

UNIVERSIDADE FEDERAL DE SANTA CATARINA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**REDES NEURAIS ARTIFICIAIS PARA  
REPRESENTAÇÃO DE CONHECIMENTO  
MÉDICO EM ANESTESIOLOGIA**

DISSERTAÇÃO SUBMETIDA À UNIVERSIDADE FEDERAL DE  
SANTA CATARINA PARA OBTENÇÃO DO GRAU DE MESTRE  
EM ENGENHARIA ELÉTRICA

**JURANDIR PAZ DE OLIVEIRA**

FLORIANÓPOLIS, FEVEREIRO DE 1997

REDES NEURAIIS ARTIFICIAIS PARA REPRESENTAÇÃO DE  
CONHECIMENTO MÉDICO EM ANESTESIOLOGIA

JURANDIR PAZ DE OLIVEIRA

ESTA DISSERTAÇÃO FOI JULGADA ADEQUADA PARA OBTENÇÃO  
DO TÍTULO DE MESTRE EM ENGENHARIA

ESPECIALIDADE ENGENHARIA ELÉTRICA, ÁREA DE  
CONCENTRAÇÃO ENGENHARIA BIOMÉDICA E APROVADA EM SUA  
FORMA FINAL PELO PROGRAMA DE PÓS-GRADUAÇÃO



Prof. Walter Celso De Lima, D.Sc,LD  
Orientador



Prof. Adroaldo Raizer, Dr.INPG  
Coordenador do Curso

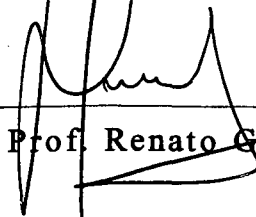
BANCA EXAMINADORA :



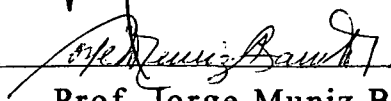
Prof. Walter Celso De Lima, D.Sc,LD  
Presidente



Prof. Fernando Mendes De Azevedo, D.Sc.



Prof. Renato Garcia Ojeda, D.Sc.



Prof. Jorge Muniz Barreto, D.Sc.

À minha Esposa e Família

## **AGRADECIMENTOS**

**Ao Prof. Walter Celso de Lima por sua orientação e solicitude.**

**Ao Prof. Renato Garcia Ojeda por suas sugestões e críticas.**

**Ao Grupo de Pesquisas em Engenharia Biomédica - GPEB pelo  
suporte operacional a este trabalho.**

**A todos que participaram, direta ou indiretamente, da construção  
da base de dados em anestesiologia.**

**Ao amigo Policarpo Batista Uliana, pelas valiosas contribuições  
no encaminhamento deste trabalho.**

## SUMÁRIO

ÍNDICE DE FIGURAS .....	vii
ÍNDICE DE TABELAS .....	viii
RESUMO .....	ix
ABSTRACT .....	x
1 - INTRODUÇÃO .....	1
1.1 - OBJETIVOS .....	4
1.2 - JUSTIFICATIVA .....	6
1.3 - PROPOSIÇÕES .....	7
1.4 - ORGANIZAÇÃO DO TRABALHO .....	8
2 - FUNDAMENTAÇÃO TEÓRICA .....	9
2.1 - REPRESENTAÇÃO DE CONHECIMENTOS ATRAVÉS DE RNAs .....	9
2.2 - DISCUSSÃO SOBRE O ALGORITMO <i>BACKPROPAGATION</i> .....	14
2.3 - SISTEMAS ESPECIALISTAS HÍBRIDOS .....	17
2.4 - EXTRAÇÃO DE REGRAS DE RNAs .....	22
2.4.1 - ALGORITMO "SUBSET" .....	26
2.4.2 - ALGORITMO "MoFN" .....	28
3 - REVISÃO DAS IMPLEMENTAÇÕES DAS RNAs .....	30
3.1 - REDES NEURAIAS ARTIFICIAIS PARA UM SISTEMA DE ANESTESIOLOGIA ...	30
3.2 - CARACTERÍSTICAS DOS DADOS DE TREINAMENTO .....	33
3.3 - TOPOLOGIAS DAS RNAs .....	38
3.4 - ALGORITMO DE TREINAMENTO <i>BACKPROPAGATION</i> .....	41
4 - IMPLEMENTAÇÕES DE ALGORITMOS DE ANÁLISE DAS RNAs .....	44
4.1 - ALGORITMO LOGIC .....	46
4.1.1 - PLANO DE ATIVAÇÃO .....	50

4.1.2 - ETAPA DE SIMPLIFICAÇÃO DE PORTAS.....	51
4.1.3 - EXTRAÇÃO DE REGRAS .....	52
4.1.4 - COMPARAÇÃO ENTRE O LOGIC E O SUBSET .....	53
4.2 - ALGORITMO PERCEP .....	56
4.2.1 - APLICAÇÃO .....	56
4.2.2 - REFINAMENTO DO TREINAMENTO .....	66
5 - RESULTADOS.....	67
5.1 - COMPARAÇÃO DE EFICIÊNCIAS DAS RNAs .....	68
5.2 - IMPLEMENTAÇÃO DAS RNAs COM <i>COUNTERPROPAGATION</i> .....	77
5.3 - APLICAÇÃO DO ALGORITMO LOGIC.....	81
5.4 - APLICAÇÃO DO ALGORITMO PERCEP.....	90
6 - DISCUSSÕES E CONCLUSÕES .....	104
7 - REFERÊNCIAS BIBLIOGRÁFICAS .....	109
8 - GLOSSÁRIO E LISTA DE ABREVIATURAS .....	121

## ÍNDICE DE FIGURAS

Figura 1 - Diagrama em blocos do PROVANES .....	3
Figura 2 - Neurônio Artificial.....	10
Figura 3 - Topologia de rede <i>feedforward</i> .....	11
Figura 4 - Gráfico e fórmula da função sigmóide.....	12
Figura 5 - Modelos de Neurônios da rede difusa MNC.....	19
Figura 6 - Topologia da RNA baseada em Memórias Associativas .....	20
Figura 7 - Ação dos algoritmos "SUBSET" e "MofN" .....	24
Figura 8 - Criação de uma KBANN a partir de regras .....	25
Figura 9 - Exemplo do algoritmo "SUBSET" .....	27
Figura 10 - Exemplo do algoritmo "MofN" .....	29
Figura 11 - Modelo de portas lógicas para um neurônio artificial.....	46
Figura 12 - Configuração de neurônio artificial após a convergência de treinamento.....	47
Figura 13 - Portas lógicas geradas pelo algoritmo LOGIC .....	49
Figura 14 - Plano de Ativação.....	50
Figura 15 - Plano de Ativação mostrando porta redundante .....	51
Figura 16 - Neurônio artificial para aplicação do algoritmo PERCEP .....	57
Figura 17 - Evolução da treinamento da RNA Classificação do Estado Físico .....	70
Figura 18 - Evolução da treinamento da RNA Medicação Pré-Anestésica .....	70
Figura 19 - Evolução da treinamento da RNA Técnica Anestésica .....	71
Figura 20 - Evolução da treinamento da RNA Nível do Bloqueio Regional .....	71
Figura 21 - Evolução da treinamento da RNA Escolha da Droga de Sedação .....	72
Figura 22 - Evolução da treinamento da RNA Escolha de Procedimentos Adjuvantes .....	72
Figura 23 - Evolução da treinamento da RNA Modalidade de Indução.....	73
Figura 24 - Evolução da treinamento da RNA Drogas de Indução/Manutenção.....	73
Figura 25 - Evolução da treinamento da RNA Bloqueador Neuro-Muscular .....	74
Figura 26 - Evolução da treinamento da RNA Manutenção das Vias Aéreas .....	74
Figura 27 - Evolução do treinamento para o algoritmo <i>Counterpropagation</i> representando a rede Classificação do Estado Físico do Paciente.....	79

## ÍNDICE DE TABELAS

Tabela 1 - Algoritmo "SUBSET" .....	26
Tabela 2 - Algoritmo "MofN" .....	28
Tabela 3 - Redes Neurais do PROVANES .....	31
Tabela 4 - Grupos de Entradas das RNAs .....	34
Tabela 5 - Exemplo de paciente para entrada das Redes .....	36
Tabela 6 - Saídas possíveis das RNAs .....	37
Tabela 7 - Comparação de resultados de eficiência das RNAs .....	75
Tabela 8 - Comparação de eficiências entre os algoritmos <i>Backpropagation</i> e <i>Counterpropagation</i> .....	79
Tabela 9- Regra gerada para o estado físico grau 1.....	84
Tabela 10 - Regra gerada para o estado físico grau 5.....	85
Tabela 11 - Regra gerada para a pré-medicação anestésica Benzodiazepínico .....	86
Tabela 12 - Número de portas lógicas geradas para a rede de Estado Físico .....	87
Tabela 13 - Número de portas lógicas geradas para a rede de Pré-Medicação Anestésica .....	87
Tabela 14 - Regra gerada para o estado físico grau 4.....	92
Tabela 15 - Regra gerada para a Técnica Anestésica Regional Peridural Lombar .....	94
Tabela 16 - Relação entre as entradas da rede de Pré-Medicação e a saída "Não Necessário" ...	98



## RESUMO

As Redes Neurais Artificiais (RNAs) têm sido largamente utilizadas nos últimos anos como ferramenta computacional para representação de conhecimento em diversas áreas. Características como aprendizagem, adaptação, generalização, tolerância à falhas e processamento paralelo tem aumentado o interesse e as pesquisas em RNAs. O trabalho descrito nesta dissertação apresenta uma análise das topologias e algoritmos de treinamento de RNAs para representar conhecimento médico especializado em anestesiologia. Estas RNAs foram previamente implementadas na construção de um sistema especialista híbrido em anestesiologia - PROVANES, com o objetivo de propor e avaliar planos de anestesia. Foram desenvolvidos e implementados algoritmos para análise da sensibilidade das RNAs com objetivo de extração e obtenção de regras de conhecimento armazenadas nos pesos das redes.

**Palavras-Chave :** Redes Neurais Artificiais, Sistemas Especialistas Híbridos, Extração de Regras de Redes Neurais Treinadas.

## ABSTRACT

### ARTIFICIAL NEURAL NETWORKS FOR MEDICAL KNOWLEDGE REPRESENTATION IN ANAESTHESIOLOGY

Artificial Neural Networks (ANNs) can be used as computing architecture for knowledge representation in many areas. Characteristics as learning, adaptation, generalisation, fault tolerance and parallel processing have increased the ANNs researches. This work presents a topologies analysis and training algorithms of the ANNs used for representing specialised medical knowledge in anaesthesiology. These ANNs were previously implemented in the construction of the PROVANES- hybrid expert system in anaesthesiology. Algorithms were developed and implemented to analyse the sensitivity of the ANN with purpose of rule-extraction of the knowledge stored in connection of the ANN.

**Key-Words :** Artificial Neural Networks, Hybrid Expert Systems, Rule-Extraction from Trained Neural Networks.

## 1 - INTRODUÇÃO

Nos últimos anos o número de pesquisas sobre o uso de Sistemas Especialistas (SE) em medicina e, em particular, para diagnóstico médico tem aumentado significativamente. Dos modelos existentes de SE, os sistemas simbolistas baseados na representação do conhecimento por regras de produção, ou seja regras "If..Then" [SHORTLIFFE79], podem ser considerados como os primeiros a terem aplicação. Como nova técnica de representação de conhecimento surgiu a utilização dos sistemas chamados conexionistas, baseados nas Redes Neurais ou Redes Neurais Artificiais (RNAs) [LIPMANN87], [DAYHOFF90], [HINTON87]. Como conseqüência das características das RNAs, entre elas o processamento paralelo, tolerância à falhas, auto-organização e habilidade para aprendizagem e adaptação, elas apresentam um melhor desempenho em situações onde são necessárias generalizações e, também, onde exista incerteza e ruído [LIPMANN87]. Portanto, as RNAs são mais indicadas na classificação e reconhecimento de padrões complexos.

As RNAs têm sua fonte de inspiração nas qualidades intrínsecas do ser-humano como a habilidade para interpretações por percepção, memória endereçada por conteúdo e raciocínio de senso comum. Estas características, em geral, existem no ser-humano devido ao tipo de processamento efetuado pelo cérebro e o sistema nervoso com uma rede de expressiva quantidade de neurônios. Outro fator que impulsiona o uso das RNAs são os avanços tecnológicos em máquinas VLSI, que permitem a construção de máquinas com alto grau de paralelismo [SOUCEK88],

concebidas especialmente para a implementação de estruturas de Redes Neurais.

Também em trabalhos de pesquisa na área de informática médica surge a tendência de utilização das RNAs em diagnósticos e representação de conhecimentos médicos especializados [AZEVEDO94b], [AZEVEDO91a], [AZEVEDO91b], [BARRETO93a], [BARRETO92], [GARCIA92], [GARCIA93], [LIMA91a], [LIMA91b], [SABBATINI92], [WISBECK96], [BRASIL96b], [XUE92], [OLIVEIRA93], [PAPADOURAKIS92]. O trabalho apresentado nesta dissertação é baseado na realização de estudos, treinamentos e análise de paradigmas de RNAs para a realização de tarefas classificatórias que um profissional anestesiológico necessita para a determinação de um plano de anestesia. As definições das topologias e implementações originais destas RNAs, bem como a construção da base de dados para a formação dos conjuntos de treinamento foram realizadas em trabalhos prévios desenvolvidos no Grupo de Pesquisas em Engenharia Biomédica (GPEB) [GARCIA92], [PASSOLD95].

No trabalho de [GARCIA92] é proposto um sistema especialista denominado "PROVANES - Técnicas de Inteligência Artificial Aplicadas ao Apoio à Decisão Médica na Especialidade de Anestesiologia", que representa uma aplicação no uso de técnicas de Inteligência Artificial para o modelamento dos conhecimentos de um especialista da área médica, no caso em anestesiologia. O trabalho de [PASSOLD95] representa um módulo de expansão do PROVANES considerando pacientes críticos/problemáticos. O PROVANES apresenta uma estrutura integrada com Redes Neurais, regras de produção, modelos clínicos e bases de dados que visam criar um ambiente híbrido onde as diferentes tarefas,

procedimentos e conhecimentos a serem utilizados por um profissional anestesiológico, durante o ato cirúrgico, possam ser representados pelas técnicas de IA mais apropriadas (Figura 1). Dentre estes conhecimentos estão os denominados Dinâmico Causal [GARCIA92], onde o efeito é conhecido mas relacionado a um número indefinido de causas. Esses conhecimentos podem ser explicitados através de casos exemplares, sendo necessário, em determinadas situações, generalizar o conhecimento a partir dos dados conhecidos. Para representar este tipo de conhecimento no PROVANES foram, dessa forma, definidas e implementadas um conjunto de topologias de Redes Neurais Artificiais (RNAs), revistas e detalhadas nos próximos capítulos.

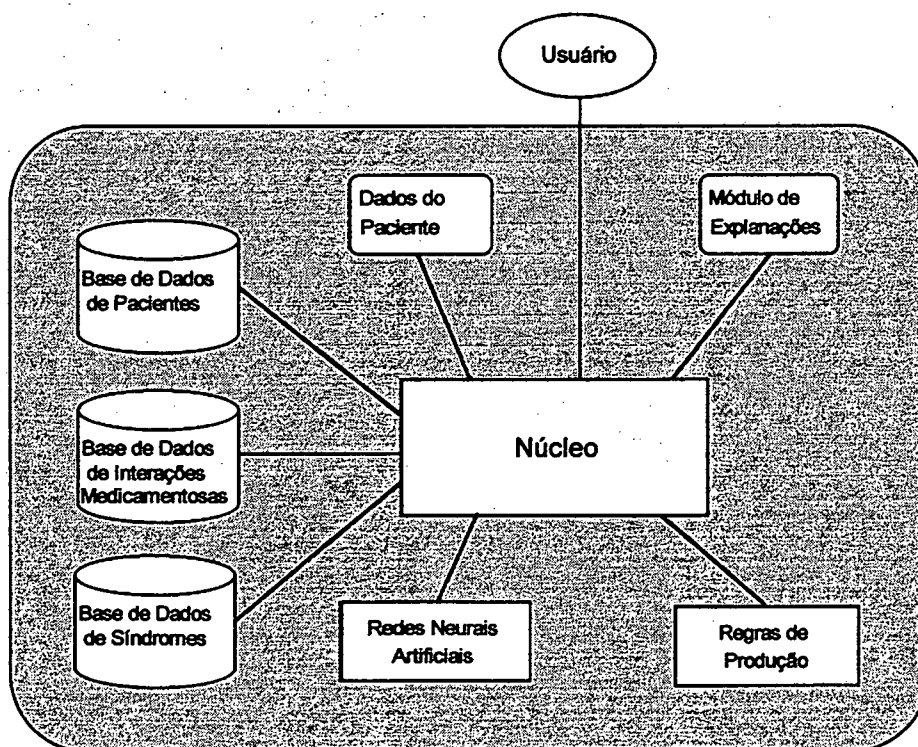


Figura 1 - Diagrama em blocos do PROVANES

## 1.1 - OBJETIVOS

Os dados processados pelas RNAs do PROVANES são relacionados a uma série de informações sobre o paciente como, p. ex., condições fisiopatológicas, exames clínicos e laboratoriais, tipo de cirurgia e outros. Para a construção do módulo de Redes Neurais do PROVANES, em [GARCIA92] foram definidas e implementadas RNAs com topologia tipo *Perceptron* Multicamada, com treinamento através do algoritmo de retropropagação (*Backpropagation*) [RUMELHART86]. Estas RNAs realizam as principais tarefas classificatórias desempenhadas pelo profissional anestesiológico como a classificação do estado físico de um paciente, escolha das drogas para a medicação pré-anestésica e escolha da técnica anestésica mais apropriada ao ato cirúrgico (além de outras sub-redes de complementação da técnica anestésica). Os detalhes médicos sobre os procedimentos a serem representados pelas redes podem ser encontrados em [DUARTE87], [DUARTE88].

A representação do conhecimento em uma RNA, ou seja, nos valores dos pesos e não de forma simbólica, apresenta um grande potencial para mapear funções complexas, porém não oferece informações claras e precisas para explicar seu raciocínio, sendo, então, chamados de sistemas “caixa-preta” [GALLANT88], [HART90]. Esta característica tem consequência direta sobre dois aspectos a respeito do processo de representação de conhecimento por RNA :

a) A demasiada dificuldade de obtenção de um processo de explanação, principalmente quando uma RNA é utilizada como base de conhecimento (ou parte dessa base) em um sistema especialista. Também na

implementação do PROVANES esta foi umas das dificuldades encontradas, limitando a utilização do seu módulo de explanação [GARCIA92].

b) A inexistência de um formalismo ou metodologia capaz de estabelecer critérios genéricos a serem utilizados para a definição de parâmetros das redes de forma a se obter a melhor estrutura de representação do conhecimento. Este aspecto será detalhado no capítulo 2 (fundamentação teórica). Em relação às redes implementadas no PROVANES, esta dificuldade está realçada na estratégia de treinamento adotada, através de um processo iterativo de testes de eficiência em diferentes topologias (elementos na camada intermediária) e com diferentes parâmetros de treinamento.

Este trabalho tem por objetivos, portanto, estudar e analisar as topologias e algoritmos de treinamento implementadas para as RNAs do PROVANES, visando, a verificação e comparação de resultados de treinamentos obtidos nos trabalhos originais de implementação e neste trabalho e, também, obter uma ferramenta que possibilite a análise dos pesos das redes treinadas.

## 1.2 - JUSTIFICATIVA

Sistemas Especialistas tradicionais possuem raciocínio baseado em regras bem definidas, que os tornam predizíveis e explicáveis. As maioria das RNAs, no entanto, representam o conhecimento através de um processamento numérico dos pesos e neurônios, de uma forma distribuída e não nítida. Dessa forma, torna-se difícil a extração de conhecimentos e explicações [LOPES93]. Como resultado das pesquisas nesta área, muitas publicações têm apresentado tentativas de formalizar procedimentos de avaliação de sistemas especialistas que utilizam RNAs [HART90], [KRUSCHKE93], [CRAVEN96], [TOWELL93]. Deve-se, também, os modelos de RNAs que utilizam o conceito de conhecimento localizado, onde o aspecto da explicação torna-se menos crítico [AZEVEDO94], [AZEVEDO93], [AZEVEDO91a], [BARRETO93a], [BARRETO92]. Alguns pesquisadores na área de IA [ANDREWS95], [TOWELL93] sugerem que, sem alguma forma de explicação, não podem ser explorados todos os recursos de representação das RNAs, já que um dos principais requisitos de validação de um SE reside justamente na sua capacidade explanatória [DUCHESSI92]. Na área médica [LUNDSGAARDE87], [NYKÄNEN91], [PELLEGRINI95] a característica da explicação torna-se ainda mais importante, pois as decisões dos especialistas médicos são baseados, na maioria dos casos, em informações incompletas ou difusas [HART90].

Portanto, trabalhos de implementação de métodos e algoritmos de análise e extração de conhecimento de RNAs são importantes contribuições no processo de validação e expansão do uso de sistemas conexionistas para a representação do conhecimento humano.



### 1.3 - PROPOSIÇÕES

Este trabalho de dissertação se propõe :

- Analisar as implementações de RNAs realizadas na construção do módulo de Redes Neurais do PROVANES para representar o conhecimento médico especializado em anestesiologia.

- Verificar os resultados e critérios adotados para a escolha do algoritmo de treinamento *Backpropagation* [GARCIA92]. Esta verificação será realizada de duas formas distintas : a) Comparando as eficiências das RNAs já obtidas com novas baterias de ensaios com *Backpropagation* a serem realizadas neste trabalho e b) Treinando as mesmas topologias com um algoritmo de treinamento distinto (*Counterpropagation*), sendo os resultados confrontados com os obtidos anteriormente

- Estudar e implementar uma metodologia de análise dos resultados de treinamento das RNAs implementadas para representar o conhecimento médico especialista em anestesiologia.

- Analisar a sensibilidade das estruturas das RNAs para realizar a extração dos conhecimentos embutidos nos valores dos pesos, buscando estabelecer um relacionamento com as informações existentes na base de dados em anestesiologia.

## 1.4 - ORGANIZAÇÃO DO TRABALHO

No capítulo 2 é apresentado uma revisão bibliográfica sobre aspectos relacionados ao processo de representação de conhecimento por uma RNA e sua aplicação como base de conhecimento em sistemas especialistas híbridos. Também são revistos algoritmos, já apresentados na literatura, de extração de regras de Redes Neurais Artificiais.

No capítulo 3 é apresentado uma revisão do trabalho de implementação de todas as RNAs do sistema PROVANES [GARCIA92], com as características dos dados de treinamento, definição das topologias e detalhamento da aplicação do algoritmo *Backpropagation*.

No capítulo 4 são apresentados duas propostas de algoritmos de análise de pesos de RNAs, desenvolvidas durante este trabalho.

No capítulo 5 são apresentados os resultados de simulação desenvolvidos durante este trabalho. Estes resultados são relativos às eficiências obtidas nos treinamentos das topologias de RNAs implementadas no PROVANES, com os algoritmos *Backpropagation* e *Counterpropagation* e também resultados de aplicação dos algoritmos de análise sobre estas mesmas RNAs.

No capítulo 6 são apresentadas conclusões, discussões e propostas de trabalhos futuros relacionados com o tema desenvolvido neste trabalho

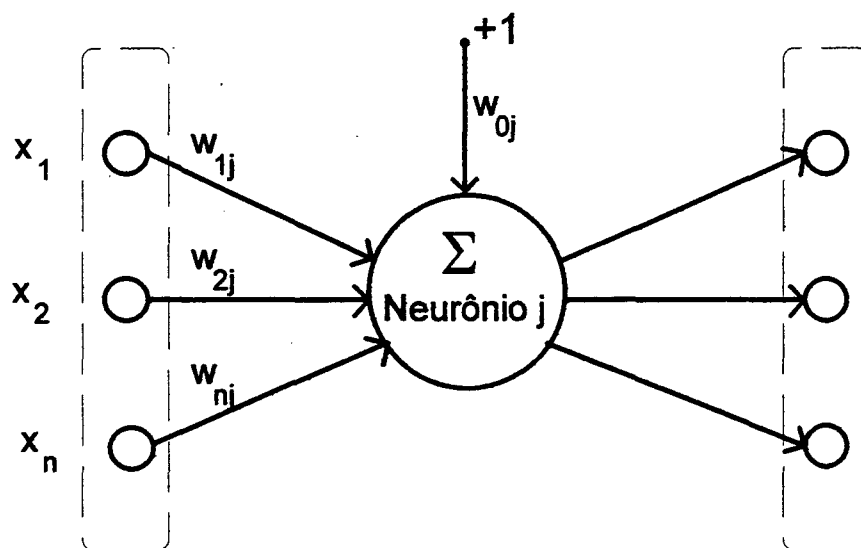
## 2 - FUNDAMENTAÇÃO TEÓRICA

### 2.1 - REPRESENTAÇÃO DE CONHECIMENTOS ATRAVÉS DE RNAs

Redes Neurais Artificiais são estruturas de processamento cujas principais características são a distribuição e o paralelismo da informação entre diversos elementos processadores de estruturas relativamente simples. Estes elementos são maciçamente interconectados (assim como as células do sistema nervoso do ser humano - os neurônios). Os modelos neurais artificiais têm grande aplicação em áreas onde muitas hipóteses são propostas para representar um determinado conhecimento como, por exemplo, em tarefas classificatórias [LIPPMANN87], [LO92]. Ao invés de efetuar um processamento como nas máquinas IBC (computadores baseados em instrução) [BARRETO90], nos quais, para a execução de uma função, deve haver uma carga de programas (instruções), as Redes Neurais exploram as hipóteses de forma paralela e simultânea através dos elementos processadores interligados através de um conjunto de pesos.

Apesar das RNAs terem como princípio básico o processamento paralelo, normalmente as implementações de topologias para simulação são realizadas em computadores que efetuam processamentos seqüenciais. Somente os sistemas computacionais de última geração, ainda não disponíveis em larga escala, buscam a inspiração nas estruturas e atividades cerebrais do ser-humano e, utilizando tecnologias emergentes, conseguem realizar um processamento paralelo das informações e dados [SOUCEK88], [SCHWARTZ90], [GARCIA95].

