, é feita abordagem inicial sobre sistemas híbridos, descrevendo-se, então, os mecanismos sobre os quais o presente trabalho foi desenvolvido, o sistema híbrido HYCONES e a Teoria da Adaptação Ressonante.

1.1 Histórico

O presente trabalho não pode ser considerado - e tampouco tratado - de forma isolada. Em 1988, como resultado do trabalho de doutorado realizado pela Dra. Beatriz de Faria Leão, é proposta uma metodologia de aquisição de conhecimento baseada na construção e extração de grafos de conhecimento, a partir de múltiplos especialistas. Esta metodologia facilita, em muito, a fase de engenharia de conhecimento, considerada gargalo na construção de sistemas especialistas convencionais [LEA 88]. Em 1989, a partir do trabalho conjunto dos Drs. Armando Rocha e Ricardo Machado, é proposta uma rede neural, chamada de Modelo Neural Combinatório (MNC), baseada nos grafos de conhecimento supra-citados [MAC 89]. Esta rede, possui as características básicas desejáveis para o desenvolvimento de sistemas especialistas conexionistas [GAL 88]. Em 1991, baseado no modelo MNC, surge o NEXTOOL, ferramenta para a construção de sistemas especialistas híbridos, que integra a rede MNC ao simbolismo das redes semânticas [MAC 91]. Em 1993, Eliseo Berni Reátegui defende sua dissertação de mestrado, elaborada sob orientação da Dra. Beatriz de Faria Leão no CPGCC da UFRGS, que trata da construção e modelagem de uma nova ferramenta para a construção de sistemas especialistas híbridos, batizada de HYCONES [REA 93b]. Esta, assim como NEXTOOL, baseia-se no modelo MNC, mas, ao contrário deste, implementa, como paradigma simbólico, mecanismo de *frames*, que fornece uma representação mais rica do conhecimento, se comparado às redes semânticas.

Finalmente, o presente trabalho trata do amadurecimento de HYCONES. A nova versão, chamada de HYCONES II, começou a ser desenvolvida com o objetivo de fornecer ao engenheiro de conhecimento, usuário alvo do sistema, um conjunto maior de alternativas, em relação aos sistemas conexionistas até então implementados. Na primeira versão, apenas o modelo MNC é utilizado.

A utilização de redes baseadas na Teoria da Adaptação Ressonante (ART) para diagnóstico médico não está ainda descrita na literatura. A maioria dos trabalhos em ART demonstra a sua eficácia em reconhecimento *isolado* de caracteres. As redes ART e, particularmente, aquela denominada *Fuzzy ARTMAP*, se destacam pela aprendizagem rápida, e, principalmente, tal como as redes MNC, pela geração de categorias de reconhecimento, durante o processo de aprendizagem. Por este e outros motivos, a rede *Fuzzy ARTMAP* foi a escolhida, inicialmente, para ser implementada em HYCONES II. A partir de trabalho desenvolvido pelo autor e pelos Drs. Dante Barone e Edson Carvalho Filho, foi projetado, em 1993, um modelo simplificado da rede ARTMAP [GUA 93b]. Esta simplificação, quando adaptada para o modelo *Fuzzy ARTMAP*, deu origem, no presente trabalho, à rede *Simplified Fuzzy ARTMAP*.

Esta dissertação reflete um trabalho de investigação longo e exaustivo que incorpora o projeto, implementação e validação de diferentes modelos neurais para resolução de problemas de diagnóstico médico em dois domínios: cardiologia e nefrologia.

1.2 Os Sistemas Híbridos

Os sistemas especialistas convencionais fornecem metodologia adequada para a representação do conhecimento e para a explanação das conclusões alcançadas; entretanto, aprendizagem e aquisição de conhecimento representam, ainda, um problema. Por outro lado, os sistemas conexionistas atraem interesse cada vez maior pelas suas inerentes capacidades de aprendizagem e reconhecimento de padrões. Os sistemas especialistas híbridos foram, portanto, propostos, integrando os paradigmas simbólico e conexionista. Nestes sistemas, tais paradigmas se complementam: um por sua natureza lógica, cognitiva e mecânica; o outro por sua natureza numérica, associativa e de auto-organização. Dados estes atributos, utiliza-se o paradigma simbólico, de um lado, para que haja o enriquecimento semântico na modelagem do conhecimento do domínio e o paradigma conexionista, de outro, para prover os recursos necessários tanto para a aquisição quanto para o refinamento do conhecimento.

O processo de aquisição de conhecimento, por exemplo, gargalo no desenvolvimento de sistemas especialistas de arquitetura convencional, pode ser automatizado em modelos de arquitetura híbrida através da criação de redes neurais e de seu treinamento por meio de casos. Por outro lado, na arquitetura puramente conexionista, a obtenção de explicações **plausíveis** para os problemas solucionados pela rede neural constitui tarefa bastante complexa [GAL 88]. Depois de treinadas para executar uma tarefa específica, as redes neurais passam a manter seu conhecimento na forma de pesos de conexão, o que dificulta a análise e compreensão do conhecimento armazenado. Esta característica também torna complexa a tarefa de obtenção de explicações da resolução de um problema por uma rede neural, o que é essencial para um Sistema Especialista (SE), ainda mais aqueles aplicados à área médica [FIE 90]. Os sistemas de arquitetura híbrida, por implementarem uma forma de representação simbólica do conhecimento, possuem mecanismos que facilmente obtêm as explicações necessárias para suportar o processo de inferência de uma rede neural.

Além disto, para a maioria das aplicações, faz-se necessária a utilização de formalismos de representação de conhecimento ricos e flexíveis, que possibilitem o armazenamento de descrições completas e fiéis ao conhecimento factual do domínio.

Quanto às formas de aprendizado, os sistemas de arquitetura híbrida possibilitam implementar o aprendizado tanto indutivo como dedutivo. Para o primeiro, recorre-se a algoritmos de treinamento das redes neurais por casos; para o segundo, busca-se a modificação estrutural das redes existentes, utilizando, por exemplo, os algoritmos genéticos [MAC 92b].

Em se tratando da forma de representação de conhecimento, observa-se que a utilização de múltiplos paradigmas pode fornecer aos engenheiros de conhecimento, especialistas e usuários em geral, visão bem mais ampla do conhecimento do domínio.

As arquiteturas híbridas também possibilitam que o sistema mimetize os 2 tipos de raciocínio humano:

- **raciocínio paralelo:** responsável pelas tarefas de reconhecimento de padrões presentes nos cinco órgãos do

sentidos (visão, audição, tato, paladar e olfato), sobre os quais o controle é automático, realizado através do sistema nervoso autônomo. Nos sistemas híbridos, estas tarefas podem ser executadas pelas redes neurais, sem a preocupação de mais tarde apresentar uma explicação para o método desenvolvido na solução do problema;

- **raciocínio lógico:** processos de raciocínio seqüenciais utilizados em tarefas de resolução de problemas. Estas tarefas são executadas, no cérebro, de forma consciente e controlada, podendo ser efetuadas no sistema híbrido pela unidade simbólica. A análise do processo de raciocínio, que objetiva prover explicações para uma dada consulta, é um procedimento notadamente lógico. Por isto, pode ser executada pela unidade simbólica.

A integração dos paradigmas simbólico e conexionista ainda constitui abordagem bastante nova na área de sistemas especialistas. No entanto, alguns sistemas especialistas híbridos já foram implementados com sucesso. Dentre eles, pode-se citar o sistema WATTS, para tratamento de efluentes cloacais e industriais [KRO 92], o sistema criado para a avaliação de projetos arquitetônicos [KNA 92], o sistema criado para o tratamento do melanoma [HUD 92] e o NEXTOOL, que é uma ferramenta para a construção de sistemas especialistas híbridos [MAC 91] [MAC 92a] [MAC 92b].

1.3 HYCONES: Ferramenta para SEs de Arquitetura Híbrida

Esta seção descreve o sistema híbrido HYCONES, que integra o formalismo de representação de conhecimento de *frames* ao modelo neural combinatório (MNC) [REA 93a] [REA 93b] [LEA 93a] [LEA 93b]. A Figura 1 ilustra a arquitetura básica do modelo HYCONES.

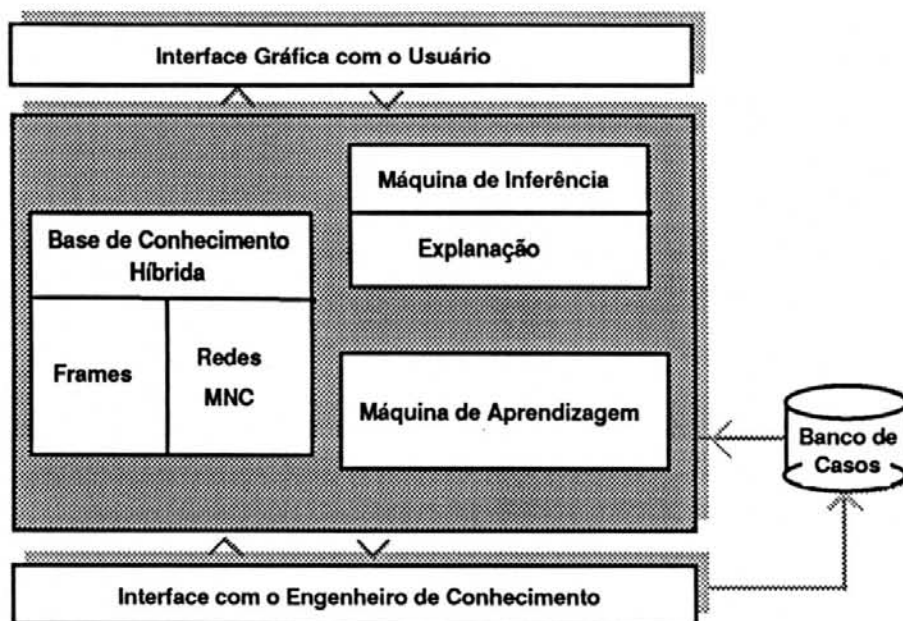


Figura 1 Arquitetura básica do modelo conexionista híbrido HYCONES

1.3.1 A Base de Conhecimento Híbrida

A base de conhecimento híbrida (BCH) de HYCONES emprega duas formas de representação de conhecimento: *frames* e redes neurais.

O conhecimento sobre o domínio, baseado no mecanismo de representação de *frames*, foi modelado em dois níveis: um nível de **diagnósticos** e um nível de **achados**. No nível de **achados**, descrevem-se os objetos elementares da aplicação que influenciam a detecção de certos diagnósticos. No nível de **diagnósticos**, descrevem-se os problemas de classificação que o sistema objetiva solucionar.

Os objetos armazenados no nível de achados são agrupados em classes (*classificação*). Estas classes são reunidas em grupos mais genéricos, definidos de acordo com os conceitos de abstração de dados de *generalização*, *agregação* e *associação*. Cada achado, mapeado em uma classe do nível de achados, aponta para um ou mais diagnósticos do nível de **diagnósticos** [REA 93b].

A representação de conhecimento baseada nos conceitos de abstração possibilita retratar diferentes tipos de relacionamentos entre as porções de

conhecimento da BCH. Os tipos construtores, oferecidos pelos conceitos de abstração, exibem grande potencial de representação semântica, possibilitando uma versão mais fiel da realidade e permitindo a utilização do modelo em diferentes domínios de aplicação.

Os níveis de **diagnóstico** e de **achados** são representados na BCH por dois tipos distintos de *frames*, a saber:

- *frames de achado*: um conjunto específico de atributos, definidos de acordo com o conhecimento do domínio. Estes atributos podem ser estabelecidos localmente, ou herdados de *frames* hierarquicamente superiores;

- *frames de diagnóstico*: utilizados para armazenar as descrições do conhecimento necessário para resolver o problema em questão. Para tanto, um *frame de diagnóstico* armazena referências a conjuntos de achados que, quando presentes, influenciam na detecção do diagnóstico.

São 4 os tipos de *slots* empregados na descrição de um *frame de diagnóstico*:

- **gatilho**: referencia um *frame de achado* que, quando presente, aponta para o *frame de diagnóstico* como solução potencial para o caso apresentado ao SE;
- **achados-essenciais**: contêm uma lista de *frames de achados* que, quando presentes, asseguram a identificação do diagnóstico representado pelo *frame de diagnóstico*;
- **achados-complementares**: contêm uma lista de *frames de achado* que pode auxiliar na confirmação da hipótese segundo a qual a conclusão representada pelo *frame de diagnóstico* é a solução do problema;
- **achados-de-negação**: referencia uma lista de *frames de achado* que, quando presentes, podem eliminar o *frame de diagnóstico* do conjunto de possíveis soluções do caso apresentado ao SE.

A ligação entre a hierarquia de *frames de achados* e os *frames de diagnósticos* faz-se através das referências aos *frames de achados* existentes nos *frames de diagnósticos*.

Para o preenchimento automático dos *slots* dos *frames diagnóstico*, HYCONES vale-se da *sensibilidade*, *especificidade* e *relevância* dos achados, nos diferentes contextos diagnósticos.

A sensibilidade é utilizada para determinar os *achados essenciais*. A noção de sensibilidade mede a probabilidade de que determinado achado *f* esteja presente em paciente com determinado diagnóstico *D*. A sensibilidade de um achado, em relação a um diagnóstico, corresponde, portanto, à frequência com que o achado *f* é identificado para aquele diagnóstico *D*. A sensibilidade do achado *f*, em relação ao diagnóstico *D*, é obtida através da seguinte fórmula [OWE 90]:

$$\text{Sensibilidade} = \frac{\text{Número de casos, onde determinado achado } f \text{ está presente no diagnóstico } D}{\text{Número total de casos com o diagnóstico } D}$$

HYCONES estabelece um limiar de aceitação para que um achado seja tomado como essencial para determinado diagnóstico. Este limiar recai no intervalo [0,1] e indica a frequência com que um achado deve aparecer nos casos de treinamento do mesmo diagnóstico, para que seja considerado essencial [REA 93b]. Na Figura 2, por exemplo, os achados mais sensíveis - e por isto considerados essenciais - para o diagnóstico *Diag1* são representados pelas letras *A* e *B*.

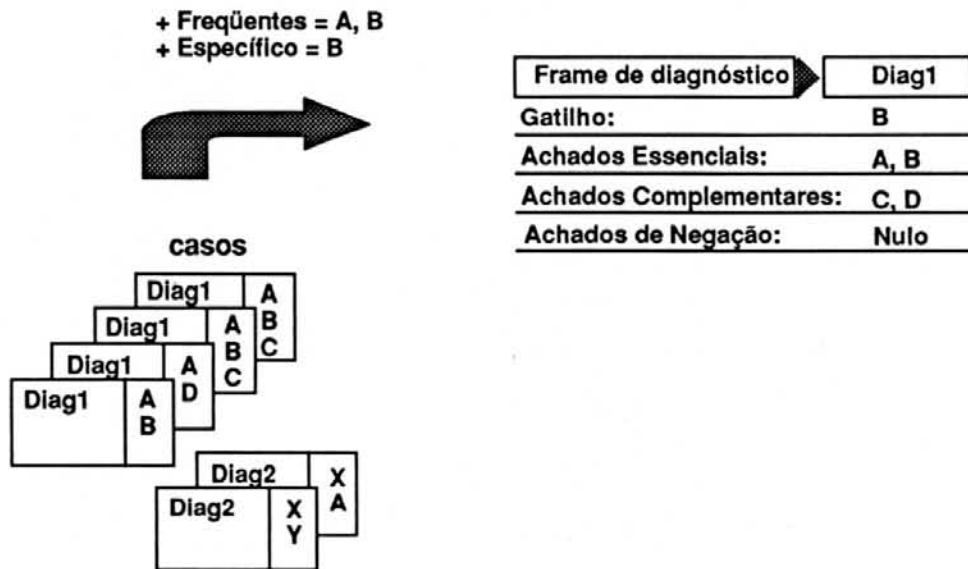


Figura 2 Preenchimento dos *frames de diagnóstico*

São *achados-complementares* aqueles que compõem algum caminho que conduz a à hipótese de diagnóstico, mas que apareçam com frequência menor que o limiar de aceitação nos casos de treinamento (na Figura 2, os achados *C* e *D* são considerados complementares para o diagnóstico *Diag1*);

Por sua vez, os *achados de negação*, determinados a partir das conexões das redes neurais formadas pelo modelo neural MNC, são aqueles cujo somatório de conexões negativas ultrapasse o somatório de conexões positivas para o diagnóstico.

A identificação do *gatilho* de um *frame de diagnóstico* é feita após a determinação de seus *achados-essenciais*. O *gatilho* do *frame* indica qual destes achados é o mais "importante" no processo de identificação do diagnóstico. HYCONES se inspira no fator de *especificidade* para determinar a importância dos achados para os diagnósticos. A *especificidade* de um achado *f* em relação a um diagnóstico *D* indica quão específico o achado *f* é para o referido diagnóstico *D*, ou ainda, a possibilidade do achado *f* não estar presente quando da detecção de outros diagnósticos. A *especificidade* do achado *f*, em relação ao diagnóstico *D*, é obtida através da seguinte fórmula:

$$\text{Especificidade} = \frac{\text{Número de casos sem o achado } f \text{ com diagnósticos diferentes de } D}{\text{Número total de casos com diagnósticos diferentes de } D}$$

Dado que o *gatilho* de um *frame de diagnóstico*, representado na Figura 2 pelo achado *B*, é selecionado de sua lista de *achados-essenciais*, ele consistirá no mais específico dos achados de maior sensibilidade para o diagnóstico.

Contudo, é possível que a *especificidade* de vários achados seja a mesma, para um determinado diagnóstico. Neste caso, emprega-se outro fator na determinação do *gatilho* do *frame de diagnóstico*: a *relevância*. Esta propriedade é definida para cada achado da base de conhecimento e determina quão significativo um achado é em relação a todos os demais achados da base. Para o médico, o conceito de *relevância* pode ser compreendido como a morbididade de um achado, ou a sua gravidade. Por exemplo, no diagnóstico de problemas cardíacos, o sintoma de *dor-no-peito* tem maior morbididade que os sintomas *cansaço* e *prurido*. Por este motivo, quando vários achados apresentam especificidade semelhante, a propriedade *relevância* é utilizada para determinar o *gatilho* do *frame de diagnóstico*.

HYCONES emprega a mesma escala de fatores de *relevância* utilizada pelo sistema INTERNIST-I [MIL 86]. A Tabela 1 mostra a interpretação dos fatores de *relevância* empregados.

Tabela 1

Fatores de relevância, conforme definidos no sistema INTERNIST

Relevância	Interpretação
1	A manifestação não é muito importante, ocorre comumente em pessoas normais e pode ser facilmente desconsiderada.
2	A manifestação é de relativa importância, mas pode ser freqüentemente ignorada.
3	A manifestação é de importância média, porém pode ser um indicador de vários diagnósticos específicos.
4	A manifestação é de grande importância e raramente pode ser desconsiderada como, por exemplo, um resultado falso-positivo.
5	A manifestação necessariamente deve ser explicada por um dos diagnósticos finais.

Através da divisão dos *frames* em *diagnóstico* e *achados*, o formalismo de representação do conhecimento simbólico abrange completamente todo o espectro da aplicação. A hierarquia de achados descreve os aspectos declarativos do conhecimento do domínio, enquanto que os *frames de diagnóstico* mantêm as possíveis soluções para os problemas tratados.

O **mapeamento** entre as redes neurais, os *frames de diagnósticos* e os *de achados* define um mecanismo de compartilhamento de estruturas de memória para representar conceitos dos componentes simbólico e conexionista, no qual os *achados* e *diagnósticos* referenciados nos nodos, ou neurônios, de evidências e de hipóteses da rede neural são, na realidade, os *frames de achados* e de *diagnósticos* da hierarquia de *frames*, respectivamente.

1.3.2 A Máquina de Aprendizado

A Máquina de Aprendizado tem o propósito de adquirir conhecimento ou refinar o conhecimento armazenado na base de conhecimento híbrida, através da

análise de conjuntos de exemplos contidos na base de casos. A máquina de aprendizado de HYCONES é baseada no modelo MNC, a seguir descrito.

1.3.2.1 O Modelo Neural Combinatório

"O Modelo Neural Combinatório (MNC) é um modelo conexionista capaz de executar aprendizado heurístico baseado no reconhecimento de regularidades ambientais através de repetidas observações do mundo exterior" [MAC 89]. A topologia de uma rede do tipo MNC segue o paradigma *feedforward* (não permite ciclos) e possui três camadas. A Figura 3 mostra um exemplo de uma rede MNC.

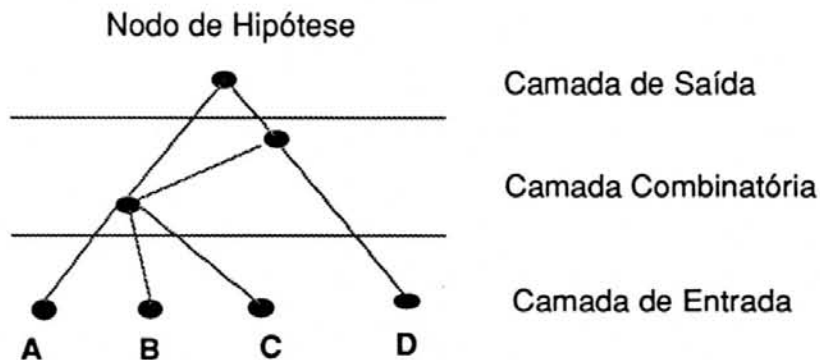


Figura 3 Topologia do Modelo Neural Combinatório (MNC)

A camada de entrada é formada por células *fuzzy*, cada uma representando um achado específico. Estas células recebem valores de entrada entre 0 e 1, correspondendo ao grau de confiança que o usuário tem nas informações que ele observa e passa para a rede neural.

Células em camadas diferentes são ligadas por conexões às quais se associam pesos, representando a influência das células da camada inferior na saída daquelas situadas na camada superior.

As conexões da camada de entrada podem ser excitatórias ou inibitórias. Uma conexão excitatória propaga o sinal de entrada, utilizando o seu peso de conexão como fator de atenuação. Uma conexão inibitória primeiramente complementa o sinal

de entrada X , transformando-o em $(1-X)$, para depois propagá-lo através da multiplicação do sinal $(1-X)$ pelo peso da conexão.

A camada combinatória associa entre si diferentes células de entrada em nodos intermediários de conhecimento, representando os padrões (grupos de evidências) que a rede aprende a reconhecer.

A camada de saída armazena as diferentes hipóteses de diagnóstico existentes no domínio do problema. Esta camada implementa um mecanismo de competição entre os diferentes caminhos formados nas camadas anteriores.

Os neurônios podem processar sinais de acordo com uma das seguintes formas:

- *E-nebuloso*: utilizado nas camadas combinatórias. Nelas, o neurônio seleciona o sinal de entrada mais fraco;
- *Ou-nebuloso*: utilizado na camada de saída. Nela, o neurônio seleciona o sinal de entrada mais forte;

O valor do sinal de saída de uma sinapse *FE* (*Fluxo Evidencial*) é calculado através da seguinte equação:

$$FE = w E t + w(1-E) (1-t)$$

na qual E representa o sinal de entrada, w representa o peso da sinapse e t é o tipo da sinapse, assumindo o valor 1 para sinapses excitatórias e 0 para as inibitórias.

O modelo MNC possui duas formas principais de operação: o modo de consulta e o modo de aprendizado. No primeiro, a partir de um conjunto de evidências (entradas), a rede propaga os sinais e obtém as hipóteses (saídas) que obtiverem grau de aceitação maior que o limiar de aceitação preestabelecido. No segundo, são dois os métodos aplicáveis. O primeiro utiliza um *algoritmo de punições e recompensas - versão de arranque* - e é capaz de gerar uma rede operante a partir de casos de treinamento. O segundo, utilizando um *algoritmo de punições e recompensas - versão de refinamento* - ajusta os valores dos pesos das conexões

das redes a partir dos casos de treinamento. Ambos os algoritmos são a seguir detalhados.

