

**UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CURSO DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

Marta Cristina Arouck Ferreira Gabriel

**ANÁLISE DA UTILIZAÇÃO DE REDES DE KOHONEN  
NO AUXÍLIO AO DIAGNÓSTICO DE DOENÇAS  
REUMATOLÓGICAS**

Florianópolis  
Santa Catarina - Brasil  
Março de 2002

**UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CURSO DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

Marta Cristina Arouck Ferreira Gabriel

**ANÁLISE DA UTILIZAÇÃO DE REDES DE KOHONEN  
NO AUXÍLIO AO DIAGNÓSTICO DE DOENÇAS  
REUMATOLÓGICAS**

Dissertação submetida à Universidade Federal de Santa Catarina como parte dos requisitos para a obtenção do grau de Mestre em Ciência da Computação


Prof. Mauro Roisenberg, Dr.  
Orientador

Belém, março de 2002

# ANÁLISE DA UTILIZAÇÃO DE REDES DE KOHONEN NO AUXÍLIO AO DIAGNÓSTICO DE DOENÇAS REUMATOLÓGICAS

Marta Cristina Arouck Ferreira Gabriel

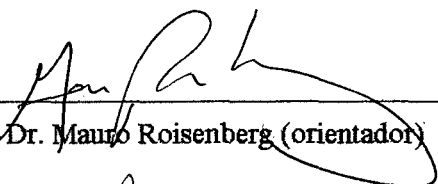
Esta Dissertação foi julgada adequada para a obtenção do título de Mestre em Ciência da Computação, Área de Concentração Sistemas de Conhecimento e aprovada em sua forma final pelo Programa de Pós-Graduação em Ciência da Computação.



---

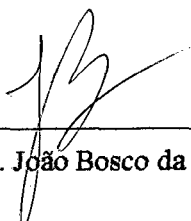
Prof. Dr. Fernando A. Ostuni Gauthier  
Coordenador do CPGCC-UFSC

Banca Examinadora



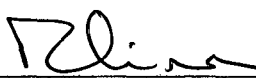
---

Prof. Dr. Mauro Roisenberg (orientador)



---

Prof. Dr. João Bosco da Mota Alves



---

Prof. Dr. Roberto Célio Limão de Oliveira

*“Toda a nossa Ciência, comparada com a realidade é primitiva e infantil,  
no entanto é a coisa mais preciosa que temos”.*  
*(Albert Einstein)*

*“Longe é um lugar que não existe”.*  
*(Richard Bach)*

Ao meu amado esposo e mestre Inacio Koury Gabriel Neto,  
por todo o significado que ele deu à minha vida.  
*(in memoriam)*

## AGRADECIMENTOS

Agradeço neste momento a todas as boas almas desse mundo que me ajudaram a chegar até o término deste trabalho com êxito, em especial ao meu orientador Prof. Dr. Mauro Roisenberg, pela atenção, capacidade intelectual, dedicação e incentivo. Aos Coordenadores do Programa de Mestrado em Belém, Prof. Dr. João Bosco da Mota Alves e Prof. Gustavo Campos por suas valiosas contribuições, a todo o Grupo Diretor da CESUPA: Dr. João Paulo Mendes, Prof. Sergio Fiúza de Melo Mendes, Dr. João Paulo Mendes Filho, Profa. Conceição Fiúza de Melo, que contribuíram para tornar possível a realização deste sonho.

Agradeço aos colegas de Mestrado Lídio Campos, Rita Gomes, Andracir Silva, Mauro Wilkens e Eugenio Pessoa, pelo apoio nos momentos mais difíceis e também aos colegas Ricardo Cabeça, Solano Neto, Fausto, Otavio Noura, Fabiano Cordeiro, Theo Flexa Ribeiro.

Um agradecimento aos professores do mestrado de Santa Catarina, que foram grandes incentivadores na busca deste novo patamar intelectual, e em especial aos membros que compuseram minha banca de defesa.

Agradeço também a Dra. Lycia Epprecht e ao Dr. Jorge Muniz Barreto por terem cedido a base de dados clínicos.