Os modelos conexionistas de representação do conhecimento consistem de um número elevado de elementos matemáticos de processamento chamados neurônios artificiais (ou também células ou unidades). Estes elementos interagem entre si através de ligações chamadas de pesos (ou também de sinapses ou conexões ou, ainda, ponderações). Cada neurônio tem um estado ou nível de ativação que é determinado por sua entrada, que por sua vez é função da saída de outros neurônios da rede (Figura 2).



- $w_{ji}$  - valor dos "pesos" entre os "n Neurônios" ligados ao "Neurônio j"

Figura 2 - Neurônio Artificial

Em uma topologia de RNA denominada *feedforward*, os neurônios estão dispostos em camadas, sendo que qualquer neurônio de uma camada pode se comunicar com qualquer neurônio da camada seguinte (Figura 3). Os padrões de entrada são apresentados à primeira camada e a resposta da

rede, a um determinado padrão de entrada, são os estados de ativação dos neurônios da camada de saída.

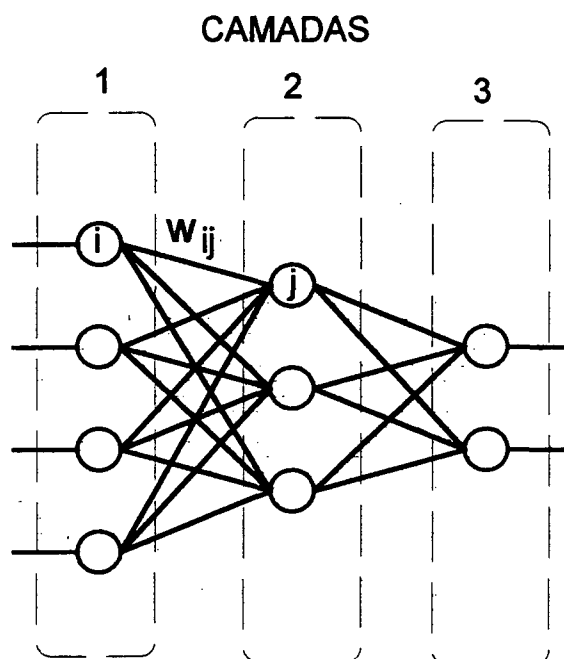



Figura 3 - Topologia de rede *feedforward*

O estado de ativação (saída) de um determinado neurônio é obtido ao aplicar uma função de ativação (ou função de transferência) ao resultado do somatório ponderado de suas entradas (Figura 2). Uma das funções de ativação mais usadas, inclusive para o algoritmo *Backpropagation*, é a função sigmoide, cuja equação e gráfico são mostrados na Figura 4.



$$f(x) = \frac{1}{1 + e^{-\alpha x}}$$

Figura 4 - Gráfico e fórmula da função sigmóide

Os diferentes paradigmas de Redes Neurais são especificados, principalmente, por três elementos : topologia da rede, características dos elementos processadores e algoritmos de treinamento. Esses algoritmos especificam um conjunto inicial de pesos e indicam como devem ser atualizados durante o treinamento de forma a realizar uma representação eficiente [LIPPMANN87].

Nos algoritmos de treinamento supervisionados são apresentados pares de entrada e saída de padrões, para que, dessa forma, o algoritmo possa adaptar os pesos, realizando, assim, o processo de aprendizado da estrutura da rede [ALLRED90]. Isto ocorre pois, neste tipo de treinamento, é necessário informar à rede qual a saída correta para cada entrada específica. A informação que os elementos processadores irão possuir será a aproximação de uma função de mapeamento de um sub-espço de dimensão "X" dentro de um espaço multidimensional "Y". Os exemplos para o treinamento de uma rede devem ser obtidos pela seleção aleatória de pares de vetores exemplares " $x_k$ " de um sub-espço que se deseja representar [HECHT-NIELSEN89].

As aproximações realizadas pelas RNAs podem ser aplicadas em diversas áreas. Entre elas estão os problemas relacionados com o tratamento de padrões - mapeamento, recuperação, filtragem e classificação e o controle de uma planta ou sistema [AZEVEDO94a], [AZEVEDO93] [BARRETO93b], [BARRETO93b].

## 2.2 - DISCUSSÃO SOBRE O ALGORITMO DE TREINAMENTO *BACKPROPAGATION*

Dos algoritmos que utilizam treinamento supervisionado, o mais difundido é o algoritmo *Backpropagation* [RUMELHART86]. A eficiência da aproximação de um sub-espço realizada pelo algoritmo *Backpropagation* pode ser medida pelo erro médio quadrático da saída. Sendo o objetivo da rede *feedforward*, com algoritmo de treinamento *Backpropagation*, minimizar este erro para todos os pares de entrada/saída, é possível se estabelecer uma função erro  $E_o(W)$  a ser minimizada para otimizar a aproximação da rede com o sub-espço desejado [CALOBA92]. Esta função será o valor esperado do erro quadrático medido entre a saída ideal "y" e a saída real "d" para todos os pares de saída [RUMELHART86]. O problema de síntese do algoritmo *Backpropagation* é encontrar o conjunto de pesos que minimizam  $E_o(W)$ . Esta síntese é feita através do treinamento da rede, ou seja, modificando os valores dos pesos por passos de modo a reduzir  $E_o(W)$ .

O algoritmo *Backpropagation*, aplicado à topologia *Perceptrons* Multicamada, teve o mérito de solucionar o problema da limitação apresentada pelos algoritmos anteriores (*Perceptron* e *Adaline/Madaline*) de somente realizar a adaptação de pesos em uma topologia de rede com duas camadas de neurônios [WIDROW90].

Nos trabalhos de análise do algoritmo *Backpropagation* de diversos grupos de pesquisa [AZEVEDO92], [HAGIWARA90], [HISUNG91] são apresentados alguns problemas intrínsecos ao processo de treinamento realizado pelo algoritmo [GORI92], [WANG89], [CARPENTER92]. Entre



os problemas conhecidos no treinamento *Backpropagation*, pode-se destacar :

- Mínimos Locais : O treinamento do algoritmo *Backpropagation* é um processo de tentativa de otimização por gradiente descendente e, portanto, sofre das conseqüências inerentes a este processo matemático. Ou seja, o espaço representado pelos pesos possui vários mínimos diferentes do mínimo global, onde o erro de representação é menor. O processo de treinamento supervisionado (gradiente descendente no caso *Backpropagation*) é uma forma de programação não linear, cuja característica de evolução não consegue "passar" por um mínimo local, não encontrando, portanto, o ponto ótimo de treinamento [HECHT-NIELSEN89].

- Coeficientes de Treinamento : Várias tentativas de grupos de pesquisas em RNAs já foram feitas para determinar quais os melhores coeficientes para a taxa de aprendizado ( $\alpha$ ) e para o momentum ( $\mu$ ) [CATER87], [EATON92], coeficientes estes utilizados no treinamento da *Backpropagation*. Porém, até o momento, poucos avanços foram obtidos de forma ser estabelecido uma regra padrão para a determinação dos coeficientes, sendo, na maioria das vezes, um processo iterativo para a melhor escolha, de forma a propiciar o menor erro de representação.

- Número de elementos na camada intermediária: Conforme demonstrou [HECHT-NIELSEN89] as topologias de redes com duas camadas de neurônios, podem realizar qualquer aplicação prática de representação. Porém, o problema do dimensionamento da rede, ou seja, número de neurônios na camada intermediária, tem sido tema freqüente nos trabalhos

de pesquisa [MIRCHANDANI89], [GUTIERREZ89], [MURATA92]. Se a rede for subdimensionada (poucos elementos na camada intermediária), ela apresentará pouca capacidade de generalização, devido à sua incapacidade de produzir sub-planos suficientes que gerem as regiões complexas de decisão para representação do espaço na entrada da rede. Para o caso de superdimensionamento (muitos elementos na camada intermediária), poderá haver o problema da "especialização" da rede, no qual os resultados de eficiência para o conjunto de treinamento são elevados, porém para o conjunto de testes são baixos.

- Treinamento pela minimização do erro : A minimização do erro médio quadrático da saída para otimizar o processo de representação da rede, usada pelo algoritmo *Backpropagation*, pode não ser realizável para grandes topologias de RNAs, com elevados graus de liberdade [HOLDAWAY89], [WILENSKY90]. A minimização do erro, nestes casos, não seria suficiente para estabelecer uma cooperação entre os diversos neurônios da rede, de forma a criar as regiões complexas de representação. Também deve ser considerado que se um determinado padrão é pouco representativo quantitativamente em uma base de dados de treinamento, a eficiência de representação do algoritmo *Backpropagation* para este padrão também será baixo.

## 2.3 - SISTEMAS ESPECIALISTAS HÍBRIDOS

Sistemas Especialistas, um dos ramos da Inteligência Artificial, simulam e manipulam capacidades de especialistas humanos para a resolução de problemas, em áreas restritas de um determinado domínio. Os SEs armazenam estes conhecimentos em uma base de conhecimento. Os SEs tradicionais são implementados a partir da aquisição direta do conhecimento de especialistas e padronizam procedimentos na forma de regras de produção. Estas regras relacionam fatos entre si, permitindo que o sistema, através de métodos de busca, encontre uma solução para um problema estabelecido (inferência). Portanto, a extração dos conhecimentos de um especialista é uma etapa de grande importância e interesse na construção de SEs, que apresenta, porém, extremas dificuldades de realização. Dessa forma, extrair o conhecimento de especialistas passou a ser um dos principais objetos de pesquisa em IA. Esta tarefa, em um SE simbolista, é desempenhada pelo engenheiro de conhecimento.

A alternativa de se automatizar o processo de aquisição do conhecimento de um domínio especialista [DENIS91] é uma característica muito importante para facilitar esta etapa. Nesta perspectiva é natural se esperar que ocorra, cada vez mais, uma integração de várias técnicas de aquisição de conhecimento [LOPES93]. Desta forma surge o conceito de Sistemas Especialistas Híbridos que combinam diferentes processos de aquisição e representação de conhecimento [CRAVEN93].

SEs simbolistas, geralmente, são desenvolvidos usando, como fase inicial, um processo de eliciação de conhecimento realizado por um profissional

conhecido como engenheiro de conhecimento. Este profissional procura exprimir o que obteve do especialista sob formas de regras que vão constituir o núcleo do SE. Ao contrário disto, os Ses conexionistas se aproveitam da grande capacidade das RNAs como ferramenta de aproximação universal de funções e da existência de bons algoritmos de aprendizado supervisionado (ex: *Backpropagation*) para utilizar uma base de exemplos como ponto de partida para a construção de sua base de conhecimento. Convém, no entanto, notar que existem excessões, pois há SEs simbolistas com aprendizado por máquina em que são capazes de criar regras a partir de uma base de exemplos. Existem, ainda, casos de SE implementadas com redes *feedforward* e cujos pesos são obtidos diretamente de um conjunto de regras extraídas de um especialista por um engenheiro de conhecimento [BRASIL96a]

Uma importante característica de sistemas híbridos é a transferência de conhecimento entre os modelos de representação utilizados. Neste aspecto as RNAs apresentam uma séria restrição devido à dificuldade encontrada quanto à explanação de um resultado processado pela rede. Buscando haver uma maior integração entre os modelos simbolistas e conexionistas [AZEVEDO91c], pesquisadores como [MACHADO92], [FU92b], [SUN91], [GALLANT88], propuseram, em seus trabalhos, sistemas especialistas híbridos, cuja estruturas combinam redes semânticas e redes neurais difusas para a representação de conhecimento. As redes semânticas permitem uma representação gráfica de conhecimento armazenado no sistema, através de grafos de conhecimentos[ROCHA90].

A Figura 5 mostra os modelos de neurônios utilizados na topologia de uma rede denominada "Modelo Neural Combinatório" [MACHADO91], em que

os elementos processadores são formados por portas lógicas difusas (“fuzzy-AND” e “fuzzy-OR”). Cada neurônio representa um conceito simbólico no domínio do problema (evidências, hipóteses, etc.). A primeira camada (camada de entrada) recebem dados simbólicos. A segunda (camada intermediária) são formadas por porta “fuzzy-AND” e associam diferentes combinações ou padrões dos dados de entrada. A camada de saída é formada por “fuzzy-OR” e representam as diferentes hipóteses (classes) existentes no domínio do problema.

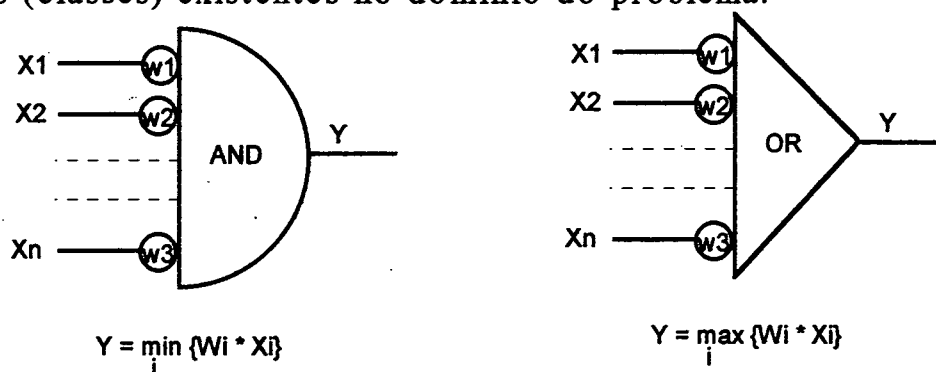


Figura 5 - Modelos de Neurônios da rede difusa MNC

Outro modelo de Rede Neural Difusa foi apresentado em [AZEVEDO91b], cujo paradigma de RNA utilizado é a do tipo Memória Associativa [KOSKO88]. Neste modelo (Figura 6) casos prévios conhecidos (com características de doenças, sintomas e testes laboratoriais) são expressos diretamente nos pesos da rede. Estes pesos, cujo intervalo de representação é de  $[-1,1]$  representam o valor difuso de excitação ou inibição entre os neurônios. As entradas dos neurônios são valores no intervalo  $[0,1]$  que representam o valor difuso de importância do sintoma ou grau de doença.




Figura 6 - Topologia da RNA baseada em Memórias Associativas

Estas RNAs (Figuras 5 e 6), cujas topologias e inicialização de pesos são definidos em função de conhecimentos prévios de casos, podem ser denominadas “Redes Neurais baseadas em conhecimento”. Uma das grandes vantagens das implementações deste tipo de RNA é a relativa facilidade de extração de explicações sobre o processo de decisão ou resultados que a rede realiza.

Atualmente no GPEB está se desenvolvendo um trabalho de doutorado nesta área [BRASIL91a], no qual é proposto uma arquitetura de sistema especialista híbrido, combinando características favoráveis dos paradigmas neural e simbólico, visando facilitar a tarefa de aquisição de conhecimento.

SEs híbridos que combinam regras de produção e RNAs (SE conexionistas) são, portanto, uma poderosa ferramenta de solução de representação de conhecimentos especializados. As opções de relação entre as duas formas de representação podem ser cooperativas em dois

sentidos, ou seja, tanto para que uma RNA possa servir como geração ou “inicialização” de regras para um SE simbólico, como um SE simbólico possa servir para o refinamento do treinamento de uma RNA [TOWELL93].

## 2.4 - EXTRAÇÃO DE REGRAS DE RNAs

As RNAs têm demonstrado ser uma importante ferramenta para a realização de tarefas como mapeamento de funções complexas e representação de conhecimento especializado na área de IA. A sua característica de habilidade de aprendizado sobre uma base de exemplo abriu novas perspectivas nas tentativas realizadas por pesquisadores para a automatização da aquisição de conhecimento especializado. Contudo, o seu comportamento como sistemas denominados “caixa-preta”, em que o processamento interno e a representação do conhecimento não podem ser inspecionados, acompanhados ou mesmo compreendidos pelo usuário [HART90], tem dificultado significativamente o seu uso para a representação de bases de conhecimento em SEs. Isto ocorre porque um processo de explanação torna-se muito difícil quando o processamento de informações para a tomada de uma decisão é realizada por uma RNA. Não existem critérios ou meios claramente definidos, nos quais um usuário possa se utilizar para obter uma clara explanação sobre as respostas de um SE baseado em modelos conexionistas.

As Redes Neurais baseadas em conhecimento apresentadas no capítulo 2.3 apresentam uma condição favorável para serem implementadas em um SEH devido a sua capacidade de explanação. Porém elas apresentam uma limitação quanto à dimensão da estrutura da RNA. Redes que envolvam elevadas dimensões (número de neurônios) apresentam dificuldades de implementação, podendo ocorrer um explosão combinatória na geração dos neurônios da rede [DENIS91]. Neste sentido, como forma de aumentar a potencialidade da integração de sistemas simbolista e conexionistas, linhas de pesquisas consideram a possibilidade de se realizar, formalmente, um



processo de extração de regras a partir dos pesos de uma rede treinada [FU91], [FU92a], [FU93], [CRAVEN96], [CRAVEN94], [TOWELL93], [ANDREWS95], [THRUN94]. Neste caso a rede pode ter sido treinada a partir de qualquer algoritmo de treinamento, incluindo a *Backpropagation*.

A aprendizagem e representação de relações e funções não lineares de uma RNA estão codificadas, de uma forma a princípio não compreensível, nos vetores de pesos. Estes algoritmos de extração de regras buscam explorar a forma de representação destes pesos, estabelecendo critérios de validação do treinamento de uma RNA.

Esta análise considera três características aonde uma RNA treinada “codifica” um conhecimento específico [ANDREWS95]:

- (a) Na própria topologia da RNA;
- (b) Na função de ativação associada aos neurônios da camada intermediária e de saída;
- (c) No conjunto de pesos que interligam os neurônios;

A tarefa de extração de conhecimento de uma RNA consiste na interpretação da forma de cooperação existente nas características (a), (b) e (c) de um treinamento.

Entre os algoritmos já propostos para extração de conhecimento de RNAs estão os denominados “SUBSET” [TOWELL93], “MofN” [TOWELL93], “RULEX” [ANDREWS95] e “VIA” [THRUN94]. Outros trabalhos associados podem ser encontrados em [ANDREWS95], [CRAVEN94], [CRAVEN96], [FU91], [TOWELL93], [TOWELL94], [THRUN94].

O algoritmo VIA[THRUN94] faz a extração de regras baseado em uma busca na estrutura de uma rede treinada para detectar inconsistências entre pesos, “bias” e as ativações de neurônios. O algoritmo RULEX [ANDREWS95] foi projetado para explorar o comportamento de um algoritmo particular de treinamento de RNA - a CEBP(“Constrained Error *Backpropagation*”), que é um tipo de algoritmo que executa as tarefas de classificação e aproximação de maneira similar às redes RBF (Radial Basis Function) [HAYKIN94].

Os algoritmos “SUBSET” e “MofN”, originariamente, foram desenvolvidos para extrair conhecimento de uma estrutura particular de RNA, definida a partir de uma base de dados geradas por um conjunto de regras de produção sobre um determinado conhecimento especializado (Figura. 7), ou seja, de uma rede baseada em conhecimento chamada KBANN (Knowledge Based Artificial Neural Network) [TOWELL94].

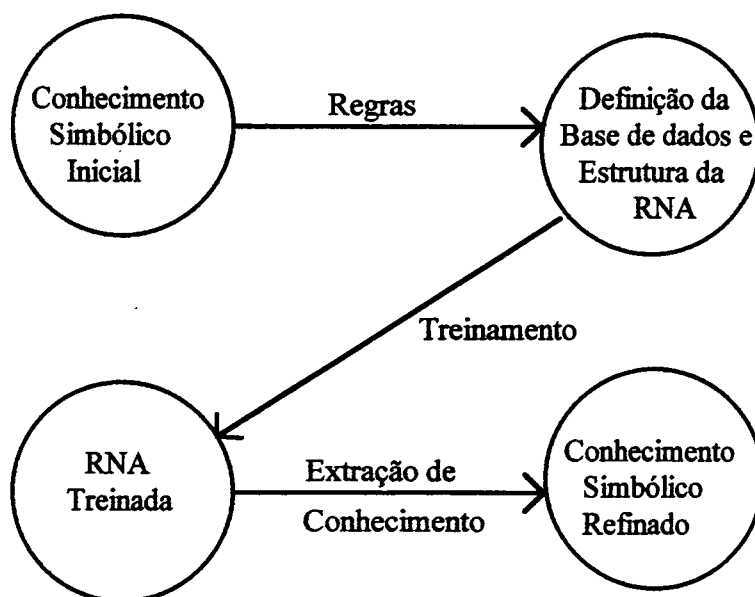


Figura 7 - Ação dos algoritmos "SUBSET" e "MofN"

Esta abordagem de RNA se aproxima bastante da rede difusa proposta por [FU89] e [BRASIL96a]. Alguns trabalhos [ANDREWS95] mostram a aplicação dos algoritmos “SUBSET” e “MofN” a uma rede genérica, treinada com *Backpropagation*, não se restringindo, no caso, à aplicação sobre uma KBANN.

Um exemplo de criação de estrutura KBANN é mostrada na Figura 8

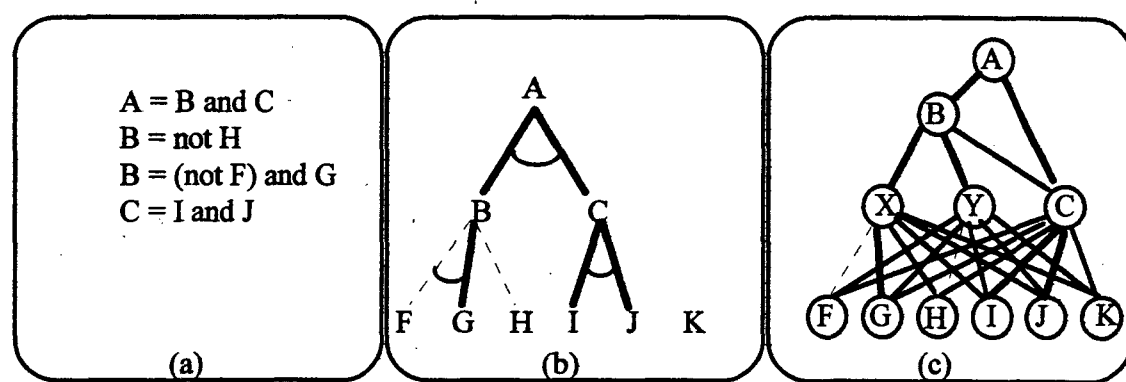


Figura 8 - Criação de uma KBANN a partir de regras

Em (8a) é mostrado um exemplo de um conjunto de regras que formam uma hipotética base de conhecimento. A Figura (8b) mostra a estrutura hierárquica (grafos AND/OR) das regras, sendo que as linhas sólidas representam ligações excitatórias e as linhas pontilhadas ligações inibitórias entre as mesmas. A Figura (8c) mostra a KBANN resultante da transformação das regras. As unidades X e Y surgem na estrutura final para respeitar a condição das cláusulas de Horn [BRASIL96a]. As linhas grossas representam ligações fortes e as finas ligações fracas na KBANN. Após esta inicialização a rede é treinada com o algoritmo *Backpropagation* e aplicado os algoritmos “SUBSET” e “MofN”.

### 2.4.1 - Algoritmo "SUBSET"

No algoritmo "SUBSET", que é inspirado no algoritmo "KT" apresentado por [FU91], o foco é a extração de regras a partir de cada neurônio das camadas intermediária e de saída. O algoritmo recebe este nome pois a idéia básica é a procura de subconjuntos de pesos de cada neurônio cuja soma supera o valor do "bias" do mesmo. Considera-se que os pesos podem assumir valores positivos e negativos e, também, que os neurônios estejam na máxima ativação (próximos de um) ou, então, inativos (próximos de zero). Este algoritmo pode ser descrito da seguinte forma (Tabela 1) :

- Para cada neurônio das camadas intermediárias e de saída fazer :
  - Formar  $S_p$  subconjuntos, combinando somente pesos positivos do neurônio cuja somatório supera o valor do "bias";
  - Para cada elemento  $P$  dos subconjuntos  $S_p$  fazer :
    - Formar  $S_n$  subconjuntos, de  $N$  elementos, considerando as combinações mínimas de pesos negativos, de forma que a soma absoluta destes pesos seja maior do que a soma de  $P$  menos o "bias" do neurônio;
    - Formar a regra : IF  $P$  AND NOT  $N$  THEN <nome do neurônio>

Tabela 1 - Algoritmo "SUBSET"

Um exemplo de aplicação deste algoritmo, que pode ser comprovado intuitivamente, é mostrado na Figura 9.

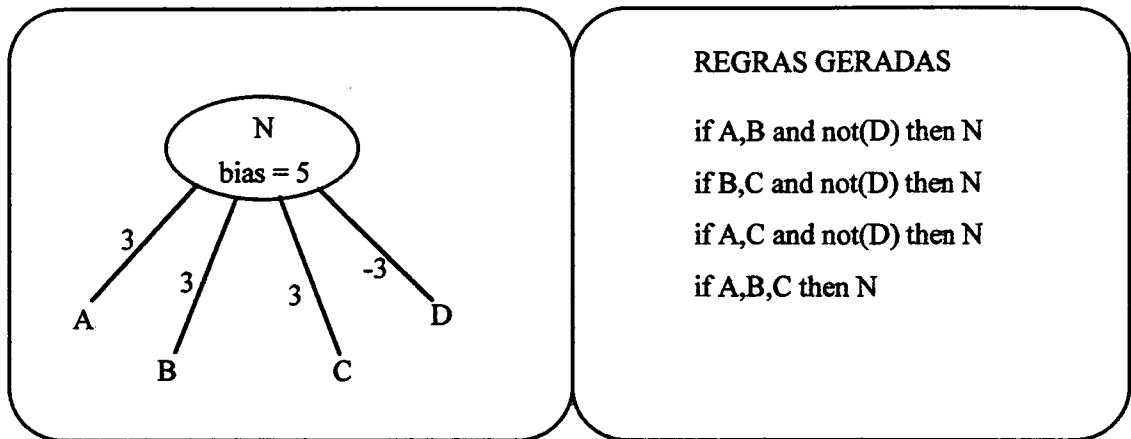


Figura 9 - Exemplo do algoritmo "SUBSET"

A maior limitação deste algoritmo está na excessivo processamento necessário para alcançar as soluções possíveis, principalmente em RNAs com elevado número de neurônios. Outro problema que surge é que algumas regras geradas podem ter um elevado número de antecedentes tornando, algumas vezes, proibitivo o seu uso prático.