1.3.2.1.1 O Aprendizado Indutivo

O aprendizado indutivo no modelo MNC, de acordo com o método originalmente proposto para a construção da rede, em [DEN 91], prevê a geração de uma rede neural MNC *vazia*. Este processo se efetiva através do agrupamento de todos os achados da base de conhecimento em nodos combinatórios de m elementos, $m-1$ elementos, ..., e 1 elemento, para todos os diagnósticos, sendo m um número da ordem de 2, 3 ou 4. Todavia, mesmo gerando nodos intermediários que agrupam um número limitado de elementos, as redes neurais geradas por este método são extremamente grandes e contêm excesso de informação irrelevante, já que reúnem, em nodos intermediários, achados que não são importantes para o diagnóstico. Por isto, na implementação de HYCONES, como descrito em [REA 93b], foi adotada a seguinte estratégia para geração das redes neurais não treinadas, na qual, para cada um dos diagnósticos, procede-se da seguinte forma:

- **passo 1:** calcular a frequência com que cada achado contribui para o diagnóstico;
- **passo 2:** selecionar os achados mais frequentes e combiná-los em nodos intermediários da rede neural de dois e três elementos, de modo a esgotar as possibilidades de combinações entre eles;
- **passo 3:** criar acumuladores de punições e de recompensas para cada conexão da rede, colocando-os em 0;
- **passo 4:** colocar todos os pesos de conexão da sub-rede em 1.

Após sua geração, a rede neural *vazia* é treinada a partir dos casos armazenados na *base de casos*. Este treinamento consiste na modificação dos pesos de cada conexão da rede neural, segundo o seguinte critério: *recompensar* os ramos da rede que levam aos diagnósticos corretos e *punir* os ramos da rede que levam aos

diagnósticos incorretos. O treinamento da rede neural tem início através da aplicação do *Algoritmo de punições e recompensas - versão de arranque*, definido para o MNC [DEN 91]. Este algoritmo produz uma rede treinada não-operante, contendo os valores dos acumuladores de punições e de recompensas. O algoritmo, que utiliza uma versão simples do mecanismo de *back-propagation* [RUM 86], é apresentado a seguir. Para cada exemplo da base de casos de treinamento, adota-se o seguinte procedimento:

- **passo 1:** propagar os sinais de entrada até a camada de hipóteses;
- **passo 2:** para cada arco que alcance algum nodo de hipótese, fazer:

Se o nodo de hipótese alcançado corresponde a um resultado correto,

Então, propagar retroativamente, a partir deste nodo, até os nodos de entrada, um acréscimo no valor do acumulador de recompensas, de acordo com a seguinte equação:

$$AR = AR + FE \cdot AD \cdot IE$$

na qual AR representa o vetor dos acumuladores de recompensas, FE representa o fluxo evidencial, AD a ativação do neurônio de destino e IE a importância do exemplo para o treinamento.

Se não, propagar retroativamente um acréscimo no valor do acumulador de punições deste nodo até os nodos de entrada, de acordo com a seguinte equação:

$$AP = AP + FE \cdot AD \cdot IE,$$

na qual AP representa o vetor de acumuladores de punições.

Para transformar a versão treinada e não-operante da rede neural numa versão operante, aplica-se o algoritmo de *poda e normalização* [DEN 91]. Este algoritmo tem o objetivo de transformar os acumuladores de punições e recompensas da rede neural em pesos de conexão no intervalo [0,1]. O algoritmo de *poda e normalização* é apresentado a seguir. Para cada arco da rede, procede-se da seguinte maneira:

- **passo 1:** calcular o valor líquido dos acumuladores, representados por *ACUMLIQ*, pela seguinte equação:

$$ACUMLIQ = AR - AP,$$

na qual *AR* representa o valor do acumulador de recompensas e *AP* o valor do acumulador de punições para cada arco.

- **passo 2:**

Se *ACUMLIQ* \leq 0,

Então,

Remover o arco da rede.

Se não,

Se acumulador de punições *AP* do arco $>$ 0,

Então,

Computar o peso do arco, de acordo com a seguinte equação:

$$w = ACUMLIQ / MAXLIQ ,$$

na qual *MAXLIQ* representa o maior *ACUMLIQ* da sub-rede da hipótese à qual o arco pertence.

Se não,

Computar o peso do arco, de acordo com a seguinte equação:

$$w = \text{SQRT}(\text{LACEIT}) + (1 - (\text{SQRT}(\text{LACEIT}))) \text{ACUMLIQ} / \text{MAXLIQ},$$

na qual *LACEIT* representa um limiar de aceitação, pré-estabelecido pelo engenheiro de conhecimento.

- **passo 3:**

Se o peso *w* do arco < *Limiar de poda*,

Então,

Remover o arco da rede.

O *Limiar de poda* também é um valor pré-estabelecido pelo engenheiro de conhecimento.

- **passo 4:** remover todos os neurônios das camadas de entrada e combinatória que percam conectividade com os nodos de hipótese.

O componente da máquina de aprendizado responsável pelo aprendizado incremental faz uso do algoritmo de *punições e recompensas - versão de refinamento*, para mimetizar a capacidade de aprendizado por experiência dos seres humanos [DEN 91]. Este algoritmo também produz uma rede treinada não operante contendo os valores dos acumuladores de punições e de recompensas. O princípio dos dois algoritmos é o mesmo: recompensar os ramos da rede que levam ao diagnóstico correto e punir os ramos da rede que levam a diagnósticos incorretos. A versão de refinamento do algoritmo é apresentada a seguir.

Para cada exemplo da base de casos de treinamento, deve-se fazer:

- **passo 1:** Propagar os sinais de entrada até a camada de hipóteses;

- **passo 2:** Para cada arco que alcance algum nodo de hipótese H , proceder da seguinte maneira:

Se o nodo de hipótese alcançado corresponde a um resultado correto,

Então, calcular

$$a = 1 - \text{ativação}(H),$$

propagando retroativamente, a partir deste nodo, até os nodos de entrada, um acréscimo no valor do acumulador de recompensas, de acordo com a seguinte equação:

$$AR = AR + a \cdot FE \cdot AD \cdot IE.$$

Se não, calcular

$$a = \text{ativação}(H),$$

propagando retroativamente um acréscimo no valor do acumulador de punições deste nodo, até os nodos de entrada, de acordo com a seguinte equação:

$$AP = AP + a \cdot FE \cdot AD \cdot IE.$$

Para transformar a rede treinada pelo algoritmo de *punições e recompensas - versão de refinamento*, em uma rede operante, aplica-se o mesmo algoritmo de *poda e normalização*, anteriormente apresentado, com o objetivo de transformar os acumuladores de punições e de recompensas em pesos de conexão e de remover conexões de peso muito baixo.

1.3.2.1.2 O Aprendizado Dedutivo

O aprendizado por dedução, executado pelo modelo MNC, é visto mais como a criação de novos conceitos a partir do conhecimento já existente do que como uma operação lógica formal.

O modelo de aprendizado por dedução, utilizado na ferramenta NEXTOOL, emprega algoritmos genéticos (AG) para fazer a análise dos modelos gerados pela aprendizagem indutiva e gerar novos modelos da realidade. Neste sistema, o ciclo formado pelos componentes conexionista e genético da máquina de aprendizado, utilizando o modelo MNC, foi denominado *Aprendizado Evolutivo* e provou ser muito eficiente no desenvolvimento de sistemas classificatórios com poderosas capacidades adaptativas [DEN 91].

Todavia, o aprendizado por dedução, implementado por HYCONES, não faz uso de algoritmos genéticos para gerar novos modelos da realidade. Concebeu-se um mecanismo de reorganização e treinamento das redes neurais, análogo ao operador de recombinação dos algoritmos genéticos [HOL 75] [GOL 89] [LAW 91]. A estratégia para recombinação dos elementos das redes neurais, extraída de [REA 93b], segue os passos abaixo descritos:

- **passo 1:** coletar todos os achados do *frame de diagnóstico* e combiná-los em nodos intermediários de dois e três elementos, de modo a esgotar as possibilidades de combinações entre eles;
- **passo 2:** calcular a frequência com que cada combinação aparece nos casos de treinamento da base de casos, eliminando as combinações menos frequentes;
- **passo 3:** criar acumuladores de punições e de recompensas para cada conexão da rede, colocando-os em 0;
- **passo 4:** colocar todos os pesos de conexão da rede em 1.
- **passo 5:** retreinar a rede pelos casos da base de casos através do *algoritmo de punições e recompensas* - versão de arranque;
- **passo 6:** normalizar e podar a rede, com o algoritmo de *poda e normalização*.

Através deste mecanismo, pode ser reestruturada uma rede neural MNC que conecta certas evidências a uma determinada hipótese, gerando novas possibilidades de solução para os problemas de classificação.

1.3.2.1.3 Os Grafos de Conhecimento

Além de possibilitar que o aprendizado heurístico seja implementado, o modelo MNC é considerado uma importante conexão entre as áreas de redes neurais e a engenharia de conhecimento, já que sua estrutura de funcionamento e sua topologia são baseadas em grafos de conhecimento extraídos de múltiplos especialistas.

Um grafo de conhecimento é definido como um grafo acíclico mínimo que representa o conhecimento de especialistas para uma determinada hipótese de diagnóstico [MAC 90]. O método para obtenção dos grafos, proposto em [LEA 90], inicia por uma fase de entrevistas com um especialista, onde lhe é solicitado que sejam escolhidos fatores importantes na resolução do problema em questão, por exemplo, sintomas importantes para o diagnóstico de uma doença .

A seguir, o especialista deve ordenar os itens selecionados, de acordo com seu grau de importância para a resolução do problema, dispondo-os na base do grafo. Os itens devem, então, ser ligados em nodos intermediários, que representam a relevância de um conjunto de fatores para a resolução do problema, a qual, por sua vez, sempre é representada pelo nodo situado no topo do grafo.

A última etapa na construção dos grafos consiste na atribuição de valores de importância, numa escala de 0 a 10, para os itens da base e para os agrupamentos de itens (nodos intermediários).

Os nodos intermediários geralmente representam um *E-lógico* entre as evidências. Já, o nodo de hipótese representa um *OU-lógico*. Por isto, separando-se todos os sub-grafos conectados por um *OU-lógico*, um grafo de conhecimento pode ser facilmente transformado em outros tantos.

A Figura 4 representa um grafo de conhecimento de um especialista para uma hipótese de diagnóstico.

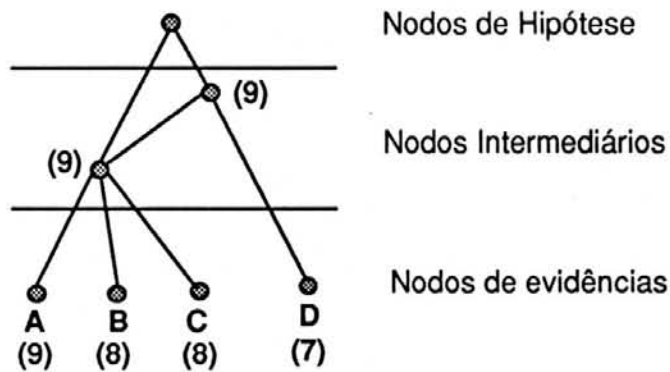


Figura 4 Grafo de conhecimento

1.3.3 O Mecanismo de Explicação

Em HYCONES, as explicações são obtidas pelo componente simbólico do sistema. Como o conhecimento da rede neural é simbolicamente representado pelos *frames de diagnóstico*, a inferência executada pela rede neural é explicada através da análise destes *frames*.

Existem diferentes formas de se conduzir a explicação do raciocínio de um sistema especialista, recorrendo aos modelos causais, à invocação da racionalização e ao recurso à clarificação [ROL 88].

O mecanismo implementado em HYCONES emprega o modelo de explicação por racionalização, ou seja, o sistema busca convencer o usuário da validade da conclusão apresentada [REA 93b].

O principal meio de obter explicações em sistemas especialistas baseia-se no armazenamento de justificativas para cada passo adotado pelo sistema. Todavia, como o raciocínio em HYCONES é desenvolvido pelo componente conexionista, o armazenamento de justificativas durante o processo de inferência se torna inviável.

Por isto, HYCONES adota um mecanismo de explanação baseado na classificação dos elementos dos *frames de diagnóstico* a partir do *gatilho*, dos *achados-essenciais*, dos *achados-complementares* e dos *achados de negação*. Estes elementos podem ser vistos como regras compostas da seguinte forma:

Se

o *gatilho* do frame de diagnóstico estiver presente,

Então,

o diagnóstico é a provável solução para o problema.

Se

todos os *achados-essenciais* estiverem presentes,

Então,

o diagnóstico é solução.

Se

algum *achado complementar* estiver presente,

Então,

ratifica-se a hipótese de que o diagnóstico é a solução.

Se

algum dos *achados de negação* estiver presente,

Então,

o diagnóstico possivelmente não é a solução para o problema.

A classificação das regras em quatro tipos possibilita que seja elaborada uma explicação com base no papel de cada um dos elementos que aparece na parte esquerda da regra.

A conclusão apresentada é, portanto, obtida através da análise dos *frames de diagnóstico* que contêm representações simbólicas do conhecimento armazenado nas redes neurais.

1.4 A Teoria da Adaptação Ressonante

A teoria da adaptação ressonante (ART) [GRO 76] é um sistema que auto-organiza padrões de entrada em categorias de reconhecimento, mantendo equilíbrio entre as propriedades de **plasticidade** (discriminação) e de **estabilidade** (generalização). A propriedade de plasticidade define a habilidade do sistema em criar novas categorias de reconhecimento, quando padrões estranhos estimulam o sistema. A propriedade de estabilidade é responsável pela habilidade em agrupar padrões similares na mesma categoria de reconhecimento.

Uma regra de similaridade que define onde agrupar os padrões é determinada pelo grau de semelhança entre dado padrão e padrões previamente armazenados (protótipos).

Vários modelos conexionistas derivados da teoria da adaptação ressonante têm sido propostos e analisados [GUA 93a], dentre eles:

- **ART 1:** é caracterizado pelo tratamento de apenas padrões binários [CAR 87a] [GUA 91] [SIM 90] [WAS 89];
- **ART 2:** processa entradas analógicas [CAR 87b] [CAR 87c] [CAR 91a];
- **ART 3:** é caracterizado por levar em conta a ação dos neurotransmissores nos mecanismos de sinapse, em uma estrutura ART hierárquica [CAR 90];
- **Fuzzy ART:** incorpora conceitos nebulosos numa arquitetura ART 1, possibilitando o tratamento de entradas analógicas [CAR 91b];
- **ARTMAP:** arquitetura preditiva, baseada em dois módulos ART [CAR 91c];
- **Fuzzy ARTMAP:** arquitetura preditiva baseada em conceitos nebulosos [CAR 92a] [CAR 92b] [CAR 92c].

Em um módulo ART, dois subsistemas complementares interagem entre si para o processamento dos padrões de entrada, são eles:

- **Subsistema Atencional:** é responsável pelo processamento de padrões de entrada familiares, estabelecendo respostas e representações internas mais precisas de tais padrões;

- **Subsistema de Orientação:** trata dos padrões estranhos, inibindo o subsistema atencional quando tais padrões são apresentados à rede.

Em ART, não há um algoritmo de busca como o de pesquisa em árvore, pois ART é capaz de realizar pesquisas paralelas que, adaptativamente, atualizam sua ordem de busca. Por isto, ART mantém a eficiência (categorias de reconhecimento são acessadas diretamente pelos padrões familiares de entrada) ao mesmo tempo em que a representação interna do conhecimento se torna arbitrariamente complexa, devido à aprendizagem.

Atualmente, a rede *Fuzzy ARTMAP* é o modelo neural baseado em ART mais utilizado, devido à sua simplicidade, quando comparado aos modelos ART 2 e ART 3 que, como *Fuzzy ARTMAP*, tratam padrões analógicos.

1.4.1 A Rede *Fuzzy ARTMAP*

A rede *Fuzzy ARTMAP*, mostrada na Figura 5, é composta basicamente por dois módulos *Fuzzy ART*, o módulo ART_a , que recebe o padrão de entrada **a**, e o módulo ART_b , que recebe o padrão de entrada **b**. Estes dois módulos são conectados por um módulo inter-ART, chamado de *map field*, que desempenha o papel de memória associativa, controlando a formação do **mapa associativo** entre as categorias de reconhecimento de ART_a e as de ART_b . Daí a denominação ARTMAP. Por esta razão, *Fuzzy ARTMAP* faz parte da classe de arquiteturas neurais chamada de ART Preditiva.

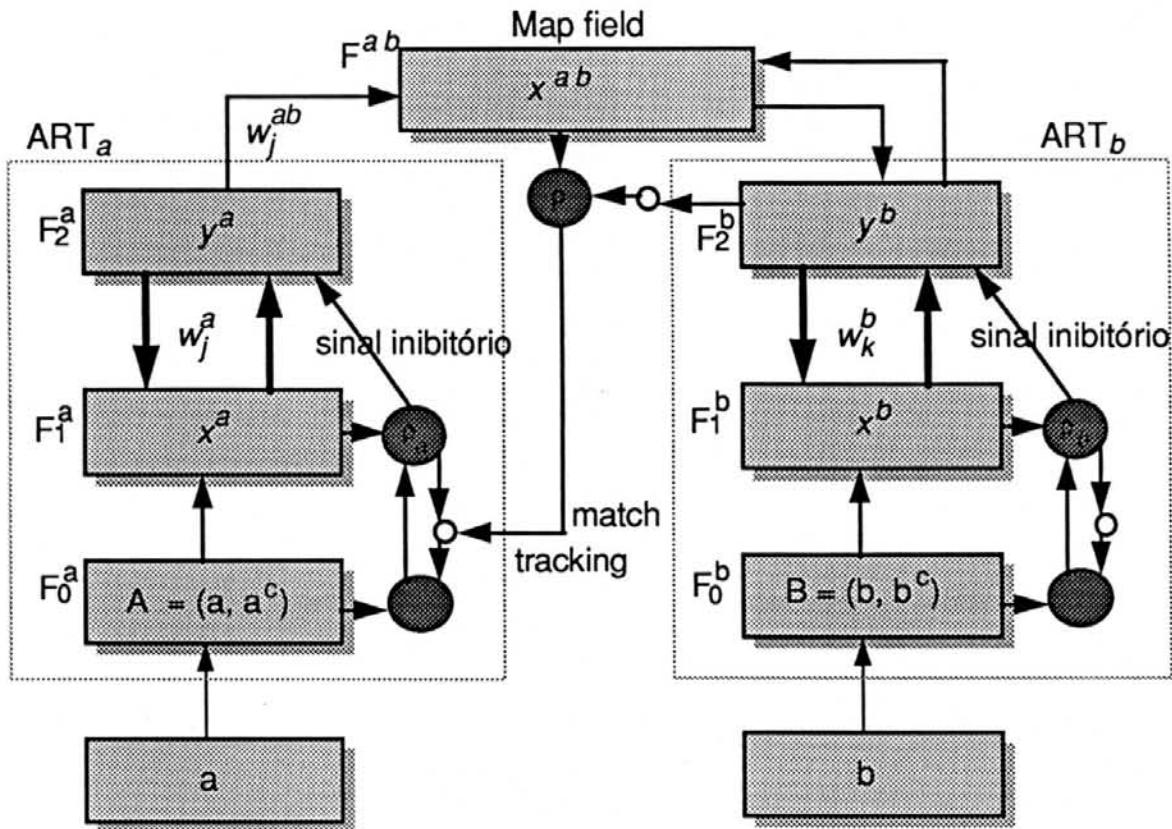


Figura 5 Arquitetura da rede Fuzzy ARTMAP

1.4.1.1 O módulo Fuzzy ART

Um módulo Fuzzy ART, representado na Figura 5 pelo módulo ART_a ou ART_b , é muito semelhante a um módulo ART 1. No caso especial do tratamento de entradas binárias, Fuzzy ART é computacionalmente idêntico à ART 1. Em Fuzzy ART, a tradicional teoria dos conjuntos utilizada em ART 1 foi substituída pela teoria dos conjuntos nebulosos [CAR 91b]. Desta forma, quando, em Fuzzy ART, é empregado o operador de mínimo (\wedge), em ART 1 é empregado o operador de intersecção (\cap). Além disto, Fuzzy ART, se comparado com ART 1, executa uma operação adicional de pré-processamento dos padrões de entrada.

No módulo Fuzzy ART, ocorrem dois processos distintos quando um padrão de entrada estimula a rede. O processo *bottom-up*, também conhecido como filtro adaptativo ou processo de ampliação dos contrastes, que produz um padrão Y , e o

processo *top-down* que realiza uma operação de similaridade, produzindo o padrão X^* (Figura 6).




Figura 6 Arquitetura da rede *Fuzzy ART*

Dado um determinado conjunto de padrões de entrada, representa-se um padrão pertencente a este conjunto pela letra I . Quando I é copiado para a camada F1 (subsistema atencional), ele passa a ser chamado de X (o padrão X é idêntico ao padrão I). Em F1, os neurônios ativados pelo padrão X geram sinais de saída que são propagados pelas conexões entre as camadas F1 e F2 (LTM). Este processo produz na camada F2 o padrão Y , que representa o padrão de contrastes ampliados. Y é o resultado de um processo *Winner-Take-All* (WTA), no qual apenas um neurônio em F2, aquele com a maior ativação de entrada, pode ser o vencedor. Enquanto os neurônios perdedores geram um sinal de saída com valor igual a 0, ao neurônio vencedor é permitida a geração de um sinal de saída igual a 1 (em *Fuzzy ARTMAP*, X e Y são identificados pelo índice do módulo *Fuzzy ART* ao qual pertencem, ou seja, no módulo ART_a , o padrão de saída de $F1^a$ é representado por x^a , e no módulo ART_b , por x^b . Já, o padrão Y , que representa o sinal de saída de F2, é representado por y^a em ART_a e y^b em ART_b).

Neste ponto, o processo *bottom-up* termina e o *top-down* inicia. A partir do neurônio vencedor em F2, é produzido um padrão *top-down* em direção à camada F1. Este novo sinal é chamado de padrão *V*, ou expectativa de aprendizagem.

Há, agora, duas fontes de entrada que estimulam F1: o padrão de entrada *I* e o *V*. Juntos, eles dão origem, em F1, ao padrão X^* que é tipicamente diferente do X . O padrão X^* indica o grau de semelhança entre ϕ a entrada e o protótipo armazenado nas conexões entre os neurônios das camadas F1 e F2. Para verificar o grau de similaridade representado em X^* , a fim de decidir se o padrão de entrada deve ser agrupado (estabilizado) no neurônio vencedor ou se outro neurônio deve ser utilizado, é necessário definir uma regra que leve em consideração X^* e *I*. É possível definir várias regras diferentes que aceitam ou rejeitam este agrupamento.

Há situações nas quais os neurônios da camada F1 devem estar desabilitados, ou seja, não devem gerar sinais de saída. Por exemplo, os neurônios em F1 não devem gerar saídas quando excitados apenas pelo padrão *V*, mas devem ser capazes de gerar saídas quando excitados pela entrada *I*. Para que esta situação seja controlada, existe o chamado controle de ganho atencional (B). Quando F2 está ativo, geram-se sinais excitatórios em direção a F1 (padrão *V*) ao mesmo tempo em que se inibe o controle de ganho B (Figura 7(a)). A regra que controla a camada F1, chamada de 2/3 [CAR 87a], indica que duas das três fontes de sinais disponíveis em F1 (padrão *V*, padrão de entrada *I* e B) são necessárias para que os neurônios possam gerar sinais de saída, também chamados de sinais supra-limiare. Durante o processamento *bottom-up*, F1 recebe o padrão *I* e um sinal excitatório do controle de ganho atencional, possibilitando que os neurônios possam gerar sinais de saída supra-limiare (Figura 7(b)). Durante o processo de comparação dos padrões *bottom-up* e *top-down* também são geradas ativações supra-limiare (Figura 7(c)).




Figura 7 A regra 2/3

1.4.1.1.1 A aprendizagem em *Fuzzy ART*

A utilização da aprendizagem rápida possibilita a adaptação instantânea de um sistema a padrões de entrada esporádicos e importantes, por isto requerendo tratamento imediato. Isto é impossível em sistemas baseados na regra *back-propagation* [RUM 86], pois, ao mesmo tempo em que o sistema aprende coisas novas, ele esquece o conhecimento previamente adquirido. Em *Fuzzy ART*, a aprendizagem rápida é combinada com uma taxa de esquecimento (enfraquecimento da conexão representativa de alguma determinada característica). Esta combinação é chamada de *fast-commit, slow-encode* [CAR 91b].

A dinâmica de um sistema *Fuzzy ART* é dirigida por 3 parâmetros, são eles o parâmetro de escolha $\alpha > 0$, o parâmetro de vigilância $\rho \in [0,1]$ e o parâmetro que regula a taxa de aprendizagem $\beta \in [0,1]$

Na aprendizagem rápida, o parâmetro β recebe o valor 1. Entretanto, se a propriedade *fast-commit slow-encode* for desejada, o valor de β , para neurônios que ainda não representam categoria alguma, é modificado tipicamente para 0,9 depois da primeira adaptação daquele neurônio.