Agradeço as minhas irmãs Profa. Lindaura Arouck Falesi e Dra. Marialva de Araújo, ao meu irmão Prof. Osmar Arouck Ferreira pelo auxílio na parte metodológica e médica, ao meu irmão Zanoni Arouck Ferreira, a minha cunhada Neusa Ferreira, ao amigo Prof. Sérgio Maneschy, a minha Mestra em Reiki Beatriz de Sordi, a Cleide Chichovisky, aos meus filhos, Nissar, Martha Thereza e Thais, aos meus queridos pais Osmar e Balsamina por tudo que sou, e principalmente a Deus.

# SUMÁRIO

<b>Sumário</b> .....	v
<b>Lista de Figuras</b> .....	vii
<b>Lista de Tabelas</b> .....	ix
<b>Lista de Abreviaturas</b> .....	x
<b>Resumo</b> .....	xi
<b>Abstract</b> .....	xii
<b>1 Introdução</b> .....	3
1.1 Motivação .....	3
1.2 Objetivos .....	7
1.2.1 Geral .....	7
1.2.2 Específicos .....	7
1.3 Estrutura da Dissertação .....	8
<b>2 Redes Neurais</b> .....	9
2.1 Introdução .....	9
2.2 O Cérebro Humano .....	10
2.3 Redes Neurais Artificiais .....	16
2.3.1 Redes Auto-organizáveis .....	19
2.3.2 Aprendizado Não Supervisionado .....	19
2.3.3 Mapas Topológicos de Kohonen .....	20
<b>3 Redes Neurais Artificiais para Auxílio ao Diagnóstico Médico</b> .....	30
3.1 Introdução .....	30
3.2 Algumas aplicações de SEC's Desenvolvidas no Brasil .....	30
3.3 Algumas aplicações de Sistemas Especialistas que Usam Redes de Kohonen .....	34
3.4 Outros Sistemas Especialistas Conexionistas .....	36
<b>4 Metodologia e Implementação dos Modelos</b> .....	39

4.1 Introdução .....	39
4.2 Base de Dados .....	40
4.3 Descrição Qualitativa das Variáveis Pesquisadas (Doenças).....	44
4.4 Topologia da Rede.....	47
4.5 Implementação dos Modelos.....	49
4.5.1 Parte 1 .....	49
4.5.1.1 Experiência 1 .....	49
4.5.1.2 Experiência 2 .....	50
4.5.1.3 Experiência 3 .....	50
4.5.2 Parte 2 .....	50
4.5.2.1 Experiência 4 .....	51
4.5.2.2 Experiência 5 .....	51
4.5.3 Implementação .....	52
<b>5 Análise dos Resultados.....</b>	<b>57</b>
5.1 Resultados Obtidos .....	57
5.1.1 Parte 1 .....	58
5.1.1.1 Experiência 1 .....	58
5.1.1.2 Experiência 2 .....	64
5.1.1.3 Experiência 3 .....	65
5.1.2 Parte 2 .....	69
5.1.2.1 Experiência 4 .....	69
5.1.2.2 Experiência 5 .....	73
5.2 Comparação dos Resultados usando Rede de Kohonen com os Resultados usando Rede Direta .....	82
<b>6 Conclusões Finais e Trabalhos Futuros .....</b>	<b>83</b>
6.1 Conclusões Finais .....	83
6.2 Trabalhos Futuros.....	85
<b>Referências Bibliográficas .....</b>	<b>88</b>