### 2.4.2 - Algoritmo "MofN"

Este algoritmo foi proposto [TOWELL93] como forma de reduzir as limitações do algoritmo "SUBSET", diferindo deste basicamente na maneira como apresenta as regras geradas. O formato geral das regras são:

IF ( $M$  dos seguintes  $N$  antecedentes são verdadeiros) THEN....

A idéia básica do algoritmo é que antecedentes individuais não possuem todos o mesmo grau de importância. Deve-se supor que grupos de antecedentes formam classes equivalentes, nas quais cada antecedente tem a mesma importância e podem ser trocados entre si (membros de uma mesma classe). A descrição básica do algoritmo "MofN" é a mostrado na Tabela 2 :

<p>Passo 1 : Para cada neurônio das camadas intermediárias e de saída, formar grupos de pesos similares numericamente.</p> <p>Passo 2 : Atribuir aos pesos de cada grupo o valor médio calculado para o grupo.</p> <p>Passo 3 : Eliminar qualquer grupo que não tenha efeito significativo para a ativação do neurônio (valor médio pequeno).</p> <p>Passo 4 : Mantendo os pesos constantes, otimizar os valores dos "bias" de todos os neurônios através do algoritmo <i>Backpropagation</i>.</p> <p>Passo 5 : Extrair uma única regra a partir dos grupos, considerando a soma dos pesos dos grupos e o valor do "bias" otimizado.</p> <p>Passo 6 : A partir da regra geral, simplificar pesos e combinações possíveis.</p>
---

Tabela 2 - Algoritmo "MofN"

Um exemplo de aplicação do algoritmo é mostrado na Figura 10

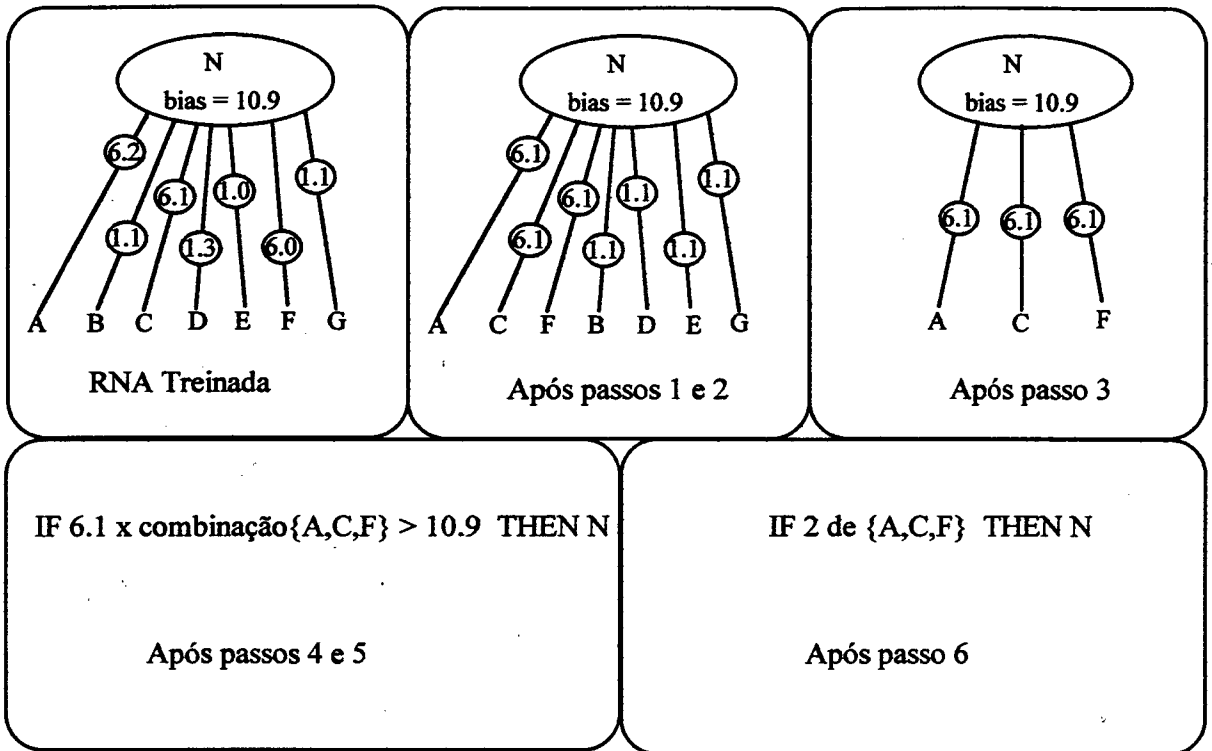


Figura 10 - Exemplo do algoritmo "MofN"

### **3 - REVISÃO DAS IMPLEMENTAÇÕES DAS RNAs**

Neste capítulo é apresentado uma revisão do trabalho, realizado em [GARCIA92], de implementação das RNAs para a construção do PROVANES. São apresentados detalhes das características da base de dados e informações processadas pelas redes.

#### **3.1 - REDES NEURAIS ARTIFICIAIS PARA UM SISTEMA DE ANESTESIOLOGIA**

Os objetivos de um especialista médico na área de anestesiologia é realizar um plano de anestesia mais indicado a um paciente a ser submetido a uma cirurgia. O especialista deve considerar um número elevado de parâmetros, preponderantes para a escolha das técnicas, medicações e procedimentos anestésicos mais apropriados. Para isso são considerados dados como estado físico do paciente, exames laboratoriais e complementares e outras informações. As RNAs propostas e implementadas no PROVANES para representação e processamento destes dados podem ser esquematizado na Tabela 3.

Estas RNAs estão relacionadas com as seguintes tarefas classificatórias :

##### **a) Rede de Classificação do Estado Físico :**

A rede faz uma classificação do estado físico do paciente que reflete as condições clínicas orgânicas segundo a proposta de classificação utilizada pela ASA (American Society of Anesthesiologists).



	<b>Tipo</b>	<b>Saída da RNA</b>
RNA 01	Classificação do estado físico do paciente	Grau 1 a Grau 5
RNA 02	Pré-medicação Anestésica	Controle da Ansiedade e dos efeitos dos parassimpáticos
RNA 03	Técnica Anestésica	Tipos de técnicas utilizadas (técnicas para anestesia geral ou regional)
RNA 04	Modalidade de Indução	Dados complementares para técnicas de anestesia geral
RNA 05	Drogas de manutenção	Dados complementares para técnicas de anestesia geral
RNA 06	Bloqueador Neuro-Muscular	Dados complementares para técnicas de anestesia geral
RNA 07	Manutenção das Vias Aéreas	Dados complementares para técnicas de anestesia geral
RNA 08	Nível do Bloqueio Regional	Dados complementares para técnicas de anestesia regional
RNA 09	Drogas para Sedação	Dados complementares para técnicas de anestesia regional
RNA 10	Procedimentos Adjuvantes	Dados complementares para técnicas de anestesia regional

Tabela 3 - Redes Neurais do PROVANES

b) Rede para Escolha de Drogas para Medicação Pré-Anestésica :

Determina a necessidade de medicação pré-anestésica, e qual a mais indicada, ao paciente, conforme definição da Confederação Latino-

americana de Sociedades de Anestesiologia (CLASA). A medicação pré-anestésica consiste na "administração de droga no período pré-operatório destinado a reduzir a ansiedade, facilitar a anestesia e minimizar as suas complicações e/ou efeitos colaterais".

**c) Rede de Escolha da Técnica Anestésica :**

Determina o tipo de técnica anestésica a ser adotada, levando em consideração o estado físico do paciente, a fisiologia das doenças e o conhecimento da farmacocinética e farmacodinâmica das drogas. Também influenciam na escolha da técnica anestésica a presença de doenças como hipertensão arterial, doenças cardiopulmonares, problemas hepáticos, etc.

Em função da técnica anestésica escolhida, são necessárias informações adicionais fornecidas pelas seguintes redes :

- Anestesia Loco-Regional : Rede de Escolha do Nível do Bloqueio Regional, Rede de Escolha da Droga para Sedação e Rede de Escolha dos Procedimentos Adjuvantes;

- Anestesia geral : Rede de Escolha da Modalidade de Indução, Rede de Escolha das Drogas de Indução e Manutenção, Rede de Escolha do Bloqueador Neuromuscular e Rede de Escolha da Modalidade de Manutenção das Vias Aéreas;

### 3.2 - CARACTERÍSTICAS DOS DADOS DE TREINAMENTO

Os dados para treinamento das topologias de RNAs implementadas foram obtidos de um banco de dados em anestesiologia, gerado a partir de fichas preenchidas por profissionais médicos ao proporem um plano de anestesia [DUARTE87]. Estas fichas são preenchidas em hospitais conveniados para este fim e enviadas ao GPEB para digitação e inserção na base de dados. Os dados compilados e utilizados para formar a base são formados por agrupamentos de dados baseados na ficha do paciente, sendo mostrados na tabela (Tabela 4) abaixo :

	Grupo	Numero de elementos por grupo
01	Idade	01
02	Condições de Internação	06
03	Presença/Usuário de drogas	09
04	Período de jejum	04
05	Condições prévias abdominais	11
06	Condições prévias cardiovasculares 01	17
07	Condições prévias cardiovasculares 02	15
08	Condições prévias endocrinos- metabólicas	14
09	Condições prévias genéticas-congênicas	06
10	Condições prévias hematológicas	14
11	Condições prévias hepáticas	08
12	Condições prévias neuromusculares 01	13
13	Condições prévias neuromusculares 02	13
14	Condições prévias osteo-cutâneo-	09

	reumatológicas 01	
15	Condições prévias osteo-cutâneo- reumatológicas 02	12
16	Condições prévias respiratórias	17
17	Condições prévias uronefrológicas	08
18	Condições prévias - Outros sistemas	16
19	Estado emocional	04
20	Peculiaridades do RN	02
21	Patologias Específicas	09
22	Exames complementares	08
23	Exame - Radiografias	16
24	Exame - Eletrocardiografia	14
25	Exame - Gasometria	17
26	Exame - Sangue	18
27	Drogas Domiciliares 01	17
28	Drogas Domiciliares 02	17
29	Drogas Domiciliares 03	17
30	Drogas Domiciliares 04	17
31	Drogas Domiciliares 05	17
32	Drogas Domiciliares 06	12
33	Local da cirurgia 01	13
34	Local da cirurgia 02	13
35	Local da cirurgia 03	27
36	Duração	02
37	Anestesia regional	8
38	Anestesia geral	4

Tabela 4 - Grupos de Entradas das RNAs



	Úlcera Péptica/Gastrite
Condições prévias cardiovasculares 01	Hipertensão Arterial Sistêmica; IAM Prévio mais de 6 meses
Condições prévias cardiovasculares 02	ICC
Condições prévias endocrino-metabólicas	Diabete Melito tipo II
Condições prévias hematológicas	Anemia Secundária
Condições prévias - Outros sistemas	Prótese Dentária/Edêntulo;
Estado emocional	Agitado
Exame - Eletrocardiografia	ECG : Taquicardia Sinusal
Exame - Sangue	Glicose alto; Hematócrito Baixo; Leucócitos Alto;

Tabela 5 - Exemplo de paciente para entrada das Redes

Para um paciente como o descrito acima, inicia-se uma tarefa de busca de respostas aos processos classificatórios incluídos dentro de um plano de anestesia. As possibilidades de respostas das RNAs são as mostradas na Tabela 6.

Convém ressaltar que no trabalho de construção do módulo expandido do PROVANES para pacientes críticos/problemáticos [PASSOLD95], as topologias de algumas RNAs sofreram alterações visando adaptação às condições específicas para estes casos. Dessa forma, a Tabela 6 contém as topologias destas RNAs já modificadas. No entanto elas mantêm, na maioria dos aspectos, as características originais propostas em [GARCIA92]. Portanto as análises feitas para as topologias do sistema expandido podem ser consideradas válidas para o sistema original. A

descrição detalhada destas modificações e adaptações das topologias das RNAs estão contidas no trabalho de [PASSOLD95].

RNA	SAÍDAS
Classificação do Estado Físico	Grau 1; Grau 2; Grau 3; Grau 4; Grau 5
Medicação Pré-anestésica	Benzodiazepínico; Opióide; Barbitúrico; Neuroléptico; Antihistamínico H1-H2; Bloqueador Muscarínico; Gastrocinético; Não necessária
Técnica Anestésica	<i>Anestesia Regional :</i> Infiltrativa; Peridural Lombar; Plexo Membro Superior; Regional Endovenosa; Subaracnóidea; Subaracnóidea Seletiva; Troncular MI; Troncular MS; <i>Anestesia Geral/Combinada :</i> Combinada; Balanceada; Endovenosa Total; Inalatória Qualitativa
Nível do Bloqueio Regional ( <i>Anestesia Regional</i> )	T03; T04; T05; T06; T07; T08; T09; T10; T11; T12; L01; L02; L04
Droga para Sedação ( <i>Anestesia Regional</i> )	Diazepan; Flunitrazepam; Midazolam; Propofol; Tiopental
Procedimentos Adicionais ( <i>Anestesia Regional</i> )	Cateter; Cateter de Oxigênio
Modalidade de Indução ( <i>Anestesia Geral</i> )	Endovenosa; Endovenosa+Inalatória; Inalatória sob máscara; Sequência rápida de IOT; Priming; IT às cegas; IT acordado
Drogas de Indução e Manutenção ( <i>Anestesia Geral</i> )	Alfentanil; Diazepan; Enflurano; Etomidato; Fentaril; Halotano; Isoflurano; Ketamine; Meperidina; Midazolam; Morfina; Propofol; óxido Nitroso; Tiopental; Outras drogas
Bloqueador Neuromuscular ( <i>Anestesia Geral</i> )	Alcurônio; Atracúrio; galamina; Pancurínio; Succilcolina; Vecurínio; Outros
Manutenção das Vias Aéreas ( <i>Anestesia Geral</i> )	Intubação Nasotraqueal; Intubação orotraqueal; Máscara facial

Tabela 6 - Saídas possíveis das RNAs

As características dos dados e informações disponíveis no banco de dados em anestesiologia indicaram, portanto, tanto para o PROVANES original quanto para o módulo expandido, a utilização de paradigmas de RNAs com algoritmos de treinamento supervisionado a partir de uma base de exemplos. Foram utilizadas redes heteroassociativas, nas quais a dimensão dos padrões de entrada diferem da dimensão dos padrões de saída.

### 3.3 - TOPOLOGIAS DAS RNAs

#### - RNA 01 : CLASSIFICAÇÃO DO ESTADO FÍSICO DO PACIENTE

<b>ENTRADA</b>	
Número de neurônios de entrada	298
Grupos (Tabela 4)	1 a 26
<b>SAÍDA</b>	
Número de neurônios de saída	5
Número possível de saídas ativadas por padrão	1

#### - RNA 02 : PRÉ-MEDICAÇÃO ANESTÉSICA

<b>ENTRADA</b>	
Número de neurônios de entrada	459
Grupos (Tabela 4)	1 a 36
<b>SAÍDA</b>	
Número de neurônios de saída	8
Número possível de saídas ativadas por padrão	2

#### - RNA 03 : ESCOLHA DA TÉCNICA ANESTÉSICA

<b>ENTRADA</b>	
Número de neurônios de entrada	459
Grupos (Tabela 4)	1 a 36
<b>SAÍDA</b>	
Número de neurônios de saída	12
Número possível de saídas por padrão	3



**- RNA 04 : NÍVEL DO BLOQUEIO REGIONAL (Anestesia Regional)**

<b>ENTRADA</b>	
Número de neurônios de entrada Grupos (Tabela 4)	67 1 e 27 a 37
<b>SAÍDA</b>	
Número de neurônios de saída	13
Número possível de saídas ativadas por padrão	1

**- RNA 05 : ESCOLHA DA DROGA DE SEDAÇÃO (Anestesia Regional)**

<b>ENTRADA</b>	
Número de neurônios de entrada Grupos (Tabela 4)	67 1 e 27 a 37
<b>SAÍDA</b>	
Número de neurônios de saída	5
Número possível de saídas ativadas por padrão	1

**- RNA 06 : ESCOLHA DOS PROCEDIMENTOS ADICIONAIS  
(Anestesia Regional)**

<b>ENTRADA</b>	
Número de neurônios de entrada Grupos (Tabela 4)	67 1 e 27 a 37
<b>SAÍDA</b>	
Número de neurônios de saída	4
Número possível de saídas ativadas por padrão	1

**- RNA 07 : ESCOLHA DA MODALIDADE DE INDUÇÃO (Anestesia  
Geral)**

<b>ENTRADA</b>	
Número de neurônios de entrada Grupos (Tabela 4)	63 1, 27 a 36 e 38
<b>SAÍDA</b>	
Número de neurônios de saída	7
Número possível de saídas ativadas por padrão	1

**- RNA 08 : ESCOLHA DAS DROGAS DE INDUÇÃO/MANUTENÇÃO  
(Anestesia Geral)**

<b>ENTRADA</b>	
Número de neurônios de entrada Grupos (Tabela 4)	63 1, 27 a 36 e 38
<b>SAÍDA</b>	
Número de neurônios de saída Número possível de saídas ativadas por padrão	15 5

**- RNA 09 : ESCOLHA DO BLOQUEADOR NEURO-MUSCULAR  
(Anestesia Geral)**

<b>ENTRADA</b>	
Número de neurônios de entrada Grupos (Tabela 4)	63 1, 27 a 36 e 38
<b>SAÍDA</b>	
Número de neurônios de saída Número possível de saídas ativadas por padrão	6 2

**- RNA 10 : ESCOLHA DE MANUTENÇÃO DAS VIAS AÉREAS  
(Anestesia Geral)**

<b>ENTRADA</b>	
Número de neurônios de entrada Grupos (Tabela 4)	63 1, 27 a 36 e 38
<b>SAÍDA</b>	
Número de neurônios de saída Número possível de saídas ativadas por padrão	3 1


### 3.4 - ALGORITMO DE TREINAMENTO *BACKPROPAGATION*

O algoritmo de treinamento *Backpropagation* foi apresentado por [RUMELHART86] e é aplicado à topologia *feedforward Perceptrons* multicamadas. A topologia mais comum encontrada nas aplicações é formada por três camadas, referenciadas como entrada, intermediária e de saída. Os neurônios da camada de entrada atuam como “buffer” de dados e os neurônios das camadas intermediárias e de saída processam informação através da soma ponderada dos vetores e pesos.

O algoritmo *Backpropagation*, que é uma generalização do algoritmo LMS [WIDROW90], tem o seguinte processo de treinamento[LIPMANN87]

:

- a) O conjunto de pesos é inicializado com valores randômicos de pequeno valor (ex.:  $\pm 0,1$ );



- b) São apresentados à rede os vetores de entrada e os respectivos vetores de saídas considerados como as respostas corretas. Dessa forma, todas as saídas da rede são setadas para zero, exceto as que correspondem à classe que se deseja representar.
- c) Através da soma ponderada e utilizando a função ativação sigmoide são calculadas as saídas da rede. Para cada neurônio “j” de uma topologia *feedforward* calcula-se a sua saída “s”:

$$y_j = \sum_{i=1}^n (w_{ij} * x_i) + w_{0j} \quad (4.1)$$

$$s_j = f(y_j) \quad (4.2)$$

onde :

$y_j$  = soma ponderada do vetor de pesos conectados ao neurônio  $j$ ;

$w_{ij}$  = valor do peso  $i$  conectado ao neurônio  $j$ ;

$x_i$  = valor da saída do neurônio  $i$  conectado ao neurônio  $j$ ;

$w_{0j}$  = valor do "bias" do neurônio  $j$ ;

$s_j$  = saída do neurônio  $j$  após a aplicação do função sigmoide;

d) Partindo-se dos neurônios de saída e retornando para os neurônios da camada intermediária, são ajustados os pesos através da seguinte fórmula:

$$W_{ij(n+1)} = W_{ij(n)} + \Delta W_{ij} \quad (4.3)$$

onde :

$W_{ij(n)}$  = Valor do peso antes do passo de treinamento;

$W_{ij(n+1)}$  = Novo valor do peso após o passo de treinamento;

$\Delta W_{ij}$  = Parcela de ajuste dos pesos;

e) A parcela de ajuste dos pesos é proporcional ao erro de saída retropropagado através da seguinte fórmula :

$$\Delta W_{ij} = W_{ij(n+1)} - W_{ij(n)} = \eta \delta_j x_i \quad (4.4)$$

onde :

$$\begin{aligned}\eta &= \text{Passo de treinamento} \\ \theta_j &= \text{Erro para o neurônio } j \\ x_i &= \text{Saída do neurônio } i\end{aligned}$$

Uma versão modificada do algoritmo original proposto por [RUMELHART86] e muito utilizada nas aplicações de RNAs treinadas com *Backpropagation* e a que utiliza um efeito integral ao efeito proporcional, acelerando o processo de convergência :

$$\Delta W_{ij} = \bar{W}_{ij(n+1)} - \bar{W}_{ij(n)} = \eta \delta_j x_i + \alpha (\bar{W}_{ij(n)} - \bar{W}_{ij(n-1)}) \quad (4.5)$$

onde  $\alpha$  = Coeficiente de atenuação ou “momentum”

- O valor do erro dos neurônios da camada de saída é calculado por :

$$\delta_j = y_j(1 - y_j)(d_j - y_j) \quad (4.6)$$

onde :

$$\begin{aligned}y_j &= \text{saída real da rede} \\ d_j &= \text{saída desejada}\end{aligned}$$

- O valor do erro dos neurônios da camada intermediária é calculado por :

$$\delta_j = x_j(1 - x_j) \sum_k \delta_k W_{jk} \quad (4.7)$$

onde :

$$\begin{aligned}x_j &= \text{Saída do neurônio da camada intermediária;} \\ k &= \text{Número de neurônios da camada de saída;}\end{aligned}$$

O processo de treinamento continua, repetindo-se os passos a partir de (b) até obter-se um valor de erro médio quadrático de saída aceitável, que deve, na maioria dos casos, coincidir com o ponto de máxima eficiência da rede.

## **4 - IMPLEMENTAÇÕES DE ALGORITMOS DE ANÁLISE DAS RNAs**

Os algoritmos de extração de regras de RNAs, apresentados no capítulo 2.3, "SUBSET" e "MofN" são aplicados para análise dos pesos das RNAs, buscando-se uma forma ou método de avaliação do que a estrutura da rede está efetivamente identificando ou aprendendo a partir de uma base de treinamento. O objetivo deste esforço surge da impossibilidade prática de formulação de questões clássicas de explanação de um resultado de inferência, como "Why?" ou "How?", em SEs implementados com paradigmas conexionistas. Este fato tem impedido o uso mais freqüente desta ferramenta na implantação de um SE.

Neste capítulo serão descritos dois algoritmos, desenvolvidos durante este trabalho de dissertação, de análise de RNAs para serem aplicados nas topologias implementadas para representação do conhecimento médico em anestesiologia. Estes algoritmos chamam-se LOGIC e PERCEP. O algoritmo LOGIC realiza uma transformação dos pesos de uma rede treinada em um conjunto de portas lógicas booleanas definidas especialmente para esta função. Já o algoritmo PERCEP faz um processamento buscando a importância relativa de cada peso no processo de ativação de um neurônio específico. Na abordagem e implementação do algoritmo PERCEP surge a possibilidade de refinamento dos pesos treinados da RNAs, corrigindo possíveis distorções ocorridas no processo de treinamento.

O objetivo final dos algoritmos desenvolvidos LOGIC e PERCEP, assim como os algoritmos apresentados anteriormente "SUBSET" e "MofN", é a obtenção de regras de conhecimento do tipo IF..THEN extraídas dos pesos de uma rede treinada. Porém, para a efetivação de uma regra deste tipo, existe uma dependência direta entre as regras geradas com as possíveis atribuições dadas a um determinado neurônio na topologia da RNA, como ocorre nas redes "baseadas em conhecimento" apresentadas no capítulo 2.3. Portanto para as topologias de redes em que os neurônios da camada intermediária não tenham atribuição específica, as regras geradas sofrem algumas restrições de aplicabilidade, devido à impossibilidade de associação entre os condicionais If..Then à neurônios em uma topologia genérica de RNA.

#### 4.1 - Algoritmo LOGIC

O algoritmo LOGIC é uma ferramenta de análise de sensibilidade das RNAs implementadas neste trabalho. Está relacionado com a transformação dos neurônios das topologias implementadas em portas lógicas booleanas (Figura 11), sendo cada neurônio da rede *feedforward* representado por um conjunto de portas lógicas AND (E) e OR (OU), definidas com três estados especiais de entrada.




Figura 11 - Modelo de portas lógicas para um neurônio artificial

Cada porta lógica AND recebe todas as entradas da rede e cada entrada destas portas representa uma conexão da matriz de pesos da RNA. Estas entradas (conforme mostrado na Figura 11) podem assumir três estados especiais denominados : DC-“Diretamente Conectado”, IC-“Inversamente Conectado” ou NI-“Não Importa”. Estes estados surgem naturalmente dos



valores de treinamento dos pesos da RNA após a convergência de treinamento.

Considerando, a título de exemplo, o neurônio mostrado Figura 12 com seus pesos, após um processo de treinamento, convergindo para os seguintes valores :

$W_1 =$	2
$W_2 =$	-1
$W_3 =$	1
$W_0 =$	-1.2




Figura 12 - Configuração de neurônio artificial após a convergência de treinamento

Este neurônio pode ser representado por um conjunto de portas lógicas definidas pelo algoritmo LOGIC. Na aplicação do LOGIC, as entradas e os estados de ativação dos neurônios devem possuir valores [-1 e +1]. Se o treinamento formal anterior à aplicação do algoritmo utilizar outros estados de ativação, uma pré-transformação destes valores deve ser realizado.