Em *Fuzzy ART*, os pesos das conexões entre as camadas F1 e F2 são inicializados com 1 e são representados pelo vetor de pesos w_j . Assim, no início,

$$w_{j1} = w_{j2} = \dots = w_{jM} = 1,$$

onde M indica o número de neurônios em F1 e N o número de neurônios em F2, com j podendo variar de 1 até N (em *Fuzzy ARTMAP*, enquanto que M_a indica o número de neurônios da camada F1^a no módulo ART_a, M_b indica o número de neurônios F1^b em ART_b. Já, N_a e N_b indicam o número de neurônios em F2 de ART_a e ART_b, respectivamente).

A escolha da categoria j em F2 por um determinado padrão de entrada I , obedece à função de escolha T_j definida como segue:

$$T_j(I) = \frac{|I \wedge w_j|}{\alpha + |w_j|},$$

na qual o operador *E-nebuloso* é definido como

$$(x \wedge y)_i \equiv \min(x_i, y_i)$$

e a norma $|\cdot|$ é definida como

$$|x| = \sum_{i=1}^M |x_i|.$$

Pelo processo WTA, o neurônio com a maior ativação de entrada será o escolhido, ou seja,

$$T_J = \max\{T_j; j = 1 \dots N\},$$

onde J representa o índice do neurônio vencedor. Se mais de um neurônio obtiver a ativação máxima, aquele que possuir índice j menor será o escolhido.

Por sua vez, o subsistema de orientação gera um sinal inibitório se

$$\frac{|I \wedge w_j|}{|I|} < \rho .$$

Quando isto acontece, o neurônio J é inibido durante a apresentação corrente do padrão de entrada para que não seja novamente selecionado, possibilitando que outro neurônio em F2 seja escolhido. O processo termina quando a inequação acima for falsa. Quando isto acontece, o sistema encontra-se em estado de ressonância, ou seja, uma categoria estável foi escolhida. Desta forma, a rede executa o processo de adaptação do padrão de entrada através da mudança dos valores das conexões da categoria ativada. Esta mudança é feita de acordo com a seguinte equação:

$$w_j(t+1) = \beta (I \wedge w_j(t)) + (1 - \beta) w_j(t).$$

Durante a aprendizagem, se o parâmetro α , usado na equação responsável pela escolha da categoria j em F2, receber um valor próximo de zero, o sistema está dentro do chamado *limite conservativo* ($\alpha \rightarrow 0$) [CAR 91b]. Quando isto acontecer, o padrão de entrada tenta sempre ativar uma determinada categoria, caso exista, que represente nos seus respectivos pesos um subconjunto nebuloso do padrão de entrada. Desta forma os pesos da LTM não são modificados, vindo daí o termo *limite conservativo*.

1.4.1.1.2 A codificação complementar

A operação de pré-processamento introduzida em *Fuzzy ART* trata da normalização dos padrões de entrada através de um procedimento chamado de codificação complementar. A introdução deste procedimento resolve um problema apresentado por Moore, citado em [CAR 91b], que prevê a criação incontrolável de categorias (neurônios em F2). Por outro lado, do ponto de vista funcional, a codificação complementar representa a porção *ligada* do padrão de entrada, na qual estão codificadas as suas características presentes, e a porção *desligada*, onde se acham codificadas as características ausentes do padrão. Além disto, a codificação complementar é um processo de normalização que preserva a amplitude da informação.

Supondo que a é um padrão, ou um vetor, de entrada qualquer, a^c representa seu complemento, ou seja,

$$a_i^c \equiv 1 - a_i.$$

Desta forma, utilizando a codificação complementar, o padrão de entrada I é codificado como sendo

$$I = (a, a^c) \equiv (a_1, \dots, a_M, a_1^c, \dots, a_M^c).$$

Note-se que

$$|I| = |(a, a^c)| = \sum_{i=1}^M a_i + (M - \sum_{i=1}^M a_i) = M,$$

ou seja, as entradas pré-processadas através da codificação complementar estão automaticamente normalizadas.

A codificação complementar estabelece ainda uma relação entre as porções *ligada* e *desligada* do padrão de entrada e as operações da teoria dos conjuntos nebulosos. De acordo com esta relação, tanto os operadores de ^{máximo} mínimo, ou *OU-nebuloso*, (\vee) como de ^{mínimo} máximo, ou *E-nebuloso*, (\wedge) fornecem uma interpretação geométrica para a aprendizagem em *Fuzzy ART*. Esta interpretação é dada através de retângulos representativos das categorias de reconhecimento, nos quais os cantos são iterativamente definidos, de acordo com os operadores \wedge e \vee . Verifica-se, assim, que, tal como acima afirmado, a codificação complementar estabelece uma conexão entre as porções *ligada* e *desligada* do padrão de entrada e as operações da teoria dos conjuntos nebulosos.

1.4.1.2 Aprendizagem em *Fuzzy ARTMAP*

Durante a aprendizagem rápida, um sistema *Fuzzy ARTMAP*, ao mesmo tempo que maximiza a generalização, minimiza o erro preditivo, em tempo real, em resposta a uma ordem arbitrária de padrões de entrada \mathbf{a} e \mathbf{b} . Entende-se por erro

preditivo a ativação de uma categoria em $F2^a$, por um determinado padrão a , que prediz outra categoria em $F2^b$, que não aquela ativada pelo padrão b corrente.

A maximização da generalização e a minimização do erro preditivo são alcançadas, durante a aprendizagem, incrementando-se o parâmetro de vigilância em resposta a um erro preditivo. Este parâmetro é incrementado até que seu valor exceda o valor resultante do processo de comparação dos padrões *bottom-up* e *top-down* realizado na camada F1 do módulo ART_a ($F1^a$). Esta estratégia, controlada pelo módulo inter-ART, é chamada de *match-tracking* [CAR 91c] e é descrita mais adiante.

O módulo inter-ART permite ainda que um sistema ARTMAP estabeleça categorias diferentes para padrões similares de entrada em ART_a , mas que fazem previsões diferentes. Inter-ART possibilita também a formação de categorias para padrões diferentes de entrada em ART_a , mas com a mesma previsão em ART_b .

Na notação empregada em [CAR 91c], a hierarquia de *Fuzzy ARTMAP*: ART_a , ART_b e o módulo inter-ART é toda descrita em termos das variáveis e dos parâmetros de *Fuzzy ART*. Os índices a e b identificam termos nos respectivos módulos ART_a e ART_b . Entretanto, as variáveis e os parâmetros de inter-ART não apresentam tal índice. Assim, ρ_a , ρ_b e ρ representam os respectivos parâmetros de vigilância de ART_a , ART_b e inter-ART.

Em *Fuzzy ARTMAP*, os neurônios da camada $F2^a$, indexados por $j = 1, \dots, N_a$, geram sinais de saída binários y_j^a , enquanto que o sinal de saída dos neurônios da camada $F1^a$ é representado pelo vetor x^a . Já, os neurônios da camada $F2^b$, indexados por $k = 1, \dots, N_b$, geram sinais de saída binários y_k^b e os neurônios da camada $F1^b$ geram sinal x^b . Os pesos das conexões entre as camadas F1 e F2 são representados por w_j^a e w_k^b nos módulos ART_a e ART_b , respectivamente. O índice do neurônio ativo em $F2^a$ é representado por J e o índice do neurônio ativo em $F2^b$ é representado por K . Como o módulo inter-ART é o lugar onde os sinais vindos de $F2^a$ e de $F2^b$ interagem, ele é representado por F^{ab} . Os neurônios de F^{ab} são indexados da mesma forma que os da camada $F2^b$, pois existe uma correspondência de um para um entre os neurônios das duas camadas. O sinal de saída gerado pelos neurônios em F^{ab} é representado por x^{ab} , enquanto que os pesos das conexões entre

o j -ésimo neurônio em F_2^a e F^{ab} são representados pelo vetor w_j^{ab} . O valor zero é atribuído aos vetores x^a, y^a, x^b, y^b e x^{ab} na apresentação dos padrões de entrada.

O módulo inter-ART F^{ab} é ativado sempre que uma das categorias de ART_a ou ART_b está ativa. Assim, três situações diferentes podem ocorrer, são elas:

- se o neurônio J de F_2^a é ativado, as conexões w_j^{ab} transmitirão seu sinal de ativação até F^{ab} ;
- se o neurônio K é ativado em F_2^b , o neurônio K em F^{ab} também é ativado, pois existe a correspondência de um para um entre os neurônios de F_2^b e F^{ab} ;
- se ambos ART_a e ART_b são ativados, F^{ab} é ativado somente se ART_a prediz a mesma categoria ativada em ART_b através das conexões w_j^{ab} .

Ou seja, o padrão de saída x^{ab} obedece à seguinte equação:

$$x^{ab} = \begin{cases} y^b \wedge w_j^{ab} & \text{se o } J\text{-ésimo neurônio de } F_2^a \text{ está ativo e } F_2^b \text{ está ativo} \\ w_j^{ab} & \text{se o } J\text{-ésimo neurônio de } F_2^a \text{ está ativo e } F_2^b \text{ está inativo} \\ y^b & \text{se } F_2^a \text{ está inativo e } F_2^b \text{ está ativo} \\ 0 & \text{se ambos } F_2^a \text{ e } F_2^b \text{ estão inativos} \end{cases}$$

Pode-se perceber pela equação acima que na ocorrência de um erro preditivo, a ativação w_j^{ab} não é confirmada por y^b , fazendo com que x^{ab} seja igualado a zero na aplicação do operador *E-nebuloso*. Neste caso, a estratégia de *match-tracking* é ativada e passa a controlar a dinâmica do sistema. Esta estratégia prevê a geração de um sinal inibitório a partir do módulo inter-ART, que é enviado para o subsistema de orientação do módulo ART_a . Esta situação ocorre sempre que

$$|x^{ab}| < \rho |y^b|$$

onde ρ é o parâmetro de vigilância do módulo inter-ART. A partir daí, ocorre o ajuste de ρ_a . Este é feito da seguinte maneira: no início da apresentação do padrão de entrada, o parâmetro de vigilância de ART_a obedece a um valor fixo básico $\bar{\rho}_a$.

Entretanto, para que o neurônio vencedor em $F2^a$ seja inibido, este valor básico deve ser incrementado até que

$$\rho_a > \frac{|I \wedge w_j^a|}{|I|},$$

onde I é o padrão de entrada pré-processado. Assim,

$$|x^a| = |I \wedge w_j^a| < \rho_a |I|,$$

onde J representa o neurônio escolhido em $F2^a$. Quando isto ocorre, o neurônio J em ART_a é inibido e a busca por uma categoria apropriada continua.

Para que a aprendizagem rápida seja possível, os pesos w_{jk}^{ab} das conexões $F2^a \rightarrow F^{ab}$ devem ser inicializados com o valor 1. Durante o estado ressonante, quando os pesos das conexões são atualizados, os pesos w_j^{ab} se aproximam do vetor x^{ab} . Na aprendizagem rápida, uma vez que uma categoria J em $F2^a$ prediz uma categoria K em $F2^b$, essa associação torna-se permanente, ou seja, w_{jK}^{ab} vai ser sempre igual a 1.

2 OBJETIVOS

O presente trabalho tem como objetivos principais:

- Adaptar a rede neural *Fuzzy ARTMAP* ao sistema HYCONES;
- Validar o sistema, utilizando as bases de dados sobre cardiopatias congênitas e síndromes renais capturadas de prontuários médicos;
- Comparar os resultados fornecidos pelo sistema HYCONES, que utiliza o modelo MNC, com os resultados obtidos com a rede ART;
- Propor modificações no modelo ART, caso a rede não apresente resultados satisfatórios.

3 METODOLOGIA

Este capítulo descreve inicialmente o porquê da escolha de *Fuzzy ARTMAP* como modelo conexionista básico do presente trabalho, para, em seguida, apresentar as duas redes neurais ART propostas e implementadas em HYCONES: *Simplified Fuzzy ARTMAP* e *Semantic ART (SMART)*. Com isto, HYCONES passa a ser chamado de HYCONES II [LEA 94] [GUA 94a] [GUA 94b]. Finalmente, são apresentados os processos de aquisição de conhecimento e o motor de inferência do sistema HYCONES II, a partir da incorporação dos novos modelos ART.

3.1 Por que Fuzzy ARTMAP?

A rede *Fuzzy ARTMAP* foi o sistema conexionista escolhido para ser representado na nova versão de HYCONES, chamada de HYCONES II, fornecendo, assim, mais uma alternativa ao engenheiro de conhecimento. Esta escolha deve-se a uma série de motivos. Dentre estes, podem-se salientar os seguintes, quanto à rede *Fuzzy ARTMAP*:

- mantém um balanço entre as propriedades de plasticidade e estabilidade, o que não é garantido, por exemplo, em se tratando de modelos neurais que empregam o algoritmo *back-propagation* [RUM 86].
- destaca-se pela sua simplicidade, se comparada a outros modelos baseados na teoria da adaptação ressonante, como ART 2 e ART 3;
- está sendo aplicada a problemas classificatórios complexos, como o do reconhecimento de caracteres escritos à mão [CAR 92a];
- Implementa o aprendizado a partir de conceitos nebulosos, permitindo, com isto, o tratamento de padrões analógicos;
- possui a capacidade de criar categorias de reconhecimento, o que facilita o entendimento do processo de inferência da rede;

- seu processo de aprendizagem é supervisionado e se desenvolve em *one-shot-learning* - um padrão precisa ser visto apenas uma vez, para que seja aprendido pela rede.

3.2 A Rede *Simplified Fuzzy ARTMAP*

A máquina de aprendizado de HYCONES II implementa a rede *Simplified Fuzzy ARTMAP* que, como seu próprio nome o diz, é uma simplificação da rede *Fuzzy ARTMAP*, descrita no capítulo 1. A rede *Simplified Fuzzy ARTMAP* é fortemente baseada na rede *Simplified ARTMAP*, descrita em [GUA 93b] e [CAR 92b], que é uma simplificação do modelo *ARTMAP* [CAR 91c]. O surgimento do modelo *fuzzy* simplificado partiu da necessidade de utilização de uma rede *ART* supervisionada que não só garantisse o desempenho apresentado pela rede *Fuzzy ARTMAP*, mas, também, representasse uma efetiva simplificação desta, do ponto de vista arquitetural e de funcionamento.

Na nova arquitetura, os módulos ART_b e inter-*ART* são substituídos por uma camada chamada $F1^b$ que é diretamente responsável pelo tratamento do padrão **b**, sendo que **b** é a predição correta de um padrão de entrada **a** qualquer (Figura 8). Apesar desta simplificação, a nova arquitetura, assim como *Fuzzy ARTMAP*, garante, conjuntamente, a maximização da generalização e a minimização do erro preditivo, em resposta a uma ordem arbitrária de padrões de entrada **a** e **b**. Esta garantia é obtida através da execução da estratégia de *match-tracking*, durante o processo de aprendizagem da rede *Simplified Fuzzy ARTMAP*.

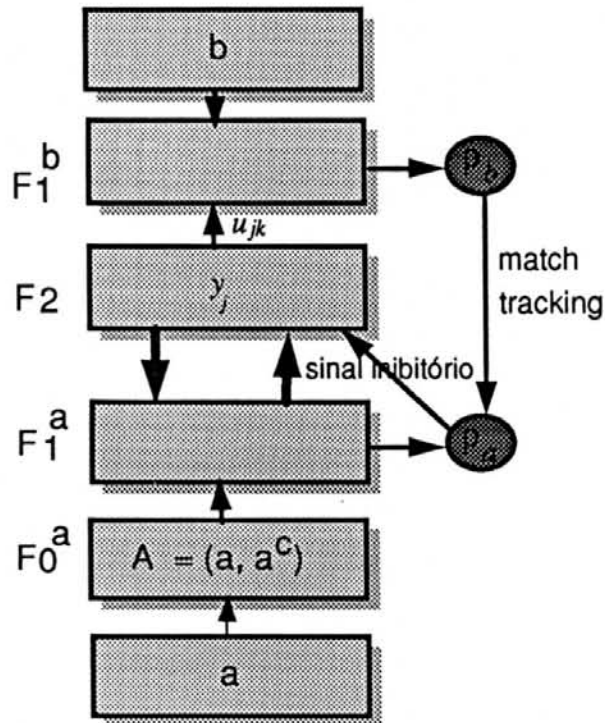


Figura 8 Arquitetura da Rede *Simplified Fuzzy ARTMAP*

Além das modificações supracitadas, na nova versão, o padrão **b** não é pré-processado e a camada $F1^b$ passa a receber apenas padrões binários. O padrão **b**, quando apresentado à rede, dá origem a um padrão T em $F1^b$, onde $T = (T_1, \dots, T_{M_b})$. Este padrão, ao contrário do que acontece em $F1^a$, não é propagado em direção à camada $F2$.

Como mencionado, o neurônio vencedor do processo WTA em $F2$ é o único a emitir um padrão de saída Y . Este padrão é enviado para a camada $F1^a$ que, juntamente com o padrão de entrada I , forma o padrão X_a^* (chamado anteriormente de X^*). Na nova versão, o neurônio vencedor também envia o padrão Y através das conexões unidirecionais para a camada $F1^b$. Inicialmente, estas novas conexões, denominadas $u_{jk} = (u_{j1}, \dots, u_{jM_b})$, possuem valor 1, onde $k = 1, \dots, M_b$ e $j = 1, \dots, N$. Em $F1^b$, o padrão Y , juntamente com o padrão T , dá origem ao padrão X_b^* . Desta maneira, a nova versão utiliza uma regra diferente para a detecção de um possível erro preditivo e conseqüente ativação do *match-tracking*. A nova regra obedece à equação seguinte:

$$\frac{|X_b^*|}{|I|} = \rho_b,$$

onde ρ_b representa a vigilância da camada $F1^b$ e possui valor 1. Se esta equação for falsa, *match-tracking* é executado, alterando o valor do parâmetro de vigilância ρ_a e, conseqüentemente, fazendo com que o subsistema de orientação emita um sinal inibitório em direção ao neurônio vencedor em $F2$.

Os demais procedimentos executados pelo módulo *Fuzzy ART* continuam inalterados, mas na versão simplificada de *Fuzzy ARTMAP* é definida uma nova regra de aprendizagem das conexões u_{jk} , que obedece à equação seguinte:

$$u_{jk} = \begin{cases} 1 & \text{se } y_j = t_k = 1 \\ 0 & \text{se } y_j = 1 \text{ e } t_k = 0 \\ u_{jk} & \text{se } y_j = 0 \end{cases}$$

na qual t_k representa o valor de entrada no k -ésimo neurônio da camada $F1^b$.

3.3 Incorporando Especificidade e Relevância ao ART: A Rede SMART

Como descrito anteriormente, a regra de aprendizagem da rede *Simplified Fuzzy ARTMAP*, baseada no operador *E-nebuloso*, leva em consideração apenas a sensibilidade dos achados de entrada. Por outro lado, o modelo MNC baseia sua regra de aprendizagem em um algoritmo de punições e recompensas que leva em consideração tanto a **sensibilidade** quanto a **especificidade** dos achados de entrada. Tal fato gerou a idéia de substituição da regra de aprendizagem do modelo ART pelo método de punições e recompensas utilizado pelo modelo MNC. Esta modificação deu origem à rede *Semantic ART* ou SMART descrita a seguir.

Para que esta substituição fosse possível, cada conexão existente entre as camadas $F2$ e $F1^a$ em ART, além de seu peso, passou a abrigar mais dois valores, o dos acumuladores de punições e o de recompensas. O processo de competição, executado entre os neurônios da camada $F2$, e o de comparação de semelhanças, executado na camada $F1^b$, não sofreram modificações. Entretanto, o processo de

comparação de semelhanças em F1ª passou a incorporar o vetor de fatores de relevância dos achados. A nova regra que regula este processo é mostrada a seguir:

$$\frac{|I \wedge w_j|}{|I \wedge E|} \geq \rho,$$

na qual E representa o vetor normalizado dos fatores de relevância dos achados de entrada. Quando o resultado desta inequação for falso, o neurônio vencedor em F2 é inibido pelo subsistema de orientação da rede.

No novo sistema, a nova regra de aprendizagem determina que os acumuladores de punições e recompensas sejam inicializados com 0 e os pesos, assim como na rede *Fuzzy ARTMAP*, sejam inicializados com 1. No novo sistema, assim como em ART, a cada caso apresentado, os achados de entrada são propagados de F1ª à F2. Nesta camada, são computados os valores das ativações de entrada de cada neurônio a partir da mesma equação definida no capítulo 1, apresentada novamente a seguir:

$$T_J(I) = \frac{|I \wedge w_j|}{\alpha + |w_j|}.$$

O neurônio vencedor J , aquele com a maior ativação em F2, será o único a emitir um sinal que será propagado até F1ª e F1ª pelas conexões entre estas duas camadas e F2. Em F1ª, de acordo com a inequação descrita acima, é executado o processo de comparação entre as evidências de entrada e as evidências representadas na categoria de reconhecimento do neurônio vencedor. Em F1ª, o diagnóstico apontado pelo caso de entrada é comparado com o diagnóstico representativo da categoria ativada. Este processo de comparação é regulado pela mesma inequação definida para o modelo *Simplified Fuzzy ARTMAP*, mostrada novamente a seguir:

$$\frac{|X_b^*|}{|I|} = \rho_b.$$

De acordo com o resultado destes dois processos de comparação, realizados em $F1^a$ e $F1^b$, uma das duas situações descritas a seguir pode ocorrer:

- se o resultado do processo de comparação realizado em $F1^b$ for igual a 1, independentemente do resultado do processo executado em $F1^a$ (maior ou menor que o parâmetro de vigilância), computam-se os valores dos acumuladores de recompensas das conexões entre o neurônio ativado em F2 e os neurônios representativos de todas as evidências de entrada em $F1^a$. Este cálculo é feito de acordo com a seguinte equação:

$$R(t+1) = R(t) + (O \cdot A \cdot E),$$

na qual R representa o vetor de acumuladores de recompensas, O é o vetor de ativações de saída dos neurônios da camada $F1^a$, A representa o valor das ativações de entrada dos neurônios em F2 e E é o vetor normalizado dos fatores de relevância das evidências de entrada;

- se o resultado da equação que regula o processo de comparação em $F1^b$ for falso e o resultado do processo de comparação em $F1^a$ for maior que o valor da vigilância da rede, então, de acordo com o processo de *match-tracking*, a vigilância da rede é incrementada até que a inequação que regula a comparação em $F1^a$ passe a ser falsa. *Match-tracking* não é executado se o resultado desta comparação resultar num valor menor que a vigilância ρ_a . Entretanto, em ambos os casos, o neurônio vencedor em F2 é inibido e para que o processo de aprendizagem continue, as evidências de entrada são restauradas na camada $F1^a$. Além disto, são computados os valores dos acumuladores de punições das conexões entre o neurônio vencedor em F2 e aqueles representativos das evidências de entrada em $F1^a$. Este cálculo obedece à seguinte equação:

$$P(t+1) = P(t) + (O \cdot A \cdot E)$$

na qual P representa o vetor de acumuladores de punições das conexões da categoria de reconhecimento ativada. O parâmetro de vigilância é restaurado ao seu valor original apenas depois que as evidências de entrada correntes forem categorizadas pela rede.

Imediatamente após o cálculo dos acumuladores de punições ou de recompensas da rede, são computados os pesos das conexões. Este cálculo é feito de acordo com a seguinte equação:

$$W = \frac{R - P}{Maxdiff}$$

onde *Maxdiff* representa a máxima diferença existente entre os acumuladores de recompensas e os de punições dentre todas as categorias da rede, relacionadas com o mesmo diagnóstico em F1^b. Se a diferença corrente entre os acumuladores é menor ou igual a zero, atribui-se o valor zero para o respectivo peso da conexão.

Finalmente, depois da fase de aprendizagem, um procedimento de poda é realizado. Cada conexão que possuir peso menor que um limiar pré-determinado é excluída da rede.

Para que a diferença entre os métodos de aprendizagem das redes *Simplified Fuzzy ARTMAP* e SMART fique mais clara são apresentados, nos apêndices II e III, respectivamente, exemplos do funcionamento destas redes, a partir de uma mesma base de casos hipotéticos.