## Lista de Figuras

2.1	Estrutura do cérebro e seus componentes .....	10
2.2	Representação do Homúnculo .....	11
2.3	Mapa citoarquitetural do córtex cerebral. Áreas de Broadman para o córtex humano .....	13
2.4	Do lado esquerdo: Lobo occipital do cérebro contendo o córtex visual Do Lado direito: O campo visual do olho direito dividido em diferentes áreas...	15
2.5	Modelo de uma RNA .....	17
2.6	Mapa de Von Der Malsburg e de Kohonen.....	21
2.7	Topologia de uma Rede SOM em 2 dimensões .....	23
2.8	Toplogia de uma Rede SOM em 3 dimensões .....	23
2.9	Função chapéu mexicano .....	24
2.10	Formatos de vizinhança .....	25
2.11	Rede de Kohonen com grade 4 X 4 .....	25
2.12	Modelo de vizinhança .....	28
2.13	Dinâmica do Aprendizado das Redes de Kohonen .....	29
4.1	Topologia da Rede de Kohonen .....	47
4.2	a) Três vetores normalizados b) Vetores não normalizados .....	52
5.1	Gráfico Resultante para Experiência 1 – etapa a .....	59
5.2	Gráfico Resultante para a Experiência 1 – etapa b .....	60
5.3	Gráfico Resultante para a Experiência 1 – etapa c .....	62
5.4	Gráfico Resultante para a Experiência 1 – etapa d .....	63
5.5	Mapeamento da Rede para a Experiência 2 .....	64
5.6	Resultado da Rede para a Experiência 3 – etapa 1 .....	66
5.7	Resultado da Rede para a Experiência 3 – etapa 2 .....	67
5.8	Saída da Rede Para a Experiência 4 – etapa1 .....	70
5.9	Saída da Rede Para a Experiência 4 – etapa 2 .....	71
5.10	Saída da Rede Para a Experiência 5 – 32 casos .....	73
5.11	Saída da Rede Para a Experiência 5 – 8 casos .....	74
5.12	Saída da Rede Para a Experiência 5 – 10 casos .....	75

5.13	Saída da Rede Para a Experiência 5 – 12 casos .....	76
5.14	Saída da Rede Para a Experiência 5 – 14 casos .....	77
5.15	Saída da Rede Para a Experiência 5 – 16 casos .....	78
5.16	Saída da Rede Para a Experiência 5 – 18 casos .....	79
5.17	Saída da Rede Para a Experiência 5 – 20 casos .....	80
5.18	Saída da Rede Para a Experiência 5 – 26 casos .....	81

## Lista de Tabelas

2.1	Algoritmo de Kohonen .....	27
4.1	Diagnóstico possíveis para os dados obtidos .....	39
4.2	Casos Clínicos de Reumatologia .....	41
4.3	Casos Clínicos de Reumatologia – <i>continuação da Tabela 4.2</i> .....	42
4.4	Casos Clínicos de Reumatologia – Abreviaturas .....	43
4.5	Casos Clínicos de Reumatologia - Normalizados .....	53
4.6	32 Casos Clínicos de Reumatologia para Treinamento, Normalizados ..	55
4.7	18 Casos Clínicos de Reumatologia para Teste, Normalizados .....	56
5.1	Convenção para os diagnósticos .....	57
5.2	Quadro Comparativo entre Resultado da Rede de Kohonen e Rede Direta .....	82

## **Lista de Abreviaturas**

- IA - Inteligência Artificial
- SECs - Sistemas Especialistas Conexionistas
- SOM - *Self Organizing Maps*
- AG - Artrite Gotosa
- AR - Artrite Reumatóide
- EA - Espondilite Anquilosante
- RNAs - Redes Neurais Artificiais
- ART - Architecture Resonancy Theory
- UCP - Unidade Central de Processamento

## Resumo

Este trabalho mostra a utilização de uma arquitetura de Rede Neural, conhecida como Redes Auto-organizáveis de Kohonen, no auxílio ao diagnóstico médico usando-se uma abordagem conexionista. Esta topologia de rede possui grande plausibilidade biológica que se auto-organiza através de mecanismos de competição permitindo detectar similaridades entre vários sinais, agrupando-os em classes. A hipótese deste trabalho é verificar se esta topologia é plausível para o problema do diagnóstico médico de maneira geral, e comparar os resultados obtidos através da topologia de rede direta. Diversos modelos foram implementados, através de uma série de experiências com uma base de 50 casos de três doenças reumatológicas quais sejam: Espondilite Anquilosante, Artrite Gotosa e Artrite Reumatóide. Na parte 1 usou-se a base amostral como conjunto de treinamento bem como para os testes, foram realizadas três experiências. Na parte 2 dividiu-se a base amostral em duas, a primeira contendo 32 casos e utilizada para treinamento e a segunda com 18 casos e utilizada para teste e validação dos resultados, foram realizadas duas experiências: na experiência 4 treinou-se a rede com 32 casos e testou-se com os 18, ignoraram-se os parâmetros sexo e idade. Na experiência 5 tomou-se primeiramente os 8 primeiros casos dos 32 para treinamento, aumentou-se para 10, depois 12, 14, 16, 18, 20, 26 e por fim 32 casos, para a base de teste utilizaram-se os 18 casos da experiência 1. Consideraram-se todos os parâmetros. Foi possível analisar o aprendizado da rede para padrões que não haviam sido apresentados à priori, bem como a capacidade de generalização para poucos exemplos de treinamento.