É possível, desta forma, estabelecer um conjunto de combinações válidas das entradas que sempre ativam o neurônio, segundo a desigualdade mostrada na fórmula 4.7.

$$W_1 * E_1 + W_2 * E_2 + W_3 * E_3 \geq -W_0 \quad (4.7)$$

As combinações possíveis, para o exemplo, são portanto :

E <sub>1</sub>	E <sub>2</sub>	E <sub>3</sub>	S
-1	-1	-1	0
-1	-1	1	0
-1	1	-1	0
-1	1	1	0
1	-1	-1	1
1	-1	1	1
1	1	-1	0
1	1	1	1

Para as entradas em que o neurônio (S=1) é ativado aplica-se o seguinte algoritmo :

- Se uma entrada específica possuir o mesmo sinal do peso que faz a conexão desta entrada, geram-se os estados “Diretamente Conectado” (DC) e “Inversamente Conectado” (IC), respectivamente se o sinal considerado é positivo ou negativo;
- Se uma entrada específica possuir sinal contrário ao do peso que faz a conexão desta entrada, então gera-se um estado “Não Importa” (NI) ;

Para o exemplo acima, portanto, as portas lógicas geradas são :

a) Porta 1

Entradas	E1 = +1	E2 = -1	E3 = -1
Pesos	W1 = + 2	W2 = -1	W3 = 1
Conexões da Porta	DC	IC	NI

## b) Porta 2

Entradas	$E1 = +1$	$E2 = -1$	$E3 = +1$
Pesos	$W1 = +2$	$W2 = -1$	$W3 = +1$
Conexões da Porta	DC	IC	DC

## c) Porta 3

Entradas	$E1 = +1$	$E2 = +1$	$E3 = +1$
Pesos	$W1 = +2$	$W2 = -1$	$W3 = +1$
Conexões da Porta	DC	NI	DC

A Figura 13 mostra a configuração das portas geradas a partir do algoritmo LOGIC.

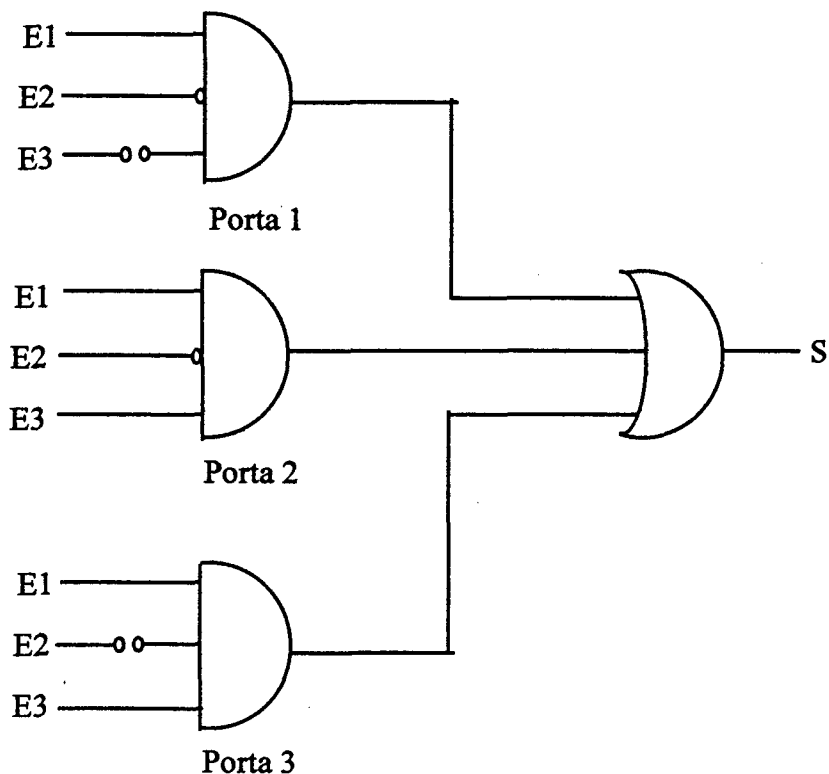


Figura 13 - Portas lógicas geradas pelo algoritmo LOGIC

#### 4.1.1 - Plano de Ativação

Uma forma alternativa de representação das portas lógicas da rede é possível com o “Plano de Ativação” mostrado na Figura 14 . Este plano mostra no eixo Y os valores resultantes do produto “Peso\*Entrada” de uma porta lógica e do “bias” de ativação do neurônio relacionado. No eixo X está o número de combinações “Peso\*Entrada” da porta lógica.




Figura 14 - Plano de Ativação

O Plano de Ativação mostrado na Figura 14 está representando a porta lógica 2 do exemplo. Pode-se comprovar o efeito de cooperação das entradas  $E_1(+)/W_1(+)$  e  $E_3(+)/W_3(+)$  que estão “Diretamente Conectados” e  $E_2(-)/W_2(-)$  que está “Inversamente Conectado”.

#### 4.1.2 Etapa de Simplificação de Portas

O algoritmo LOGIC prevê uma etapa de simplificação na qual são eliminadas portas lógicas redundantes. No neurônio-exemplo utilizado, obteve-se as seguintes portas lógicas :

	E1	E2	E3
Porta 1	+1	-1	0
Porta 2	+1	-1	1

Estas duas portas são claramente redundantes, pois sendo as entradas E1 e E2 iguais nas duas portas e a entrada E3 na porta 1 considerada "NI", a porta 2 representa um estado de ativação já considerado na porta 1.

Com o Plano de Ativação a seguir pode-se comprovar esta situação :




Figura 15 - Plano de Ativação mostrando porta redundante

Neste plano de ativação pode-se comprovar :

- a) O estado “Não Importa” da entrada E3 que, para a porta 1, não influi no resultado final da ativação (ou desativação) do neurônio.
- b) A redundância da porta 2, que nada mais representa do que a porta 1 com a entrada E3 no estado +1.

#### 4.1.3 - Extração de Regras

Como resultado final da aplicação deste algoritmo a uma estrutura treinada de RNA, pode-se obter um conjunto de regras de causa-efeito do tipo :

*IF* (Entrada X) *AND NOT* (Entrada Y)  
*THEN* (Conclusão)

Para obtenção desta estrutura de regra, deve-se associar a cada entrada das portas lógicas AND uma hipótese e a cada saída das portas OU uma conclusão (ou classe). O uso da condição “NOT” estará associado à condição “Inversamente Conectado” das portas lógicas.

Para o exemplo mostrado, a saída S está associada à seguinte regra hipotética :

*IF*  
 (E1) *AND NOT* (E2) -----(Porta 1)  
*OR*  
 (E1) *AND* (E3) -----(Porta 3)  
*THEN S*

#### 4.1.4 - Comparação entre o LOGIC e o SUBSET

A regra gerada pelo algoritmo LOGIC possui a mesma forma final da regra gerada pelo algoritmo SUBSET proposto por [TOWELL93] e apresentado no capítulo 2.4.1. Os dois algoritmos partem da mesma premissa básica de determinação de subconjuntos de pesos cuja soma ponderada resultam em condição suficiente para a ativação de um determinado neurônio. A diferença entre estes algoritmos está no processamento efetuado para se chegar às regras. O LOGIC realiza um processo de comparação baseado na consistência entre o sinal da entrada com o sinal do peso na qual esta entrada está conectada. Já o SUBSET faz uma separação de grupos de pesos, dividindo-os inicialmente em grupos de pesos positivos e negativos, iniciando, então, um processo combinação entre eles para a determinação de subgrupos que formam as condições suficientes para a ativação do neurônio.

Para exemplificar a comparação acima, será aplicado o algoritmo LOGIC sobre o neurônio-exemplo utilizado para demonstrar as regras geradas pelo SUBSET. Este neurônio é apresentado no capítulo 2.4.1 :

a) Tabela-Verdade do Neurônio :

ENTRADAS				
A	B	C	D	S
-1	-1	-1	-1	-1
1	-1	-1	-1	-1
-1	1	-1	-1	-1
1	1	-1	-1	1
-1	-1	1	-1	-1
1	-1	1	-1	1
-1	1	1	-1	1
1	1	1	-1	1

ENTRADAS				
A	B	C	D	S
-1	-1	-1	1	-1
1	-1	-1	1	-1
-1	1	-1	1	-1
1	1	-1	1	-1
-1	-1	1	1	-1
1	-1	1	1	-1
-1	1	1	1	-1
1	1	1	1	1

b) De acordo com o processo aplicação do LOGIC, para as saídas ativas do neurônio (em destaque na tabela-verdade) são associadas as seguintes portas lógicas :

	A	B	C	D
Porta 1 :	1	1	0	-1
Porta 2 :	1	0	1	-1
Porta 3 :	0	1	1	-1
Porta 4 :	1	1	1	-1
Porta 5 :	1	1	1	0

c) Conforme descrito anteriormente, a Porta 4 representa uma condição redundante, pois a Porta 1 é a própria Porta 4 com entrada "C" em estado "Não Importa".

d) Sendo assim, as regras geradas pelo LOGIC são :

- If (A) and (B) and (not D) then S (Porta 1);
- If (A) and (C) and (not D) then S (Porta 2);
- If (B) and (C) and (not D) then S (Porta 3);
- If (A) and (B) and (C) then S (Porta 5);

e) Pode-se observar que estas regras são as mesmas geradas pela aplicação do algoritmo SUBSET para o neurônio-exemplo.

O tipo de processamento realizado pelo algoritmo SUBSET, como é realçado pelos seus autores [TOWELL93], apresenta uma desvantagem devido ao excessivo processamento necessário para se obter todas as combinações possíveis e, portanto, as regras finais. Neste aspecto o



LOGIC pode ser considerado como um avanço na aplicação do método pois, apesar de seguir a mesma filosofia de extração de regras, a sua aplicação é mais simples e direta, não exigindo todo o processamento necessário ao SUBSET.

## 4.2 - Algoritmo PERCEP

A aplicação do algoritmo PERCEP está associado com a busca da importância relativa de cada peso ou, então, da relação “Peso\*Entrada” para a ativação de um determinado neurônio. Esta é uma abordagem diferenciada do algoritmo anterior LOGIC que considera todas as entradas (ou antecedentes) com o mesmo grau de importância.

### 4.2.1 - Aplicação

Este algoritmo possui três etapas de aplicação. A primeira, com objetivo de facilitar a análise e compreensão do significado das entradas, realiza uma transformação nos pesos de uma rede treinada, sem perda de generalidade. Após esta transformação todos os pesos resultantes do treinamento de uma RNA passam a ter valores somente positivos. A segunda etapa do PERCEP recalcula os valores dos pesos para um limiar de ativação (“bias”) de “Um” (ou 100%). Com isso pode-se verificar a importância relativa de cada peso para ativação do neurônio. A terceira etapa consiste na associação entre os valores dos pesos transformados e as hipóteses representadas pelas entradas e formar uma regra geral de extração de conhecimento da rede, com as respectivas relevâncias para a confirmação de uma conclusão (ou classificação).

O algoritmo PERCEP opera com entradas e saídas dos neurônios na máxima ativação (próximos de um) ou inativos (próximos de zero).

A demonstração da aplicação do algoritmo é realizada considerando um neurônio genérico com três entradas mostrado na Figura 16.




Figura 16 - Neurônio artificial para aplicação do algoritmo PERCEP

a) Primeira Etapa - Transformação dos pesos para valores somente positivos :

A saída  $S$  do neurônio da Figura 16 é calculada por :

$$y = W_1 * E_1 + W_2 * E_2 + W_3 * E_3 + W_0 \quad (4.8)$$

onde :

$$\begin{cases} S = 1 & \text{se } y > 0 \\ S = 0 & \text{se } y \leq 0 \end{cases}$$

Considerações para o neurônio :

- Entradas podem assumir os valores [0 e +1];
- Após uma convergência de treinamento os pesos assumem valores positivos ou negativos. Para o exemplo :  $W_1 > 0$ ,  $W_2 < 0$  e  $W_3 > 0$ ;

A principal consideração a ser feita nesta etapa está relacionada com as entradas em que os pesos negativos serão transformados para positivos.

Estas entradas devem ser consideradas negadas ( $\bar{Y}=1-Y$ ). Para os pesos positivos utiliza-se a própria entrada :

$$E_{1r} = E_1 \quad (W_1 > 0)$$

$$E_{2r} = (1 - E_2) \text{ ou } \bar{E}_2 \quad (W_2 < 0)$$

$$E_{3r} = E_3 \quad (W_3 > 0)$$

Dessa forma, a equação 4.8 pode ser apresentada da seguinte forma :

$$y = W_1 * E_{1r} + W_2 * (1 - E_{2r}) + W_3 * E_{3r} + W_0$$

$$y = W_1 * E_{1r} + W_2 - W_2 * E_{2r} + W_3 * E_{3r} + W_0$$

$$y = W_1 * E_{1r} - W_2 * E_{2r} + W_3 * E_{3r} + W_{0r} \quad (4.9) \quad (\text{para } W_2 < 0 \text{ e } W_{0r} = W_0 + W_2)$$

Uma forma alternativa de representação da equação 4.9 é :

$$y = |W_1| * E_1 + |W_2| * \bar{E}_2 + |W_3| * E_3 + W_{0r} \quad (4.10) \quad (\text{para } W_{0r} = W_0 - |W_2|)$$

Deve-se observar que o efeito da transformação dos pesos negativos para positivos está relacionado com a alteração do valor do "bias". Esta alteração muda o nível de ativação do neurônio preservando, porém, as combinações originais de entrada de ativação do mesmo neurônio.

Esta etapa será exemplificada através de um neurônio de três entradas com os pesos assumindo os valores  $W1=+2$ ,  $W2=-1$  e  $W3=+1$  e o valor do "bias"  $W0=1.2$ .

Para esta rede a tabela verdade de ativação do Neurônio é o seguinte :

E <sub>1</sub>	E <sub>2</sub>	E <sub>3</sub>	S
0	0	0	0
0	0	1	0
0	1	0	0
0	1	1	0
1	0	0	1
1	0	1	1
1	1	0	0
1	1	1	1

Os valores dos pesos transformados são os seguintes :

$W_1=+2$ ,  $W_2=+1$  e  $W_3=+1$  e o novo valor do "bias"  $W_0=2.2$ .

Nesta condição e considerando a entrada E<sub>2</sub> negada obtém-se a seguinte tabela verdade :

E <sub>1</sub>	$\overline{E_2}$	E <sub>3</sub>	S
0	1	0	0
0	1	1	0
0	0	0	0
0	0	1	0
1	1	0	1
1	1	1	1
1	0	0	0
1	0	1	1

b) Segunda Etapa - Representação percentual dos pesos relativo ao “bias” do neurônio:

Deve-se dividir todos os termos dos pesos da equação 4.9 ou equação 4.10 pelo termo  $W_{of}$ . Com isso todos os pesos terão um valor relativo a um valor ativação (“bias”) de “Um” (ou 100%).

$$\frac{|W_1|}{W_{of}} * E_1 + \frac{|W_2|}{W_{of}} * \overline{E_2} + \frac{|W_3|}{W_{of}} * E_3 > \frac{W_{of}}{W_{of}}$$

$$W_{1r} * E_1 + W_{2r} * \overline{E_2} + W_{3r} * E_3 > 1 \quad (4.11)$$

Para o exemplo anterior, os pesos representados percentualmente são :

$$0.90 * E_1 + 0.45 * \overline{E_2} + 0.45 * E_3 > 1$$

c) Terceira Etapa - Extração da regra geral de ativação do neurônio :

Da equação 4.11 pode-se considerar a seguinte regra geral :

“SE um determinado padrão :

*APRESENTAR*

as características  $E_1$  e  $E_3$ , isto contribui para a conclusão  $S$  com importância relativa de 90% e 45% , respectivamente

E

*NÃO APRESENTAR*

a característica  $E_2$  , isto contribui para a conclusão  $S$  com importância relativa de 45% .”

Nesta etapa, tanto a condição “*APRESENTAR*” como a “*NÃO APRESENTAR*” são representadas pelo estado “1” de ativação.

Pode-se observar que o efeito da transformação dos pesos para valores somente positivos permite a extração de regras que evidenciam não somente a importância da “presença” de uma evidência A, B ou C em um determinado padrão (ou paciente), mas também permite evidenciar a importância da “ausência” de uma determinada evidência, condição esta que poderá reforçar uma conclusão ou classificação. Muitas vezes um profissional médico realiza um diagnóstico baseado nesta forma de pensar, o que atribui aplicação relevante na utilização do PERCEP.

- Um exemplo de Aplicação do PERCEP :

O exemplo mostrado abaixo, extraído de [DENIS91], mostra o treinamento de uma rede para realizar um diagnóstico médico diferencial. O banco de dados de treinamento é formado pelos quatro seguintes casos de pacientes com a doença D1 ou D2, que apresentam os sintomas S1, S2, S3 E S4 :

Paciente	Sintomas	Doença
1	S1, S2 e S3	D1
2	S1, S2 e S4	D1
3	S1, S3 e S4	D2
4	S2, S3 e S4	D2

Uma rede com convergência válida, treinada com *Backpropagation*, que pode representar a base de dados é a seguinte :

$$\text{Matriz de Pesos } W = \begin{vmatrix} +1,2368 & +1,2412 & -1,2458 & -1,2551 \\ -1,2454 & -1,2416 & +1,2400 & +1,2447 \end{vmatrix}$$

$$\text{"Bias" dos neurônios de saída} = | 0,0147 \quad 0,0042 |$$

Aplicando-se o algoritmo PERCEP, obtém-se os seguintes resultados :

a) Primeira Etapa :

- Equações dos neurônios antes da transformação :

$$\text{Eq. Neurônio1} = 1,2308 * S_1 + 1,2412 * S_2 - 1,2458 * S_3 - 1,2551 * S_4 > -0,0147$$

$$\text{Eq. Neurônio2} = -1,2454 * S_1 - 1,2416 * S_2 + 1,2400 * S_3 + 1,2447 * S_4 > -0,0042$$

-Tabela-Verdade das equações dos neurônios (em destaque as entradas usadas para o treinamento) :

S <sub>1</sub>	S <sub>2</sub>	S <sub>3</sub>	S <sub>4</sub>	D <sub>1</sub>	D <sub>2</sub>
0	0	0	0	1	1
0	0	0	1	0	1
0	0	1	0	0	1
0	0	1	1	0	1
0	1	0	0	1	0
0	1	0	1	1	1
0	1	1	0	1	1
<b>0</b>	<b>1</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>1</b>
1	0	0	0	1	0



1	0	0	1	0	1
1	0	1	0	1	0
<b>1</b>	<b>0</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>1</b>
1	1	0	0	1	0
<b>1</b>	<b>1</b>	<b>0</b>	<b>1</b>	<b>1</b>	<b>0</b>
<b>1</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>1</b>	<b>0</b>
1	1	1	1	0	1

- Equações dos neurônios após a transformação para pesos positivos :

Neurônio de Saída 1 :

$$\text{Equação} = 1,2308 * S_1 + 1,2412 * S_2 + 1,2458 * \overline{S_3} + 1,2551 * \overline{S_4} > 2,4862$$

Neurônio de Saída 2 :

$$\text{Equação} = +1,2454 * \overline{S_1} + 1,2416 * \overline{S_2} + 1,2400 * S_3 + 1,2447 * S_4 > 2,4828$$

b) Segunda etapa (representação percentual relativo ao “bias”):

- Neurônio 1 :

$$\text{Equação} = 49,74 * S_1 + 49,92 * S_2 + 50,10 * \overline{S_3} + 50,48 * \overline{S_4} > 100 \quad (\text{em } \%)$$

- Tabela-Verdade para o neurônio 1 com os pesos transformados :

$S_1$	$S_2$	$\overline{S_3}$	$\overline{S_4}$	$D_1$
0	0	1	1	1
0	0	1	0	0
0	0	0	1	0
0	0	0	0	0
0	1	1	1	1
0	1	1	0	1
0	1	0	1	1
<b>0</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>0</b>

1	0	1	1	1
1	0	1	0	0
1	0	0	1	1
<b>1</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
1	1	1	1	1
<b>1</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>1</b>
<b>1</b>	<b>1</b>	<b>0</b>	<b>1</b>	<b>1</b>
1	1	0	0	0

- Neurônio 2 :

$$\text{Equação} = +50,16 * \overline{S_1} + 50,00 * \overline{S_2} + 49,94 * S_3 + 50,13 * S_4 > 100 \quad (\text{em } \%)$$

- Tabela-Verdade para o neurônio 2 com os pesos transformados :

$\overline{S_1}$	$\overline{S_2}$	$S_3$	$S_4$	$D_2$
1	1	0	0	1
1	1	0	1	1
1	1	1	0	1
1	1	1	1	1
1	0	0	0	0
1	0	0	1	1
1	0	1	0	1
<b>1</b>	<b>0</b>	<b>1</b>	<b>1</b>	<b>1</b>
0	1	0	0	0
0	1	0	1	1
0	1	1	0	0
<b>0</b>	<b>1</b>	<b>1</b>	<b>1</b>	<b>1</b>
0	0	0	0	0

0	0	0	1	0
0	0	1	0	0
0	0	1	1	1

Deve-se observar que o treinamento da RNA não foi alterado, pois os resultados das tabelas-verdade dos Neurônios 1 e 2 permaneceram os mesmos .

c) Terceira etapa (Geração de regras gerais de ativação) :

- Regra geral para o Neurônio 1 (doença 1) :

“Hipótese : Paciente com a doença D1.

SE este paciente :

**APRESENTAR**

*sintoma S<sub>1</sub>* contribui com 49,74 %;

*sintoma S<sub>2</sub>* contribui com 49,92 %;

E

**NÃO APRESENTAR**

*sintoma S<sub>3</sub>* contribui com 50,10 %;

*sintoma S<sub>4</sub>* contribui com 50,48 %”;

- Regra geral para o Neurônio 2 (doença 2) :

“Hipótese : Paciente com a doença D2. Se este paciente :

**APRESENTAR**

*sintoma S<sub>3</sub>* contribui com 49,94 %;

*sintoma S<sub>4</sub>* contribui com 50,13 %;

E

**NÃO APRESENTAR**

*sintoma S<sub>1</sub>* contribui com 50,16 %;

*sintoma S<sub>2</sub>* contribui com 50,00 %”;

#### 4.2.2 - Refinamento do Treinamento

Uma aplicação investigada entre os grupos de pesquisas que estudam a extração de regras simbólicas de RNA é a possibilidade de refinamento do treinamento de uma RNA após a convergência [OPTIZ95], [TOWELL93]. Esta possibilidade também existe na aplicação em anestesiologia descrito neste trabalho. As equações originais de processamento da RNA, representadas pelas matrizes de pesos, podem ser substituídas, sem perda de generalidade, pelas equações transformadas obtidas com a aplicação do algoritmo PERCEP. Um especialista, de posse das informações e conhecimentos adquiridos pela RNA (representadas de acordo com formato de saída geradas pela aplicação do PERCEP), pode detectar distorções ou mesmo reforçar uma característica importante na área em questão. Para o exemplo acima mostrado, seria possível, por exemplo, associar uma importância mais preponderante entre o sintoma S1 e a Doença D1. Para tanto, na equação do Neurônio associado à doença D1 (neurônio 1) deve-se elevar a contribuição do sintoma S1, que é de 49,7 %, para um valor maior ou mesmo 100 %, se for o caso. Com isto garante-se o efeito de contribuição e associação entre um sintoma (ou entrada) e uma doença (ou saída).

## 5 - RESULTADOS

Os resultados apresentados neste capítulo são os seguintes :

No item 5.1 são apresentados resultados comparativos de treinamento das RNAs com o algoritmo *Backpropagation* entre os trabalhos de [GARCIA92], [PASSOLD95] e neste trabalho

No item 5.2, de acordo com os objetivos propostos de comparação dos critérios utilizados para a opção do algoritmo *Backpropagation* utilizado nas implementações originais do PROVANES, são apresentados resultados de implementações das mesmas topologias de RNAs com um algoritmo distinto de treinamento. Este algoritmo foi o *Counterpropagation*, que utiliza, como principal característica no seu algoritmo de treinamento, princípio de treinamento não-supervisionado de *Kohonen* [KOHONEN90]. Detalhes da *Counterpropagation* serão vistos no item 5.2.

Nos itens 5.3 e 5.4 são apresentados alguns resultados de aplicação dos algoritmos LOGIC e PERCEP sobre os valores de pesos advindos dos treinamentos efetuados para as RNAs do sistema de anestesiologia.

## 5.1 - COMPARAÇÃO DE EFICIÊNCIAS DAS RNAs

Neste item são apresentados os resultados de comparação entre os treinamentos realizados neste trabalho em relação aos treinamentos anteriores realizados nas topologias de RNAs implementadas em [GARCIA92] e [PASSOLD95]. Nos treinamentos realizados neste trabalho foram utilizadas os mesmos conjuntos de treinamentos e testes do trabalho apresentado em [PASSOLD95] e consideradas estratégias de treinamento semelhantes às utilizadas por [GARCIA92]. Ressalta-se que as topologias implementadas no PROVANES original e para o seu módulo de expansão para pacientes críticos/problemáticos, sofreram algumas mudanças quanto aos números de elementos de entrada e saída. Estas alterações estão descritas no trabalho de [PASSOLD95]. Neste trabalho, contudo, considerou-se que as mudanças realizadas não alteraram significativamente a forma de representação dos pacientes pelas RNAs no processo de proposta de um plano de anestesia, que são objetivos comuns dos dois sistemas citados.

As estratégias de treinamento, portanto, consideraram a busca da melhor estrutura para a maximização da medida da eficiência de representação das topologias implementadas. Esta eficiência foi medida considerando o número de acertos de classificação em relação às respostas existentes na base de dados. O valor da eficiência foi medido a cada ciclo em um conjunto de testes e um conjunto de treinamento.

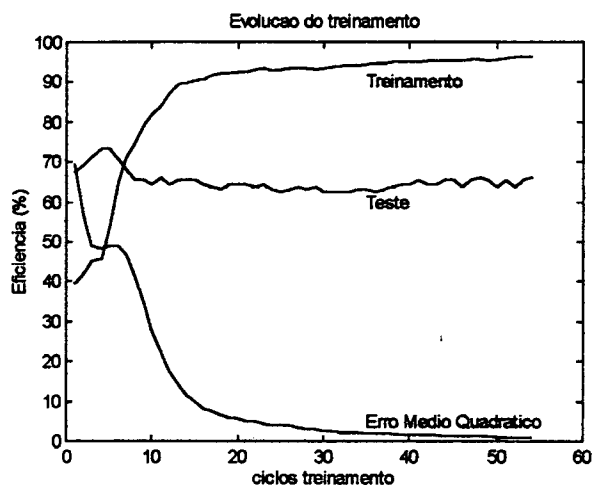
A estratégia global de treinamento proposta em [GARCIA92] é a seguinte:

- Mudança de estrutura da topologia, relacionada com baterias de ensaios com diferentes quantidades de neurônios na camada intermediária.
- Utilização de técnicas de treinamento como o "simulated annealing" que insere uma pequena quantidade de "ruído" nos pesos da rede para tentar retirar o processo treinamento de um mínimo local. A presença deste mínimo local pode ser verificada pela não evolução da eficiência, ou seja, quando se verificar que a rede não consegue mais "aprender" ou responder à apresentação de novos padrões de treinamento.
- Utilização de diferentes coeficientes de treinamento  $\eta$  (taxa de aprendizagem) e  $\alpha$  ("momentum").