3.4 A Aquisição Automática de Conhecimento

A aquisição automática de conhecimento para a construção da base de conhecimento e o aprendizado por experiência é um processo inerente ao funcionamento dos sistemas conexionistas [HIN 92].

Em modelos ART, os casos são apresentados à rede um a um. Na rede *Simplified Fuzzy ARTMAP* e SMART, implementadas em HYCONES II, enquanto que o diagnóstico, ou solução correta para o problema, é apresentado à camada F1^b, os achados fornecidos em cada caso, são apresentados à camada F1^a (Figura 9). A partir daí, de acordo com o processo de aprendizagem, a rede trata de formar o mapeamento entre os achados e a hipótese por eles apontada. Como a rede executa aprendizagem rápida (*one-shot-learning*), os casos precisam ser ensinados uma só vez.

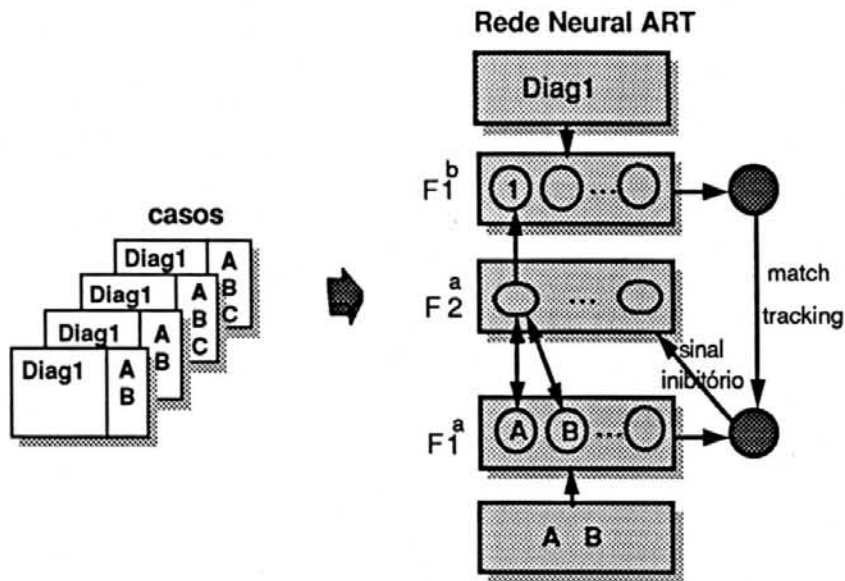


Figura 9 Aquisição automática de conhecimento em ART

3.5 O Motor de Inferência

A função do motor de inferência é a de resolver problemas através da análise do conhecimento armazenado na base de conhecimento. Como o conhecimento dos sistemas especialistas híbridos aqui tratados está armazenado na forma de *frames* e de redes neurais, o motor de inferência do sistema deve operar sobre ambas as formas de representação de conhecimento.

A inferência no sistema HYCONES II baseia-se no mecanismo de reconhecimento de padrões, implementado por um dos modelos neurais disponíveis no sistema: SMART, *Simplified Fuzzy ARTMAP* e MNC [LEA 94]. Um conjunto de evidências é apresentado às redes neurais, as quais, quando ativadas, passam a apresentar sinais de saída para cada um dos diagnósticos tratados pelo sistema. O mecanismo de explanação, baseando-se nos *frames* e na rede neural responsável pelo diagnóstico apontado apresenta, então, uma explicação para o raciocínio. A regra definida sobre os achados de negação nos *frames de diagnóstico* não se aplica aos modelos baseados na teoria da adaptação ressonante, pois tais achados são capturados apenas a partir dos pesos das conexões no modelo MNC. ART não

possui conexões inibitórias. A Figura 10 apresenta o esquema de funcionamento do motor de inferência.

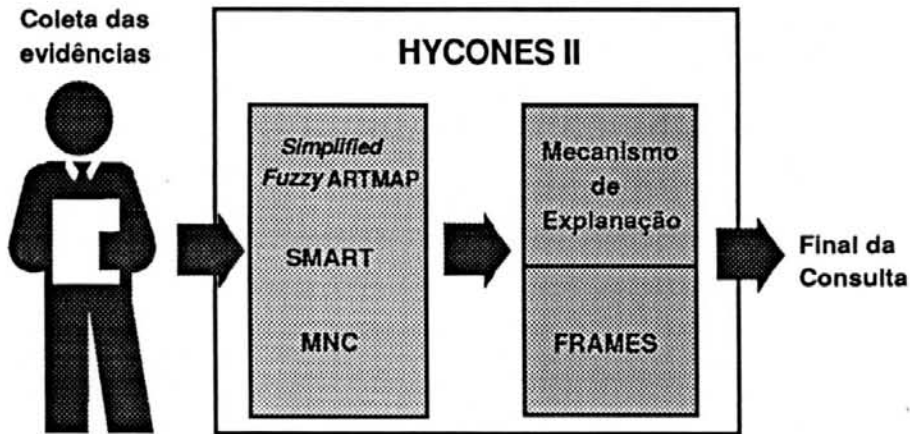


Figura 10 O motor de inferência de HYCONES II

Em todos os três modelos neurais SMART, *Simplified Fuzzy ARTMAP* e MNC, a rede que apresenta a maior ativação de saída é aquela que identifica, segundo cada modelo, a provável solução para o problema. No modelo MNC, para que uma determinada hipótese seja apresentada como solução, a rede com a maior ativação deve apresentar ainda um sinal de saída maior que um limiar de aceitação previamente estabelecido.

4 IMPLEMENTAÇÃO

O sistema HYCONES, desenvolvido em equipamento PC 486, configuração EISA e 16 Mb de memória RAM, utilizou a ferramenta Goldworks III para a criação da estrutura de *frames* do modelo híbrido [HEN 89]. O modelo MNC e as funções de acesso e manipulação da base de conhecimento híbrida, por outro lado, foram implementados a partir da linguagem de programação Golden Common LISP. A descrição completa da implementação do sistema HYCONES é descrita em [REA 93b].

As redes *Simplified Fuzzy ARTMAP* e SMART, incorporadas ao HYCONES, foram também desenvolvidas sobre a mesma plataforma, ou seja, em equipamento PC 486 e implementadas em linguagem Golden Common LISP **orientada a objetos**. A ferramenta Goldworks III, além de fornecer a estrutura de *frames*, propicia a programação LISP orientada a objetos.

Além dos modelos ART, foram implementadas, também em LISP, as funções de acesso e manipulação da base de conhecimento híbrida.

A seguir, é apresentado um trecho de programa (função *learning*), em Golden Common LISP orientado a objetos, responsável por parte do processo de aprendizagem em uma rede *Simplified Fuzzy ARTMAP*:

```

;*****
; SIMPLIFIED FUZZY ARTMAP
; Function LEARNING
; This function performs inductive learning in a Simplified
; Fuzzy ARTMAP neural network. First, it sets the global variables
; and gets all the cases to be learned from the case data
; base. For each case, it sends a message to the learn-case
; handler. After this, it fills the findings slot
; of each ART net generated during learning, calling the
; set-findings handler. Then, it sends a message to the
; pruning handler, which is responsible for the pruning
; procedure.
; Messages to:
; learn-case
; set-findings
; pruning
; Calling functions:
;   change-cases-order
;   convert-l-obj
; Global variables:

```



```

; *outstream*      -> output file used by the print function
; *alpha*         -> used by signal-transfer
; *l-all-diagnoses* -> gets all the diagnosis from frame
;                 diagnoses
; *l-all-findings* -> gets all the findings from frame
;                 gen-findings
; *baseline-vigilance* -> baseline vigilance parameter
; Returns: nil
;*****
(defun learning ()
  (with-open-file
   (*outstream* "c:\\hy\\art-learn.dat" :direction :output)
    (let((case nil)
          (l-arts nil)
          (art-net nil)
          (count 0)
          (l-cases (convert-l-obj (frame-all-instances 'case-base))))
      (setq *pruning-threshold* 0.0)
      (setq *alpha* 0.0001)
      (setf *l-all-diagnoses* (convert-l-obj
                               (frame-all-instances 'diagnosis)))
      (setq l-cases (change-cases-order l-cases nil))
      (setf *l-all-findings* (convert-l-obj
                              (frame-all-instances 'gen-findings)))
      (iterate for case in l-cases
               do
                (setf *baseline-vigilance* 0.2)
                (setf *l-signal* nil)
                (send-msg case :learn-case))
      (setq l-arts (convert-l-obj (frame-all-instances 'art-net)))
      (iterate for art-net in l-arts
               do
                (sys:gc)
                (send-msg art-net :pruning)
                (send-msg art-net :set-findings))))))

```

Pode-se notar, a partir deste trecho de programa, a falta de recursões, característica marcante de programas implementados em LISP. Durante a implementação das redes ART, as recursões foram, em grande parte, retiradas do código após constatado que o sistema se tornava mais lento com seu uso em demasia. Com elas, a quantidade de memória atribuída à *pilha* devia ser maior, o que dificultava o trabalho do *garbage collector* do sistema GOLDWORKS III, no ambiente MS-DOS utilizado.

Quanto às estruturas de dados, a seguir é apresentado um trecho de programa responsável pela criação do *frame art-net*.

```

DEFINE-FRAME ART-NET
(:IS ROOT)
(W_F1A_F2)
(W_F2_F1B)
(DIAGNOSIS)
(FINDINGS)

```

As instâncias deste *frame* representam as categorias de reconhecimento geradas durante o processo de aprendizagem da rede *Simplified Fuzzy ARTMAP*. Nele, pode-se identificar o vetor de pesos entre as camadas F1^a e F2 e entre F2 e F1^b, representados, respectivamente, pelos *slots* W_F1A_F2 e W_F2_F1B, o diagnóstico para o qual a categoria aponta, representado pelo *slot* DIAGNOSIS e, finalmente, os achados respectivos a cada conexão, representados pelo *slot* FINDINGS.

Na Figura 11, é apresentada a hierarquia de *frames* do sistema HYCONES II. Pode-se perceber através desta figura que tanto as redes MNC, representadas pelo *cnm-net frame*, quanto às redes ART, representadas por *smart-net* e *art-net*, ocupam o mesmo nível na hierarquia. As bases de casos de treinamento e teste fazem parte do ramo *frame-tree* onde se encontra todo o conhecimento simbólico acerca do domínio.

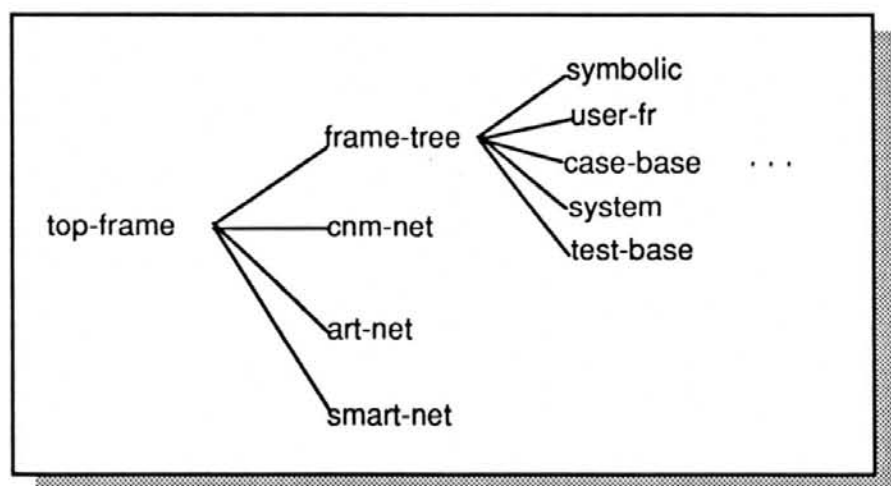


Figura 11 A hierarquia de frames

Visando a portabilidade, além da implementação em LISP e do atrelamento das duas redes neurais ART ao HYCONES, os três modelos neurais também foram

implementados em linguagem C, ambiente UNIX, e estão disponíveis em estações de trabalho SUN *Microsystems* e no supercomputador CRAY YMP da Universidade Federal do Rio Grande do Sul.

A seguir, é apresentado um trecho do programa em C (procedimento *learning*) responsável por parte do processo de aprendizagem no modelo *Simplified Fuzzy ARTMAP*.

```

/.....
* SIMPLIFIED FUZZY ARTMAP
* LEARNING Procedure
* This procedure reads each training case from the database; this
* is done in fact by the put_pattern procedure. Next, the procedure
* dot product is called to compute the dot product for each
* F2 neuron; the greatest input points out the winner neuron.
* Then, the procedure learn_pattern, which will in fact execute
* the learning mechanism, is called. Finally, the pruning
* procedure is executed.
* Calling functions:
* put_pattern
* dot_product
* learn_pattern
* pruning
* Global Variables:
* ntraining_patterns -> number of training patterns
* f2neurons          -> number of categories in F2
* Returns: nothing
/...../
void learning()
{
  int i, j;
  for(i = 0; i < ntraining_patterns; i++)
  {
    printf("Learning pattern %d ...n", i);
    for (j = 0; j < f2neurons; j++)
      if (f2[j].state == BLOCKED)
        f2[j].state = ACTIVE;
    D = 0;
    put_pattern();
    dot_product();
    learn_pattern();
  }
  pruning();
}

```

Como pode-se perceber, as duas funções *learning* mostradas acima apresentam quase a mesma funcionalidade. Em primeiro lugar, os casos de treinamento são apresentados à rede para aprendizagem. Ao final, é realizado

procedimento de poda das conexões que apresentem peso menor que o limiar de poda preestabelecido.

5 VALIDAÇÃO

Neste capítulo, apresentam-se os resultados dos experimentos realizados com HYCONES, a partir dos modelos MNC, *Simplified Fuzzy ARTMAP*, com e sem codificação complementar, e SMART. Cada modelo foi validado a partir das mesmas bases de casos de cardiopatias congênitas e de síndromes renais.

5.1 As Bases de Casos Utilizadas

A validação de HYCONES II foi feita a partir das bases de casos de cardiopatias congênitas e síndromes renais descritas abaixo.

5.1.1 A base de casos de cardiopatias congênitas

Para a construção da base de casos de cardiopatias congênitas, 66 prontuários médicos das três cardiopatias congênitas mais freqüentes foram extraídos do banco de dados de pacientes submetidos à cirurgia cardíaca no Instituto de Cardiologia RS (ICFUC-RS). Tais prontuários abrangem o período de janeiro de 1986 a dezembro de 1990 e reportam 22 casos de *Comunicação Interatrial (CIA)*, 29 de *Comunicação Interventricular (CIV)* e 15 de *Defeito Septal Atrioventricular (DSAV)*.

Para a análise de desempenho do sistema, 33 casos adicionais, do mesmo período mencionado, foram extraídos aleatoriamente do banco de dados do ICFUC-RS. Destes 33 casos, 13 apresentam *CIA*, 10 *CIV* e 10 *DSAV*.

5.1.2 A base de casos de síndromes renais

Por sua vez, a base de casos de síndromes renais foi obtida através da análise semi-automática de 381 prontuários do banco de dados de síndromes renais da Escola Paulista de Medicina. Do total de casos selecionados, 136 apresentam *Uremia*, 85 *Nefrite*, 100 *Hipertensão* e 60 *Litíase*. A partir dos prontuários médicos, foram selecionadas 56 evidências correspondentes a dados de história clínica e exame físico dos pacientes [MAC 92b]. Dos 381 casos, 254 foram escolhidos aleatoriamente para a composição do conjunto de treinamento; os demais 127 casos foram utilizados para a elaboração do conjunto de testes.

Para ambas as situações de teste, quer da base de cardiopatias congênitas, quer da de síndromes renais, o desempenho das diferentes versões *Simplified Fuzzy ARTMAP* e SMART foi cotejado com o da versão MNC, pela aplicação do teste qui-quadrado (χ^2). O nível de significância adotado foi o de 0,05. Sempre que ocorreram diferenças estatisticamente significativas, estas foram assinaladas nas tabelas que seguem.

5.2 MNC e *Simplified Fuzzy ARTMAP*: Resultados

Nesta etapa, 32 versões da base de conhecimento híbrida foram construídas. Destas, 30 abrangem a construção da BCH para a rede *Simplified Fuzzy ARTMAP*, com codificação complementar, e duas para a rede MNC. Das 30 versões ART, 15 foram criadas a partir do treinamento dos casos da base de CHD e 15 a partir dos casos da base de síndromes renais. Da mesma forma, das duas versões MNC, uma foi criada a partir da base de CHD e a outra a partir da base de síndromes renais (Figura 12).

As versões MNC decorrem de aprendizagem automática a partir dos casos de treinamento, com base nos algoritmos descritos no capítulo 1, respectivamente, "punições e recompensas" e "poda e normalização".




Figura 12 Construção das versões MNC-CHD e MNC-RENAL

Para a construção das versões ART, dois fatores inerentes aos sistemas baseados em ART foram levados em consideração: as redes ART possuem um parâmetro de vigilância que controla quão especializadas ou genéricas serão as categorias de reconhecimento formadas durante o processo de aprendizagem.

Quanto maior o valor deste parâmetro, maior o grau de discriminação da rede e maior o número de categorias formadas. Por esta razão, as versões ART da BCH foram constituídas levando-se em consideração os três seguintes valores do parâmetro de vigilância: 0,0, 0,7 e 0,9.

Além da vigilância, os modelos baseados em ART são sensíveis à ordem de apresentação dos casos de treinamento. Dependendo desta ordem, as categorias de reconhecimento podem apresentar conformação diferente, mesmo quando a rede trabalha com valores iguais do parâmetro de vigilância. Por esta razão, os 66 casos de treinamento da base de CHD foram sorteados aleatoriamente e apresentados à rede ART em quinze ordens diferentes, divididas segundo os três valores distintos atribuídos ao parâmetro de vigilância. Desta forma, para cada valor, cinco versões da BCH foram criadas. O mesmo procedimento foi feito para os 254 casos de treinamento da base de síndromes renais. O processo de construção das diferentes versões ART é ilustrado na Figura 13.

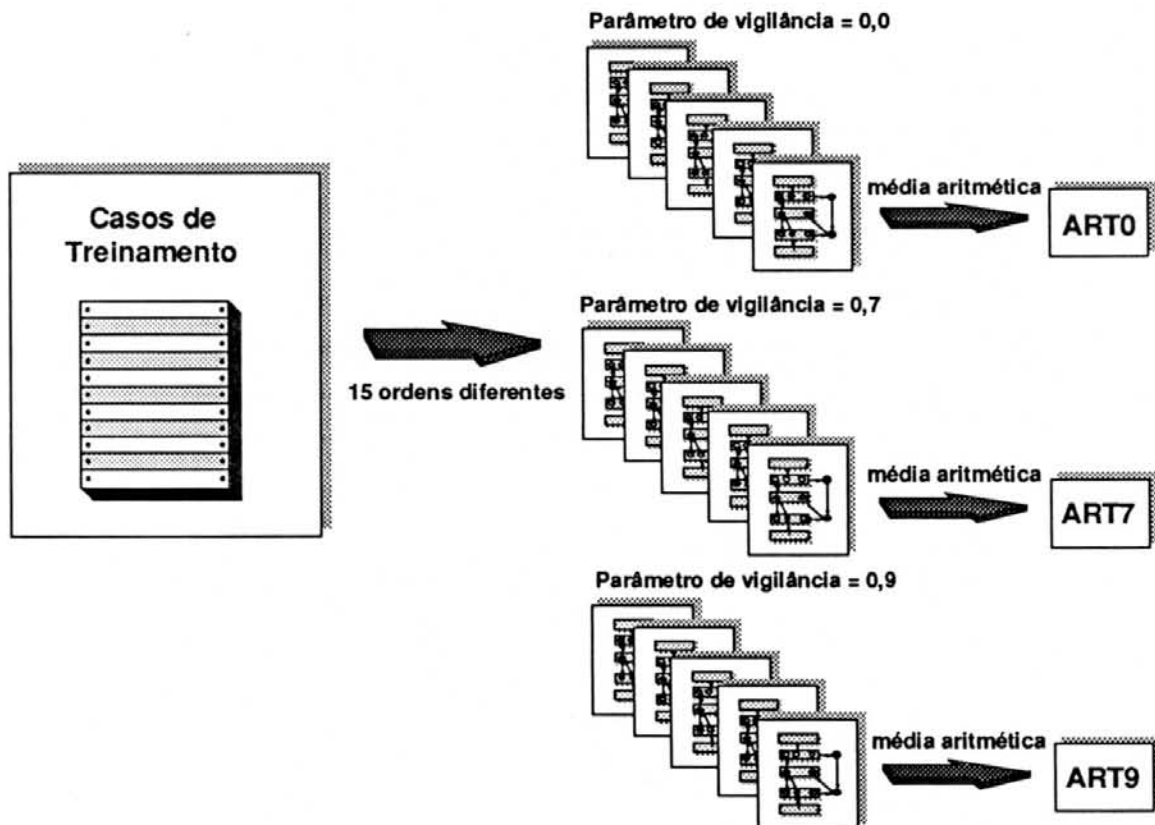


Figura 13 Construção das 15 versões ART-CHD e das 15 ART-RENAL

Os resultados obtidos pelas 15 versões ART da base de CHD e pelas 15 da base de síndromes renais foram agrupados de acordo com os três diferentes valores do parâmetro de vigilância. Este agrupamento levou em consideração a média aritmética dos resultados obtidos pelas 5 versões referentes a cada uma das vigilâncias e a cada base de treinamento e teste, arredondada para o inteiro mais próximo. Os resultados apresentados nas Tabelas 2 e 3 baseiam-se na seguinte divisão: a primeira coluna de ambas as tabelas mostra o desempenho obtido a partir do modelo MNC, representado através dos rótulos MNC-CHD e MNC-RENAIS, respectivamente; as demais colunas mostram os resultados obtidos a partir do modelo *Simplified Fuzzy* ARTMAP, representados pelos rótulos ART0-CHD, ART7-CHD e ART9-CHD, para a base de CHD, bem como ART0-RENAIS, ART7-RENAIS e ART9-RENAIS, para a base de síndromes renais, de acordo com as vigilâncias 0,0, 0,7 e 0,9, respectivamente.

Tabela 2

Validação de MNC-CHD, ART0-CHD, ART7-CHD e ART9-CHD

	MNC-CHD		ART0-CHD		ART7-CHD		ART9-CHD	
	N	%	N	%	N	%	N	%
Diagnósticos Corretos	31	93,9	27	81,8	29	87,9	27	81,8
Diagnósticos Errados	0	-	6	18,2	4	12,1	6	18,2
Falta de Evidências para Conclusão	2	6,1	0	-	0	-	0	-
Total	33	100,0	33	100,0	33	100,0	33	100,0

Tabela 3

Validação de MNC-RENAIS, ART0-RENAIS, ART7-RENAIS e ART9-RENAIS

	MNC-RENAIS		ART0-RENAIS*		ART7-RENAIS*		ART9-RENAIS	
	N	%	N	%	N	%	N	%
Diagnósticos Corretos	95	74,8	108	85,0	108	85,0	106	83,5
Diagnósticos Errados	10	7,9	19	15,0	19	15,0	21	16,5
Falta de Evidências para Conclusão	22	17,3	0	-	0	-	0	-
Total	127	100.0	127	100.0	127	100.0	127	100.0

* $p < 0,05$, quando comparado ao desempenho da versão MNC-RENAIS.

Na análise dos resultados obtidos a partir da base de CHD (Tabela 2), o processo de validação mostrou que a versão MNC-CHD apresentou os melhores resultados: 31 dos 33 (93,9%) diagnósticos foram corretos. O melhor resultado apresentado pelas versões ART foi o de 29 diagnósticos corretos em 33 (87,9%). Deve-se enfatizar que os dois diagnósticos de CHD nos quais a versão MNC não conseguiu concluir por algum dos diagnósticos, por falta de evidência, eram, na verdade, lesões não isoladas. Durante a revisão destes casos, verificou-se que o primeiro referia-se a um paciente que possuía, além de *CIA*, um diagnóstico associado de *Estenose Pulmonar Valvar*, que não constava na base de treinamento. O segundo caso tratava-se de um diagnóstico de *CIV* com lesão congênita cardíaca associada, a *Hipertensão Pulmonar Severa*, que não apresenta a evidência *sopro sistólico*, característica de pacientes com *CIV*. A versão MNC-CHD não havia sido treinada para reconhecer qualquer destes dois diagnósticos [REA 93b]. O mesmo caso de *CIV* também não foi diagnosticado corretamente pelas versões ART.