Ao final foram comparados os resultados com os obtidos através de Rede Neural Direta, sendo observado um bom desempenho das redes de Kohonen quando comparadas com aquela. A Rede de Kohonen conforme a topologia e modelos propostos nesta dissertação mostrou-se capaz de *clusterizar* os padrões de entrada em classes distintas permitindo ser possível distinguir com clareza os três diagnósticos propostos, desde os primeiros experimentos de maneira satisfatória.

### Palavras chaves:

Redes Neurais Artificiais, RNA, Rede de Kohonen, Mapas Auto-organizáveis de Kohonen, Sistemas Especialistas Conexionistas, Diagnóstico Médico.

## **Abstract**

### **Title: Analysis of the Utilization of Kohonen Neural Network (Self Organizing Maps) in order to help Medical Diagnosis**

This thesis evaluates the feasibility of Kohonen Feature Maps, or Self Organizing Maps in Expert systems, as appropriate tools for medical diagnoses. The Kohonen Neural Network is a topological network with sound biological plausibility that self-organizes through a competitive mechanism capable of detecting similarity beyond various (diverse) signals, clustering them into classes. Thus, the primary aim of this work is to investigate if the Kohonen Features Maps are useful for medical diagnoses suggesting the correct diagnosis for three specific rheumatic diseases: Ankylosing Spondylitis; Arthritis of gout and Rheumatoid Arthritis, and to compare with a solution gave by an Expert System using Direct network.

Several models were implemented using a 50 case sample, utilizing five experiments. All factors were taken into consideration. Results show that it was possible to analyze learning processes for standards that were not priorly known as well as the capacity to generalize when little training was provided.

Results were also compared to those obtained in the Direct Neural Network, revealing that Kohonen networks yield good performances when compared to this standard. Thus, the Kohonen network is capable of clustering stimuli into distinct classes allowing to clearly distinguish the three proposed diagnoses in a satisfactory manner.

#### **Keywords:**

Kohonen Neural Network, Self-Organizing Maps, Experts Systems, Medical Diagnosis, *Connectionism approach*.

# Capítulo 1

## Introdução

### 1.1 Motivação

A Inteligência Artificial ou simplesmente IA é uma ciência que visa modelar a inteligência humana. É composta de ferramentas, métodos e sistemas que buscam solucionar problemas que geralmente requerem para a sua solução inteligência humana (KASABOV, 1998).

Para Kasabov, o termo inteligência é sempre definido como: “*A habilidade de aprender efetivamente, a reagir adaptativamente, a tomar decisões próprias, comunicar-se em linguagens ou imagens de um modo sofisticado, e de compreender*” (KASABOV, 1998).

O objetivo da Inteligência Artificial (IA) é o desenvolvimento de paradigmas ou algoritmos que requeiram máquinas para realizar tarefas cognitivas, para as quais os humanos são atualmente melhores (SAGE, *Apud* HAYKIN, 2001).

Entre as técnicas que a IA utiliza para a solução de problemas, destacam-se duas abordagens bastante distintas. Uma abordagem procura utilizar princípios da lógica, psicologia e filosofia que através de um meta-conhecimento do funcionamento do raciocínio humano, desenvolve sistemas por meio da manipulação de símbolos, a fim de solucionar problemas que necessitem de inteligência para serem resolvidos. A esta abordagem se dá o nome de *Abordagem Simbólica*. Entre as aplicações mais populares desta abordagem está a de incorporar as habilidades de um especialista humano em determinada área específica do conhecimento para a resolução de problemas. Estes sistemas são normalmente chamados de Sistemas Especialistas. A outra abordagem procura analisar o funcionamento dos elementos básicos que compõem o cérebro humano, os neurônios. Parte-se do princípio que se um modelo suficientemente preciso do neurônio e de suas interconexões for implementado em um sistema computacional, deste sistema, emergirão características de inteligência similares ao modelo biológico simulado. Esta abordagem é conhecida como *Abordagem Conexionista*.

Como visto acima são dois os paradigmas da IA: O *simbólico* e o *paradigma conexionista*.