A seguir são apresentados os resultados dos treinamentos mostrando-se a evolução do comportamento das eficiências no conjunto de testes e treinamento, bem como a evolução do parâmetro "erro médio quadrático" do algoritmo *Backpropagation*.

Por fim é apresentado uma tabela comparativa dos resultados de eficiências obtidos neste trabalho, em [GARCIA92] e [PASSOLD95]


## - RNA 01 : CLASSIFICAÇÃO DO ESTADO FÍSICO DO PACIENTE



Camada de Entrada = 298  
 Camada Intermediária = 8  
 Camada de Saída = 5  
 Resultado de Eficiência :  
 Conjunto de Treinamento = 96 %  
 Conjunto de Testes = 66 %

Figura 17 - Evolução da treinamento da RNA Classificação do Estado Físico

## - RNA 02 : MEDICAÇÃO PRÉ-ANESTÉSICA




Camada de Entrada = 459  
 Camada Intermediária = 15  
 Camada de Saída = 8  
 Resultado de Eficiência :  
 Conjunto de Treinamento = 82 %  
 Conjunto de Testes = 60 %

Figura 18 - Evolução da treinamento da RNA Medicação Pré-Anestésica




### - RNA 03: TÉCNICA ANESTÉSICA



Camada de Entrada = 459  
 Camada Intermediária = 20  
 Camada de Saída = 12  
 Resultado de Eficiência :  
 Conjunto de Treinamento = 87 %  
 Conjunto de Testes = 50 %

Figura 19 - Evolução da treinamento da RNA Técnica Anestésica

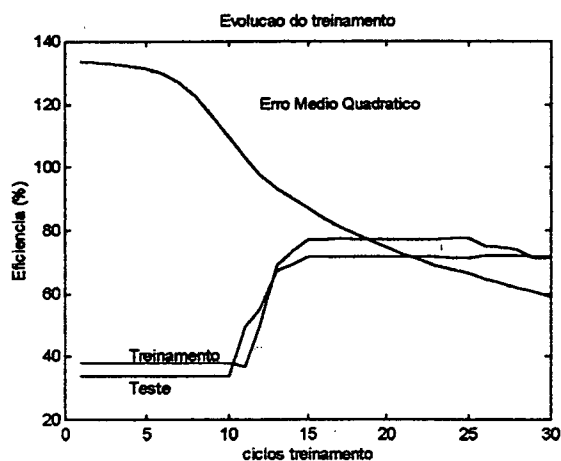
### - RNA 04 : NÍVEL DO BLOQUEIO REGIONAL



Camada de Entrada = 459  
 Camada Intermediária = 20  
 Camada de Saída = 12  
 Resultado de Eficiência :  
 Conjunto de Treinamento = 43 %  
 Conjunto de Testes = 33 %

Figura 20 - Evolução da treinamento da RNA Nível do Bloqueio Regional


## - RNA 05 : ESCOLHA DA DROGA DE SEDAÇÃO



Camada de Entrada = 459  
 Camada Intermediária = 20  
 Camada de Saída = 12  
 Resultado de Eficiência :  
 Conjunto de Treinamento = 77 %  
 Conjunto de Testes = 72 %

Figura 21 - Evolução da treinamento da RNA Escolha da Droga de Sedação

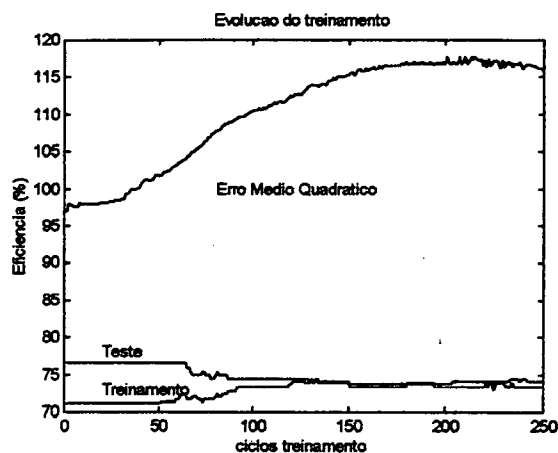
## - RNA 06 : ESCOLHA DE PROCEDIMENTOS ADICIONAIS/ADJUVANTES



Camada de Entrada = 459  
 Camada Intermediária = 20  
 Camada de Saída = 12  
 Resultado de Eficiência :  
 Conjunto de Treinamento = 87 %  
 Conjunto de Testes = 80 %

Figura 22 - Evolução da treinamento da RNA Escolha de Procedimentos Adjuvantes


## - RNA 07 : ESCOLHA DA MODALIDADE DE INDUÇÃO



Camada de Entrada = 459  
 Camada Intermediária = 20  
 Camada de Saída = 12  
 Resultado de Eficiência :  
 Conjunto de Treinamento = 74 %  
 Conjunto de Testes = 73 %

Figura 23 - Evolução da treinamento da RNA Modalidade de Indução

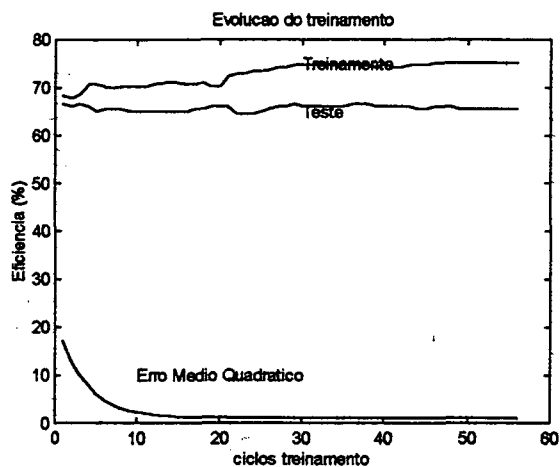
## - RNA 08 : ESCOLHA DAS DROGAS DE INDUÇÃO/MANUTENÇÃO



Camada de Entrada = 459  
 Camada Intermediária = 20  
 Camada de Saída = 12  
 Resultado de Eficiência :  
 Conjunto de Treinamento = 80 %  
 Conjunto de Testes = 74 %

Figura 24 - Evolução da treinamento da RNA Drogas de Indução/Manutenção

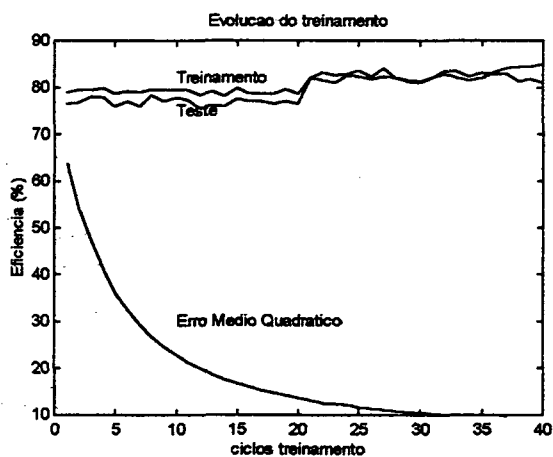
## RNA 09 : ESCOLHA DO BLOQUEADOR NEURO-MUSCULAR



Camada de Entrada = 459  
 Camada Intermediária = 20  
 Camada de Saída = 12  
 Resultado de Eficiência :  
 Conjunto de Treinamento = 75 %  
 Conjunto de Testes = 65 %

Figura 25 - Evolução da treinamento da RNA Bloqueador Neuro-Muscular

## - RNA 10 : ESCOLHA DE MANUTENÇÃO DAS VIAS AÉREAS



Camada de Entrada = 459  
 Camada Intermediária = 20  
 Camada de Saída = 12  
 Resultado de Eficiência :  
 Conjunto de Treinamento = 84 %  
 Conjunto de Testes = 81 %

Figura 26 - Evolução da treinamento da RNA Manutenção das Vias Aéreas

**- TABELA COMPARATIVA DE RESULTADOS OBTIDOS DOS TREINAMENTOS DAS RNAs :**

RNAs	RESULTADOS DE EFICIÊNCIAS (%)					
	PROVANES Original [GARCIA92]		PROVANES- Módulo Expandido [PASSOLD95]		Neste trabalho	
	Conj. Treino	Conj. Testes	Conj. Treino	Conj. Testes	Conj. Treino	Conj. Testes
Estado Físico	97	75	99	64	96	66
Pré-Medicação	88	79	78	71	82	60
Técnica Anestésica	76	69	69	53	87	50
Bloqueio Regional	89	69	35	35	43	33
Drogas de Sedação	87	79	92	67	77	72
Procedimentos Adicionais	98	98	95	82	87	80
Modalidade de Indução	83	81	63	66	74	73
Drogas de Indução	95	85	73	74	80	74
Bloqueador NeuroMuscular	96	80	63	66	75	65
Manutenção Vias Aéreas	100	88	63	65	84	81

Tabela 7 - Comparação de resultados de eficiência das RNAs

Como pode ser observado na Tabela 7, em função da estratégia de treinamento adotada nos três trabalhos de treinamento das redes, baseada em um processo iterativo de busca da melhor estrutura e ponto de convergência das redes, diferentes resultados de eficiências foram obtidos para os conjuntos de testes e treinamentos. Porém estas diferenças não foram acentuadas (somente a Rede de Bloqueio Regional apresentou resultados de eficiências menores no trabalho atual e em [PASSOLD95] do que em [GARCIA92]), indicando, de forma geral, comportamento de convergência semelhantes das RNAs. Isto indica, portanto, que para as condições de contorno consideradas, representadas pelas características dos dados utilizados e topologias de redes definidas, os resultados de representação das RNAs, treinadas com *Backpropagation*, estão em seu ponto máximo de eficiência de representação.

## 5.2 - IMPLEMENTAÇÃO DAS RNAs COM O ALGORITMO *COUNTERPROPAGATION*

As características das informações na base de dados em anesthesiologia, construída durante a implementação do PROVANES, cuja forma de representação do conhecimento médico é baseado em exemplos, indicaram o uso por uma topologia de rede heteroassociativa com um algoritmo supervisionado de treinamento[GARCIA92].

Em função disso, todas as RNAs, tanto no PROVANES original quanto no seu módulo estendido para pacientes críticos/problemáticos, foram implementadas com topologia *feedforward* multicamadas treinadas com o algoritmo *Backpropagation*. Como forma de comparação dos critérios utilizados para a escolha do algoritmo *Backpropagation* para o treinamento das redes, estas mesmas topologias foram implementadas, neste trabalho, com um algoritmo distinto baseado no princípio de treinamento Não-Supervisionado [KOHONEN90]. Uma RNA que usa este princípio e, devido à sua característica de rede heteroassociativa, pode ser aplicado na base de anesthesiologia é a denominada *Counterpropagation* [HECHT-NIELSEN87].

A rede *Counterpropagation* também utiliza três camadas, sendo a primeira um "buffer" da dados na qual são apresentados os padrões de treinamento. A segunda camada (camada oculta) realiza um aprendizado não-supervisionado baseado no treinamento competitivo [CALOBA92]. Esta camada competitiva representa a principal característica da rede *Counterpropagation*, sendo nesta camada que a rede realiza a maior parte do processo de aprendizagem e representação de conhecimento. A camada

de saída é uma camada Grossberg [DAYHOFF90] treinada pela regra *Grossberg* ou *Widrow-Hoff* [WIDROW90]. Esta camada, na prática, existe para determinar a característica de heteroassociatividade da *Counterpropagation*, realizando uma “compatibilização” dos resultados do treinamento não-supervisionado da camada intermediária com o formato desejado dos dados de saída da rede. Para isso, o treinamento desta camada é supervisionado, através da regra *Grossberg* ou *Widrow-Hoff*.

O treinamento não-supervisionado ou “auto-organizável” da camada intermediária está baseado no princípio de que é possível a identificação de classes de um padrão por similaridade, e não informando previamente a qual classe pertence este padrão.

O processo de treinamento *Counterpropagation* inicia com a apresentação de um padrão à rede. Os neurônios da camada oculta, através da soma ponderada das conexões com a camada de entrada, realizam um processo “competitivo” no qual um único neurônio “vence” e permanece ativo. Este neurônio e seus pesos representam uma classe do padrão de entrada, classificando os demais padrões apresentados por similaridade. A camada de saída realiza uma média dos vetores de pesos que surgem cada vez que um neurônio da camada competitiva vence. Esta estrutura é chamada “Outstar” [HECHT-NIELSEN87].

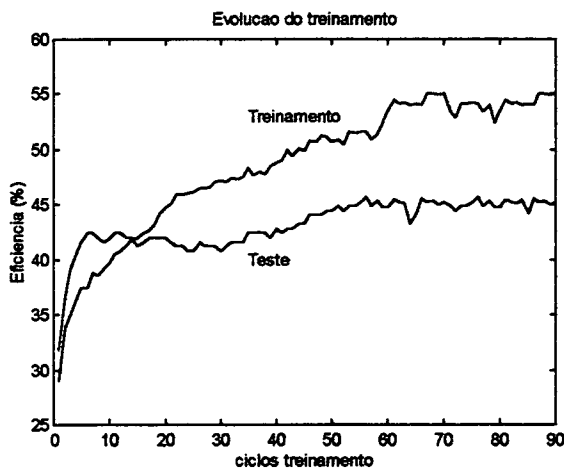
As RNAs “Classificação do Estado Físico do Paciente”, “Pré-medicação Anestésica” e “Técnica Anestésica” do sistema de anestesiologia foram implementadas com a *Counterpropagation* sendo mostrados abaixo uma tabela comparativa com os resultados do algoritmo *Backpropagation*. É



mostrado também a evolução do treinamento com a *Counterpropagation* para a rede de “Classificação do Estado Físico”.

RNAs	<i>Backpropagation</i>		<i>Counterpropagation</i>	
	Conj.	Conj.	Conj.	Conj.
	Treino	Testes	Treino	Testes
Classificação do Estado Físico	96	66	55	45
Pré-Medicação Anestésica	82	60	62	52
Técnica Anestésica	87	50	45	40

Tabela 8 - Comparação de eficiências entre os algoritmos *Backpropagation* e *Counterpropagation*



Camada de Entrada = 298  
 Camada Intermediária = 33  
 Camada de Saída = 5  
 Resultado de Eficiência :  
 Conjunto de Treinamento = 55 %  
 Conjunto de Testes = 45 %

Figura 27 - Evolução do treinamento para o algoritmo *Counterpropagation* representando a rede Classificação do Estado Físico do Paciente

Como pode ser observado na Tabela 8 e Figura 27, o desempenho da *Counterpropagation* mostrou-se bastante deficiente nesta aplicação. O processo de classificação, utilizando o aprendizado competitivo, desempenhado pela camada de *Kohonen* na topologia *Counterpropagation*, não conseguiu realizar o mapeamento necessário para classificar as regiões

dos padrões representados pelo conjunto de treinamento da base de dados em anestesiologia.

### 5.3 - APLICAÇÃO DO ALGORITMO LOGIC

A seguir são mostrados os resultados da aplicação do algoritmo LOGIC sobre redes treinadas para a representação do conhecimento médico anesthesiológico. Para aplicação do algoritmo, foram treinadas com *Backpropagation* topologias especiais derivadas das redes “Classificação do Estado Físico” e “Pré-medicação Anestésica” do PROVANES. Os resultados são mostrados como regras gerais de causa-efeito que relacionam diretamente as entradas e saídas das RNAs.

Estas topologias especiais, como descrito no capítulo 4 - implementações dos algoritmos LOGIC e PERCEP, foram utilizadas pois para a geração de regras de produção completas, considerando os neurônios da camada intermediária (e não somente de regras de causa-efeito que relacionam hipóteses - elementos da camada de entrada e conclusões - elementos da camada de saída), é necessário que estes neurônios da camada intermediárias possuam atribuição específica. Esta condição ocorre em redes do tipo “baseadas em conhecimento” discutidas no capítulo 2.3 mas não ocorre nas topologias, como as implementadas no PROVANES, que consideram os neurônios da camada intermediária sem uma atribuição específica (condição esta, aliás, muito utilizada e encontrada nas aplicações de RNAs). Para a obtenção das regras de causa-efeito citadas acima, portanto, foram treinadas topologias especiais de RNAs, derivadas das implementações originais do PROVANES, em que a camada intermediária foi suprimida. Ressalta-se que estas topologias especiais, treinadas com *Backpropagation* para a posterior aplicação dos algoritmos, não são indicadas para aplicação direta no processamento das redes do PROVANES devido a características não desejadas como rápida

especialização e deficiências de representação e generalização, porém serão utilizadas para permitir a verificação da organização dos pesos ao representar e relacionar as diferentes entradas com as classes possíveis de respostas.

Portanto, fica ressaltada a restrição da aplicabilidade direta dos algoritmos LOGIC e PERCEP sobre as atuais topologias utilizadas no PROVANES, sendo necessário, para a eliminação desta restrição, um trabalho de redefinição das topologias associando aos neurônios das camadas intermediárias atribuição específica como, por exemplo, diagnósticos médicos parciais. Esta questão será rediscutida, neste trabalho, no capítulo Conclusões e Discussões.

Os resultados da aplicação do algoritmo LOGIC, portanto, sobre as matrizes de pesos e "bias" da topologias especiais das redes treinadas são portas lógicas, das quais podem ser extraídas regras do tipo IF (entradas) AND NOT (entradas) THEN (saída), mostradas nas tabelas a seguir. Primeiramente são mostrados todas as conexões geradas para uma porta lógica específica. Dessa forma, o valor "+1" significa uma entrada "Diretamente Conectada", o valor "-1" significa uma entrada "Inversamente Conectada" e o valor "0" significa uma entrada "Não Importa".

- PORTA LÓGICA GERADA PARA O GRAU 1 DA REDE DE CLASSIFICAÇÃO DO ESTADO FÍSICO :

```
-1 +1 -1 0 +1 -1 0 -1 -1 0 -1 0 0 0 -1 -1 0 -1 0 +1 0 0 0 -1 -1 -1 -1 -1 -1 -1 -1 0 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1
0 -1 0 0 0 -1 -1 -1 0 0 0 -1 -1 0 0 -1 0 -1 0 0 -1 -1 -1 -1 0 0 -1 0 0 -1 0 0 -1 0 0 -1 -1 -1 -1 -1 -1 0 -1 -1 -1
0 0 0 -1 -1 -1 -1 0 -1 -1 -1 -1 -1 -1 -1 0 -1 -1 0 -1 0 -1 -1 -1 -1 -1 -1 -1 0 -1 0 0 -1 0 -1 -1 0 0 0 0 -1 -1 -1
-1 -1 -1 -1 -1 -1 -1 -1 -1 0 0 0 0 -1 -1 -1 +1 -1 -1 0 -1 -1 0 0 0 -1 -1 -1 0 -1 -1 -1 -1 -1 0 -1 0 -1 -1 -1 -1 0
0 -1 -1 -1 -1 -1 -1 -1 -1 0 -1 -1 -1 0 0 0 -1 -1 -1 0 0 -1 -1 -1 -1 0 -1 +1 -1 -1 0 -1 0 -1 -1 -1 0 -1 0 0 0
-1 -1 -1 0 0 0 -1 0 -1 0 -1 -1 -1 -1 0 -1 -1 -1 0 -1 -1 -1 -1 -1 -1 -1 0 -1 -1 -1 -1 -1 -1 -1 -1 0 -1 -1 -1 0
0 -1 0 0 0 0 -1 -1 -1 -1 -1 -1 0 -1 -1 0 0 -1 -1 0 -1 0 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 0 -1 -1 -1 0
```

- REGRA "IF AND NOT THEN" ASSOCIADA:

Estado físico grau 1 da RNA Classificação do Estado Físico do Paciente

<b>IF</b>	ELETIVO FRAT/LUX MEMVROS	AMBULATORIAL	JEJUM : MAIS DE 6HS	ESTADO EMOC. CALMO
<b>AND NOT</b>	IDADE	ANEMIA MEGALOBLASTICA ANEMIA SECUNDARIA	INFECCAO DAS VIAS AEREAS INFERIO INFECCAO PARENQUIMATOSA PNEUMOPATIA RESTRITIVA PNEUMOTORAX	DIABETE MELITO TIPO II HIPERTIREOIDISMO HIPOTIREOIDISMO INSUFICIENCIA SUPRARRENAL OBESIDADE SINDROME DE CUSHING SECRECAO INAPROPRIADA DE ADH ABERRACOES CROMOSSOMICAS OUTRAS
ECG : DISRRITMIA VENTRICULAR	EMERGENCIA			
ECG : BLOQUEIO A-V	INTERNADO	CIVD		
ECG : BLOQUEIO DE RAMO	UTI/UTC	HEMOFILIAS		
ECO : SOBRECARGA DE CAMARAS ECG : ISQUEMIA SUBENDOCARDICA ECG : ISQUEMIA SUBEPICARDICA	ALCOOL ANFETAMINA OPIOIDES	LEUCEMIA MIELOMA POLICITEMIA	SARA/SARI TRAUMA TORACICO HEMODIALISE	
ECG : ISQUEMIA TRANSMURAL	SEDATIVOS	PURPURA	INFECCAO DAS VIAS URINARIAS IRA	
ECG : ZONAS INATIVAS	MENOS DE 2h	SIND. COAGULO INTRACAVITARIO CIRROSE		
ECG : ALTERACOES DE REPOLARIZACA	ABDOME AGUDO OBSTRUTIVO		IRC	AIDS
GASOMETRIA NORMAL	ABDOME AGUDO PERFURATIVO	HIPERTENSAO PORTAL	SINDROME NEFRITICO	ANEMIA APLASTICA
HIPOXEMIA ARTERIAL	ABDOME AGUDO TRAUMATICO	ICTERICIA HEPATOCELULAR ICTERICIA OBSTRUTIVA	SINDROME NEFROTICO	LIMITACAO DE ABERTURA DE BOCA LES
HIPOCAPNIA	HEMORRAGIA DIGESTIVA		TRAUMA DAS VIAS URINARIAS UROPATIA OBSTRUTIVA	
pVO2 AUMENTADA	HEMORRAGIA INTRAABDOMINAL	INSUFICIENCIA HEPATICA AVC HEMORRAGICO	ALERGIA A DROGAS	OSTEITES
D(s-v)O2 AUMENTADA	INCOMPETENCIA CARDIOESOFAGICA MASSAS	AVC ISQUEMICO	COMPLICACAO DE ANESTESIA ANTERIO	OSTEOPATIA DEGENERATIVA ASMA
D(s-v)O2 DIMINUIDA	ABDOMINO/PELVICAS VOLUMOS OBSTRUCAO PILORICA	COMA		BRONCOPASMO
ACIDOSE METABOLICA	ULCERA PEPTICA / GASTRITE	DISTROFIA MUSCULAR	DISTURBIOS DO SENSORIO E CONDUTA FALENCIA DE MULTIPLS SISTEMAS GRANDE QUEIMADO	BRONQUITIE CRONICA
ALCALOSE METABOLICA	ARTERIOPATIA PERIFERICA	EPILEPSIA		DERRAME PLEURAL
ACIDOSE RESPIRATORIA	CARDIOPATIA CONGENITA ACIANOTICA	ESCLEROSE MULTIPLA	HEMORRAGIA AGUDA	ENFISEMA PULMONAR
ALCALOSE RESPIRATORIA	CARDIOPATIA CONGENITA CIANOTICA	GUILLAIN-BARRE	NEOPLASIA	FIBROSE PULMONAR
ALCALEMIA	CARDIOPATIA CONGENITA CIANOTICA	HEMIPLEGIA/PARESIA	POLITRAUMATISMO	FISTULA BRONCO- PLEURAL RX : SARA/EDEMA PULMONAR RX : HIDROTORAX RX : HIPERINSUFL. PULMONAR RX : FIBROSE PULMONAR
BILIRRUBINAS	ISQUEMICA CHOQUE ANAFILATICO	LESAO EXPANSIVA INTRACRANIANA MIASTENIA GRAVIS MONOPLEGIAS/PARESIA	PROTESE DENTARIA/EDENTULO SEPTICEMIA OUTRAS PATOLOGIAS	
CREATININA	CHOQUE CARDIOGENICO CHOQUE HIPOVLEMICO	NEUROPATIA PERIFERICA POLIOMIELITE ATIVA	ESTADO EMOCIONAL: AGITADO ESTADO EMOCIONAL: APATICO A TERMO	
FOSFATASE ALCALINA GLICOSE/GLICEMIA			PRE-TERMO	
HEMOGLOBINA	CHOQUE SEPTICO			
KPTT_TCA	DISRRITMIA SUPRAVENTRICULAR			
LEUCOCITOS	DISRRITMIA VENTRICULAR	POLIOMIELITE-SEQUELA		
OSMOLALIDADE PLASMATICA	HIPERTENSAO ARTERIAL	SINDROME MIASTENICO		

POTASSIO	SISTEMICA IAM PREVIO MAIS DE 6 MESES	TCE	ATRESIA DE ESOFAGO	TORACICA RX : AUMENTO AREA CARDIACA
TAP	IAM TEMPO INDETERMINADO	TRM - FASE AGUDA	ESTENOSE PÍLORICA	ECG : NORMAL/RITMO SINUSAL
UREIA	KCC	TRM - SUB- AGUDO/CRONICO	FISTULA TRAQUEO- ESOFAGICA	ECG : TAQUICARDIA SINUSAL
ACROMEGALIA	PERICARDITE CONSTRICTIVA	TETRAPLEGIA / PARESIA	GASTROSQUISIS	ECG : DISRRITMIA SV
DESNUTRICAÇÃO	PERICARDITES-OUTRAS	DOENÇA CEREBRO- VASCULAR	MENINGO(MIELO)CELE	RX : DEFORMIDADE TORACICA
DIABETE INSÍPIDO	TAMPONAMENTO CARDIACO	ARTIRITE REUMATOIDE	HIPOSTENURIA	RX : SINAIS DE DPOC
FRAT/LUX COLUNA	TROMBOEMBOLISMO PERIFERICO	DEFORMIDADE DA CV	HIPERSTENURIA	RX : CONDENS. PARENQUIMATOSAS
FRAT/LUX COSTELAS	VALVULOPATIA AORTICA	DISCOPATIA CERVICAL	HEMATURIA	RX : ATELECTASIA LAMINAR
FRAT/LUX FACE	VALVULOPATIA MITRAL W-P-W	DISCOPATIA LOMBAR DISOSTOSE CRANIANA/FACIAL	PROTEINURIA	