Por sua vez, na análise dos resultados obtidos a partir da base de síndromes renais (Tabela 3), o processo de validação mostrou que as versões ART7-RENAIS e ART0-RENAIS apresentaram os melhores resultados: 108 dos 127 diagnósticos

foram corretos (85,0%). Já, o resultado apresentado pela versão MNC foi de 95 diagnósticos corretos em 127 (74,8%).

Tabela 4

Número de categorias de reconhecimento das versões ART0-CHD, ART7-CHD e ART9-CHD

ART0-CHD	ART7-CHD	ART9-CHD
9	57	65

Por outro lado, a média aritmética arredondada para o inteiro mais próximo do número de categorias de reconhecimento formadas para cada grupo de versões ART é apresentada na Tabela 4. Nesta, pode-se perceber que o parâmetro de vigilância é responsável direto pela quantidade de categorias formadas. Quanto maior a vigilância, maior o número de categorias. Com parâmetro de vigilância igual a 0,9 (versão ART9-CHD), em média apenas dois casos, dos 66 utilizados na aprendizagem, foram categorizados conjuntamente. Com a vigilância alta, a rede discrimina mais, passando a criar maior número de categorias de reconhecimento em resposta aos casos de entrada. Desta forma, a rede requer grande semelhança entre o estímulo de entrada e a categoria de reconhecimento ativada, para que a aprendizagem ocorra. Em consequência, pode-se dizer que a taxa de esquecimento da rede é menor, pois casos não parecidos ativarão categorias distintas, não havendo a poda indiscriminada das conexões representativas das evidências não comuns aos casos de entrada que apontam para o mesmo diagnóstico.

Durante o processo de validação da rede *Simplified Fuzzy ARTMAP*, a codificação complementar, descrita no capítulo 1, ainda que essencial para o bom desempenho da rede ART, foi retirada de sua implementação. Desta forma, para que a nova configuração fosse validada, as 30 versões ART da base de conhecimento híbrida foram novamente construídas, segundo as especificações utilizadas na construção das versões ART anteriores (Figura 14).

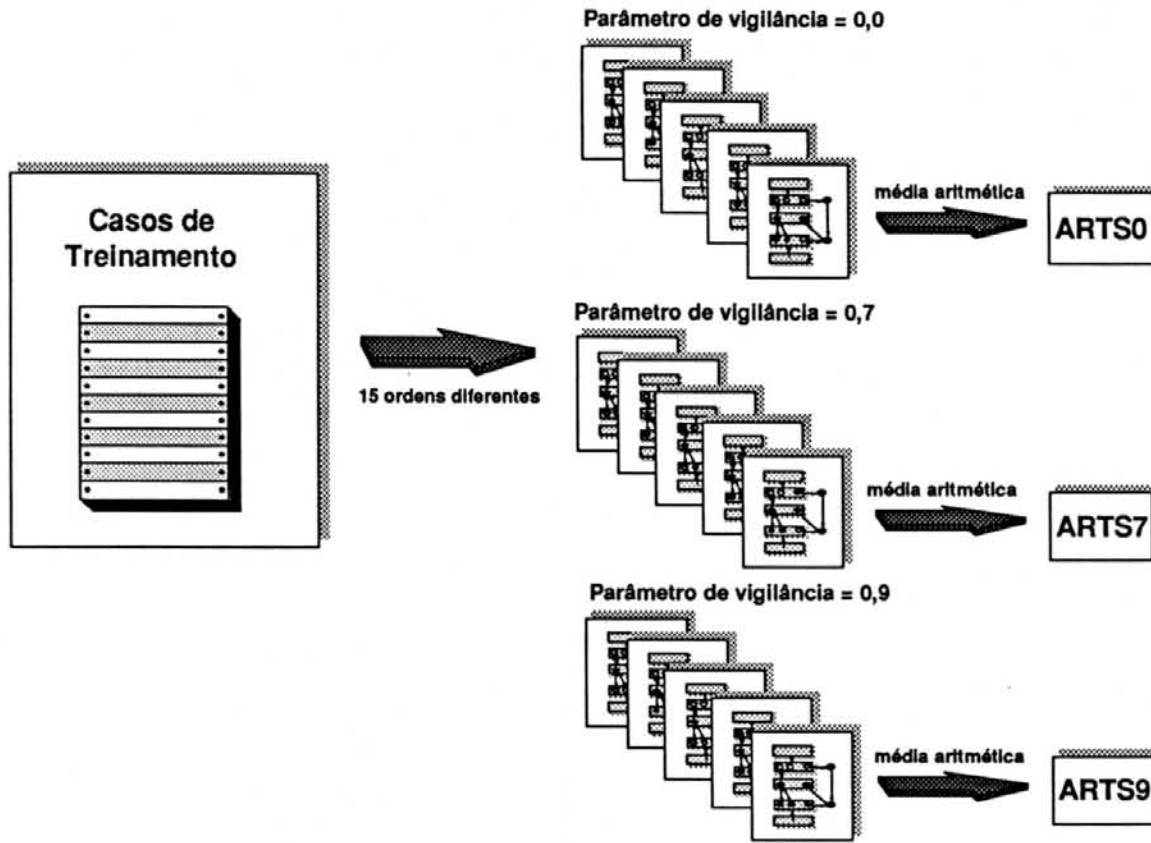


Figura 14 Construção das 15 versões ARTS-CHD e das 15 ARTS-RENAL

Os novos resultados obtidos pelas 15 versões ART da base de CHD e pelas 15 da base de síndromes renais foram agrupados de acordo com os mesmos três valores diferentes do parâmetro de vigilância. Este agrupamento também levou em consideração a média aritmética dos resultados obtidos pelas 5 versões referentes a cada uma das vigilâncias e a cada base de treinamento e teste, arredondada para o inteiro mais próximo.

As Tabelas 5 e 6 mostram os resultados obtidos a partir do modelo *Simplified Fuzzy ARTMAP* sem a codificação complementar, representados pelos rótulos ARTS0-CHD, ARTS7-CHD e ARTS9-CHD para a base de CHD e ARTS0-RENAIS, ARTS7-RENAIS e ARTS9-RENAIS para a base de síndromes renais, de acordo com as vigilâncias 0,0, 0,7 e 0,9, respectivamente.

Tabela 5

Validação de MNC-CHD, ARTS0-CHD, ARTS7-CHD e ARTS9-CHD

	MNC-CHD		ARTS0-CHD*		ARTS7-CHD*		ARTS9-CHD*	
	N	%	N	%	N	%	N	%
Diagnósticos Corretos	31	93,9	23	69,7	24	72,7	25	75,8
Diagnósticos Errados	0	-	10	30,3	9	27,3	8	24,2
Falta de Evidências para Conclusão	2	6,1	0	-	0	-	0	-
Total	33	100,0	33	100,0	33	100,0	33	100,0

* $p < 0,05$, quando comparado ao desempenho da versão MNC-CHD.

Tabela 6

Validação de MNC-RENAIS, ART0-RENAIS, ART7-RENAIS e ART9-RENAIS

	MNC-RENAIS		ARTS0-RENAIS*		ARTS7-RENAIS		ARTS9-RENAIS	
	N	%	N	%	N	%	N	%
Diagnósticos Corretos	95	74,8	63	49,6	98	77,1	94	74,0
Diagnósticos Errados	10	7,9	64	50,4	29	22,9	33	26,0
Falta de Evidências para Conclusão	22	17,3	0	-	0	-	0	-
Total	127	100,0	127	100,0	127	100,0	127	100,0

* $p < 0,01$, quando comparado ao desempenho da versão MNC-RENAIS.

Na análise dos resultados obtidos a partir das bases de CHD e de síndromes renais (apresentados nas Tabelas 5 e 6, respectivamente), o processo de validação

mostrou que as versões MNC, quando comparadas às versões ARTS, apresentam desempenho equivalente (casos de síndromes renais) ou superior (casos de CHD). O melhor resultado apresentado pelas versões ART foi o de 25 diagnósticos corretos em 33 (75,8%) para CHD e 98 para síndromes renais (77,1%), enquanto que a rede MNC diagnosticou corretamente 31 dos 33 casos de CHD (93,9%) e 95 dos 127 de síndromes renais (74,8%).

5.3 SMART: Resultados

As mesmas bases de casos utilizadas para o treinamento e teste das versões anteriores de HYCONES foram utilizadas na validação da rede SMART. Assim como nas versões ART, três valores distintos do parâmetro de vigilância foram escolhidos para a construção das versões SMART da BCH, são eles: 0,0, 0,7 e 0,9. A criação das versões SMART também levou em consideração a ordem de apresentação dos casos de entrada. Por esta razão, os mesmos 66 casos de treinamento da base de CHD e os 254 casos da base de síndromes renais foram novamente sorteados aleatoriamente e apresentados à rede SMART, em quinze ordens diferentes para cada base de treinamento, divididas de acordo com os três valores distintos atribuídos ao parâmetro de vigilância. Para cada valor, cinco versões da BCH foram criadas. Além disto, os mesmos 33 casos de CHD e os 127 de síndromes renais utilizados na composição das bases de testes foram utilizados para a análise de desempenho do sistema frente as 15 novas versões criadas para cada base (Figura 15).

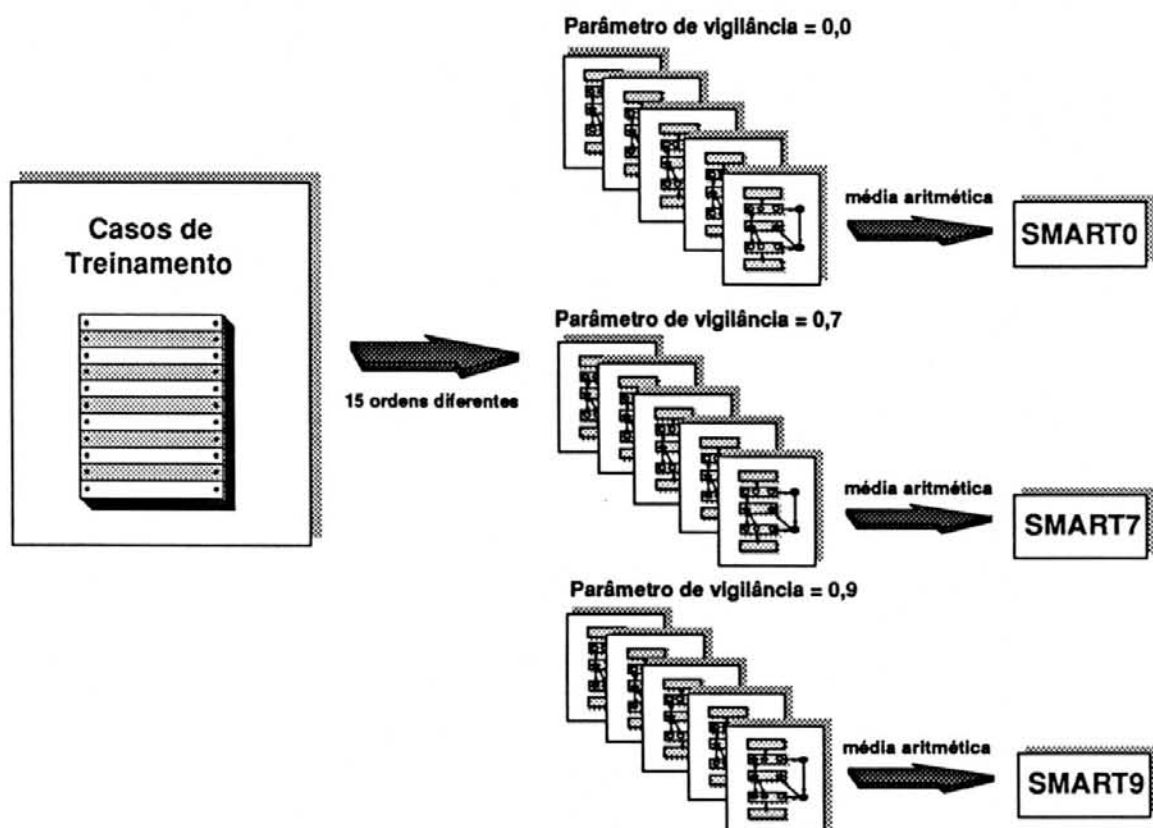


Figura 15 Construção das 15 versões SMART-CHD e das 15 SMART-RENAL

Para a base de CHD, os resultados obtidos pelas 15 versões SMART foram agrupados segundo os três valores diferentes do parâmetro de vigilância. Este agrupamento levou em consideração a média aritmética dos resultados obtidos pelas 5 versões, respectivas a cada uma das vigilâncias, arredondada para o inteiro mais próximo. Na tabelas 7, 8, 9 e 10 são apresentados os resultados obtidos a partir do modelo SMART, representados pelos rótulos SMART0-CHD, SMART7-CHD e SMART9-CHD, para as vigilâncias 0,0, 0,7 e 0,9, respectivamente. Além disto, cada uma das tabelas apresenta, respectivamente, os resultados obtidos de acordo com os seguintes valores do parâmetro de poda: 0,0, 0,3, 0,5 e 0,7.

Tabela 7

Validação das versões MNC-CHD, SMART0-CHD, SMART7-CHD e SMART9-CHD com limiar de poda igual a 0,0

	MNC-CHD		SMART0-CHD		SMART7-CHD		SMART9-CHD	
	N	%	N	%	N	%	N	%
Diagnósticos Corretos	31	93,9	28	84,8	28	84,8	28	84,8
Diagnósticos Errados	0	-	5	15,2	5	15,2	5	15,2
Falta de Evidências para Conclusão	2	6,1	0	-	0	-	0	-
Total	33	100,0	33	100,0	33	100,0	33	100,0

Tabela 8

Validação das versões MNC-CHD, SMART0-CHD, SMART7-CHD e SMART9-CHD com limiar de poda igual a 0,3

	MNC-CHD		SMART0-CHD*		SMART7-CHD		SMART9-CHD	
	N	%	N	%	N	%	N	%
Diagnósticos Corretos	31	93,9	23	69,7	29	87,9	29	87,9
Diagnósticos Errados	0	-	10	30,3	4	12,1	4	12,1
Falta de Evidências para Conclusão	2	6,1	0	-	0	-	0	-
Total	33	100,0	33	100,0	33	100,0	33	100,0

* $p < 0,05$, quando comparado ao desempenho da versão MNC-CHD.

Tabela 9

**Validação das versões MNC-CHD, SMART0-CHD, SMART7-CHD e SMART9-CHD
com limiar de poda igual a 0,5**

	MNC-CHD		SMART0-CHD		SMART7-CHD		SMART9-CHD	
	N	%	N	%	N	%	N	%
Diagnósticos Corretos	31	93,9	29	87,9	28	84,8	28	84,8
Diagnósticos Errados	0	-	4	12,1	3	9,1	3	9,1
Falta de Evidências para Conclusão	2	6,1	0	-	2	6,1	2	6,1
Total	33	100,0	33	100,0	33	100,0	33	100,0

Tabela 10

**Validação das versões MNC-CHD, SMART0-CHD, SMART7-CHD e SMART9-CHD
com limiar de poda igual a 0,7**

	MNC-CHD		SMART0-CHD		SMART7-CHD		SMART9-CHD	
	N	%	N	%	N	%	N	%
Diagnósticos Corretos	31	93,9	29	87,9	29	87,9	28	84,9
Diagnósticos Errados	0	-	4	12,1	2	6,05	3	9,1
Falta de Evidências para Conclusão	2	6,1	0	-	2	6,05	2	6,0
Total	33	100,0	33	100,0	33	100,0	33	100,0

Os resultados apresentados nas tabelas acima demonstram a melhoria de desempenho do sistema HYCONES a partir da utilização do modelo SMART, em relação ao modelo ART sem a codificação complementar. Os dois casos não diagnosticados corretamente por falta de evidência resultam da ativação de um neurônio em F2 que não representa qualquer categoria. Isto ocorreu porque estes dois casos não possuíam qualquer evidência em comum com aquelas representadas pelas categorias de reconhecimento da rede após o procedimento de poda. Um destes casos é o de *CIV*, supracitado, com lesão congênita cardíaca associada, a *Hipertensão Pulmonar Severa*, que não apresenta a evidência *sopro sistólico*, característica essencial de pacientes com *CIV*.

Por sua vez, a Tabela 11 apresenta as médias aritméticas (arredondadas para o inteiro mais próximo) dos números de categorias formadas em cada grupo das versões SMART-CHD, de acordo com o parâmetro de vigilância. Assim como ocorre em ART, observa-se que quanto maior o parâmetro de vigilância, maior o número de categorias formadas. Por outro lado, através da poda das conexões com peso inferior ao limiar de poda, quanto maior este último, menor o número de categorias e conexões mantidas pela rede SMART.

Tabela 11

Número de categorias de reconhecimento das versões SMART0-CHD, SMART7-CHD e SMART9-CHD a partir dos limiares de poda 0,0, 0,3, 0,5 e 0,7

	SMART0-CHD	SMART7-CHD	SMART9-CHD
Limiar de poda = 0,0	9	57	65
Limiar de poda = 0,3	6	32	46
Limiar de poda = 0,5	4	24	33
Limiar de poda = 0,7	3	15	21

Por sua vez, as tabelas 12, 13, 14 e 15 apresentam os resultados obtidos a partir do modelo SMART, representados pelos rótulos SMART0-RENAIS, SMART7-

RENAIS e SMART9-RENAIS, quando testado sobre a base de casos de síndromes renais, para as vigilâncias 0,0, 0,7 e 0,9, respectivamente. Este agrupamento também levou em consideração a média aritmética (arredondada para o inteiro mais próximo) dos resultados obtidos pelas 5 versões relativas a cada uma das vigilâncias. Além disto, cada tabela mencionada apresenta, respectivamente, os resultados obtidos de acordo com os seguintes valores do parâmetro de poda: 0,0, 0,3, 0,5 e 0,7.

Tabela 12

Validação das versões MNC-RENAIS, SMART0-RENAIS, SMART7-RENAIS e SMART9-RENAIS com limiar de poda igual a 0,0

	MNC-RENAIS		SMART0-RENAIS*		SMART7-RENAIS		SMART9-RENAIS**	
	N	%	N	%	N	%	N	%
Diagnósticos Corretos	95	74,8	108	85,0	86	67,7	73	57,5
Diagnósticos Errados	10	7,9	19	15,0	41	32,3	54	42,5
Falta de Evidências para Conclusão	22	17,3	0	-	0	-	0	-
Total	127	100,0	127	100,0	127	100,0	127	100,0

* $p < 0,05$, quando comparado ao desempenho da versão MNC-RENAIS.

** $p < 0,01$, quando comparado ao desempenho da versão MNC-RENAIS.

Tabela 13

Validação das versões MNC-RENAIS, SMART0-RENAIS, SMART7-RENAIS e SMART9-RENAIS com limiar de poda igual a 0,3

	MNC-RENAIS		SMART0-RENAIS		SMART7-RENAIS		SMART9-RENAIS	
	N	%	N	%	N	%	N	%
Diagnósticos Corretos	95	74,8	87	68,5	90	70,9	102	80,3
Diagnósticos Errados	10	7,9	40	31,5	37	29,1	25	19,7
Falta de Evidências para Conclusão	22	17,3	0	-	0	-	0	-
Total	127	100,0	127	100,0	127	100,0	127	100,0

Tabela 14

Validação das versões MNC-RENAIS, SMART0-RENAIS, SMART7-RENAIS e SMART9-RENAIS com limiar de poda igual a 0,5

	MNC-RENAIS		SMART0-RENAIS		SMART7-RENAIS		SMART9-RENAIS	
	N	%	N	%	N	%	N	%
Diagnósticos Corretos	95	74,8	94	74,0	96	75,6	89	70,1
Diagnósticos Errados	10	7,9	33	26,0	31	24,4	38	29,9
Falta de Evidências para Conclusão	22	17,3	0	-	0	-	0	-
Total	127	100,0	127	100,0	127	100,0	127	100,0

Tabela 15

Validação das versões MNC-RENAIS, SMART0-RENAIS, SMART7-RENAIS e SMART9-RENAIS com limiar de poda igual a 0,7

	MNC-RENAIS		SMART0-RENAIS		SMART7-RENAIS		SMART9-RENAIS*	
	N	%	N	%	N	%	N	%
Diagnósticos Corretos	95	74,8	85	66,9	83	65,4	72	56,7
Diagnósticos Errados	10	7,9	42	33,1	44	34,6	55	43,3
Falta de Evidências para Conclusão	22	17,3	0	-	0	-	0	-
Total	127	100,0	127	100,0	127	100,0	127	100,0

* $p < 0,01$, quando comparado ao desempenho da versão MNC-RENAIS.

Os resultados apresentados nas tabelas acima demonstram que a rede SMART não obteve bom desempenho, quando o limiar de poda foi fixado em 0,7, para qualquer valor do parâmetro de vigilância utilizado. Isto ocorre devido à própria formação da base de casos de síndromes renais. Os casos que a integram apresentam um pequeno número de evidências, com um grupo de achados presentes em todos os casos. Por outro lado, SMART apresentou bom desempenho quando o parâmetro de vigilância e o limiar de poda foram fixados em 0,0 (108 dos 127 casos diagnosticados corretamente). Devido à natureza da rede SMART, a vigilância baixa propicia a alta categorização conjunta dos padrões de entrada para cada diagnóstico, enquanto que o limiar de poda igual a 0,0 propicia a retenção dos poucos achados presentes em cada caso. Desta forma, a rede adquire maior representação do conhecimento para que possa fazer o diagnóstico correto. Por outro lado, o parâmetro de vigilância igual a 0,9 possibilita maior discriminação. Esta vigilância associada ao limiar de poda 0,3, fez com que a rede SMART diagnosticasse corretamente, em média, 102 dos 127 casos da base de testes. A alta vigilância manteve o valor da variável *Maxdiff* baixo, pois não houve grande

categorização conjunta dos casos. Desta forma, os pesos das conexões das categorias se mantiveram altos, fazendo com que o limiar de poda 0,3 excluísse apenas as conexões que perturbaram o diagnóstico, ou seja, aquelas com grande número de punições.

Na Tabela 16 são apresentadas as médias aritméticas (arredondadas para o inteiro mais próximo) do número de categorias de reconhecimento associadas aos limiares de poda 0,0, 0,3, 0,5 e 0,7 em cada grupo de versões SMART-RENAIS.

Tabela 16

Número de categorias de reconhecimento das versões SMART0-RENAIS, SMART7-RENAIS e SMART9-RENAIS a partir dos limiares de poda 0,0, 0,3, 0,5 e 0,7

	SMART0-RENAIS	SMART7-RENAIS	SMART9-RENAIS
Limiar de poda = 0,0	23	107	195
Limiar de poda = 0,3	7	40	100
Limiar de poda = 0,5	6	13	59
Limiar de poda = 0,7	5	6	25

6 DISCUSSÃO

Neste capítulo, discutem-se as bases de casos envolvidas no processo de validação de HYCONES II. A seguir, são apresentados os grafos de conhecimento, elicitados de múltiplos especialistas, para os diagnósticos de *CIA*, *CIV* e *DSAV*, bem como os *frames de diagnóstico* obtidos automaticamente a partir da base de treinamento de CHD e as redes MNC mais ativadas durante o processo de validação da versão MNC-CHD. Tais instrumentos são, então, utilizados para a comparação com as categorias de reconhecimento CHD mais ativadas durante a validação do modelo *Fuzzy ARTMAP*. Por último, são apresentadas as categorias de reconhecimento mais ativadas durante a validação de SMART-CHD.

6.1 As Base de Casos

Como descrito no capítulo 5, a base de casos de síndromes renais foi extraída de prontuários médicos de forma semi-automática. Este processo foi realizado através de uma ferramenta computacional utilizada para a identificação, a partir de registros médicos, dos objetos a serem representados na forma de evidências nos casos da base. Esta mesma base de casos foi utilizada previamente para a validação do sistema NEXTOOL, que implementa o modelo MNC. Dentre os resultados incorretos apontados por este sistema, a maioria tratava-se de casos de *Nefrite*, classificados como casos de *Uremia* [MAC 92b]. Este fato também foi observado durante a validação do sistema HYCONES II, onde tanto os modelos ART como o modelo MNC tiveram dificuldades em classificar corretamente os casos de *Nefrite*. Entretanto, tais erros são justificáveis, já que a discriminação entre estas duas afecções é feita a partir de dados obtidos em testes laboratoriais, informação não disponível na base de casos.