O *paradigma simbólico* é baseado em manipulação de símbolos e o *conexionista* é baseado em neurocomputação.

O problema do *paradigma simbólico* é que ele não é muito eficiente para casos onde a informação usada é incerta, inexata, vaga ou incompleta. Isso não parece ser difícil para os humanos.

Para desenvolver sistemas especialistas usando a abordagem simbólica é necessário “descobrir” o modo do especialista resolver um problema, ou seja, como ou com que regras ele manipula o seu conhecimento para resolver um problema. Isto não é tarefa fácil, pois muitas vezes nem mesmo o especialista sabe explicitar como ele chega a solução de um problema. Ele usa um raciocínio ou vários, um após o outro ou simultaneamente, de acordo com as características do problema. Por exemplo, o médico ao tentar diagnosticar uma determinada doença usa vários tipos de raciocínio: o raciocínio plausível ao considerar os sintomas como evidências para formar uma conjectura; o raciocínio probabilístico ao relacionar os sintomas com informações probabilísticas de doenças já existentes no meio; o raciocínio nebuloso ao considerar a imprecisão dos sintomas ou o raciocínio qualitativo ao avaliar as informações qualitativas.

Uma possível alternativa, então, é observar exemplos de problemas resolvidos pelo especialista e implementar um sistema especialista *conexionista* que utilize o conhecimento que está implícito nos exemplos.

O *Paradigma conexionista* (SMOLENSKI 1990 *apud* KASABOV, 1998) sustenta que o comportamento inteligente é realizado em um nível subsimbólico o qual é maior do que o nível neuronal no cérebro, mas diferente do simbólico. O processamento do conhecimento é realizado através de mudanças de estados de redes construídas de pequenos elementos chamados neurônios, replicando a analogia com neurônios reais. Tem sido mostrado que é possível construir modelos inteligentes que realizam o comportamento global, embora os componentes do sistema sejam simples e operem com informações puramente locais (KASABOV, 1998).

Os sistemas especialistas usando a abordagem *conexionista* pretendem, através da observação de exemplos de como o especialista resolve um problema, utilizar o



conhecimento que está implícito nos exemplos e solucionar o problema. Esta é a abordagem que será usada neste trabalho.

Um terceiro paradigma proposto é uma mistura dos dois primeiros, como é o caso dos sistemas *fuzzy* que usa a representação do conhecimento na forma simbólica, mas também emprega a representação numérica similar àquela usada em sistemas conexionistas.

A IA objetiva desenvolver métodos e sistemas para solucionar problemas, que geralmente são solucionados pelos humanos, através de suas atividades intelectuais, como exemplo pode-se citar: reconhecimento de padrões, processamento de voz e linguagem, planejamento e predição, diagnóstico, como o que será abordado nesta dissertação, aprimorando por conseguinte os sistemas de informações computacionais; além de desenvolver modelos que simulem comportamentos de seres vivos e o cérebro humano em particular (KASABOV, 1998).

O termo Sistemas Especialistas é geralmente usado para sistemas que são desenvolvidos abordando o *paradigma simbólico*, porém o termo Sistemas Especialistas Conexionistas (SECs) é usado neste trabalho e tem sido usado por outros pesquisadores para denominar Sistemas desenvolvidos abordando o *paradigma conexionista*, mais especificamente Redes Neurais Artificiais. O termo conexionista é usado devido ao grande número de conexões entre os neurônios dessas redes e foi consolidado por Gallant, em seu artigo "*Connectionist Expert Systems*" publicado em 1988 no *Communications of the Association for Computing Machines (ACM)* (KASABOV, 1998).

Neste trabalho busca-se fazer uma análise da utilização de Redes de Kohonen no auxílio ao diagnóstico médico usando-se a abordagem conexionista, neste caso, Redes Neurais Artificiais, mais especificamente Redes de Kohonen.

Optou-se pela construção de uma abordagem conexionista construindo uma RNA que fosse capaz de aprender a diagnosticar um conjunto de doenças baseado em dados clínico, que constam de sintomatologia e exames laboratoriais. A princípio tinha-se como objetivo diagnosticar três síndromes que acometem o Sistema Neurológico: Mielite Transversa, Esclerose Múltipla e Síndrome de Guillain-Barré (ou Síndrome Landry-Guillain-Barré, polineuropatia inflamatória aguda, neuropatia auto-imune aguda).