Tabela 9- Regra gerada para o estado físico grau 1

- PORTA LÓGICA GERADA PARA O GRAU 5 DA REDE DE CLASSIFICAÇÃO DO ESTADO FÍSICO :

0	-1	+1	-1	-1	-1	-1	0	-1	0	-1	-1	0	-1	-1	0	0	0	0	-1	0	0	-1	1	-1			
-1	-1	-1	0	-1	-1	-1	0	-1	-1	0	0	0	0	-1	0	-1	-1	0	-1	0	0	0	-1	-1	0		
0	0	-1	-1	0	-1	0	0	0	1	0	-1	0	0	-1	-1	-1	-1	-1	0	0	-1	0	-1	-1	-1		
0	-1	-1	-1	0	-1	-1	-1	-1	0	-1	0	0	0	0	-1	0	-1	0	0	-1	0	-1	0	-1	0		
0	-1	-1	0	-1	-1	0	-1	-1	0	-1	0	0	0	0	0	0	-1	-1	0	0	1	-1	0	0	-1	-1	0
-1	-1	0	0	0	-1	-1	-1	0	-1	-1	-1	0	-1	0	0	-1	0	-1	-1	-1	-1	-1	-1	-1	-1	-1	0
-1	-1	-1	0	0	0	0	0	-1	-1	-1	0	-1	-1	-1	0	-1	-1	0	-1	0	0	-1	-1	-1	-1	-1	-1
0	0	0	0	-1	-1	-1	0	-1	1	-1	0	0	0	0	-1	1	0	0	-1	0	-1	0	-1	-1	-1	1	-1
0	0	0	-1	-1	-1	0	0	0	1	-1	-1	-1	1	-1	-1	-1	0	0	0	-1	0	0	-1	-1	0	-1	-1
-1	-1	-1	0	-1	-1	-1	-1	0	-1	-1	-1	0	-1	-1	1	-1	-1	-1	-1	0	0	0	-1	-1	-1	-1	-1
-1	0	-1	0	-1	-1	0	-1	0	-1	0	0	-1	-1	0	0	-1	-1	0	0	-1	0	-1	-1	0	-1	-1	-1
0	1	-1	0	0	0	-1	0	-1	-1	0	0	-1	-1	0	0	1	1	0	0	0	0	-1	-1	-1	1	-1	-1

- REGRA "IF AND NOT THEN" ASSOCIADA:

Estado físico grau 5 da RNA Classificação do Estado Físico do Paciente

<b><u>IF</u></b>	FRAT/LUX FACE	CHOQUE HIPOVOLEMICO	ABDOME AGUDO TRAUMATICO
	EMERGENCIA	DISRRITMIA SUPRAVENTRICUL AR	HEMORRAGIA INTRAABDOMINAL
	Politraumatismo	COMA	
<b><u>AND NOT</u></b>	PROTESE VALVAR	LESÃO EXPANSIVA INTRARAQUIDEA	PNEUMOTORAX
<b><u>ELETIVO</u></b>	TRAUMA CARDIACO	MIASTENIA GRAVIS	TRAUMA TORACICO
URGENCIA	TROMBOEMBOLISMO PERIFERICO	MIOTONIAS	INFECÇÃO DAS VIAS URINARIAS
AMBULATORIAL	TROMBOEMBOLISMO ABDOMINAL	MONOPLEGIAS/PARESIA	SINDROME HEFROTICO
INTERNADO	VALVULOPATIA AORTICA	OCULOPLEGIA/PARESIA	UROPATIA OBSTRUTIVA
UCCP	VALVULOPATIA MITRAL	FE DIABETICO	ATOPIAS
ALCOOL	W-P-W	POLIMIÉLITE- SEQUELA	COMPLICAÇÃO DE ANESTESIA ANTERIO
ALUCINOGENOS	ACROMEGALIA	SINDROME MIASTENICO	DISTURBIOS DO SENSORIO E CONDUTA
ANFETAMINA	SOCIOATÓXICO	TCE	GESTACÃO DE 15
			RX : FRATURA COLUNA/COSTELAS
			RX : CONDENS. PARENQUIMATOSAS
			RX : ATELECTASIA LAMINAR
			RX : PNEUMOTORAX
			RX : HIDROTORAX
			RX : HIPERINSUFL. PULMONAR
			RX : FIBROSE PULMONAR
			RX : ALT. MORTA TORACICA
			RX : AUMENTO AREA

CIRRAGO	FEOCROMOCITOMA	TRM - FASE AGUDA	TRIMESTRE HEMORRAGIA AGUDA	CARDIACA ECG : NORMAL/RITMO SINUSAL
MACONHA	HIPERPARATIREOIDISMO HIPOPARATIREOIDISMO	TRM - SUB- AGUDO/CRONICO	NEOPLASIA	ECG : TAQUICARDIA SINUSAL
2-6h		TETRAPLEGIA / PARESIA	PEQUENO E MEDIO QUEIMADO	ECG : DISRRITMIA SV
MAIS DE 6h	INSUFICIENCIA SUPRARRENAL	DOENÇA CEREBRO- VASCULAR	OUTRAS PATOLOGIAS	ECG : DISRRITMIA VENTRICULAR
ASCITE	SINDROME DE CUSHING	DEFORMIDADE DA CV	ESTADO EMOCIONAL: AGITADO	ECG : BLOQUEIO DE RAMO
ABDOME AGUDO INFLAMATORIO	SECRECAO	DISCOPATIA CERVICAL	ESTADO EMOCIONAL: ANSIOSO	ECG : ISQUEMIA SUBENDOCARDICA
ABDOME AGUDO OBSTRUTIVO	INAPROPRIADA DE ADE OUTRAS	DISCOPATIA LOMBAR	ESTADO EMOCIONAL: CALMO	ECG : ZONAS HEATIVAS
ABDOME AGUDO PERFORATIVO	AIDS	FRAT/LUX BACIA	A TERMO	ECG : ALTERACOES DE REPOLARIZACA
INCOMPETENCIA CARDIOESOFAGICA	ANEMIA FALCIFORME	FRAT/LUX COLUNA	PRE-TERMO	GASOMETRIA NORMAL
MASSAS ABDOMINO/PELVICAS VOLUMOS	ANEMIA FERROPRIVA	FRAT/LUX COSTELAS	ESTROSE PILORICA	HIPOXEMIA ARTERIAL
ARTERIOPATIA PERIFERICA	ANEMIA	LIMITACAO DE	HERNIA	HIPOCAPNIA
CARDIOPATIA CONGENITA ACIANOTICA	MEGALOBLASTICA	ABERTURA DE BOCA	DIAPHRAGMATICA	D(a-a)O2 AUMENTADA
CARDIOPATIA ISQUEMICA	ANEMIA SECUNDARIA	LES	MENINGO (MIELO)CELE	Ca/Qt AUMENTADO
DISRRITMIA VENTRICULAR	HEMOFILIAS	OSTEITES	OSFALOCLELE	pvcO2 AUMENTADA
	CIRROSE	OSTEOPATIA DEGENERATIVA	URINA NORMAL	
HIPERTENSAO ARTERIAL PULMONAR	HIPERTENSAO PORTAL	RETRACAO CICATRICAL	HIPOSTENURIA	D(a-v)O2 AUMENTADA
		TROMBO/AXIL		
IAM PREVIO MENOS DE 3 MESES	INFECCAO	BRONCOPASMO	HIPERSTENURIA	ALCALOSE METABOLICA
IAM PREVIO 3-6 MESES	HEPATOBILIAR	BRONQUITE CRONICA	LEUCOCITURIA	ALCALEMIA
IAM PREVIO MAIS DE 6 MESES	AVC HEMORRAGICO	CISTO AEREO	CILINDRURIA	CALCIO
IAM TEMPO INDETERMINADO	AVC ISQUEMICO	DERRAME PLEURAL	BACTERIURIA	CKE/CK-MB
MARCAPASSO	DISTROFIA MUSCULAR	INFECCAO DAS VIAS AEREAS SUPERIO	GLICOSURIA	CREATININA
	EPILEPSIA	INFECCAO	RADIOGRAFIA NORMAL	FOSFORO
PERICARDITE CONSTRICTIVA	HIPERTENSAO	PARENQUIMATOSA	RE : DEFORMIDADE TORACICA	GLICOSE/GLICEMIA
PERICARDITES-OUTRAS	INTRACRANIANA	INFECCAO PLEURAL	TRANSAMINASES	
	LESAO EXPANSIVA			
PR CURTO	INTRACRANIANA			
	SODIO	TAP		

Tabela 10 - Regra gerada para o estado físico grau 5

- PORTA LÓGICA GERADA PARA A MEDICAÇÃO  
BENZODIAZEPÍNICO DA REDE DE PRÉ-MEDICAÇÃO ANESTÉSICA :

0	1	-1	-1	-1	1	-1	-1	-1	0	0	0	1	0	0	0	-1	0	0	0	-1	-1	-1	-1	-1	0	-1	-1
0	0	-1	0	-1	-1	-1	1	-1	0	-1	-1	-1	0	0	0	-1	-1	-1	0	-1	0	-1	0	-1	0	-1	0
0	0	0	0	-1	0	-1	-1	0	0	0	0	-1	-1	-1	0	-1	0	0	-1	0	0	0	-1	0	-1	-1	0
0	-1	-1	0	0	0	-1	0	0	-1	0	-1	-1	-1	0	0	0	0	0	0	0	0	0	0	-1	0	0	-1
0	-1	-1	-1	0	-1	0	-1	0	-1	-1	0	-1	-1	0	-1	-1	0	-1	-1	0	0	0	0	0	0	-1	0
-1	-1	0	-1	0	-1	0	-1	-1	0	0	-1	-1	-1	0	0	0	-1	-1	0	-1	0	-1	0	0	-1	-1	-1
-1	-1	0	-1	-1	-1	0	-1	0	0	0	-1	1	-1	0	-1	-1	0	-1	-1	0	0	-1	0	-1	0	-1	1
0	0	0	0	1	-1	-1	0	-1	-1	-1	0	-1	-1	-1	0	-1	0	0	-1	0	-1	0	0	-1	-1	0	-1
-1	-1	-1	-1	-1	-1	0	0	0	-1	0	0	0	-1	0	0	-1	0	0	-1	0	0	1	-1	0	0	-1	0
0	-1	-1	0	0	-1	-1	0	0	0	0	-1	-1	-1	-1	0	0	0	-1	-1	0	-1	-1	0	0	-1	-1	-1
0	0	-1	0	-1	0	0	-1	0	0	0	0	-1	-1	0	0	0	-1	-1	0	0	0	0	-1	0	0	-1	-1
1	0	-1	-1	-1	-1	-1	0	-1	-1	-1	0	0	0	0	0	0	0	0	-1	-1	0	-1	0	-1	0	0	0
0	0	-1	-1	-1	-1	0	0	0	0	-1	0	0	0	-1	0	0	0	0	-1	-1	-1	0	-1	0	0	0	0
0	0	0	0	0	0	0	0	-1	0	-1	0	0	0	-1	0	0	-1	0	0	0	0	-1	-1	0	-1	-1	-1
1	0	0	0	0	-1	0	-1	0	0	-1	-1	-1	-1	0	-1	-1	-1	-1	-1	-1	0	-1	-1	-1	0	0	-1
-1	0	0	-1	0	-1	0	-1	0	0	0	0	-1	-1	-1	-1	0	-1	-1	-1	0	0	0	-1	0	0	0	-1

- REGRA "IF AND NOT THEN" ASSOCIADA:

### Medicação Benzodiazepínico da Rede de Pré-Medicação Anestésica

<b>IF</b>	<b>ELETIVO</b>	<b>INTERNADO</b>	<b>FUMANTE</b>	<b>CARDIOPATIA ISQUEMICA ESTADO EMOCIONAL: CALMO</b>
<b>AND NOT</b>	EMERGENCIA	W-P-W	TETRAPLEGIA / PARESIA	ALCALOSE RESPIRATORIA CALCIO
A TERMO	URGENCIA	DIABETE INSIPIDO	DOENCA CEREBRO-VASCULAR	CPK/CK-MB
PRE-TERMO	AMBULATORIAL	DIABETE MELITO TIPO I	ESCLERODERMIA	FOSFATASE ALCALINA
ATRESIA DE ESOFAGO	UCCP	DIABETE MELITO TIPO II	FEBRE REUMATICA AIIVA	FOSFORO
ENFISEMA LOMBAR	UTI/UTC	HIPERINSULINISMO	FEBRE REUMATICA INATIVA	HEMOGLOBINA KPTT_TCA
ESTENOSE PILORICA	ALCOOL	HIPOFISITARISMO	FRAT/LUX COLUNA	LEUCOCITOS
GASTROSQUISIS	OUTROS	OBESIDADE	FRAT/LUX FACE	
HERNIA DIAFRAGMATICA	ESTOMAGO CHEIO	SECRECAO	LIMITACAO DE ABERTURA DE BOCA LES	FLAQUETAS
MENINGO(MELO)CELE	ASCITE	INAPROPRIADA DE ADH		
ONFALOCELE	ABDOME AGUDO INFLAMATORIO	ABERRACOES CROMOSSOMICAS	OSTEOPATIA DEGENERATIVA	SODIO
HIPERSTENURIA	ABDOME AGUDO OBSTRUTIVO	ERROS INATOS DO METABOLISMO	RETRACAO CICATRICIAL FACE/PESCOO	UREIA
LEUCOCITURIA	ABDOME AGUDO PERFURATIVO	ANEMIA FALCIFORME	RETRACAO CICATRICIAL TRONCO/AXIL	AMINOFILINA
GLICOSURIA	ABDOME AGUDO TRAUMATICO	ANEMIA SECUNDARIA	BRONQUITE CRONICA	AMINOGLICOSIDEOS
PROTEINURIA	HEMORRAGIA INTRAABDOMINAL	HIPOPROTROMBINEMIA	CISTO AEREO	ANALGESICO-OUTRO
RX : DEFORMIDADE TORACICA	INCOMPETENCIA CARDIOESOFAGICA	MIELOMA	ENFISEMA PULMONAR	ANTAG. BENZODIAZEPINICO
RX : SINAIS DE DPOC	ULCERA PEPTICA/ GASTRITE	POLICITEMIA	FISTULA BRONCO-PLEURAL	ANTAGONISTA HI - OUTROS
RX : CONDENS. PARENQUIMATOSAS	ARTERIOPATIA PERIFERICA	PURPURA	INFECCAO PARENQUIMATOSA	ANTICOLINESTERASICO
RX : ATELECTASIA LAMINAR	CARDIOPATIA CONGENITA ACIANOTICA	AVC ISQUEMICO	INFECCAO PLEURAL	ANTIHIPERTENSIVO CENTRAL
RX : SARA/EDEMA PULMONAR	CARDIOPATIA CONGENITA CIANOTICA	EPILEPSIA	PNEUMOPATIA RESTRIITIVA	ANTI-PARKINSONIANO
RX : PNEUMOTORAX	CHOQUE ANAFILATICO	HEMIPLEGIA/PARESIA	SARA/SARI	ANTIPISSICOTICO-FENOTIAZINA
RX : HIDRATORAX	CHOQUE HIPOVolemico	HIPERTENSAO INTRACRANIANA	TRAUMA TORACICO	ASPIRINA
RX : LINHAS B DE KERLEY	CHOQUE SEPTICO	LESAO EXPANSIVA INTRACRANIANA	ANOMALIA CONGENITA	ATROPINA
ECG : DISRRITMIA SV	DISRRITMIA SUPRAVENTRICULAR	MENINGISMO/MENINGITE	DIALISE PERITONIAL	BENZODIAZEPINICO-OUTRO
ECG : BLOQUEIO DE RAMO	HIPERTENSAO ARTERIAL PULMONAR	MIOTONIAS	HEMODIALISE	BETA-AGONISTA-OUTRO
ECG : ISQUEMIA TRANSMURAL	IAM PREVIO MENOS DE 3 MESES	NEUROPATIA PERIFERICA	IRA	BETABLOQUEADORE-OUTRO
ECG : SINAIS DIST. ELETROLITICO	IAM PREVIO 3-6 MESES	OCULOPLEGIA/PARESIA	TRAUMA DAS VIAS URINARIAS	BLOQUEADOR CANAL DE CALCIO
HIPOXEMIA ARTERIAL	IAM TEMPO INDETERMINADO	PARKINSONISMO	ALERGIA A DROGAS	CARBONATO DE LITIO
HIPERXEMIA ARTERIAL	LESOES VASCULARES TRAUMATICAS	PE DIABETICO	COMPLICACAO DE ANESTESIA ANTERIO	CEFALOSPORINA
RELACAO (a/A) O2 REDUZIDA	MARCAPASSO	POLIOMIELITE-SEQUELA	DISTURBOS DO SENSORIO E CONDUTA	CITOSTALICOS/IMUNOSSU PRESSOR DIGITALICO
D(A-a)O2 AUMENTADA	PERICARDITE CONSTRITIVA	SINDROME MIASTENICO	GESTACAO DE 1§ TRIMESTRE	DIMENIDRINATO
D(s-v)O2 DIMINUIDA	PR CURTO	TRM - FASE AGUDA	GESTACAO DE 2§ E 3§ TRIMESTRE	DIPIRONA
ACIDOSE METABOLICA	TROMBOEMBOLISMO PULMONAR	POLITRAUMATISMO	HEMORRAGIA AGUDA	ETILEFRINA
ALCALOSE METABOLICA	VALVULOPATIA MITRAL	SEPTICEMIA	PEQUENO E MEDIO QUEIMADO	FENOBARBITAL
ACIDOSE RESPIRATORIA	DIURETICOS-OUTROS	ERGOT - DERIVADOS	ESCOPOLAMINA	ENDOSCOPIA RESPIRATORIA
HEPARINA	XANTINAS-OUTRAS	MEDIASTINO	PAREDE TORAXICA	ENDOSCOPIA URINARIA
IMUNOGLOBULINA/ANATOXINA	OUTRAS DROGAS	MI	PESCOCO	LITOTRIPSIA
LAXANTE OSMOTICO/OUTROS	CAVIDADE CRANIANA/CRANEO	MS	PULMAO	PERCUTANEA/EXTRACOR P
LIDOCAINA	CAVIDADE ABDOMINAL	NARIZ	TRAQUEIA	PERITONIOSCOPIA
MANITOL	COLUNA VERTEBRAL	ORGAO GENITAIS	VASOS	MEDIASTINOSCOPIA
METOCLOPRAMIDA	COURO CABELUDO	OROFARINGE	INTRACRANIANOS	RADIODIAGNOSTICO
PROMETAZINA	FACE	OUVIDO	VASOS MI	RTU DE PROSTATA
PROTAMINA	INTESTINO DELGADO	PANCREAS	VASOS TORACICOS	TEMPO_CIRURGIA
SAIS DE FERRO	LOMBOSACRAL	PAREDE ABDOMINAL	NERVOS	
TRIMETAFAAN			ARTROSCOPIA	

Tabela 11 - Regra gerada para a pré-medicação anestésica Benzodiazepínico



As tabelas acima representam algumas das portas lógicas geradas através do algoritmo LOGIC. O número total de portas geradas nas redes chegam aos seguintes valores :

RNA Classificação do Estado Físico do Paciente	
Neurônio de Saída	Número de portas geradas
Grau 1	50
Grau 2	75
Grau 3	24
Grau 4	32
Grau 5	08

Tabela 12 - Número de portas lógicas geradas para a rede de Estado Físico

RNA Pré-Medicação Anestésica	
Neurônio de Saída	Número de portas geradas
Benzodiazepínico	298
Opióide	17
Barbitúrico	03
Neuroléptico	07
Antihistamínico H1-H2	21
Bloqueador Muscarínico	92
Gastrocinético	57
Não Necessária	133

Tabela 13 - Número de portas lógicas geradas para a rede de Pré-Medicação Anestésica

Observações a respeito dos resultados apresentados:

1 - O número de portas lógicas geradas está diretamente relacionado com as combinações possíveis de ativação do neurônio e, obviamente, com o número de ativações de uma determinada saída. Alguns números elevados de portas geradas representando os neurônios nas RNAs de anestesiologia surgem em função das diversas combinações possíveis, segundo a fórmula 4.7 apresentada no capítulo 4 :

$$W_1 * E_1 + W_2 * E_2 + \dots + W_n * E_n \geq -W_0$$

Ou seja, diferentes combinações de pares do produto  $W_i * E_i$  podem representar condição suficiente para superar o valor do "bias" de um determinado neurônio. Se este número de combinações, portanto, for elevado, também será elevado o número de portas lógicas.

2 - É relevante observar que os resultados mostrados indicam somente a forma de organização dos pesos para diferentes classes de padrões (ou pacientes). Neste sentido, as regras de causa-efeito resultantes da aplicação do LOGIC no sistema de anestesiologia, apesar de indicarem, na maioria dos casos, uma relação coerente entre hipóteses e classes, não podem ser consideradas como regras válidas para a implementação de um módulo de explanação. Esta limitação surge em função, principalmente, de dois aspectos básicos : O número excessivo de antecedentes gerados pela aplicação do LOGIC, já que a camada intermediária foi suprimida e, também, porque o algoritmo considera todas as relações "Entrada\*Peso" com o mesmo grau de importância, o que pode gerar conclusões distorcidas a respeito da importância entre uma entrada preponderante

para uma conclusão (como por exemplo, indicação de paciente com “Politraumatismo”) e outra entrada sem o mesmo grau de preponderância (como por exemplo, “Estado Emocional”).

#### 5.4 - APLICAÇÃO DO ALGORITMO PERCEP

Conforme descrito no capítulo 4 (implementações), diferentemente do algoritmo LOGIC, este algoritmo busca “filtrar” as combinações mais importantes e representativas que ativam um determinado neurônio. Novamente considerando as topologias especiais implementadas (sem camada intermediária) para verificação da aplicabilidade dos algoritmos, são apresentados, abaixo, os resultados da aplicação do algoritmo PERCEP nas redes de “Classificação do Estado Físico” e “Técnica Anestésica”.

Convém ressaltar as restrições de aplicação do PERCEP, discutidas nos resultados do algoritmo LOGIC, sobre topologias de RNAs em que os neurônios da camada intermediária não possuam atribuição específica, como ocorre no PROVANES.