Além disto, o sistema NEXTOOL, como relatado em [MAC 92b], obteve o mesmo desempenho utilizando apenas 20 das 58 evidências selecionadas para a formação dos casos da base. Este fato mostra que dentre estas 58 evidências há sérios conflitos semânticos. Por exemplo, os achados *AVC na Família* e *Familiares com Acidentes Vasculares* foram representados distintamente na base de casos. Não obstante, tais evidências possuem o mesmo significado semântico. Em contrapartida, a base de casos de CHD, ao contrário da de síndromes renais, foi extraída

manualmente dos prontuários médicos, com o auxílio de um especialista, não apresentando, portanto, conflitos de ordem semântica.

Além disto, enquanto os grafos de conhecimento para o diagnóstico de CHD constam da literatura técnica [LEA 88], os mesmos não foram obtidos para as síndromes renais, o que compromete a análise do valor semântico das categorias de reconhecimento formadas por HYCONES II, por falta do padrão de comparação *ad-hoc*. Por esta razão, a discussão que segue faz-se apenas a partir dos casos de CHD.

6.2 Grafos de Conhecimento para CHD

Os grafos de conhecimento são a base do modelo MNC (ver capítulo 1). A metodologia para sua obtenção foi validada a partir de entrevistas com diversos especialistas e não-especialistas da área de CHD [LEA 88].

Com este procedimento, foram construídos os grafos para os diagnósticos de *CIA*, *CIV* e *DSAV*, entre outras cardiopatias congênitas não consideradas no presente trabalho. Neles, os achados essenciais são representados pelos nodos mais à esquerda, sendo que o gatilho é efetivamente representado pelo nodo mais à esquerda. Tais grafos, extraídos de trabalho anterior [LEA 88], são apresentados a seguir.

O grafo que aponta para o diagnóstico de *CIA* (Figura 16), foi elicitado a partir de entrevistas com 18 especialistas. Este mostra que os especialistas apoiam seu diagnóstico no dado de ausculta da segunda bulha (B2-FIXO). Também foram consideradas importantes para o diagnóstico de *CIA* as evidências de sopro sistólico de ejeção pulmonar (SSEJAP) e radiografia de tórax com hiperfluxo pulmonar (HIPERFLUXO). No Apêndice I, pode-se encontrar a lista de todas as evidências presentes nos casos da base de CHD.

de tórax com cardiomegalia (RX COM CARDIOMEGALIA). Também foi considerado importante o achado radiografia de tórax com hiperfluxo pulmonar (HIPERFLUXO) .

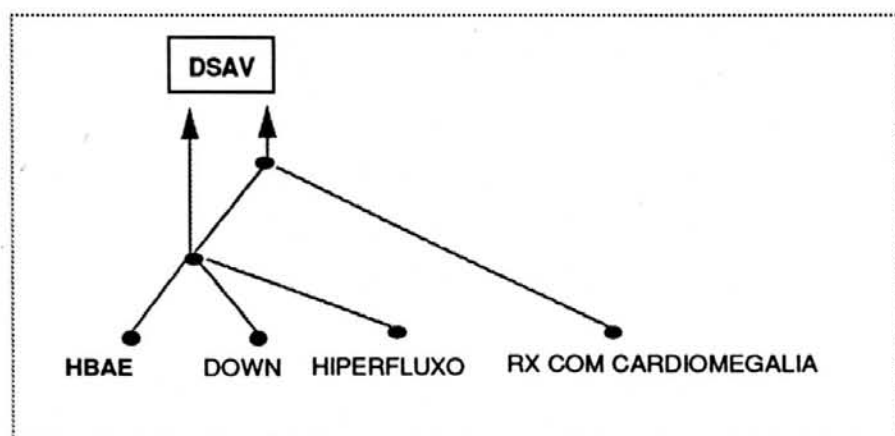


Figura 18 Grafo de Conhecimento para o diagnóstico de DSAV

A discussão detalhada do conteúdo dos grafos de conhecimento obtidos de especialistas na área de CHD e as diferenças apresentadas quando estes são comparados com os grafos elicitados de não-especialistas pode ser encontrada em [LEA 88].

6.3 Frames de diagnóstico - CHD

Como salientado no capítulo 1, o conteúdo dos *slots* dos *frames de diagnóstico*, automaticamente gerados por HYCONES, são preenchidos a partir do cálculo dos fatores de *sensibilidade* e *especificidade* dos achados da base de treinamento. Além disto, a *relevância* de cada achado é também levada em consideração, quando há indecisão na determinação do gatilho. Na Tabela 17, é apresentado o conteúdo destes *frames* para os diagnósticos de *CIA*, *CIV* e *DSAV*, preenchidos a partir da análise da base de treinamento de CHD. Nesta tabela, pode-se constatar que os achados essenciais, selecionados automaticamente por HYCONES, são semelhantes aos grafos de conhecimento de especialistas, apresentados na seção anterior, para os diagnósticos de *DSAV* e *CIA*. Para o diagnóstico de *CIV*, entretanto, verifica-se que HYCONES retirou da lista de achados a evidência *Sopro Holo-Sistólico (HOLO-SIST)*, mesmo sendo ela a mais importante, segundo os especialistas. Este fato pode ser explicado, levando-se em consideração

Na análise da tabela 17, pode-se perceber o grande número de achados considerados complementares por HYCONES para os diagnósticos de *CIA*, *CIV* e *DSAV*. Estes representam as evidências presentes no caso que podem auxiliar na confirmação da hipótese diagnóstica. Entretanto, deve-se salientar a diferença entre os achados complementares dos *frames diagnóstico* em HYCONES e o processo de codificação complementar, executado pelas redes *Fuzzy ARTMAP*, que trata da apresentação à rede do caso de entrada e de seu complemento. Neste sentido, os achados complementares representam a negação do padrão de entrada.

6.4 Redes MNC-CHD

As redes mais ativadas na versão MNC-CHD, apresentadas na Figura 19, refletem semelhança muito grande com os grafos elicitados de especialistas para os diagnósticos de *CIA*, *CIV* e *DSAV*. Entretanto, assim como acontece no preenchimento dos *frames diagnóstico*, verifica-se que, para *CIV*, o modelo MNC também não representa, em suas redes, a evidência *Sopro Holo-Sistólico (HOLO-SIST)*, substituindo-a pelo achado *Sopro Sistólico de Regurgitação Ventrículo Direito (SSRGVD)*.

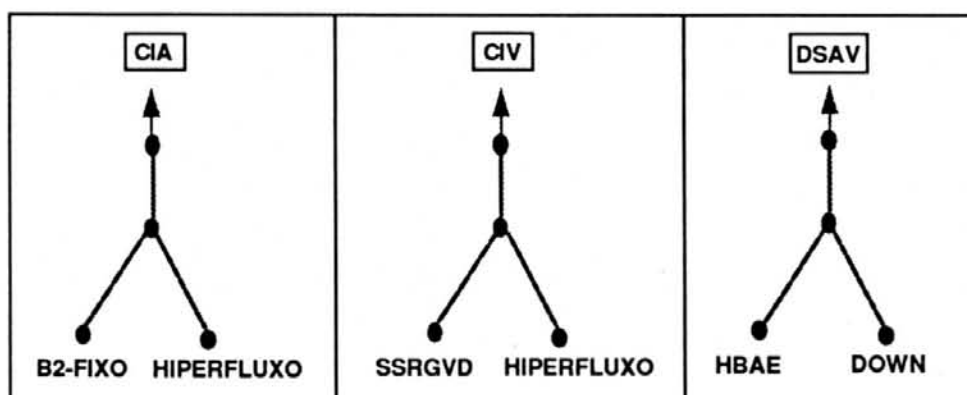


Figura 19 Redes MNC mais ativadas para o diagnóstico de *CIA*, *CIV* e *DSAV*

6.5 Categorias *Simplified Fuzzy ARTMAP* - CHD

As tabelas 18 e 19, mostradas a seguir, apresentam, respectivamente, a parte *ligada* e a *desligada* das categorias de reconhecimento mais ativadas para cada um dos três diagnósticos de cardiopatias congênitas em uma das cinco versões ART0-

Tabela 19

Achados e respectivos pesos da parte *desligada* das categorias de reconhecimento mais ativadas em uma das versões ART0-CHD para os diagnósticos CIA, CIV e DSAV

CIA		CIV		DSAV	
N CRISE-CIAN	= 1,0	N RX-NL	= 1,0	N RX-NL	= 1,0
N DOWN	= 1,0	N TONTURA	= 1,0	N CANS-MAMAR	= 1,0
N HOLO-SIST	= 1,0	N CIAN	= 1,0	N CIAN	= 1,0
N ROLAR-VE	= 1,0	N HOLO-SIST	= 1,0	N CRISE-CIAN	= 1,0
N SSEJAO	= 1,0	N SSEJAO	= 1,0	N TONTURA	= 1,0
N SSRGVD	= 1,0	N BRE	= 1,0	N HOLO-SIST	= 1,0
N SSRGVE	= 1,0	N HBAE	= 1,0	N ROLAR-VD	= 1,0
N CRESCAE	= 1,0	N HBPE	= 1,0	N SSEJAO	= 1,0
N CRESCVE	= 1,0	N BAV3	= 1,0	N SSRGVD	= 1,0
N BRE	= 1,0	N MOBIZ1	= 1,0	N CRESCAE	= 1,0
N HBAE	= 1,0	N MOBIZ2	= 1,0	N BRE	= 1,0
N HBPE	= 1,0	N CARDM-AD	= 1,0	N HBPE	= 1,0
N BAV3	= 1,0	N IMP-PEE	= 1,0	N BAV3	= 1,0
N MOBIZ1	= 1,0	N TIRAGEM	= 1,0	N MOBIZ1	= 1,0
N MOBIZ2	= 1,0	N B1-HIPER	= 1,0	N MOBIZ2	= 1,0
N CARDM-AD	= 1,0	N B1-HIPO	= 1,0	N CARDM-AE	= 1,0
N CARDM-AE	= 1,0	N B2-AMPLO-FIXO	= 1,0	N CARDM-VE	= 1,0
N CARDM-VE	= 1,0	N B2-ÚNICA	= 1,0	N CONG-PULM	= 1,0
N CONG-PULM	= 1,0	N B2-FIXO	= 1,0	N DIL-TAP	= 1,0
N PULSE-COAO1	= 1,0	N ROLAR-VD	= 0,1	N PULSE-COAO1	= 1,0
N PULSE-HYPER	= 1,0	N SSRGVE	= 0,1	N PULSE-HYPER	= 1,0
N HEPATO	= 1,0	N BAV1	= 0,1	N DESEN-HIPO	= 1,0
N FR-SIST	= 1,0	N CARDM-VE	= 0,1	N HEPATO	= 1,0
N B1-HIPO	= 1,0	N CONG-PULM	= 0,1	N FR-SIST	= 1,0
N B2-AMPLO-FIXO	= 1,0	N FR-SIST	= 0,1	N IMP-PEE	= 1,0
N B2-ÚNICA	= 1,0	N DOWN	= 0,01	N TIRAGEM	= 1,0
N B3-T	= 1,0	N B3-T	= 0,01	N B1-HIPER	= 1,0
N RX-NL	= 0,1	N CRESCAD	= 0,001	N B1-HIPO	= 1,0
N CANS-MAMAR	= 0,1	N DESEN-NL	= 0,001	N B2-AMPLO-FIXO	= 1,0
N CIAN	= 0,1	N TAQUIPN	= 0,001	N B2-HIPER	= 1,0
N TONTURA	= 0,1	N ASSINTOM	= 0,0001	N B2-ÚNICA	= 1,0
N BAV1	= 0,1	N CANSAÇO	= 0,0001	N B3-T	= 1,0
N DESEN-HIPO	= 0,1	N SIST-NS	= 0,0001	N ASSINTOM	= 0,1
N TAQUIPN	= 0,01	N BRD	= 0,0001	N INF-RESP	= 0,1
N B2-HIPER	= 0,01	N CARDM-VD	= 0,0001	N DOWN	= 0,1
N INF-RESP	= 0,0001	N DIL-TAP	= 0,0001	N BRD	= 0,1
N ROLAR-VD	= 0,00001	N HEPATO	= 0,00001	N CARDM-AD	= 0,1
N CARDM-VD	= 0,00001	N CANS-MAMAR	= 0,0000001	N CARDM-NS	= 0,1
N BRD	= 0,0000001	N ROLAR-VE	= 0,0000001	N SIST-NS	= 0,01
N DIL-TAP	= 0,0000001	N SSRJAP	= 0,0000001	N CRESCVE	= 0,01
N B2-FIXO	= 0,0000001	N CRESCVD	= 0,0000001	N HBAE	= 0,01
N SIST-NS	= 0,0000001	N CARDM-NS	= 0,0000001	N TAQUIPN	= 0,01
N CANSAÇO	= 0,0000001	NPULSE-HYPER	= 0,0000001	N ROLAR-VE	= 0,01
		N B2-HIPER	= 0,0000001	N CRESCAD	= 0,01
		N INF-RESP	= 0,0000001		

Os modelos *Fuzzy ARTMAP* e sua versão simplificada utilizam o processo de normalização dos padrões de entrada, denominado codificação complementar. Esta codificação prevê a apresentação à rede do padrão de entrada e de seu complemento. Por exemplo, se um achado como *dor-no-peito* possui grau de possibilidade igual a 0,7, a rede também recebe no neurônio complementar deste achado em $F1^a$ (neurônio *não-dor-no-peito*) um valor igual a 0,3 ($1 - 0,7$). Entretanto, se o paciente não apresenta tal sintoma, a rede recebe o valor zero no neurônio representativo do achado e 1 no neurônio complementar deste achado.

Sendo assim, a rede ART, a partir da criação de categorias de reconhecimento através da minimização dos pesos das conexões, permite, através da utilização da codificação complementar, a formação de categorias fortemente baseadas em conceitos complementares, fato que pode ser constatado a partir da análise das tabelas 18 e 19. A codificação complementar possibilita, ainda, a formação de categorias baseadas apenas em conceitos complementares.

Como salientado no capítulo 1, em se tratando de sistemas especialistas conexionistas, a explanação fornecida pelo sistema acerca de suas decisões é, na maioria das vezes, um dos seus maiores gargalos. Isto ocorre devido à não existência de uma representação simbólica atrelada à representação conexionista. Este problema é resolvido, em parte, pelos sistemas especialistas conexionistas híbridos, através da representação simbólica do conhecimento a partir de regras, redes semânticas, ou *frames*. Entretanto, mesmo um sistema especialista híbrido como o HYCONES não possui condições de explicar suas conclusões baseando-se em conceitos complementares que não possuem qualquer significado no contexto do diagnóstico médico.

Pode-se traçar um paralelo entre a inferência de uma rede ART, que utiliza a codificação complementar, com a de um médico que faz diagnósticos a partir de evidências que os pacientes não apresentam. Na área médica, os diagnósticos não são elaborados a partir da ausência de evidências, ou da não observância de determinados achados. Se fosse o caso, é possível imaginar que o diagnóstico de *câncer* poderia ser atribuído a um determinado paciente que **não** apresenta achados como os de *dor-no-peito*, *síndrome de Down* ou *hiperfluxo*, evidências observadas em pacientes com cardiopatias congênitas.

Por este motivo, a ausência de achados também não é considerada na formação dos grafos de conhecimento [LEA 90], nos quais o sistema HYCONES e o modelo MNC são fundamentados [REA 93b] [MAC 90].

Assim, a partir da constatação das categorias de reconhecimento geradas pelo modelo *Simplified Fuzzy ARTMAP* (Tabelas 18 e 19), pode-se perceber a inviabilidade do uso da codificação complementar em sistemas especialistas conexionistas, aplicados à área médica ou, ainda, em sistemas que devem explicar suas conclusões a partir do conteúdo da categoria de reconhecimento responsável pelo diagnóstico final.

A codificação complementar é parte do modelo *Fuzzy ARTMAP*. Sem ela, é inviável a normalização dos padrões de entrada. Entretanto, a fim de que as conclusões da rede ART pudessem ser suportadas por HYCONES e para que o diagnóstico dado pelo sistema não fosse baseado na ausência de evidências, decidiu-se pela retirada da codificação complementar da implementação da rede.

Desta vez, sem a codificação complementar, as categorias formadas apresentam apenas a parte *ligada* do padrão de entrada. Na Tabela 20 são apresentadas as categorias de reconhecimento mais ativadas, para cada um dos três diagnósticos de cardiopatias congênitas, em uma das cinco versões geradas para ARTS0-CHD descritas no capítulo 5, aleatoriamente selecionada. Também são apresentados o valor do peso de cada conexão entre os neurônios representativos das evidências de entrada em F1^a e os neurônios de F2.

Tabela 20

Achados e respectivos pesos das categorias de reconhecimento mais ativadas em uma das versões ARTS0-CHD para cada diagnóstico CIA, CIV e DSAV, sem a codificação complementar

<i>CIA</i>	<i>CIV</i>	<i>DSAV</i>
HIST-SOPRO = 1.0	HIPERFLUXO = 1,0	DOWN = 1,0
CRESCVD = 0,01	CRESCVE = 0,001	CARDM-NS = 0,01
HIPERFLUXO = 0,0001	CRESCVD = 0,0001	HBAE = 0,01
B2-FIXO = 0.0001	HIST-SOPRO = 0,0000001	HIPERFLUXO = 0,01
CARDM-NS = 0.000001	INF-RESP = 0,0000001	HIST-SOPRO = 0,00001
IINF-RESP = 0.0000001	ROLAR-VE = 0,0000001	CRESCVD = 0,00001
ROLAR-VD = 0.0000001	SSRGVD = 0,0000001	SIST-NS = 0,0000001
SSEJAP = 0.0000001	CARDM-VD = 0,0000001	ROLAR-VE = 0,0000001
DESEN-NL = 0.0000001	DESEN-NL = 0,0000001	CRESCAD = 0,0000001
		BRD = 0,0000001
		B2-FIXO = 0,0000001

Como se pode perceber pela análise das tabelas 5 e 6, apresentadas no capítulo 5, a falta da codificação complementar, ao mesmo tempo que aumenta a consistência semântica das redes formadas, diminui o desempenho do sistema. Anteriormente, a codificação complementar assegurava uma alta taxa de ativação da camada F1^a (sempre a metade dos neurônios desta camada eram ativados). Desta forma, as decisões do sistema eram tomadas tendo por base maior número de conceitos, complementares ou não. A rede ART não faz distinção semântica entre os achados *dor-no-peito* e *não-dor-no-peito*.

Por outro lado, a partir da análise das Tabelas 18, 19 e 20, constata-se que as categorias de reconhecimento formadas pela rede ART, com ou sem codificação complementar, apresentam um valor semântico muito pobre se comparadas com os grafos de conhecimento elicitados de especialistas, apresentados nas Figuras 16, 17 e 18, ou com as redes ativadas pela versão MNC-CHD, apresentadas na Figura 19. Isto ocorre porque o modelo *Fuzzy ARTMAP* aprende a partir de uma regra baseada na minimização dos pesos das conexões executada pelo operando *E-nebuloso*. Ao contrário do MNC, esta minimização baseia-se **somente** na frequência de ocorrência de um determinado achado (sensibilidade), não levando em conta a respectiva especificidade. Por exemplo, na Tabela 18, o achado HIPERFLUXO foi considerado o mais importante na parte ligada pela rede *Simplified Fuzzy ARTMAP*, para os

diagnósticos de *CIA* e *CIV*, enquanto que para o diagnóstico de *DSAV* este foi um dos achados mais importantes. Isto corresponde à realidade, pois este achado é **comum** aos três diagnósticos, portanto possui alto valor de sensibilidade e baixo valor de especificidade. Por este motivo, **HIPERFLUXO não** pode ser utilizado como elemento discriminador entre as três categorias diagnósticas. Já a partir do cálculo dos acumuladores de punições e recompensas e da posterior poda e normalização, o modelo MNC, como visto no capítulo 1, é capaz de extrair informações valiosas acerca da especificidade e da sensibilidade dos achados de entrada. Este fato pode ser constatado através da análise da Figura 19, que mostra as redes MNC mais ativadas para CHD. Pode-se notar, nesta figura, que **HIPERFLUXO** foi considerada como sendo uma evidência importante, mas não a mais importante.

Além disto, no modelo ART não há o tratamento do fator de relevância das evidências de entrada. A relevância de um achado determina quão significativo ele é em relação a todos os demais achados da base. Para o médico, o conceito de relevância pode ser compreendido como a morbidade, ou gravidade, de um achado. No diagnóstico de problemas cardíacos, como já enfatizado, a evidência *cansaço* é considerada menos relevante que a evidência *dor-no-peito*. Como descrito no capítulo 1, *HYCONES* define um fator de relevância para cada achado da base de conhecimento. Tais fatores são utilizados pelo sistema para a determinação do gatilho do *frame de diagnóstico*, quando vários achados apresentam a mesma especificidade. Além disto, os fatores de relevância também são utilizados durante o processo de inferência da rede MNC. Se duas ou mais redes obtiverem a mesma ativação de saída, o fator de relevância dos achados contidos em tais redes são utilizados no desempate e conseqüente indicação da rede vencedora.

6.6 Categorias SMART-CHD

E quanto ao valor semântico das categorias de reconhecimento formadas pelo modelo SMART. É ele superior ao do modelo ART? Pode-se assegurar que **sim**. As Tabelas 21, 22, 23, 24, 25, 26, 27, 28 e 29 o comprovam. Em grupos de três, elas apresentam os achados e os pesos de conexão das categorias de reconhecimento mais ativadas em apenas uma das cinco versões de cada um dos três grupos, SMART0-CHD, SMART7-CHD e SMART9-CHD, descritos no capítulo 5. Além disto, estas tabelas apresentam a situação das categorias de reconhecimento para cada

diagnóstico e para cada grupo de versões, a partir dos limiares de poda 0,3, 0,5 e 0,7. Cada versão apresentada nas tabelas foi escolhida aleatoriamente, dentre as cinco versões de cada grupo construído a partir dos diferentes valores atribuídos ao parâmetro de vigilância.