O interesse na área da saúde surgiu após um membro de minha família ter sido acometido de Mielite Transversa, o que me levou a ter mais interesse na pesquisa.

Após levantamento bibliográfico- e exaustivas tentativas de obtenção dos prontuários em vários hospitais especializados, no Brasil e no exterior, sem lograr êxito, visto que os pesquisadores alegaram ser os dados confidenciais e não ser possível a disponibilização, buscou-se a alternativa de usar a base de dados não mais de Mielite transversa, Esclerose Múltipla e Síndrome de Guillain-Barré. Utiliza-se neste trabalho uma base de dados de doenças reumatológicas, com 50 (cinquenta) casos e 17 (dezesete) exames/sintomas e três patologias a diagnosticar a saber: Artrite da Gota ou Atrite Gotosa, Artrite Reumatóide e Espondilite Anquilosante. Esta base de dados é oriunda da Clínica *EMONT GODINE* da Universidade Católica de Lovain , na Bélgica (BARRETO E EPPRECHT, 1991).

A pesquisa e o desenvolvimento deste trabalho permitirá que se aponte a viabilidade da utilização de Rede de Kohonen para a construção de uma ferramenta de auxílio ao diagnóstico destas doenças, que poderá ser útil tanto em unidades básicas de saúde para os médicos, quanto em sala de aula como apoio didático aos professores.

O presente trabalho tem como finalidade a análise da utilização de Redes de Kohonen no auxílio ao diagnóstico de doenças reumatológicas, conhecidas como Mapas de Kohonen, ou SOM (*Self Organizing Maps*). Escolheu-se esta topologia por se tratar de uma topologia com grande plausibilidade biológica que se auto-organiza através de mecanismos de competição. Este paradigma, do tipo aprendizado não supervisionado, permite detectar similaridades entre vários sinais, agrupando-os em classes de similaridade, sendo desta forma, um passo para a determinação de padrões de uma coleção de sinais (BARRETO, 1999).

A escolha recaiu nesta abordagem visto ser o diagnóstico médico já tema de inúmeros trabalhos científicos, mas poucos abordam o uso de Mapas de Kohonen para diagnosticar doenças, a hipótese do trabalho é verificar se a topologia de Kohonen irá permitir criar um Sistema Especialista Conexionalista capaz de diagnosticar corretamente as doenças propostas.

Um outro objetivo do trabalho é comparar os resultados obtidos usando Redes de Kohonen com o resultados usando-se uma topologia conhecida como Rede Direta Multicamada com algoritmo de aprendizado do tipo *Backpropagation*.

## **1.2 Objetivos**

### **1.2.1 Geral:**

Assim sendo, reafirma-se a proposta inicial, ou seja, a de encetar a aplicabilidade das Redes de Kohonen (Mapas Auto-organizáveis de Kohonen) no auxílio ao diagnóstico médico, para uma doença específica.

### **1.2.2 Específicos:**

Assim, serão perseguidos os seguintes objetivos específicos:

1. Fazer uma análise da utilização de Redes de Kohonen (Mapas Auto-organizáveis de Kohonen) no auxílio ao diagnóstico médico, para doenças do sistema reumatológico, com estudo de caso para as seguintes patologias: Artrite Gotosa (AG), Artrite Reumatóide (AR) e Espondilite Anquilosante (EA).
2. Adquirir a Base de Dados
3. Implementar a Rede de Kohonen
4. Executar as experiências de acordo com as diversas topologias propostas
5. Analisar os resultados obtidos
6. Confirmar ou não a hipótese da aplicabilidade da Rede de Kohonen no auxílio ao diagnóstico médico mediante os resultados analisados
7. Comparar os resultados obtidos usando Mapas Topológicos de Kohonen com os obtidos usando Rede Direta Multicamada.

### **1.3 Estrutura da Dissertação**

Este trabalho está dividido em 6 capítulos. O capítulo 1 descreveu a motivação para a realização deste trabalho bem como o contexto geral em que o trabalho está inserido. Também são apresentados neste capítulo os objetivos gerais e específicos desta dissertação.