## Estado físico Grau 4 da RNA Classificação do Estado Físico do Paciente

Entradas Excitatórias ("SE APRESENTAR")	Contribuição (%)	Entradas Inibitórias ("SE NÃO APRESENTAR")	Contribuição (%)
URGENCIA	(0.9)	ELETIVO	(4.2)
UTI/UTC	(4.8)	AMBULATORIAL	(1.3)
ALCOOL	(2.1)	INTERNADO	(0.6)
2-6h	(1.1)	UCCP	(1.6)
ASCITE	(3.2)	FUMANTE	(1.3)
ABDOME AGUDO	(1.9)	SEDATIVOS	(0.8)
INFLAMATORIO			
ABDOME AGUDO	(2.3)	MENOS DE 2h	(2.1)
OBSTRUTIVO			
ABDOME AGUDO	(3.3)	MAIS DE 6h	(1.1)
PERFURATIVO			
ABDOME AGUDO	(2.2)	ESTOMAGO CHEIO	(1.2)
TRAUMÁTICO			
ARTERIOPATIA PERIFERICA	(1.1)	HEMORRAGIA DIGESTIVA	(1.1)
CARDIOPATIA ISQUEMICA	(2.1)	HEMORRAGIA	(4.4)
		INTRAABDOMINAL	
CHOQUE HIPOVOLEMICO	(0.7)	INCOMPETENCIA	(0.6)
		CARDIOESOFAGICA	
DISRRITMIA	(2.7)	ULCERA PEPTICA	(1.2)
SUPRAVENTRICULAR		/GASTRITE	
IAM PREVIO MENOS DE 3	(1.6)	CHOQUE CARDIOGENICO	(2.0)
MESES			
IAM TEMPO	(0.5)	CHOQUE SEPTICO	(1.5)
INDETERMINADO			
ICC	(0.7)	DISRRITMIA VENTRICULAR	(0.5)
PERICARDITES-OUTRAS	(2.5)	MARCAPASSO	(0.6)
VALVULOPATIA MITRAL	(0.9)	W-P-W	(0.8)
DESNUTRICAÇÃO	(3.5)	DIABETE MELITO TIPO II	(1.5)
DIABETE MELITO TIPO I	(0.5)	FEOCROMOCITOMA	(0.5)
ERROS INATOS DO	(0.5)	HIPOPITUITARISMO	(0.6)
METABOLISMO			
ANEMIA FALCIFORME	(0.5)	OBESIDADE	(1.1)
ANEMIA SECUNDARIA	(3.6)	PURPURA	(0.7)
CIRROSE	(0.7)	COMA	(0.6)
ICTERICIA	(0.8)	EPILEPSIA	(0.6)
HEPATOCELULAR			
ICTERICIA OBSTRUTIVA	(1.3)	PARKINSONISMO	(1.0)
INSUFICIENCIA HEPATICA	(0.8)	ARTRITE REUMATOIDE	(0.6)
AVC ISQUEMICO	(2.0)	DISCOPATIA LOMBAR	(0.7)
HEMIPLEGIA/PAREZIA	(0.6)	FRAT/LUX FACE	(3.6)
HIPERTENSAO	(1.4)	FRAT/LUX MEMBROS	(1.9)
INTRACRANIANA			
PARAPLEGIA/PAREZIA	(1.2)	INFECCAO DAS VIAS	(1.1)
		AEREAS INFERIOR	
PE-DIABETICO	(0.7)	SARA/SARI	(1.3)

TCE	(2.4)	HEMODIALISE	(2.2)
TRM - FASE AGUDA	(0.9)	ALERGIA ADROGAS	(1.8)
TRM - SUB-AGUDO/CRONICO	(1.1)	ATOPIAS	(0.5)
TETRAPLEGIA / PARESIA	(1.6)	PROTESE DENTARIA/ EDENTULO	(0.7)
DOENCA CEREBRO- VASCULAR	(1.8)	ESTADOEMOCIONAL: ANSIOSO	(1.1)
DEFORMIDADE DA CV	(2.5)	ESTADOEMOCIONAL: APATICO	(1.1)
OSTEOPATIA DEGENERATIVA	(1.7)	ESTADOEMOCIONAL: CALMO	(3.6)
ASMA	(0.7)		
BRONCOPASMO	(0.8)		
BRONQUITE CRONICA	(2.7)		
ENFISEMA PULMONAR	(0.7)		
INFECCAO	(0.8)		
PARENQUIMATOSA			
PNEUMOTORAX	(1.2)		
INFECCAO DAS VIAS URINARIAS	(3.2)		
SINDROME NEFROTICO	(1.5)		
UROPATIA OBSTRUTIVA	(0.9)		
COMPLICACAO DE ANESTESIA ANTERIOR	(2.0)		
DISTURBIOS DO SENSORIO E CONDUTA	(2.9)		
NEOPLASIA	(2.5)		
OUTRAS PATOLOGIAS	(0.7)		
ESTADO EMOCIONAL : AGITADO	(1.0)		
A TERMO	(0.5)		

Tabela 14 - Regra gerada para o estado físico grau 4

## Técnica Anestésica Regional "Peridural Lombar"

Entradas Excitatórias	Contribuição (%)	Entradas Inibitórias	Contribuição (%)
INTERNADO	(0.6)	EMERGENCIA	(3.5)
UCCP	(1.4)	URGENCIA	(1.5)
FUMANTE	(0.7)	AMBULATORIAL	(1.3)
JEJUM : MENOS DE 2h	(0.9)	ALCOOL	(2.7)
JEJUM : 2-6h	(1.6)	MAIS DE 6h	(0.7)
ABDOME AGUDO	(1.3)	ABDOME AGUDO	(1.1)
OBSTRUTIVO		INFLAMATORIO	
ABDOME AGUDO	(0.7)	ANEURISMA DE AORTA	(0.6)
PERFURATIVO			
ICC	(0.9)	ARTERIOPATIA	(2.5)
		PERIFERICA	
LESOES VASCULARES	(0.5)	CARDIOPATIA	(1.3)
TRAUMATICAS		ISQUEMICA	
TROMBOEMBOLISMO	(0.7)	DISRRITMIA	(0.7)
PERIFERICO		VENTRICULAR	
VALVULOPATIA	(0.5)	PROTESE VALVAR	(0.6)
AORTICA			
CIRROSE	(1.2)	VALVULOPATIA	(1.1)
		MITRAL	
HEMIPLÉGIA/PARESIA	(0.7)	DESNUTRICAÇÃO	(0.8)
TRM - SUB-	(0.6)	DIABETE INSIPIDO	(0.5)
AGUDO/CRONICO			
FRAT/LUX FACE	(0.7)	DIABETE MELITO	(1.5)
		TIPO I	
NEUROFIBROMATOSE	(0.7)	OBESIDADE	(1.0)
OSTEITES	(0.7)	ICTERICIA	(0.7)
		HEPATOCELULAR	
ENFISEMA PULMONAR	(0.5)	AVC ISQUEMICO	(0.5)
TRAUMA TORACICO	(0.5)	EPILEPSIA	(0.7)
ANOMALIA CONGENITA	(1.7)	OCULOPLÉGIA/PARESI	(0.5)
		A	
A TERMO	(1.0)	DEFORMIDADE DA CV	(0.8)
		FRAT/LUX BACIA	(0.7)
		OSTEOPATIA	(1.8)
		DEGENERATIVA	
		ASMA	(1.2)
		BRONQUITE CRONICA	(0.5)
		INFECCAO DAS VIAS	(0.9)
		URINARIAS	
		ATOPIAS	(0.8)
		COMPLICACAO DE	
		ANESTESIA	
		ANTERIOR(-1.2)	
		GLAUCOMA	(0.6)
		NEOPLASIA	(0.9)
		POLITRAUMATISMO	(0.9)

	PROTESE	(1.4)
	DENTARIA/EDENTULO	
	ESTADO EMOCIONAL:	(0.5)
	APATICO	

Tabela 15 - Regra gerada para a Técnica Anestésica Regional Peridural Lombar

As tabelas acima mostram as entradas que mais influem na ativação do neurônio específico. As demais entradas possuem valores que, filtrados, não influem significativamente na ativação.

A filtragem dos valores percentuais de pouco significado para a ativação do neurônio pode ser realizado diretamente na equação 4.11 resultante da aplicação do algoritmo PERCEP :

$$W_{1t} * E_1 + W_{2t} * \overline{E_2} + W_{3t} * E_3 + \dots + W_{nt} * E_n > 1 \quad (4.11)$$

Nas tabelas mostradas acima, por exemplo, todos os pesos abaixo de 0.5% foram filtrados sem prejuízo na representação dos conhecimentos da rede.

- Refinamento do Treinamento :

Uma importante aplicação da transformação ocorrida nos pesos através do algoritmo PERCEP é a possibilidade do refinamento de um treinamento, após a convergência do mesmo. Este refinamento pode ser realizado através da observação de um resultado incompatível da rede (conclusão) quando apresentado uma determinada combinação das entradas (sintomas de um paciente). Alguns algoritmos de refinamento existentes na literatura, como, por exemplo, "TopGEN" [OPITZ95], realizam mudanças na própria topologia da rede, podendo ser necessário novas



etapas de treinamento. Diferentemente de algoritmos deste tipo, o PERCEP permite a alteração somente dos pesos já treinados, buscando priorizar ou realçar uma relação entre uma hipótese ou característica com uma conclusão ou classificação de um padrão.

Para exemplificar esta característica do algoritmo PERCEP, os pesos das topologias sem camada intermediária citadas no capítulo 4, treinadas especialmente para aplicação dos algoritmos LOGIC e PERCEP, serão utilizados para a demonstração da aplicação do refinamento de treinamento. As topologias especiais utilizadas foram derivadas das redes “Classificação do Estado Físico” e “Premedicação Anestésica” do PROVANES. Os pesos destas redes serão alterados para comparar o resultado de aplicação de algumas das “Regras de Filtro” no sistema PROVANES [GARCIA92]. As “Regras de Filtro” do PROVANES são regras gerais que filtram as saídas das redes neurais. Estas regras permitiram introduzir o processamento lógico sobre intuitivo das redes [GARCIA92], representando os conhecimentos do especialista sobre limitações na utilização dos procedimentos e/ou drogas anestésicas em determinadas condições do paciente. Estes filtros verificam se as saídas das RNAs apresentam respostas inconsistentes, verificando a existência de alguma limitação importante que o processo de treinamento da rede não considerou [PASSOLD95].

Algumas destas regras são as seguintes :

- Regra 1 : Para os casos de pacientes de emergência não deve ser indicado nenhuma medicação pré-anestésica;

- Regra 2 : Para os casos de pacientes com as seguintes características :  
Cirurgia no Baço, Estômago, Fígado/Vias Biliares, Intestino Delgado, Intestino Grosso, Membro Inferior, Membro Superior, Órgãos Genitais, Pâncreas, Parede Abdominal, Parede Torácica, Períneo, Vasos Abdominais, Vasos de Membro Inferior, Vasos de Membro Superior, Vias Urinárias; Classificação do Estado Físico IV ou V e Especialidades Traumatologia/Ortopedia ou Vascular, a técnica anestésica de primeira escolha deve ser do grupo Anestesia Geral;
  
- Regra 3 : Para os casos de pacientes com cirurgia em Membro Superior, deve ser evitada a proposta de técnica anestésica Peridural - Lombar;

#### 5.3.1 - Refinamento do Treinamento para a Regra 1

- Regra 1 : Para os casos de pacientes de emergência não deve ser indicado nenhuma medicação pré-anestésica;

Na rede especial treinada para a escolha da medicação pré-anestésica e aplicando-se o algoritmo PERCEP, os pesos transformados que conectam a saída "Não Necessário" (medicação pré-anestésica) e as entradas da rede são os seguintes (serão mostradas somente as conexões que tem preponderância acima de 1 %):

**Relação entre as entradas da rede Pré-Medicação e a saída "Não  
Necessário"**

Entradas Excitatórias	Contribuição (%)	Entradas Inibitórias	Contribuição (%)
EMERGÊNCIA	1.3456	ELETIVO	1.4753
UCCP	1.1010	INTERNADO	1.6706
FUMANTE	1.9764	COCAINA	1.3247
JEJUM : MAIS DE 6h	1.3712	MASSAS	1.7069
		ABDOMINO/PELVICAS	
ESTOMAGO CHEIO	1.2343	VOLUMOSA	
ABDOME AGUDO	1.4191	HIPERTENSAO ARTERIAL	2.7291
INFLAMATORIO		SISTEMICA	
ABDOME AGUDO	1.4281	IAM PREVIO DE 6 MESES	1.0345
PERFURATIVO		ICC	1.8942
ABDOME AGUDO	2.8218	VALVULOPATIA MITRAL	2.4113
TRAUMATICO		CIRROSE	1.8080
HEMORRÁGIA	1.3534		
INTRAABDOMINAL		MONOLEGIAS/PAREZIA	1.4675
ANEMIA SECUNDARIA	1.4370	TCE	1.9450
AVC ISQUEMICO	1.0682	ARTRITE REUMATOIDE	1.2606
PE DIABETICO	1.0805	INFECCAO DAS VIAS	1.1816
FRAT/LUX FACE	1.8638	AREAS INFERIORES	
OSTEOPATIA	1.5303	COMPLICACAO DE	2.2704
DEGENERATIVA		ANESTESIA ANTERIOR	
ENFISEMA PULMONAR	2.1577	ESTADO	1.2448
		EMOCIONAL:AGITADO	
INFECCAO DAS VIAS	1.1169	CILINDRURIA	1.0055
AREAS SUPERIOR			
INFECCAO	1.6371	OUTRAS EXAMES	1.1006
PARENQUIMATOSA			
PNEUMOPATIA RESTRITIVA	1.6457	ECG: NORMAL/SINUSAL	1.5710
TRAUMA TORACICO	1.1472	BILIRRUBINAS	1.3429
IRA	1.8683	ALFA-AGONISTAS-	2.1497
		OUTROS	
ATOPIAS	1.4857	ANTIBIOTICOS-OUTROS	2.1723
DISTURBIOS DO SENSORIO	1.2438	ANTIDREPRESSIVO-	1.3164
E CONDUTA		TRICICLICO	
OUTRAS PATOLOGIAS	1.1429	CEFALOSPORINA	1.0339
RX: ATELECTASIA	1.3606	DIAZEPAN	1.7443
LAMINAR			
ECG:DISRITMIA SV	1.2203	DICLOFENAC	1.3770
KPTT TCA	1.1534	HIPOGLICEMIANTE ORAL	1.6961
AMINOGlicosídeos	1.2785	MIDAZOLAN	1.1907
ANTIHIPERTENSIVO	1.5578	PROPALONOL	2.5565
CENTRAL			
ASPIRINA	1.1514	VASO DILATADORES -	2.0884
		OUTROS	
HEPARINA	1.0700	INTESTINO DELGADO	1.1275
INSULINA	1.1908	PERINEO	1.0635
SAIS DE FERRO	3.1439		
OUTRAS DROGAS	1.1611		
MS	1.3299		

ORGAOS GENITAIS	1.1039	
VASOS MI	1.7378	
ARTROSCOPIA	1.8215	
ENDOSCOPIA URINARIA	1.1322	

**Tabela 16 - Relação entre as entradas da rede de Pré-Medicação e a saída "Não Necessário"**

A entrada específica "Paciente de Emergência" é a entrada de número 03, a qual, após o processo de convergência da rede, coopera com 1,3% para a ativação da saída "Não Necessário", caso esta entrada esteja presente. Do conjunto de pacientes utilizados para o treinamento de rede foram separados pacientes de emergência, que a saída da rede, indevidamente, sugere a aplicação de uma medicação pré-anestésica. Para corrigir esta distorção o peso específico que faz a interligação entre a entrada "EMERGÊNCIA" e a saída "NÃO NECESSÁRIO" foi modificado para 100%. Desta forma garante-se a preponderância a entrada "EMERGÊNCIA" sobre a saída "NÃO NECESSÁRIO" fazendo com que esta saída seja efetivamente ativada sempre que um paciente de emergência for apresentado à rede. Convém ressaltar que esta modificação não altera o processamento de nenhuma outra saída ou entrada, não prejudicando, portanto, a capacidade de generalização da rede.

Abaixo são mostrados pacientes de emergência que, na proposta do plano de anestesia, a rede sugere indevidamente algum tipo de pré-medicação anestésica. Os resultados mostram a saída da rede antes e depois da aplicação do refinamento do treinamento :

**PACIENTE :**

EMERGÊNCIA - INTERNADO - JEJUM : MAIS DE 6 HS - FRAT/LUX BACIA -  
ASMA - ESTADO EMOCIONAL : CALMO - ECG : NORMAL/RITMO SINUSAL -  
ECG : ALTERAÇÕES DE REPOLARIZAÇÃO - MEMBRO INFERIOR

**PRÉ-MEDICAÇÃO INDICADA PELA REDE ANTES DA APLICAÇÃO DO  
REFINAMENTO :**

BLOQUEADOR MUSCARÍNICO

**PRÉ-MEDICAÇÃO INDICADA PELA REDE APÓS A APLICAÇÃO DO  
REFINAMENTO :**

NÃO NECESSÁRIA

**PACIENTE :**

EMERGÊNCIA - INTERNADO - JEJUM : MAIS DE 6 HS - LOCAL : INTESTINO  
GROSSO

**PRÉ-MEDICAÇÃO INDICADA PELA REDE ANTES DA APLICAÇÃO DO  
REFINAMENTO :**

NEURO LÉPTICO

**PRÉ-MEDICAÇÃO INDICADA PELA REDE APÓS A APLICAÇÃO DO  
REFINAMENTO :**

NÃO NECESSÁRIA

### 5.3.2 - Refinamento do Treinamento para a Regra 2

- Regra 2 : Para os casos de pacientes com as seguintes características :  
 Cirurgia no Baço, Estômago, Fígado/Vias Biliares, Intestino Delgado, Intestino Grosso, Membro Inferior, Membro Superior, Órgãos Genitais, Pâncreas, Parede Abdominal, Parede Torácica, Períneo, Vasos Abdominais, Vasos de Membro Inferior, Vasos de Membro Superior, Vias Urinárias; Classificação do Estado Físico IV ou V e Especialidades Traumato/Ortopedia ou Vascular, a técnica anestésica de primeira escolha deve ser do grupo Anestesia Geral;

Da mesma forma que a regra anterior, foram separados pacientes que se enquadram na regra descrita, em que a rede "Técnica Anestésica" apresentou saídas contra-indicadas pelo especialista. Os pacientes são :

***PACIENTE :***

URGENCIA - UCCP - JEJUM : MAIS DE 6 HS - ABDOME AGUDO OBSTRUTIVO -  
 DISRITMIA SUPRAVENTRICULAR - ECG : BLOQUEIO DE RAMO - EXAME  
 UREIA : ALTO - LOCAL : INTESTINO DELGADO

***TÉCNICA ANESTÉSICA INDICADA PELA REDE ANTES DA  
 APLICAÇÃO DO REFINAMENTO :***

Primeira Escolha : Peridural Lombar - Segunda Escolha : Inalatória  
 Qualitativa

***TÉCNICA ANESTÉSICA INDICADA PELA REDE APÓS A APLICAÇÃO  
 DO REFINAMENTO :***

Primeira Escolha : Inalatória Qualitativa - Segunda Escolha : Balanceada

**PACIENTE :**

ELETIVO - INTERNADO - ALCOOL - FUMANTE - JEJUM : MAIS DE 6 HS -  
ENFISEMA PULMONAR - ESTADO EMOCIONAL : CALMO - RX: ALT. AORTA  
TORACICA - ECG : NORMAL/RITMO SINUSAL - LOCAL : INTESTINO GROSSO

**TÉCNICA ANESTÉSICA INDICADA PELA REDE ANTES DA  
APLICAÇÃO DO REFINAMENTO :**

Primeira Escolha : Subaracnóidea - Segunda Escolha : Inalatória  
Qualitativa

**TÉCNICA ANESTÉSICA INDICADA PELA REDE APÓS A APLICAÇÃO  
DO REFINAMENTO :**

Primeira Escolha : Inalatória Qualitativa - Segunda Escolha : Balanceada

### 5.3.3 - Refinamento do Treinamento para a Regra 3

- Regra 3 : Para os casos de pacientes com cirurgia em Membro Superior, deve ser evitada a proposta de técnica anestésica Peridural - Lombar;

Nesta situação a presença de uma determinada entrada ou característica de um paciente deve INIBIR uma determinada saída e não ao contrário como nos casos anteriores. Como resultado da aplicação do PERCEP, contudo, trabalha-se com valores de pesos transformados somente em valores positivos, sendo portanto insuficiente a mudança da conexão entre a entrada "CIRURGIA EM MEMBRO SUPERIOR" e a saída "PERIDURAL LOMBAR" como técnica anestésica. Com uma simples alteração para 100 % o efeito seria o contrário do que se deseja. Ou seja, a entrada "MEMBRO SUPERIOR" estaria contribuindo para que a saída "PERIDURAL LOMBAR" fosse ativada. O outro extremo (0 %) também não garante que a saída NÃO seja ativada. Dessa forma, o refinamento do treinamento exige que, nestas situações, o conjunto de pesos percentuais sejam manipulados preservando o sinal original advindo do conjunto de pesos antes da aplicação do PERCEP. Isto resulta em uma operação mais simples na qual os valores percentuais são obtidos através da divisão de todos os pesos que interligam cada neurônio de saída com as entradas pelo valor do "bias" relativo. A fórmula genérica a ser usada é o seguinte :

$$(W_1 / W_0) * E_1 - (W_2 / W_0) * E_2 + (W_3 / W_0) * E_3 > 1$$

$$W_{1t} * E_1 - W_{2t} * E_2 + W_{3t} * E_3 > 1 \quad (5.1)$$



Onde  $W_1$ ,  $-W_2$  e  $W_3$  são os pesos originais e  $W_0$  é o valor absoluto do “bias”;

Nestes casos nenhuma das entradas serão negadas no processamento da saída da rede. Para que a entrada  $E_1$ , por exemplo, tenha o efeito de forçar a saída para zero quando esta entrada está presente, a conexão  $W_{1t}$  poderá ter o valor de -1 (ou -100%) de forma que a soma ponderada de um padrão não consiga superar o valor do “bias” do neurônio.

Abaixo é mostrado um paciente com cirurgia em Membro Superior que, na proposta do plano de anestesia, a rede sugere indevidamente a técnica Peridural-Lombar (mesmo como segunda escolha). Os resultados mostram a saída da rede antes e depois da aplicação do refinamento do treinamento

:

***PACIENTE :***

ELETIVO - AMBULATORIAL - JEJUM : MAIS DE 6 HS - PRÓTESE DENTÁRIA/EDÊNTULO - ESTADO EMOCIONAL : CALMO - RADIOGRAFIA NORMAL - ECG : BLOQUEIO AV - LOCAL : MEMBRO SUPERIOR

***TÉCNICA ANESTÉSICA INDICADA PELA REDE ANTES DA APLICAÇÃO DO REFINAMENTO :***

Primeira Escolha : Regional Endovenosa - Segunda Escolha : Peridural  
Lombar

***TÉCNICA ANESTÉSICA INDICADA PELA REDE APÓS A APLICAÇÃO DO REFINAMENTO :***

Primeira Escolha : Regional Endovenosa - Segunda Escolha : Inalatória  
Qualitativa

## 6 - DISCUSSÕES E CONCLUSÕES

- As comparações efetuadas dos resultados dos treinamentos das RNAs com o algoritmo *Backpropagation* entre os trabalhos de [GARCIA92], [PASSOLD95] e este trabalho indicam que, com estratégias convencionais de treinamento, as possibilidades de eficiência de representação para as topologias de RNAs implementadas para o PROVANES dificilmente podem ser aumentadas. Somente com alteração das condições de contorno de treinamento este aumento de eficiência poderá ser obtido. Estas condições estão relacionadas com a mudança de representação dos dados de entrada (adotando entradas analógicas, por exemplo) ou dividindo as topologias das RNAs em sub-redes de menores dimensões buscando-se otimizar a relação número de exemplos e dimensão da rede.

- Para esta aplicação em anestesiologia, a verificação do desempenho do algoritmo *Backpropagation* também foi realizada através dos testes de implementação com a estrutura de RNA *Counterpropagation*. Como mostrado nas tabelas de resultados de treinamento, o desempenho da *Counterpropagation* não conseguiu atingir os patamares alcançados pela *Backpropagation*, ou seja, o processo de classificação por similaridade de padrões, efetuado pela rede *Counterpropagation*, não foi adequado para as características dos dados de treinamento da base de dados em anestesiologia.

- Há uma discussão entre pesquisadores [ANDREWS95], [TOWELL93] sugerindo que as potencialidades de uso das Redes Neurais Artificiais, principalmente quando utilizadas como base de conhecimento de sistemas especialistas, somente serão maximizadas se for possível o

estabelecimento de critérios e propostas de explanação do conhecimento armazenado em redes treinadas. Com este propósito, os algoritmos LOGIC e PERCEP, implementados para análise das RNAs do sistema de anestesiologia, apresentaram resultados satisfatórios, no sentido de se tornarem uma ferramenta útil para a explanação do que as redes estão efetivamente representando a partir do treinamento efetuado e a base de dados utilizada.

- Apesar dos resultados de aplicação dos algoritmos LOGIC e PERCEP indicarem a organização aproximada dos pesos das topologias das RNAs do sistema em anestesiologia, cabe ressaltar as restrições de aplicação destes algoritmos na aplicação das RNAs do PROVANES. Estas restrições estão relacionadas basicamente com o fato de que os algoritmos foram aplicados sobre topologias especiais em que a camada intermediária foi suprimida. O resultado dessa aplicação foram regras de causa-efeito relacionando diretamente hipóteses e conclusões. Essa condição foi assumida neste trabalho, em função da inexistência de atributos diretos aos neurônios na camada intermediária nas topologias de RNAs implementadas para o PROVANES, condição esta necessária para a obtenção de regras completas IF..THEN a partir dos algoritmos. Estes atributos intermediários, inclusive, são apresentados como objeto de propostas de trabalhos futuros apresentados em [GARCIA92]. Os pesos resultantes do treinamento destas topologias especiais, sem camada intermediária, não podem ser considerados válidos para aplicação na estrutura do PROVANES para a representação do processo classificatório que o profissional anestesiologista realiza na proposta de um plano de anestesia.

- Outra limitação encontrada na aplicação do algoritmo LOGIC foi a quantidade elevada de portas lógicas geradas, tornando restritivo o uso destas informações como regras de explicação do conhecimento armazenado. Esta limitação, contudo, está relacionada mais às características da convergência do treinamento das RNAs do que no próprio princípio do método. Nos algoritmos similares encontrados na literatura - SUBSET e MofN [TOWELL93] esta limitação também é realçada quando a topologia da rede é elevada e, principalmente, quando os valores dos pesos e “bias” convergem para valores muito próximos entre si, gerando muitas diferentes combinações que ativam um determinado neurônio.
- Para o sistema em questão de anesthesiologia, outra limitação do LOGIC, conforme realçado no item de resultados, está relacionado com a não distinção do grau de importância entre diferentes entradas das redes, podendo gerar regras inconsistentes para determinadas conclusões de classificação que as RNAs indicam.
- Uma aplicação derivada que surge na implementação do algoritmo LOGIC está relacionada quanto à detecção de redundância que determinados produtos “Peso $\times$ Entrada” podem assumir na ativação de um determinado neurônio, mesmo que o peso tenha valores absolutos não próximos de zero. Como demonstrado no capítulo 4.4.1 (implementação do algoritmo LOGIC), através do “Plano de Ativações”, algumas combinações de pesos e entradas podem assumir esta condição e, portanto, este peso poderá ser eliminado da estrutura sem prejudicar o treinamento da rede.

- O algoritmo PERCEP mostrou-se útil como ferramenta de análise de sensibilidade das redes, determinando a importância relativa de cada entrada em relação a uma saída específica. A transformação para pesos somente positivos propicia uma lógica que evidencia a importância ou contribuição da “ausência” de uma determinada entrada para a ativação de um neurônio. Esta característica do algoritmo permite a extração do conhecimento da rede de maneira análoga à lógica de pensamento de muitos especialistas médicos, os quais, para chegar a um diagnóstico, avaliam não somente os sintomas presentes, mas também os ausentes em um determinado paciente.

- Também a característica de refinamento do treinamento através do PERCEP lhe atribui uma importante aplicação. A manipulação de valores percentuais, ao invés dos valores “brutos” de uma matriz de pesos, é desejável para a determinação da importância do peso ou conexão para a ativação de uma saída. De posse destes dados, um engenheiro de conhecimento, juntamente com um especialista, pode contribuir para alterar ou corrigir possíveis distorções no treinamento de uma RNA com muito mais facilidade e segurança.

- Como propostas de trabalhos futuros surgem dois caminhos distintos. Um caminho está relacionado a uma reavaliação da base de dados anesthesiológico e topologias das RNAs no sentido de mudar as condições de contorno de treinamento, como já citado anteriormente. Outro caminho está relacionado com a aplicação dos algoritmos LOGIC e PERCEP propostos neste trabalho. Entre estas aplicações citam-se :

- Utilização do algoritmo LOGIC em um Sistema Especialista Simbolista como gerador de regras iniciais a serem refinadas pelo

especialista ou, então, de forma contrária, utilizando uma RNA e o algoritmo LOGIC para o refinamento de regras simbólicas. No primeiro caso, a partir de um conjunto de dados brutos treinadas por uma rede neural, o algoritmo pode “sugerir” ou “inferir” algumas relações iniciais entre causas e efeitos em um sistema. No outro caso, o objetivo é a utilização da capacidade de generalização de uma RNA para o refinamento de regras geradas por um processo de aquisição de conhecimento.

- Seguindo uma proposta já apresentada em [GARCIA92] e discutida anteriormente, para as RNAs do sistema de anesthesiologia definir topologias de redes nas quais os elementos da camada intermediária tenham um atributo definido, como diagnósticos intermediários parciais, aplicando posteriormente os algoritmos LOGIC e PERCEP. Dessa forma a extração de regras pode ser realizado de forma que módulo de explanação do PROVANES possa ser efetivamente melhorado.