Tabela 21

Categorias de reconhecimento mais ativadas em SMART0-CHD para CIA, CIV e DSAV com limiar de poda igual a 0,3

<i>CIA</i>		<i>CIV</i>		<i>DSAV</i>	
B2-FIXO	= 1,0	SSRGVD	= 1,0	HBAE	= 0.56
SSEJAP	= 0,48	HIPERFLUXO	= 0,73	B2-FIXO	= 0.49
HIPERFLUXO	= 0,45	CRESCVE	= 0,68	ROLAR-VE	= 0.42
CRESCVD	= 0,37	CRESCVD	= 0,6	CRESCAD	= 0.42
HIST-SOPRO	= 0,35	ROLAR-VE	= 0,51	HIPERFLUXO	= 0.42
CARDM-NS	= 0,35	CARDM-NS	= 0,47	HIST-SOPRO	= 0.38
		HIST-SOPRO	= 0,47	SIST-NS	= 0.38
		INFEC-RESP	= 0,39	CRESCVD	= 0.38
		CRESCAE	= 0,38	DOWN	= 0.34
		CARDM-AE	= 0,31		

Tabela 22

Categorias de reconhecimento mais ativadas em SMART0-CHD para *CIA*, *CIV* e *DSAV* com limiar de poda igual a 0,5

<i>CIA</i>		<i>CIV</i>		<i>DSAV</i>	
B2-FIXO	= 1,0	SSRGVD	= 1,0	HBAE	= 0,56
		HIPERFLUXO	= 0,73		
		CRESCVE	= 0,68		
		CRESCVD	= 0,6		
		ROLAR-VE	= 0,51		

Tabela 23

Categorias de reconhecimento mais ativadas em SMART0-CHD para *CIA*, *CIV* e *DSAV* com limiar de poda igual a 0,7

<i>CIA</i>		<i>CIV</i>		<i>DSAV</i>	
B2-FIXO	= 1,0	SSRGVD	= 1,0	HBAE	= 1,0
		HIPERFLUXO	= 0,73	DOWN	= 0,94

Tabela 24

Categorias de reconhecimento mais ativadas em SMART7-CHD para *CIA*, *CIV* e *DSAV* com limiar de poda igual a 0,3

<i>CIA</i>		<i>CIV</i>		<i>DSAV</i>	
B2-FIXO	= 0,85	SSRGVD	= 0,4	HBAE	= 0,9
SSEJAP	= 0,43			DOWN	= 0,79

Tabela 25

Categorias de reconhecimento mais ativadas em SMART7-CHD para *CIA*, *CIV* e *DSAV* com limiar de poda igual a 0,5

<i>CIA</i>		<i>CIV</i>		<i>DSAV</i>	
B2-FIXO	= 1,0	SSRGVD	= 1,0	HBAE	= 0,63
		CRESCVE	= 0,64	DOWN	= 0,51
		HIPERFLUXO	= 0,51		

Tabela 26

Categorias de reconhecimento mais ativadas em SMART7-CHD para *CIA*, *CIV* e *DSAV* com limiar de poda igual a 0,7

<i>CIA</i>		<i>CIV</i>		<i>DSAV</i>	
B2-FIXO	= 1,0	SSRGVD	= 1,0	HBAE	= 1,0
				DOWN	= 0,87

Tabela 27

Categorias de reconhecimento mais ativadas em SMART9-CHD para *CIA*, *CIV* e *DSAV* com limiar de poda igual a 0,3

<i>CIA</i>		<i>CIV</i>		<i>DSAV</i>	
B2-FIXO	= 1,0	SSRGVD	= 0,49	HBAE	= 0,41
SSEJAP	= 0,3				

Tabela 28

Categorias de reconhecimento mais ativadas em SMART9-CHD para *CIA*, *CIV* e *DSAV* com limiar de poda igual a 0,5

<i>CIA</i>	<i>CIV</i>	<i>DSAV</i>
B2-FIXO = 1,0	SSRGVD = 1,0	HBAE = 0,65
	CRESCVE = 0,64	DOWN = 0,53
	HIPERFLUXO = 0,51	

Tabela 29

Categorias de reconhecimento mais ativadas em SMART9-CHD para *CIA*, *CIV* e *DSAV* com limiar de poda igual a 0,7

<i>CIA</i>	<i>CIV</i>	<i>DSAV</i>
B2-FIXO = 1,0	SSRGVD = 1,0	HBAE = 1.0
		DOWN = 0.87

Pode-se perceber, a partir das tabelas acima, a grande semelhança entre as categorias de reconhecimento formadas pelo modelo SMART e os grafos de conhecimento, elicitados de múltiplos especialistas, apresentados nas Figuras 16, 17 e 18. Os dados mostram que, tanto para *CIA* quanto para *DSAV*, não ocorreram grandes modificações no conhecimento dos achados essenciais. Para *CIV*, assim como ocorre com os *frames* de diagnóstico, também muito semelhantes às redes SMART, foi removida da lista de achados a evidência *Sopro Holo-Sistólico (HOLO-SIST)*. O mesmo ocorre em relação ao modelo MNC [REA 93b]. Este problema pode ser resolvido incorporando-se ao motor de inferência a capacidade de identificação de conexões semânticas entre os achados.

Conforme demonstrado neste trabalho, as categorias de reconhecimento formadas por SMART incorporam, além do conceito de sensibilidade dos achados, a especificidade e a relevância dos mesmos. A principal contribuição do modelo SMART é, pois, o maior valor semântico das categorias formadas, em relação aos

modelos ART convencionais. As novas categorias de reconhecimento criadas por SMART apresentam conteúdo similar aos grafos de conhecimento, colhidos de vários especialistas. Além disto, as categorias criadas por SMART são similares às redes criadas pelo modelo MNC. Desta forma, alcança-se o grau de confiança necessário para adequar a explanação das conclusões do sistema ao contexto médico.

Pode-se, ainda, ressaltar a diferença entre o simples reconhecimento de caracteres e a classificação realizada por SMART para o diagnóstico de cardiopatias congênitas e síndromes renais. Para reconhecer caracteres, quando tratados isoladamente, em geral não há necessidade de semântica atrelada. Pode-se imaginar que, para uma rede ART, a letra A seja reconhecida por não possuir as características da letra B. Ressalte-se que, até o momento, os sistemas neurais como o *Fuzzy ARTMAP* e sua versão simplificada vêm sendo empregados com sucesso no reconhecimento de caracteres [CAR 92a] [CAR 92b]. As redes *Fuzzy ARTMAP* trabalham com um padrão duplicado - codificação complementar - que fornecem informações adicionais. Do ponto de vista do tratamento de caracteres, este procedimento é perfeitamente aceitável. Pode-se argumentar, entretanto, que numa letra A existem partes mais relevantes que outras. Porém, as redes ART tradicionais não levam este fato em consideração. O que realmente importa são as características mais freqüentes, ou seja, aquelas vistas na maioria dos padrões de entrada que são apresentados à rede.

Por outro lado, um padrão ou caso médico possui, incontestavelmente, uma forte semântica atrelada. Existem características ou evidências mais específicas, sensíveis e relevantes que outras, para um determinado diagnóstico ou domínio médico. O diagnóstico de um caso de *nefrite* não pode, simplesmente, ser tratado da mesma forma que a classificação de sinais de sonar ou o reconhecimento de caracteres, mesmo porque, na área médica, tais diagnósticos devem ser suportados por uma explanação convincente acerca da inferência realizada. Ainda que não se o possa comprovar a partir deste trabalho, acredita-se que outras áreas classificatórias, além do diagnóstico médico, possuam as mesmas características, i.e, as evidências que levam às conclusões possuem diferentes significados e importância.

O processo de aprendizagem executado pelo modelo SMART pode ser visto como um modo de aprendizagem mais assemelhado ao do ser humano. Comparativamente aos modelo MNC e ART, SMART agrega o processo de punições

e recompensas a uma regra de formação de categorias de reconhecimento, característica de modelos baseados em ART.

A teoria comportamentalista de Skinner e os experimentos de Pavlov são exemplos da aprendizagem por punições e recompensas. O modelo MNC, apesar de utilizar esta regra de aprendizagem, analisa toda a base de casos, computando as punições e recompensas de cada conexão para que, apenas numa segunda etapa, os pesos efetivos destas mesmas conexões sejam calculados. Isto é, sem dúvida, diferente do processo de aprendizagem humano onde a cada nova experiência se aprende um pouco mais. Seria estranho considerar que, para aprender a distinguir um conjunto de cheiros diferentes, alguém tivesse que, primeiro, sentir todos os cheiros, computando as recompensas e punições e só, mais tarde, durante uma segunda etapa (poda e normalização) estaria apto a reconhecer os diversos padrões olfativos. Por outro lado, SMART, por ser um modelo baseado na teoria da adaptação ressonante, garante o reconhecimento destes padrões olfativos desde o início, através da criação, em tempo-real, das categorias de reconhecimento, em resposta à apresentação de padrões estranhos à rede (cheiros nunca sentidos antes) e ao refinamento das categorias previamente formadas, em resposta aos padrões familiares (cheiros já sentidos previamente).

Tal como demonstrado neste trabalho, as categorias de reconhecimento formadas por SMART incorporam, além do conceito de sensibilidade dos achados, especificidade e relevância. A principal contribuição do modelo SMART é, pois, o maior valor semântico das categorias formadas, em relação aos modelos ART convencionais. As novas categorias de reconhecimento, criadas por SMART, apresentam conteúdo similar aos grafos de conhecimento, colhidos de vários especialistas. Além disto, as categorias criadas por SMART são similares às redes criadas pelo modelo MNC. Desta forma, alcança-se o grau de confiança necessário a adequar a explanação das conclusões do sistema ao contexto médico.

Mesmo a partir do bom desempenho obtido com a aprendizagem indutiva, é prevista, como continuação do presente trabalho, a inclusão da aprendizagem dedutiva em HYCONES II, através da implementação de algoritmos genéticos. Estes, como supracitado, podem ser utilizados na análise dos modelos gerados pela aprendizagem indutiva e na geração de novos modelos da realidade. O ciclo de aprendizagem formado pelo dois paradigmas é conhecido como *Aprendizado*

Evolutivo e, quando utilizado na ferramenta NEXTOOL, provou ser muito eficiente no desenvolvimento de sistemas classificatórios com poderosas capacidades adaptativas.

BIBLIOGRAFIA

- [CAR87a] CARPENTER, G. A.; GROSSBERG, S. A massively parallel architecture for a self-organizing neural pattern recognition machine. **Computer Vision, Graphics and Image Processing**, v. 37, p. 54-115, 1987.
- [CAR87b] CARPENTER, G. A.; GROSSBERG, S. ART 2: Self-organization of stable category recognition codes for analog input patterns. **Applied Optics**, v. 26, n. 23, p. 4919-4930, 1987.
- [CAR87c] CARPENTER, G. A.; GROSSBERG, S. ART 2: Stable self-organization of pattern recognition codes for analog input patterns. In: INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, 1., 1987, San Diego. **Proceedings ...** New York: IEEE Press, 1987.
- [CAR90] CARPENTER, G. A.; GROSSBERG, S. ART 3: Hierarchical search using chemical transmitters in self-organizing pattern recognition architectures. **Neural Networks**, v. 3, p. 129-152, 1990.
- [CAR91a] CARPENTER, G. A.; GROSSBERG, S. ART 2-A: An adaptative resonance algorithm for rapid category learning and recognition. **Neural Networks**, v. 4, p. 493-504, 1991.
- [CAR91b] CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. Fuzzy ART: Fast stable learning and categorization of analog patterns by adaptive resonance system. **Neural Networks**, v. 4, p. 759-771, 1991.
- [CAR91c] CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: Supervised real-time learning classification of nonstationary data by a self-organizing neural network. **Neural Networks**, v. 4, p. 565-588, 1991.
- [CAR92a] CARPENTER, G. A.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS, J. H.; ROSEN, D. B. Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Networks**, v. 3, n. 5, p. 698-713, Sept., 1992.
- [CAR92b] CARPENTER, G. A.; GROSSBERG, S.; IIZUKA, K. Comparative performance measures of Fuzzy ARTMAP, Learned Vector Quantization, and Back Propagation for handwritten character recognition. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 1992, Baltimore. **Proceedings ...** [S.l.:s.n.], 1992. p. 1794-1799.

- [CAR92c] CARPENTER, G. A.; GROSSBERG, S. A self-organizing neural network for supervised learning, recognition, and prediction. **IEEE Communications Magazine**, p. 38-49, Sept., 1992.
- [DEN 91] DENIS, F. A. R.; MACHADO, R. J., **O Modelo Conexionista Evolutivo**. Rio de Janeiro: CCR/IBM, 1991. (Technical Report CCR128).
- [FIE 90] FIESCHI, M. **Artificial intelligence in medicine: expert systems**. Londres: Chapman and Hall, 1990. 166 p.
- [FIK 85] FIKES, R.; KEHLER, T. The Role of frame-based reasoning. **Communications of the ACM**, New York, v. 28, n. 9, p. 904-920, 1985.
- [GAL 88] GALLANT, S. I. Connectionist expert systems. **Communications of the ACM**, New York, v. 31, n. 2, p. 152-169, Feb. 1988.
- [GOL 89] GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. [S.I.]: Addison-Wesley, 1989.
- [GRO 76] GROSSBERG, S. Adaptive pattern classification and universal recoding, II. Feedback, expectation, olfaction, and illusions. **Biological Cybernetics**, n. 23, p. 187-202, 1976.
- [GUA 91] GUAZZELLI, A. **Fundamentação de modelos de redes neurais e seus métodos de aplicação no reconhecimento de caracteres**. Porto Alegre: Universidade Federal do Rio Grande do Sul, Instituto de Informática, 1991. 118 p. (Projeto de Diplomação)
- [GUA 93a] GUAZZELLI, A. **Do ART 1 ao Fuzzy ARTMAP: um estudo sobre modelos de redes neurais artificiais baseados na teoria da adaptação ressonante (ART)**. Porto Alegre: Universidade Federal do Rio Grande do Sul, Instituto de Informática, 1993. 61 p. (Trabalho Individual)
- [GUA 93b] GUAZZELLI, A.; BARONE, D. A. C.; FILHO, E. C. B. C., A Simplified ARTMAP Architecture for Real-Time Learning, In: MIRA, J., CABESTANY, J.; PRIETO, A. (eds.). **New Trends in Neural Computation**, [S.I.]: Springer-Verlag, 1993. 750 p. p. 255-260. (Lecture Notes in Computer Science, 686)
- [GUA 94a] GUAZZELLI, A.; LEÃO, B. F.; BARONE, D. A. C. HYCONES' SMART Version: Incorporating Semantic Concepts to ART. In: **WORLD CONGRESS ON MEDICAL PHYSICS AND BIOMEDICAL ENGINEERING**, 1994, Rio de Janeiro. A ser publicado.
- [GUA 94b] GUAZZELLI, A.; LEÃO, B. F. Incorporating Semantics to ART. In: **IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS**,

- 1994, Orlando. **Proceedings ... [S.I.]** : IEEE Press, 1994. 4804 p. p. 1726-1731.
- [HAY 83] HAYES-ROTH, I. et al. **Building expert systems**. Reading: Addison-Wesley, 1983. 444 p.
- [HEN 89] HENSON, D. G. **Goldworks III** : reference manual. Cambridge: Gold Hill Computers, 1989. 328 p.
- [HIN 92] HINTON, G. E. How neural networks learn from experience. **Scientific American: Special Issue Mind and Brain**, New York, v. 267, n. 3, p. 27-45, Sept. 1992.
- [HOL 75] HOLLAND, J. H., **Adaptation in Natural and Artificial Systems**. Ann Arbor, Mich.: University of Michigan Press, 1975.
- [HUD 92] HUDSON, D. L.; BANDA, P. W.; COHEN, M. E.; BLOIS M. S. Medical diagnosis and treatment plans derived from a hybrid expert system. In: KANDEL, A.; LANGHOLZ, G. **Hybrid architectures for intelligent systems**. Boca Raton: CRC Press, 1992. 420 p.
- [HUL 87] HULL, R.; KING, R. Semantic database modeling: survey, applications, and research issues. **ACM Computing Surveys**, New York, v. 19, n. 3, p. 201-260, Sept. 1987.
- [KAN 92] KANDEL, E. R.; HAWKINS, R. D. The Biological basis of learning and individuality. **Scientific American** : Special Issue Mind and Brain, New York, v. 267, n. 3, p. 48-57, Sept. 1992.
- [KNA 92] KNAUS, R. Representing expert knowledge in neural nets. In: KANDEL, A.; LANGHOLZ, G. **Hybrid architectures for intelligent systems**. Boca Raton: CRC Press, 1992. 420 p. p. 345-356.
- [KNI 89] KNIGHT, K. **A Gentle introduction to subsymbolic computation: connectionism for the AI researcher**. Pittsburgh: Carnegie-Mellon University, 1989. 28 p.
- [KRO 92] KROVVIDY S.; WEE W. G. An Intelligent Hybrid System for wastewater treatment. In: KANDEL, A.; LANGHOLZ, G. **Hybrid architectures for intelligent systems**. Boca Raton: CRC Press, 1992. 420 p. p. 357-378.
- [KUR 90] KURZWEIL, R. **The Age of intelligent machines**. Cambridge: MIT Press, 1990. 569 p.

- [LAW 91] LAWRENCE, D. **The Handbook of genetic algorithms**. New York: Van Nostrand Reinhold, 1991. 383 p.
- [LEA 88] LEÃO, B. F. **Construção da base de conhecimento de um sistema especialista de apoio ao diagnóstico de cardiopatias congênitas**. São Paulo: Escola Paulista de Medicina, 1988. 230 p. (Tese de Doutorado)
- [LEA 90] LEÃO, B. F.; ROCHA, A. F. Proposed methodology for knowledge acquisition: a study on congenital heart disease diagnosis. **Methods of Information in Medicine**, Amsterdam, v. 29, n. 1, p. 30-40, Jan. 1990.
- [LEA 93a] LEÃO, B. F.; REÁTEGUI, E. B. HYCONES: a Hybrid Connectionist Expert System, In: ANNUAL SYMPOSIUM ON COMPUTER APPLICATIONS IN MEDICAL CARE, 17., 1993, Washington. **Proceedings ...** [S.l.]: Mc Graw-Hill, 1993. p. 461-465.
- [LEA 93b] LEÃO, B. F.; REÁTEGUI, E. B. HYCONES: a Hybrid Connectionist Expert System, In: ANNUAL SYMPOSIUM ON COMPUTERS AND CARDIOLOGY, 1993, Londres. **Proceedings ...** [S.l.]: IEEE Press, 1993. p. 461-465.
- [LEA 94] LEÃO, B. F.; REATEGUI, E. B.; GUAZZELLI, A.; MENDONÇA, E. A. HYCONES II - a tool to develop hybrid connectionist expert systems. In: WORLD CONGRESS ON MEDICAL PHYSICS AND BIOMEDICAL ENGINEERING, 1994, Rio de Janeiro. A ser publicado.
- [MAC 89] MACHADO, R. J.; ROCHA, A. F. **Handling knowledge in high order neural networks: the combinatorial neural model**. Rio de Janeiro: IBM Rio Scientific Center, 1989. 22 p. (Technical Report CCR076).
- [MAC 90a] MACHADO, R. J.; ROCHA, A.F.; LEÃO, B. F. Calculating the mean knowledge representation from multiple experts. In: FEDREZZI, M.; KACPRZKYK, J. (eds.). **Multiperson decision making models using fuzzy sets and possibility theory**, Amsterdam: Kluwer Academic Publishers, 1990. p. 113-127.
- [MAC 90b] MACHADO, R. J.; ROCHA, A. F. The Combinatorial Neural Network: a Connectionist Model for Knowledge-Based Systems. In: INTERNATIONAL CONFERENCE IPMU - INFORMATION PROCESSING AND MANAGEMENT OF UNCERTAINTY IN KNOWLEDGE-BASED SYSTEMS, 3., 1990, Paris. **Proceedings ...** [S.l.:s.n], 1990. p. 9-11.

- [MAC 91] MACHADO R. J. et al. **Next: the neural expert tool**. Rio de Janeiro: IBM Rio Scientific Center, 1991. 57 p. (Technical Report CCR-120)
- [MAC 92a] MACHADO, R. J. et al. **Combining semantic networks and neural networks in expert systems**. Rio de Janeiro: IBM Rio Scientific Center, 1992. (Technical Report CCR-140)
- [MAC 92b] MACHADO, R. J.; ROCHA, A. F. A Hybrid Architecture for Fuzzy Connectionist Expert Systems. In: KANDEL, A.; LANGHOLZ, G. **Hybrid architectures for intelligent systems**. Boca Raton: CRC Press, 1992. 420 p. p. 135-152.
- [MIC 83] MICHALSKI, R. S.; CARBONELL, J. G.; MITCHELL, T. M. **Machine learning : an artificial intelligence approach**. Palo Alto: Morgan Kaufmann, 1983. 572 p.
- [MIL 86] MILLER, R. A. et al., Internist - I: an experimental computer-based diagnostic consultant for general internal medicine. In: REGGIA, J. A. & STANLEY, T. (eds.). **Computer-assisted medical decision making**, New York: Springer-Verlag, 1986. v. 2, p. 139-158.
- [OWE 90] OWENS, D. K. et al. Medical decision making: probabilistic medical reasoning. In: SHORTLIFE, E. H. et al. (eds.). **Medical informatics: computer applications in health care**. Reading: Addison-Wesley, 1990. p. 70-116.
- [PEA 88] PEAT F. D. **Artificial intelligence: how machines think**. New York: Ben Publishing Enterprises, 1988. 356 p.
- [REA 93a] REÁTEGUI, E. B.; LEÃO, B. F., Integrating Neural Networks with the Formalism of Frames, In: WORLD CONGRESS ON NEURAL NETWORKS, 1., 1993, Portland. **Proceedings ...** [S.l.:s.n.], 1993.
- [REA 93b] REÁTEGUI, E. B. **Um modelo para sistemas especialistas conexionistas híbridos**. Porto Alegre: Universidade Federal do Rio Grande do Sul, Curso de Pós-Graduação em Ciências da Computação, 1993. 126 p. (Dissertação de Mestrado)
- [ROL 88] ROLSTON, D. W. **Artificial Intelligence and expert systems development**. New York: McGraw-Hill, 1988. 257 p.
- [RUM 86] RUMELHART, D. E.; McLELLAND, J. L. **Parallel distributed processing**. Cambridge: MIT Press, 1986. v. 1, 547 p.
- [SAM 92] SAMAD, T. Hybrid distributed/ local connectionist architectures. In: KANDEL, A.; LANGHOLZ, G. **Hybrid architectures for intelligent systems**. Boca Raton: CRC Press, 1992. 420 p. p. 199-220.

- [SIM90] SIMPSON, P. K. **Artificial Neural Systems: foundations, paradigms, applications, and implementations.** Pergamon Press, 1990.
- [WAS89] WASSERMAN, P. D. **Neural Computing: theory and practice.** New York: Van Nostrand Reinhold, 1989.

APÊNDICE I

Achados que compõem a base de casos de Cardiopatias Congênitas:

- HOLO-SIST: sopro holo-sistólico;
- SIST-NS: sopro sistólico não especificado;
- SSEJAO: sopro sistólico ejeção aorta;
- SSEJAP: sopro sistólico ejeção artéria pulmonar;
- SSRGVD: sopro sistólico regurgitação ventrículo direito;
- SSRGVE: sopro sistólico regurgitação ventrículo esquerdo;
- ROLAR-VD: rolar diastólico de ventrículo direito;
- ROLAR-VE: rolar diastólico de ventrículo esquerdo;
- CRESCAD: crescimento de átrio direita;
- CRESCAE: crescimento de átrio esquerda;
- CRESCVD: crescimento do ventrículo direito;
- CRESCVE: crescimento do ventrículo esquerdo;
- BRD: bloqueio de ramo direito;
- BRE: bloqueio de ramo esquerdo;
- HBAE: hemi-bloqueio anterior esquerdo;
- HBPE: hemi-bloqueio posterior esquerdo;

- BAV1: bloqueio átrio-ventricular de 1º grau;
- BAV3: bloqueio átrio-ventricular de 3º grau;
- MOBIZ1: bloqueio átrio-ventricular de 2º grau tipo Mobitz 1;
- MOBIZ2: bloqueio átrio-ventricular de 2º grau tipo Mobitz 2 ou Weckenbach;
- RX-NL: radiografia de tórax normal;
- CARDM-AD: cardiomegalia às custas de átrio direito;
- CARDM-AE: cardiomegalia às custas de átrio esquerdo;
- CARDM-NS: cardiomegalia não-especificada;
- CARDM-VD: cardiomegalia às custas de ventrículo direito;
- CARDM-VE: cardiomegalia às custas de ventrículo esquerdo;
- CONG-PULM: radiografia de tórax com sinais de congestão pulmonar;
- HIPERFLUXO: radiografia de tórax com hiperfluxo pulmonar;
- DIL-TAP: dilatação do tronco de artéria pulmonar;
- PULSE-COAO1: diferença de pulsos entre membros inferiores e superiores;
- PULSE-HYPER: pulsos hipercinéticos;
- DESEN-HIPO: hipo-desenvolvimento;
- DESEN-NL: desenvolvimento normal;

- HEPATO: hepatomegalia;
- FR-SIST: frêmito sistólico;
- IMP-PEE: impulsão sistólica paraesternal esquerda;
- TAQUIPN: taquipnéia;
- TIRAGEM: tiragem intercostal;
- B1-HIPER: B1 hiperfonética;
- B1-HIPO: B1 hipofonética;
- B2-AMPLO-FIXO: B2 com desdobramento amplo e fixo;
- B2-FIXO: B2 com desdobramento fixo;
- B2-HIPER: B2 hiperfonética;
- B2-UNICA: B2 única;
- B3-T: presença de B3;
- ASSINTOM: assintomático;
- CANS-MAMAR: cansaço para mamar;
- CANSACO: cansaço aos esforços;
- CIAN: história de cianose aos esforços;
- CRISE-CIAN: crises de cianose;
- HIST-SOPRO: história de sopro;

- INFEC-RESP: infecções respiratórias de repetição;
- TONT: tonturas;
- DOWN: síndrome de Down.

APÊNDICE II

Para se ilustrar através de um exemplo o tratamento dos conceitos de sensibilidade, especificidade e relevância, é descrito, a seguir, o processo de aprendizagem de uma rede *Simplified Fuzzy ARTMAP* sem a codificação complementar e, por simplicidade, sem considerar a propriedade *fast-commit slow-recode*, a partir de 6 casos hipotéticos. A base de casos gerada possui 7 evidências representadas pelas letras maiúsculas de A a G e dois diagnósticos X e Y. A composição de cada um dos 6 casos é descrita a seguir:

- **caso 1:** possui as evidências A, B e F, e aponta o diagnóstico X;
- **caso 2:** possui as evidências B, D, F e G, e indica o diagnóstico Y;
- **caso 3:** possui as evidências A, B, C e G, e aponta o diagnóstico X;
- **caso 4:** possui as evidências A, C e F, e aponta o diagnóstico X;
- **caso 5:** possui as evidências B, E e D, e indica o diagnóstico Y;
- **caso 6:** possui as evidências B, C, D e E, e aponta o diagnóstico Y.