O capítulo 2 visa apresentar o conceito de Redes Neurais baseadas nas características do cérebro humano. Inicialmente, discorre-se sobre o cérebro humano, suas peculiaridades e funcionamento e sua modularidade. A seguir, descreve-se sobre as Redes Neurais conceitos e funcionamento. Continuando o capítulo 2, apresenta-se o conceito de redes neurais auto-organizáveis, bem como o processo de aprendizagem de Redes Neurais não supervisionado. Finalizando o capítulo, procura-se mostrar os conceitos e funcionamento das Redes Auto-organizáveis de Kohonen.

O capítulo 3 pretende situar o trabalho no estado da arte, mostrando o que se tem de desenvolvimento em termos de Redes Neurais para diagnóstico médico e o uso das Redes de Kohonen.

O capítulo 4 visa apresentar a metodologia e implementações dos modelos experimentais feitos, usando a topologia de Kohonen.

No capítulo 5 apresentam-se os resultados obtidos após o treinamento das redes. O capítulo 6 as conclusões bem como sugestões para trabalhos futuros.

## Capítulo 2

### Redes Neurais

#### 2.1 Introdução

As pesquisas na área de Redes Neurais Artificiais começaram concomitantemente com o estudo dos computadores digitais, na década de 40. Portanto é objeto de estudo por aproximadamente 50 anos, visto que houve um período de aproximadamente 10 anos considerado de marasmo em relação às pesquisas na área de RNA. Fato esse muito conhecido pelos pesquisadores e estudiosos da área devido ao trabalho divulgado por Minsky & Papert (1969) sobre o estudo do Perceptron, que teve uma repercussão muito negativa do estudo das RNA na época, levando com isso a uma paralisação das pesquisas em quase todo o mundo, principalmente nos grandes projetos, já que os patrocinadores destes projetos, geralmente as entidades governamentais não acreditavam mais que se pudesse alcançar sucesso com pesquisa nesse campo. Alguns pesquisadores mais audaciosos continuaram suas pesquisas apesar de tudo. Dentre eles, está o Finlandês Teuvo Kohonen que continuou dedicando-se à pesquisa e, em 1984, desenvolveu uma família de redes que possui a capacidade de auto-organização. Estas redes são capazes de reconhecer relações entre padrões apresentados à entrada da mesma após ser treinada por um processo competitivo e não supervisionado. Como poderá se observar mais adiante nesta dissertação, esta família de redes auto-organizáveis é inspirada na formação dos mapas topológicos do cérebro humano. O interesse desta dissertação é abordar os modelos de RNA que procuram se inspirar nesta característica, visto que o estudo das RNA é um campo muito extenso, portanto foge do escopo deste trabalho discorrer sobre outras topologias de RNA.

## 2.2 O Cérebro Humano

As Redes Neurais Artificiais tiveram sua origem e fundamentação baseada no estudo do cérebro e de suas conexões sinápticas. As Redes Neurais de Kohonen foram inspiradas no modelo dos mapas topológicos cerebrais. Esta seção trata sobre o funcionamento do cérebro humano, de onde os cientistas tiveram a inspiração para a construção de modelos destas redes.

Uma ilustração do cérebro com as partes que o compõem pode ser vista na Figura 2.1 a seguir.




Figura 2.1: Estrutura do cérebro e seus componentes

O cérebro humano foi objeto de atenção de cientistas desde o início das investigações, ou seja, desde Paracelso ou Philippus Aureolus Theophrastus Bombastus, cientista, médico e alquimista renascentista que acreditava que o cérebro humano era habitado por um pequeno ser, *o homúnculo*, o qual controlava o resto do corpo, passando por Descartes que comungou com a idéia. Mas sua crença era de que o homúnculo habitava a glândula pineal, por ele chamado o sítio da alma. Vide ilustração na Figura 2.2.



Figura 2.2: Representação do Homúnculo

Mesmo na Antigüidade, os gregos provavelmente em menor grau, para outras civilizações, o cérebro já era conhecido em nível macroscópico, ou seja, a anatomia de seus órgãos e elementos que os constituíam. Estudos sobre o cérebro continuaram e, no século XIX, os trabalhos do cientista espanhol Ramón y Cajal, merecem destaque em que descreveu não somente os vários tipos de neurônios presentes no sistema nervoso com suas árvores dentritais e axônios, mas também aglomerados destas células que formam as redes de processamento de informação do sistema.