## 7 - REFERÊNCIAS BIBLIOGRÁFICAS

- [001]-ALLRED, L.G & G.E. KELLY. "Supervised Learning Techniques for Backpropagation Networks". Proc. of the IEEE Int. Conf. on Neural Networks, San Diego, I:721-728, June 1990.
- [002]-ANDREWS,R., & S. GEVA. "Inserting and Extracting Knowledge from Constrained Error Back Propagation MLP". Proc. 5th Australian Conference on Neural Networks, Sydney, 1995.
- [003]-AZEVEDO, F. M. & J. M. BARRETO. "Identification of Arm Dynamics Using Neural Networks". 46ª Reunião Anual SBPC, Vitória, ES, Anais pp: 97, Trab. A.4-032,17-22 julho, 1994a.
- [004]-AZEVEDO, F. M. & J.M. BARRETO & L.R. EPPRECHT & W.C. LIMA & C.I. ZANCHIN. "A Neural Network Approach for Expert Systems". World Congress on Medical Physics and Biomedical Engineering, Rio de Janeiro, 21-26 August, Proceedings, PartI, Abstract PS17-1.18, pp:466, 1994b.
- [005]-AZEVEDO, F. M. "Contribuiton to the Study of Neural Networks in Dynamical Expert Systems". D.Sc. Thesis, Institut d'Informatique, FUNDP - Facultés Universitaires Notre-Dame de la Paix, Namur- Belgium, 1993.
- [006]-AZEVEDO, F. M. & J. M. BARRETO & W.C. LIMA & C.I.ZANCHIN. "The Choice of the Training Set for Backpropagation: is It a Simple Task?". 44a. Reunião Anual SBPC, São Paulo, Proceedings p: 122, 12-17 julho, 1992.
- [007]-AZEVEDO, F. M. & J.M. BARRETO & L.R. EPPRECHT & W.C. LIMA & C.I. ZANCHIN. "A Neural Network Approach for Medical Diagnostic". ISMM International Conference - Mini and

Microcomputers in Medicine and Healthcare, December 16-18, Long Beach, USA, 1991a.

- [008]-AZEVEDO, F. M. & J.M. BARRETO & E.K. EPPRECHT & L.M. EPPRECHT & W.C. LIMA. "Two Approaches in Cased-Based Connectionist Expert Systems". IASTED International Conference - Artificial Intelligence Applications and Neural Networks, Zurich, Switzerland, July 1-3, 1991b.
- [009]-AZEVEDO, F. M. & J.M. BARRETO & A. DE BAENST-VANDENBROUCKE & E.K. EPPRECHT & C. I. ZANCHIN. "Connectionist Networks: Insights Towards a More Operational Technology ". IASTED International Conference - Artificial Intelligence Applications and Neural Networks, Zurich, Switzerland, July 1-3, 1991c.
- [010]-BERNER, E.S. & et all. "Performance of Four Computer-based Diagnostic Systems". The New England Journal of medicine, Vol 330 (25): 1792-1796, 23th, June 1994.
- [011]-BARRETO, J. M. & F. M. AZEVEDO. "Model Control of a Robot Arm Using Neural Networks". World Congress on Medical Physics and Biomedical Engineering, Rio de Janeiro, Proceedings, Part I, Abstract PS02-1.6,pp:43, 21-26 August, 1994b.
- [012]-BARRETO, J. M. & F. M. AZEVEDO. "Connectionist expert systems as medical decision aid". Artificial Intelligence in Medicine, 5:515-523, Netherlands, Elsevier, 1993a.
- [013]-BARRETO, J. M. & F. M. AZEVEDO. "On the robot neural control". Internal Report nr.08/93, Facultes Universitaires Notre Dame de la Paix-FUNDP, Institut d'Informatique, Namur, Belgique, May, 1993b.



- [014]-BARRETO, J. M. & F. M. AZEVEDO & W.C. LIMA & C.I.ZANCHIN. "A Neural Network with Fuzzy Elements for a Medical Diagnosis". LATICON'92 - Congresso Latinoamericano de Control Automatico, Santiago, Chile, Anales pp:335-339, 17-21 Agosto, 1992.
- [015]-BARRETO, J. M. "Neural Network Learning : A New Programming Paradigm?". In ACM International Conference: Trends and Directions in Expert System, October 29-November 03. Orlando Florida, 1990.
- [016]-BRASIL, L. M. "Uma Proposta de Arquitetura para Sistema Especialista Híbrido e a Correspondente Metodologia de Elicitação/Representação do Conhecimento". Exame de Qualificação de Doutorado, GPEB, UFSC, Florianópolis, 1996a.
- [017]-BRASIL, L. M. & F.M. AZEVEDO & R. GARCIAO. & J.M. BARRETO. "A Methodology for Implementing Hybrid Expert Systems". MELECON'96 - 8th Mediterranean Electrotechnical Conference, May 13-16, Bari, Italy, Proceedings Vol. II, pp: 661-664, 1996b.
- [018]-CALOBA, L. P. "Introdução à Computação Neuronal". Anais do 9º Congresso Brasileiro de Automática, Setembro 1992.
- [019]-CARPENTER, G. & S. GROSSBERG & K. LIZUJA. "Comparative Performance Measures of Fuzzy Artmap, Learned Vector Quantization, and Back propagation for Handwritten Character Recognition". Proc. of the IEEE First Int. Conf. on Neural Networks, Baltimore, I:794-799, June 1992.
- [020]-CATER, J.P. "Successfully Using Peak Learning Rates of 10 (and greater) in Backpropagation Networks with the Heuristic

Learning Algorithm". Proc. of the IEEE First Int. Conf. on Neural Networks, San Diego, II:645-651, 1987.

[021]-CRAVEN, M.W., & J.W. SHAVLIK. "Learning Symbolic Rules Using Artificial Neural Networks". Machine Learning :Proceedings of the Tenth International Conference, San Mateo, CA, 1993.

[022]-CRAVEN, M.W., & J.W. SHAVLIK. "Using Sampling and Queries to Extract Rules from Trained Neural Networks". Machine Learning :Proceedings of the 11 International Conference, San Francisco, CA, 1994.

[023]-CRAVEN, M.W., & J.W. SHAVLIK. "Extracting Tree-Structured Representations of Trained Networks". Advances in Neural Information Processing Systems, Vol 8, MIT Press, MA, 1996.

[024]-DAYHOFF, J., Neural Networks Architectures - An Introduction, Van Nostrand Reinhold, New York, 1990.

[025]-DENIS, F.A.R.M. & R.M.MACHADO. "O Modelo Conexcionista Evolutivo". Relatório Técnico CCR-128, Centro Científico Rio-IBM Brasil, Set 1991

[026]-DUARTE,D.F & L.H.M PACHECO. "Farmacocinética dos Anestésicos Venosos". Rev. Brasileira Anestesiologia, Vol. 37, num 6, pp:421-429, Nov-Dec 1987

[027]-DUARTE, D. F. & C.I.ZANCHIN & W.C. LIMA & J. FALQUETO. "Bases de Dados em Anestesiologia". In: CONGRESSO BRASILEIRO DE INFORMÁTICA EM SAÚDE. Anais, Outubro,1988.

[028]-DUCHESSI, P. "Contrasting Successful and Unsuccessful Expert Systems". European Journal of operational Research, Elsevier Publisher, Nr 61, pp:122-134, 1992.

- [029]-EATON, H. A. C. & T. OLIVIER. "Learning Coefficient Dependence on Training Set Size". *Neural Networks*, 5:283-288, 1992.
- [030]-FU, L.M. "Rule Learning by Searching on Adapted Nets" In: *Proceedings of The International Conference on Artificial Intelligent, AAAI-91*, pp:325-340, Anaheim, CA, 1991.
- [031]-FU, L.M. "Knowledge-based refinement by Backpropagation". *Data & Knowledge Engineering*, 07(1):35-46, 1992a.
- [032]-FU, L.M. "A Connectionist Approach to Rule Refinement". *Applied Intelligence, International Journal Artificial Intelligence, Neural networks Complex Problem-Solving Technologic*, 2(2):93-103, 1992b.
- [033]-FU, L.M. "Rule Generation from Neural Networks". *IEEE Transactions on Systems, Man and Cybernetics*, 23(1):173-182, 1993.
- [034]-GALLANT, S.H. "Connectionist Expert Systems". *Communications of the ACM*, Vol 31, Number 2, pp:152-169, Feb 1988.
- [035]-GARCIA O., R. & F. M. AZEVEDO & J. M. BARRETO. "Genetic Algorithms in the Optimal Choise of Neural Networks for Signal Processing". *38th Midwest Sympsium on Circuits and Systems*, Rio de Janeiro, pp:1361-1364, August 13-16, 1995.
- [036]-GARCIA O., R. & F. M. AZEVEDO & J. M. BARRETO. "Training Neural Networks for Medical Knowledge Representation". *9th Int. Conf. On Systems Engineering*, University of nevada, Las Vegas, USA, July 14-19, 1993.
- [037]-GARCIA O., R. "Técnicas de Inteligência Artificial Aplicadas ao Apoio à Decisão Médica na Especialidade de Anestesiologia". *Tese de Doutorado, UFSC, Florianópolis, Julho 1992.*

- [038]-GORI,M. & A.TESI. "On Problem of Local Minima in Backpropagation". IEEE Trans. on Pattern Analysis and Machine Intelligence, 14(1):76-86, January 1992.
- [039]-GUTIERREZ,M. & J. WANG & R. GRODIN. "Estimating Hidden Unit for Two-Layer Perceptrons". Proc. of the IEEE Int. Conf. on Neural Networks, Washington DC, I:677-681, 1989.
- [040]-HART, A. & J. WYATT, "Evaluating Black-Boxes as Medical Decision Aids: Issues Arising from a Study of Neural Networks". Med. Inform, Vol. 15, Nr 03. pp:229-236, 1990.
- [041]-HAGIWARA, M., "Novel, Backpropagation Algorithm for Reduction of Hidden Units and Acceleration of Convergence using Artificial Selection ". Proc. of the IEEE Int. Conf. on Neural Networks , San Diego, Vol. 1:625-630, June 1990.
- [042]-HAYKIN, S., Neural Networks - A Comprehensive Foundation, IEEE Press, Macmillan Publishing Company, New Jersey, 1994.
- [043]-HINTON, G.E. "Connectionist Learning Procedures". Technical Report CMU-CS-87-115(version 2), Computer Science Dept, Carnegie-Mellon Univ., Pittsburgh, PA, Dec 1987.
- [044]-HSIUNG,J.T. & W. SUEWATANAKUL & D.M.HIMMELBLAU. "Should Back Propagation Be Replaced By More Effective Optimization Algorithm?" Proc. of the IEEE Int. Conf. on Neural Networks, Seattle, I:353-356, July 1991.
- [045]-HECHT-NIELSEN, R. "Counterpropagation Networks". Proc. of the IEEE First Int. Conf. on Neural Networks, San Diego, II:19-32, 1987.
- [046]-HECHT-NIELSEN, R. "Theory of the Backpropagation Neural Network". Proc. of the IEEE Int. Conf. on Neural Networks, Washington DC, I:593-605, 1989.

- [047]-HOLDWAY, R. M. "Enhancing Supervised Learning Algorithms Via Self-organization". Proc. Int. Joint Conf. on Neural Networks, IJCNN 89, Washington DC, II:523-529, 1989.
- [048]-KOHONEN, T. "The Self-Organizing Map". Proc. of the IEEE, Special Issue on Neural Networks I, 78(9):1464-1480, Sept 1990.
- [049]-KOSKO, B. "Bidirecional Associative Memories". IEEE Transactions on Systems, Man and Cybernetics, 18(1):49-60, Jan/Feb 1988
- [050]-KRUSCHE, J.K. "Human Category Learning: Implications for Backpropagation Models". Connections Science, Vol 5(1):3-36, 1993.
- [051]-LIMA, W.C. & R.G. OJEDA & D.F. DUARTE. "Using Neural Networks in an ansthetic Intelligent System". World Congress on Medical Physics and Biomedical Engineering, Kyoto, Japan, July 7-12, Proceedings 29:816, 1991a.
- [052]-LIMA, W.C. & R.G. OJEDA & D.F. DUARTE. "Un Ejemplo de Uso de Redes Neurales para Anestesiologia". IEEE - Confegrencia sobre el estado Actual de la Ingenieria Biomedica en latinoamerica, Mexico, 6-8 maio, 1991b.
- [053]-LIPPMANN, R. P. "An Introduction to Computing with Neural Networks". IEEE ASSP Mag., 4-22, April 1987.
- [054]-LO, Z. & Y. YU & B. BAVARIAN. "Analysis of a Laerning Algorithm for Neural Networks Classifiers". Proc. Int. Joint Conf. on Neural Networks- IJCNN, Baltimore, Vol I:589-594, June 1992.
- [055]-LOPES, H. S. & S. M. NASSAR & A. R. POZO & W.C. LIMA. "Arquitetura híbridas Integrando Paradigmas Conexionistas e

Simbolistas". I Simpósio Brasileiro de Automação Inteligente-SBAI, Rio Claro, pp:10-18, 8-10 Setembro, 1993.

[056]-LUNDSGAARDE, H.P. "Evaluating Medical Expert Systems". Soc. Sei. Med., Pergamon Journals Ltd, Vol 24(10):805-819, 1987.

[057]-MACHADO, J.M. & A.M. ROCHA. "The Combinatorial Neural Network: A Connectionist Model for Knowledge based Systems". IPMU'90, Paris, France, Vol. Uncertainty in Knowledge Bases, pp: 578-587, Jul 1990.

[058]-MACHADO, J.M. & A.M.ROCHA & C. FERLIN, "Combining Semantic and Neural Networks in Expert Systems". Relatório Técnico CCR-140, centro Científico - IBM, Rio de Janeiro, Brazil, pp: 1-21, Jan 1992.

[059]-MIRCHANDANI, G. & W. CAO. "On Hidden Nodes for Neural Nets". IEEE Transaction on Circuits and Systems, 34(5):661-664, May 1989.

[060]-MURATA, N. & S. YOSHIKAWA & S. AMARI. "Network Information Criterion - Determining the Number of Hidden Units for an Artificial Network Model". Technical Reports, Dept of Mathematical Engineering, The University of Tokyo, METR92-05, pp:1-17, June 1992.

[061]-NARENDA, K.S. & K. PARTHASARATHY. "Identification and Control of Dynamical Systems Using Neural Networks". IEEE Trans. On Neural Networks, Vol 1(1):4-27, March 1990.

[062]-NASSAR, S. M. & W.C.LIMA & J. M. BARRETO. "Knowledge Acquisition: The Case Study of Statistical Support for Medical Research". EXPERSYS'95, San Francisco, USA, Nov 9-10, 1995.

[063]-NYKÄNEN, P. & S. CHOWDHURY, O.WIGERTZ. "Evaluation of Decision Support systems in Medicine". Computer Methods and

Programs in Biomedicine, Elsevier Science Publisher, Nr. 34, pp:229-238, 1991.

- [064]-OLIVEIRA, J. P. & R. GARCIA O. & R. F. CUSTÓDIO & W. C. LIMA. "Redes neurais artificiais para representação de conhecimento médico em anestesiologia". X Congresso Chileno de Ingenieria Electrica, 22-26 novembro, Valdivia, Chile, pp: I-37/42, 1993.
- [065]-OLIVEIRA, J. P. & R. GARCIA O. & W. C. DE LIMA. "Artificial Neural Networks for Representing Medical Knowledge in Anesthesiology". World Congress on Medical Physics and Biomedical Engineering, Rio de Janeiro, Proceedings, Part I, Abstract PS17-2.15, pp: 474, 21-26 August 1994.
- [066]-OPITZ, W. O. & J.W. SHAVLIK. "Dynamically Adding Symbolically Meaningful Nodes to Knowledge-Based Neural Networks ". Knowledge-Based Systems, 8(6):301-311, 1995
- [067]-PAPADOURAKIS, G.M. & E.GAGA & G. VARELTIZ & G. BEBIS. "Use of Artificial Neural Networks for Clinical Decision-Making (Maldescensus Testis)". Proceedings of International Joint Conference on Neural Networks, III:159-164, June 1992.
- [068]-PASSOLD, F. & J. P. OLIVEIRA & J. S. DIAS & R. GARCIA O. & W. C.LIMA. "Proposta e avaliação de procedimentos anestésicos para pacientes críticos/problemáticos através de sistema especialista híbrido". X Congresso Chileno de Ingenieria Electrica, Valdivia, Chile, I:43-48, 22-26, novembro 1993.
- [069]-PASSOLD, F. "Sistema Especialista Híbrido em anestesiologia para pacientes Críticos/Problemáticos". Dissertação de Mestrado, Grupo de Pesquisas em Engenharia Biomédica - GPEB, UFSC, 1995.

- [070]-PASSOLD, F. & R. GARCIA O. & J.M. BARRETO. "Hybrid Expert System in Anesthesiology for Critical Patients". MELECON'96 - 8th Mediterranean Electrotechnical Conference, Bari, Italy, Proceedings Vol. III, pp: 1486-1489, May 13-16 1996
- [071]-PELLEGRINI, G. F. & R. GARCIA O. "Avaliação de Sistemas Especialistas na Área Médica". ELECTRO'95 - XI Congreso Chileno de Ingeniería Eléctrica, Punta Arenas, Chile, Proceedings, Vol. I, pp: H-013 a H-017, Nov 13-17 1995.
- [072]-PERUGINI, N.K. & W.E. ENGELER. "Neural Network Learning Time: Effects of Networks and Training Set Size". Proceedings of International Joint Conference on Neural Networks, Vol II :395-401, June 1989.
- [073]-PRADE, H. "Gradual Inference Rules in Approximate Reasoning". Information Science, 61:103-122, 1992.
- [074]-ROCHA, A.F. et al. "Declarative and Procedural Knowledge-Two Complementary Tools for Expertise". Approximate Reasoning Tools for Artificial Intelligence, Eds: Verdegay, J.L and Delgado, M., Tuv-Interdisciplinary Systems Research Series, Rheiland, 1990.
- [075]-RUMELHART, D. E. & G.E. HINTON & R.J. WILLIAMS, . "Learning Internal Representations by Error Propagation". Parallel Distributed Processing : Explorations in the Microstructure of Cognition, Vol I : Foundations, MIT Press, Cambridge, Massachusetts, 1986
- [076]-SABBATINI, R. M. E. "Applications of Connectionist Systems in Biomedicine" , International Congress on Medical Informatics, 7th, Geneva, sept 1992



- [077]-SCHWARTZ,T.J. "A Neural Chips Survey " , AI Expert, pp:34-38, December 1990.
- [078]-SHORTLIFFE, E.H. & B.G. BUCHANAN & E.A. FEINGENBAUM. "Knowledge Engineering for Medical decision Making : A Review of Computer-Based Clinical Decision Aids". Proceedings of the IEEE, vol 67(9):1207-1224, Sept 1979.
- [079]-SOUCEK, B. & M. SOUCEK, Neural and Massively Paralell Computers- The Sixth Generation, John Wiley & Sons Publication, New York, 1988
- [080]-SUN,R. & D. WALTZ. "A Neurally Inspired Massively parallel Model of Rule-Based Reasoning". Neural and Intelligent Systems Integration, pp:341-381, John Wiley & Sons, Inc. New York, USA, 1991.
- [081]-TANG, Z., & G.J.KOEHLER. "A Convergent Neural Networks Learning Algorithm". Proc. IJCNN, Baltimore, II:127-132, Jun 1982.
- [082]-TOWELL,G.G. & J.W.SHAVLIK. "Extracting Refined Rules from Knowledge-Based Neural Networks". Machine Learning, vol 131, pp:71-101, 1993.
- [083]-TOWELL,G.G. & J.W.SHAVLIK. "Knowledge-Based Artificial Neural Networks". Artificial Intelligence, vol 70, 1994.
- [084]-THRUN,S.B.,"Extracting Provably Correct Rules from Artificial Neural Networks". Technical Reports IAI-TR-93-5 Institut fur Informatik, Universitat Bonn, 1994.
- [085]-WANG, J. & B. MALAKOOTI. "On Training of Artificial neural networks". Proc. Proceedings of International Joint Conference on Neural Networks, Washington DC, June 1989.

- [086]-WIDROW, B. & M.A.LEHR. "30 Years of Adaptive Neural Networks: Perceptrons, Madaline and Backpropagation". Proc. of the IEEE, Special Issue on Neural Networks I, 78(9):1415-1442, Sept 1990.
- [087]-WILENSKY, G. D. & J.A.NEUHAUS. "Scaling of Back-propagation Training Time to Large Dimensions". Proceedings of International Joint Conference on Neural Networks, III:239-244, June 1990.
- [088]-WISBECK, J. O. & R. GARCIA O. "Aplicação de Redes Neurais no Tratamento de Interferências em Sinais de ECG". XV Congresso Brasileiro de Engenharia Biomédica - Forum Nacional de Ciência e Tecnologia em Saúde, Campos do Jordão, SP, Anais, Vol. 2, pp: 525-526, 13-17 Outubro 1996.
- [089]-XUE, Q. & Y.H.HU & W.J.TOMPKINS. "Neural-Networks-Based Adaptive Matched Filtering for QRS Detection". IEEE Trans. Biomed. Eng., 39(4):317-329, April 1992.

## 8 - GLOSSÁRIO E LISTA DE ABREVIATURAS

***Algoritmos de Treinamento de RNA*** - Definem como são adaptados os pesos de uma RNA, de forma a realizar o treinamento ou aprendizado da rede.

***Aquisição de Conhecimentos*** - Processo de identificação, extração, análise e documentação do conhecimento de um especialista, para a construção de um SE.

***Backpropagation*** - Algoritmo de treinamento no qual os pesos são adaptados através do processo matemático gradiente descendente, em função da retropropagação do erro médio quadrático dos neurônios da camada de saída.

***Base de Conhecimento*** - Parte de um SE onde estão armazenados conhecimentos e informações a respeito de uma determinada área de conhecimento especializado.

***Coeficientes de Treinamento*** - Coeficientes utilizados como "ajuste fino" para o processo de adaptação dos valores dos pesos de uma RNA.

***Camadas de uma RNA*** - Conjunto de neurônios em um mesmo nível hierárquico dentro de uma topologia de RNA.

***Camada Intermediária*** - Em uma topologia de três camadas, está disposta entre a camada de entrada e a de saída. Esta camada têm destacada relevância, pois sua configuração determina características importantes para a eficiência de representação de um paradigma de RNA.

***Conexionistas (sistemas)*** - Sistemas de representação de conhecimentos baseados nas Redes Neurais Artificiais.

**Conjunto de Testes** - Conjunto de exemplos e dados, não coincidentes com os existentes em um conjunto de treinamento, utilizados para verificação do desempenho e validação de uma RNA.

**Conjunto de Treinamento** - Conjunto de exemplos e dados utilizados para realizar o treinamento de uma RNA.

**Erro Quadrático de Saída** - São os valores quadráticos da medida realizada através da comparação entre a saída atual da camada de saída de uma RNA com a saída correta que deveria ser a resposta. Valor utilizado para cálculo da adaptação dos pesos utilizado pelo algoritmo de treinamento *Backpropagation*.

**Estado de Ativação** - Valor de saída de um determinado neurônio artificial, após ser aplicado a função de ativação ao resultado do somatório ponderado na sua entrada.

**Feedforward (topologia)** - Topologia de RNA em que os neurônios são dispostos em camadas sendo que qualquer neurônio de uma camada pode ligar-se com qualquer outro neurônio da camada seguinte.

**Função de Ativação** - Função na qual é submetido o resultado de saída de um Neurônio Artificial.

**Inteligência Artificial** - Conjunto de técnicas e procedimentos que têm como objetivo reproduzir, em uma máquina, o comportamento humano nos domínios da percepção, compreensão, raciocínio e decisão.

**Inferência** - É a forma ou "raciocínio" utilizado por um SE para chegar a uma conclusão a respeito de um determinado problema.

**Motor de Inferência** - Parte de um SE simbolista que seleciona, usa e valida determinadas regras de produção da base de conhecimento para atingir uma solução.

**Neurônio Artificial** - Elemento processador de uma RNA. Normalmente sua saída é resultado do somatório ponderado (através dos pesos) dos elementos conectados à sua entrada, tratado por uma função Ativação.

**Paradigmas de RNA** - Características de uma RNA, relacionadas com : Tipo de topologia, modelo de neurônio e Algoritmo de treinamento.

**Perceptrons Multicamada** - Topologia de RNA *feedforward* utilizada pelo algoritmo *Backpropagation*.

**Pesos (ou conexões)** - Valor das conexões existentes entre os diversos neurônios artificiais de uma RNA e que representam o espaço de representação da rede.

**Redes Neurais Artificiais (RNA)** - Arquitetura computacional que consiste de elementos de processamento distribuídos e paralelos (neurônios artificiais) maciçamente interconectados.

**Sigmoide (função)** - Um dos tipos de função de ativação conhecidos. É utilizada em diversos algoritmos de treinamento (ex: *Backpropagation*).

**Sistemas Especialistas** - Um dos ramos da Inteligência Artificial, manipulam conhecimentos de especialistas humanos para a resolução de problemas, em áreas restritas de um determinado domínio.

**Sistemas Especialistas Simbolistas** - SE que utilizam lógica simbólica ou conhecimento baseado em casos para representação de informações na base de conhecimentos e regras de produção para a realização de inferências.

**Sistemas Especialistas Conexionistas** - SE que utilizam Redes Neurais Artificiais para representação de informações na base de conhecimentos.

***Sistemas Especialistas Híbridos*** -SE que utilizam diferentes modelos de representação de conhecimentos, como p. ex., modelos simbolistas e conexionistas.

***Supervisionado (treinamento)*** - Forma de treinamento de RNA em que são apresentados pares de padrão à rede. Estes pares representam a entrada e a correspondente saída correta que a rede deverá "aprender".

***Topologias de RNA*** - Definem como são distribuídos e interconectados os Neurônios e as camadas de uma RNA.

***Treinamento de RNA*** - Significa o processo de adaptação iterativa dos pesos de uma RNA, de forma que os valores finais destes venham a representar um sub-espço de conhecimento.

#### **LISTA DE ABREVIATURAS**

IA - Inteligência Artificial

RNA - Redes Neurais Artificiais

SE - Sistema Especialista

SEC - Sistema Especialista Conexionista

SES Sistema Especialista Simbolista

SEH - Sistema Especialista Híbrido

GPEB - Grupo de Pesquisas em Engenharia Biomédica