As evidências presentes em cada caso são representadas por um grau de possibilidade igual a 1.

A partir dos 6 casos hipotéticos e utilizando-se da equação para o cálculo da sensibilidade descrita no capítulo 1, são apresentados na Tabela 1 os valores do fator de sensibilidade de cada um dos 7 achados ou evidências que fazem parte da base gerada. Na Tabela 2, são apresentados os valores do fator de especificidade de cada uma das evidências computados a partir da equação para o cálculo da especificidade também apresentada no capítulo 1. Os fatores de relevância ou morbidade dos achados, assim como os próprios achados, também foram hipoteticamente criados. Tais fatores são apresentados na Tabela 3.

Tabela 1

Sensibilidade dos achados hipotéticos

	A	B	C	D	E	F	G
Diagnóstico X	1,00	0,66	0,66	0,00	0,33	0,66	0,33
Diagnóstico Y	0,00	1,00	0,33	1,00	0,66	0,33	0,33

Tabela 2

Especificidade dos achados hipotéticos

	A	B	C	D	E	F	G
Diagnóstico X	1,00	0,00	0,66	0,00	0,33	0,66	0,66
Diagnóstico Y	0,00	0,33	0,33	1,00	1,00	0,33	0,66

Tabela 3

Relevância dos achados

	A	B	C	D	E	F	G
Fator de Relevância	0,8	0,6	0,4	1,0	0,8	0,6	0,4

No início todos os neurônios da camada F2 da rede estão completamente conectados aos neurônios das camadas F1^a e F1^b com pesos iguais a 1. O parâmetro de vigilância básico da rede é igual a 0,2 (Figura 1).

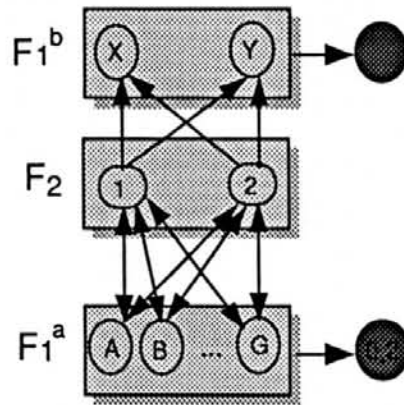


Figura 1 Rede ART não operante

A formação das categorias de reconhecimento e as transformações sofridas pela rede durante a apresentação dos casos é descrita a seguir:

- **apresentação do caso 1:** quando o caso 1 é apresentado à rede, as evidências de entrada são propagadas da camada F1^a à camada F2. O processo de competição em F2 aponta como vencedor o neurônio mais à esquerda (neurônio 1), pois inicialmente as ativações de todos os neurônios em F2 são iguais. O sinal emitido pelo neurônio 1 é comparado, em F1^a, às evidências A, B e F. O resultado desta comparação, igual a 1, é maior que o parâmetro de vigilância previamente estabelecido - igual a 0,2. O sinal de F2 também é emitido para a camada F1^b onde é comparado ao sinal de entrada X. O resultado desta comparação também é 1. Desta forma, o neurônio vencedor está apto a aprender o caso 1. Assim, através da regra de aprendizagem rápida, definida no capítulo 3, a rede é podada das conexões entre o neurônio vencedor em F2 e os neurônios em F1^a representativos das evidências C, D, E e G, não encontradas no caso apresentado. Também é feita a poda da conexão entre o neurônio 1 e o neurônio Y da camada F1^b. A rede resultante é mostrada na Figura 2. A partir desta figura e do processo acima descrito, pode-se perceber a grande importância da ordem de apresentação dos casos para a formação das categorias de reconhecimento. As evidências que não fazem parte do primeiro caso categorizado, não mais serão representadas pela categoria de reconhecimento formada;




Figura 2 Rede ART depois do aprendizado do caso hipotético 1

- **apresentação do caso 2:** o sinal de entrada, composto pelas evidências B, D, F e G, é completamente propagado de $F1^a$ para $F2$. O neurônio 1 é novamente o vencedor da competição realizada em $F2$, com ativação de entrada igual a 0,66. Desta forma, a categoria de reconhecimento representada pelo neurônio 1 é comparada ao sinal de entrada em $F1^a$. O resultado desta comparação, igual a 0,5, é maior que a vigilância da rede. Entretanto, quando o neurônio X, ativado em $F2^b$, é comparado com o alvo - diagnóstico Y, o resultado é igual a zero. A camada $F2^b$ ativa, então, o processo chamado *match-tracking* que eleva a vigilância da rede para 0,51, fazendo com que o neurônio 1 seja inibido. As evidências B, D, F e G são restauradas em $F1^a$ e novamente propagadas até $F2$. Como mais nenhuma categoria foi criada além daquela representada pelo neurônio 1, o neurônio 2, o mais à esquerda com exceção do 1, será o vencedor. O sinal emitido pelo neurônio 2 é, portanto, comparado com as evidências de entrada em $F1^a$. O resultado desta comparação, igual a 1, é maior que o parâmetro de vigilância. O sinal de $F2$ também é emitido para a camada $F1^b$, onde é comparado ao sinal de entrada Y. Desta vez, o resultado é igual a 1. Desta forma, o neurônio vencedor está apto a incorporar o caso 2. Através da regra de aprendizagem baseada no operador *E-nebuloso*, a rede é podada das conexões A, C e E, não encontradas no caso apresentado. Também é feita a poda da conexão entre o neurônio 2 e o neurônio X da camada $F1^b$. Finalmente, atribui-se novamente ao parâmetro de vigilância seu valor original - 0,2. A rede resultante é mostrada na Figura 3;




Figura 3 Rede ART depois do aprendizado do caso hipotético 2

- **apresentação do caso 3:** quando o caso 3 é apresentado, o sinal de entrada é também propagado de $F1^a$ para $F2$. Desta vez, a competição em $F2$ se dá entre o neurônio 1 e 2. O vencedor é o neurônio 1, com resultado igual a 0,66. Em $F1^a$, o sinal emitido pelo neurônio 1 é comparado com as evidências do caso 1, resultando o grau de semelhança de 0,5, maior que a vigilância de 0,2. Em $F1^b$, a comparação do sinal de entrada com o neurônio X, ativado, é igual a 1. Assim, executando-se a regra de aprendizagem, a conexão entre o neurônio 1 e o neurônio F é podada, e as conexões com os neurônios A e B são mantidas, enquanto que as evidências C e G são perdidas, pois suas conexões já haviam sido podadas. O achado B foi mantido, pois sua sensibilidade é alta. Entretanto, como mostrado na Tabela 2, a especificidade dos achados F, C e G, igual a 0,66, é muito maior que a especificidade do achado B, igual a 0,0;

- **apresentação do caso 4:** como nos casos anteriores, quando o caso 4 é apresentado, o sinal de entrada é propagado de $F1^a$ para $F2$, onde o neurônio 1 é o vencedor do processo competitivo, com resultado igual a 0,5. O neurônio 2 apresenta ativação de entrada igual a 0,25. Em $F1^a$, a comparação entre o sinal emitido pelo neurônio 1 e o sinal de entrada é maior que a vigilância ($0,33 > 0,2$). A comparação de sinais em $F1^b$ é igual a 1. Assim, as evidências A, C e F são categorizadas junto com o que restou do processo de aprendizagem dos casos 1 e 3. Pela regra de aprendizagem ART, apenas a conexão entre o neurônio representativo da evidência A e o neurônio 1 é mantida. Como se pode perceber, o processo de esquecimento da rede é bastante acentuado. Das 5 evidências que formam os casos representativos do diagnóstico X, apenas aquela com sensibilidade igual a 1,0 resistiu à operação de minimização executada pelo operador *E-nebuloso*;

- **apresentação do caso 5:** quando o caso 5 é apresentado à rede, o sinal de entrada é mais uma vez propagado de $F1^a$ para $F2$. Desta vez, o neurônio vencedor é o 2, pois o 1 apresenta ativação zero. O processo de comparação entre a categoria representada pelo neurônio 2 e o caso de entrada resulta em 0,5 que é maior que 0,2. Por outro lado, o resultado do processo de comparação na camada $F1^b$ é mais uma vez igual a 1. De acordo com a regra de aprendizagem, a categorização do caso 5 com o caso 2 resulta na poda das conexões F e G. Assim, a categoria passa a ser composta apenas pelas conexões entre o neurônio 2 e aqueles representativos das evidências B e D;

- **apresentação do caso 6:** quando da apresentação do caso 6, as evidências de entrada B, C, D e E são completamente propagadas de $F1^a$ para $F2$. O neurônio 2 é novamente o vencedor da competição realizada em $F2$. A ativação do neurônio 1 é zero, pois este não apresenta em sua categoria de reconhecimento qualquer coincidência com as evidências de entrada do caso 6. Desta forma, a categoria de reconhecimento representada pelo neurônio 2 é comparada com o sinal de entrada em $F1^a$. O resultado desta comparação, igual a 0,5, é maior que a vigilância da rede. O sinal de $F2$ também é emitido para a camada $F1^b$, onde é comparado com o sinal de entrada Y. O resultado desta comparação é igual a 1. Desta forma, o neurônio vencedor está apto a incorporar o caso 6 em sua categoria de reconhecimento. Através da regra de aprendizagem, nenhuma mudança acontece na categoria de reconhecimento, pois as conexões entre o neurônio vencedor e os neurônios em $F1^a$, representativos das evidências C e E, já foram previamente podadas. Como se pode notar, a categoria resultante deste processo retém a conexão com a evidência B, apesar de sua especificidade ser de apenas 0,33, enquanto que poda a conexão com a evidência E, que possui especificidade igual a 1. Além disto, pode-se perceber que em nenhum momento a rede ART leva em consideração o fator de relevância dos achados.

As categorias de reconhecimento resultantes da aprendizagem dos 6 casos hipotéticos são mostradas na Figura 4.

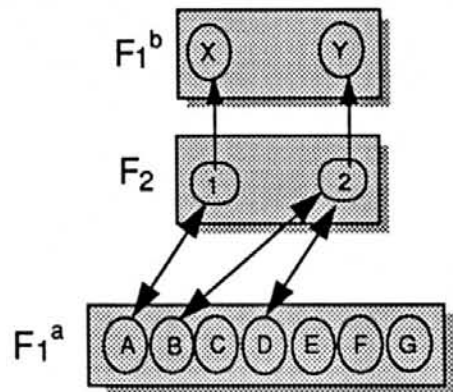


Figura 4 Rede ART resultante após o aprendizado dos 6 casos hipotéticos

APÊNDICE III

Para que o funcionamento do modelo SMART também possa ser acompanhado através de um exemplo, é apresentada, a seguir, a aprendizagem da mesma base de casos hipotéticos utilizada anteriormente na análise do modelo *Simplified Fuzzy ARTMAP*, feita no apêndice II.

No processo de formação das categorias de reconhecimento a seguir apresentado, a conexão entre o neurônio vencedor em F2 e aquele representativo de uma evidência k , qualquer, em F1^a, é representada por *conexão k*. A apresentação de cada caso e seu processo de categorização é descrito a seguir:

- **apresentação do caso 1:** quando o caso 1 é apresentado, as evidências de entrada A, B e F são propagadas da camada F1^a até a camada F2. O resultado do processo de competição em F2 aponta como vencedor o neurônio mais à esquerda - neurônio 1. O sinal emitido pelo neurônio vencedor é, então, comparado, em F1^a, com as evidências de entrada A, B e F. O resultado desta comparação, igual a 1,5, é maior que o parâmetro de vigilância previamente estabelecido, igual a 0,2. O sinal de F2 também é emitido para a camada F1^b, onde é comparado com o sinal de entrada. O resultado desta comparação é igual a 1. Conseqüentemente, o neurônio 1 está apto a aprender o caso apresentado. Para que isto aconteça, são computados os acumuladores de recompensas das conexões A, B e F. A partir destes valores, é realizado o cálculo dos pesos das conexões. Finalmente, é feita a poda da conexão entre o neurônio 1 e o neurônio Y da camada F1^b. Na Tabela 1, são apresentados os valores dos acumuladores de punições e de recompensas e os pesos de todas as conexões entre o neurônio vencedor e os neurônios representativos das evidências em F1^a;

Tabela 1

Valores dos acumuladores e pesos das conexões da categoria de reconhecimento formada pelo neurônio 1 após o cálculo das recompensas realizado a partir da aprendizagem do caso hipotético 1

	Acumuladores de Recompensas	Acumuladores de Punições	Pesos
A	0,8	0,0	0,8
B	0,6	0,0	0,6
C	0,0	0,0	0,0
D	0,0	0,0	0,0
E	0,0	0,0	0,0
F	0,6	0,0	0,6
G	0,0	0,0	0,0

- **apresentação do caso 2:** o sinal de entrada, composto pelas evidências B, D, F e G, é propagado de F1^a para F2. De acordo com a equação que regula o processo de competição em F2, o neurônio 1 é novamente o vencedor. Sua ativação de entrada é igual a 0,6. Desta forma, a categoria de reconhecimento representada pelo neurônio 1 é comparada com o sinal de entrada em F1^a. O resultado desta comparação, igual a 0,46, é maior que a vigilância da rede. Entretanto, quando o neurônio X, ativado em F2^b, é comparado com o alvo - diagnóstico Y, o resultado é igual a zero. A camada F2^b ativa, então, o processo *match-tracking*, que eleva a vigilância da rede para 0,47, fazendo com que o neurônio 1 seja inibido. Quando isto acontece, são computados os acumuladores de punições das conexões B, D, F e G. Em seguida, os novos pesos das conexões também são computados. As diferenças entre os acumuladores de recompensas e punições que resultam em valores menores ou iguais a zero indicam um peso de conexão igual a zero. Na Tabela 2, são apresentados os valores dos acumuladores de punições e de recompensas e os pesos de todas as conexões entre o neurônio 1 e os neurônios representativos das evidências em F1^a. A partir da restauração das evidências B, D, F e G, na camada F1^a, o processo de aprendizagem do caso 2 continua. De F1^a, as evidências são novamente propagadas até F2. Como mais nenhuma categoria foi criada além daquela representada pelo neurônio 1, o 2, o mais à esquerda com exceção daquele,

é o vencedor. Sua ativação de saída é, portanto, propagada e comparada com as evidências de entrada em $F1^a$. O resultado desta comparação, maior que 1, é maior que o parâmetro de vigilância, que agora é igual a 0,47. O sinal de $F2$ também é emitido para a camada $F1^b$ onde é comparado ao sinal de entrada Y . Desta vez, o resultado é igual a 1. Desta forma, o neurônio vencedor está apto a incorporar o caso 2. Através da nova regra de aprendizagem, os acumuladores de recompensa das conexões B, D, F e G são computados, alterando-se, conseqüentemente, os pesos das conexões. Além disto, é feita a poda da conexão entre o neurônio 2 e o neurônio X da camada $F1^b$. Finalmente, atribui-se novamente ao parâmetro de vigilância seu valor original - 0,2. Na Tabela 3, são apresentados os valores dos acumuladores de punições e de recompensas e os valores dos pesos de todas as conexões entre o neurônio 2 e os neurônios representativos das evidências em $F1^a$;

Tabela 2

Valores dos acumuladores e pesos das conexões da categoria de reconhecimento formada pelo neurônio 1 após o cálculo das punições realizado a partir da aprendizagem do caso hipotético 2

	Acumuladores de Recompensas	Acumuladores de Punições	Pesos
A	0,8	0,00	0,80
B	0,6	0,36	0,24
C	0,0	0,00	0,00
D	0,0	0,60	0,00
E	0,0	0,00	0,00
F	0,6	0,36	0,24
G	0,0	0,24	0,00

Tabela 3

Valores dos acumuladores e pesos das conexões da categoria de reconhecimento do neurônio 2 após o cálculo das recompensas realizado a partir da aprendizagem do caso hipotético 2

	Acumuladores de Recompensas	Acumuladores de Punições	Pesos
A	0,0	0,0	0,0
B	0,6	0,0	0,6
C	0,0	0,0	0,0
D	1,0	0,0	1,0
E	0,0	0,0	0,0
F	0,6	0,0	0,6
G	0,4	0,0	0,4

- **apresentação do caso 3:** quando o caso 3 é apresentado, o sinal de entrada, composto pelas evidências A, B, C e G, é também propagado até F2. Desta vez, a competição nesta camada se dá entre os neurônios 1 e 2. O vencedor deste processo é o primeiro, com resultado igual a 0,81. O neurônio 2 apresenta ativação de entrada igual a 0,38. Em F1^a, o sinal emitido pelo neurônio 1 é comparado com as evidências do caso 1, resultando em 0,47, que é maior que 0,2. Em F1^b, a comparação do sinal de entrada com o neurônio X ativado é igual a 1. Executando-se a regra de aprendizagem, são calculados os novos valores dos acumuladores de recompensas para as conexões A, B, C e G. Na seqüência, são computados os pesos das conexões da categoria vencedora. Na Tabela 4, são apresentados os valores dos acumuladores de punições e de recompensas e os valores dos pesos de todas as conexões entre o neurônio 1 e os neurônios representativos das evidências em F1^a.

Tabela 4

Valores dos acumuladores e pesos das conexões da categoria de reconhecimento do neurônio 1 após o cálculo de recompensas realizado a partir da aprendizagem do caso hipotético 3

	Acumuladores de Recompensas	Acumuladores de Punições	Pesos
A	1,45	0,00	1,00
B	1,09	0,36	0,50
C	0,32	0,00	0,22
D	0,00	0,60	0,00
E	0,00	0,00	0,00
F	0,60	0,36	0,17
G	0,32	0,24	0,06

- **apresentação do caso 4:** como no que precedeu, quando o caso 4 é apresentado, o sinal de entrada, representado pelas evidências A, C e F, é propagado de F1^a para F2, onde o neurônio 1 é o vencedor do processo competitivo, com resultado igual a 0,71. O neurônio 2 apresenta ativação de entrada igual a 0,23. Em F1^a, a comparação entre o sinal emitido pelo neurônio 1 e o sinal de entrada é maior que a vigilância ($0,77 > 0,2$). A comparação de sinais em F1^b é igual a 1. Assim, o caso 4 é categorizado junto com os casos 1 e 3. Pela regra de aprendizagem de SMART, são computados os valores dos acumuladores de recompensas das conexões A, C e F. Os pesos das conexões da categoria vencedora são calculados a partir destes novos valores. Na Tabela 5, são apresentados os valores dos acumuladores de punições e de recompensas e os valores dos pesos de todas as conexões entre o neurônio 1 e aqueles representativos das evidências em F1^a.

Tabela 5

Valores dos acumuladores e pesos das conexões da categoria de reconhecimento do neurônio 1 após o cálculo das recompensas realizado a partir da aprendizagem do caso hipotético 4

	Acumuladores de Recompensas	Acumuladores de Punições	Pesos
A	2,02	0,00	1,00
B	1,09	0,36	0,36
C	0,60	0,00	0,30
D	0,00	0,60	0,00
E	0,00	0,00	0,00
F	1,03	0,36	0,33
G	0,32	0,24	0,04

- **apresentação do caso 5:** quando o caso 5 é apresentado à rede, o sinal de entrada, representado pelas evidências B, E e D, é propagado de F1^a para F2. Desta vez, é vencedor o neurônio 2, com ativação de entrada igual a 0,62, pois o neurônio 1 apresenta ativação igual a 0,18. Em F1^a, o processo de comparação entre a categoria representada pelo neurônio 2 e o caso de entrada é igual a 0,67, maior que 0,2. O resultado do processo de comparação na camada F1^b, mais uma vez, é igual a 1. De acordo com a regra de aprendizagem do sistema SMART, a categorização do caso 5 com o caso 2 resulta no cálculo dos novos valores dos acumuladores de recompensas das vias B, E e D. Além disto, de acordo com estes valores, os pesos das conexões entre o neurônio 2 e os neurônios representativos das evidências B, E, D, F e G são alterados. Na Tabela 6 são apresentados os valores dos acumuladores de punições e de recompensas e os pesos de todas as conexões entre o neurônio 2 e os neurônios representativos das evidências em F1^a.

Tabela 6

Valores dos acumuladores e pesos das conexões da categoria de reconhecimento do neurônio 2 após o cálculo de recompensas realizado a partir da aprendizagem do caso hipotético 5

	Acumuladores de Recompensas	Acumuladores de Punições	Pesos
A	0,00	0,0	0,00
B	0,97	0,0	0,60
C	0,00	0,0	0,00
D	1,62	0,0	1,00
E	0,50	0,0	0,31
F	0,60	0,0	0,37
G	0,40	0,0	0,25

- **apresentação do caso 6:** quando da apresentação do caso 6, as evidências de entrada B, C, D e E são completamente propagadas de F1^a para F2. Novamente, o neurônio 2 é o vencedor da competição realizada em F2. Sua ativação de entrada é igual a 0,74, enquanto que a ativação do neurônio 1 é 0,33. Desta forma, a categoria de reconhecimento representada pelo neurônio 2 é comparada com o sinal de entrada em F1^a. O resultado desta comparação, igual a 0,68, é maior que a vigilância da rede. O sinal de F2 também é emitido para a camada F1^b, onde é comparado com o sinal de entrada Y. O resultado desta comparação é igual a 1. Desta forma, o neurônio vencedor está apto a incorporar o caso 6 em sua categoria de reconhecimento. Através da nova regra de aprendizagem, são computados os novos valores dos acumuladores de recompensas das vias B, C, D e E. Tais valores resultam nos novos pesos das conexões. Na Tabela 7, são apresentados os valores dos acumuladores de punições e de recompensas e os valores dos pesos de todas as conexões entre o neurônio 2 e aqueles representativos das evidências em F1^a.

Tabela 7

Valores dos acumuladores e pesos das conexões da categoria de reconhecimento do neurônio 2 após o cálculo de recompensas realizado a partir da aprendizagem do caso hipotético 6

	Acumuladores de Recompensas	Acumuladores de Punições	Pesos
A	0,00	0,0	0,00
B	1,42	0,0	0,60
C	0,30	0,0	0,13
D	2,37	0,0	1,00
E	1,10	0,0	0,46
F	0,60	0,0	0,25
G	0,40	0,0	0,17

A rede resultante da aprendizagem dos 6 casos, depois da poda das conexões com pesos inferiores a 0,3, é apresentada na Figura 1.

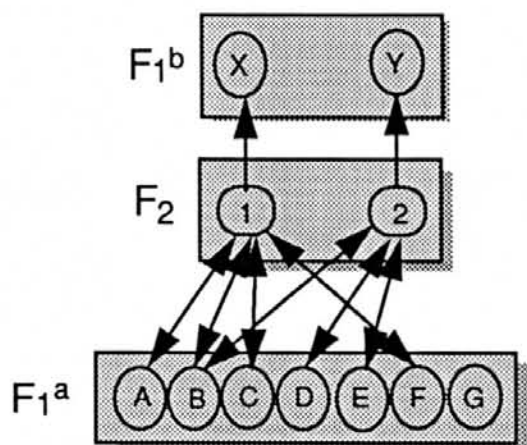


Figura 1 Rede SMART resultante após o aprendizado dos 6 casos hipotéticos

Como se pode perceber, a rede SMART, ao contrário da *Simplified Fuzzy ARTMAP*, com funcionamento exemplificado no Apêndice II, reteve, em suas

categorias de reconhecimento, aqueles achados mais sensíveis, específicos e relevantes para os diagnósticos X e Y.



Informática
UFRGS

Aprendizagem em Sistemas Híbridos.

Dissertação apresentada aos Senhores:

Luis Otavio Campos

Prof. Dr. Luis Otávio Campos Alvares

Philippe Navaux

Prof. Dr. Philippe Olivier Alexandre Navaux

Ricardo José Machado

Prof. Dr. Ricardo José Machado (IBM/RJ)

Vista e permitida a impressão.
Porto Alegre, 20 / 07 / 94.

Dante Augusto Couto Barone

Prof. Dr. Dante Augusto Couto Barone,
Orientador.

Jose Palazzo Moreira de Oliveira

Prof. Dr. José Palazzo Moreira de Oliveira,
Coordenador do Curso de Pós-Graduação
em Ciência da Computação.