Em 1909, Broadman mapeia o córtex cerebral humano em 50 áreas distintas por critérios citoarquiteturais, conforme pode ser visto na Figura 2.3 (KOVÁCS, 1997).

Muita coisa mudou desde então, os estudos a respeito do cérebro e do sistema nervoso permitiram avanços significativos nesta área. Apesar do estudo contínuo, o funcionamento das redes biológicas ainda não foi totalmente desvendado pelo homem. Não se sabe ao certo a forma como as funções cerebrais são realizadas, no entanto, a estrutura fisiológica básica destas redes de neurônios é conhecida. É exatamente nesta estrutura que se baseiam as Redes Neurais Artificiais (BRAGA, 1997).

Do ponto de vista físico, as redes neurais artificiais diferem bastante das redes biológicas. Vale ressaltar as similaridades entre estes dois tipos de sistema para que se possa compreender melhor o sistema nervoso ou para buscar idéias e inspirações a fim de pesquisa em neurocomputação. As características comuns são: os dois sistemas são baseados em unidades de computação paralela e distribuída que se comunicam por meio de conexões sinápticas, possuem detetores de características, redundância e modularização das conexões. Apesar de serem poucas, estas similaridades permitem que as RNAs reproduzam com fidelidade várias funções só encontradas nos seres humanos (BRAGA, 1997).

O cérebro é a parte mais importante do sistema nervoso central. Sob o ponto de vista do processo de informação, possui três níveis distintos:

1. Estrutural: composto por neurônios, regiões de neurônios e suas conexões;
2. Psicológico: é a maneira como o cérebro processa a informação em nível químico e reações físicas e transmissão de substâncias.
3. Cognitivo: que diz respeito ao pensamento humano.

O cérebro é um computador (sistema de processamento de informação) altamente *complexo, não-linear e paralelo*. Ele tem a capacidade de organizar seus constituintes estruturais, conhecidos por *neurônios*, de forma a realizar certos processamentos (por ex. reconhecimento de padrões, percepção e controle motor) muito mais rapidamente que o mais rápido computador digital hoje existente (HAYKIN, 2001).

A modularidade do cérebro desenvolveu-se por milhões de anos seguindo a evolução com o objetivo de executar funções cognitivas, usando uma estrutura compacta e adquiriu várias formas de organização: neurônios, colunas, regiões e hemisférios. O cérebro pode ser visto como várias redes de neurônios em diversas regiões que podem realizar processamento paralelo para executar funções cognitivas específicas (DODEL et. al., 2001), (KNOBLAUCH et. al., 2001). O mesmo pode ser comparado como um grupo de especialistas, que colaboram e executam as funções cognitivas, dividindo a tarefa em elementos menores (REILLY, 2001).

O cérebro humano contém cerca de 100 bilhões de neurônios ( $10^{11}$ ) e outras  $10^{15}$  conexões entre eles (KASAVOB, 1998). Sendo uma rede neuronal muito densa com neurônios altamente interconectados através de caminhos de transmissão, podendo cada um desses ter cerca de um metro ou mais, comunicando-se continuamente e em paralelo. A parte mais externa chama-se córtex cerebral. É responsável pela enorme quantidade de informação à qual se atribui estar armazenada a intensidade das conexões sinápticas entre os neurônios. As sinapses têm um papel fundamental na memorização da informação. Esta camada é extensamente convoluída, abrangendo uma superfície total de  $2000 \text{ cm}^2$ . Ao microscópio, revela-se uma estrutura laminar com tecido neural estratificado em seis camadas básicas. Cada camada é dominada por neurônios com estruturas anatômicas próprias (KÓVACS, 1997). Sob o ponto de vista da complexidade, o córtex cerebral provavelmente supera qualquer outra estrutura conhecida no universo (HUBEL e WEISEL, 1977).



Os estudos de Brodman sugerem que as regiões do córtex cerebral estão associadas a determinadas funções mentais, tais como: função motora, sensoriais e associativas.

Observando a Figura 2.3 pode-se ver que diferentes entradas sensoriais (motora, somestésica, visual, auditiva, etc.) são mapeadas sobre áreas correspondentes do córtex cerebral de uma forma ordenada.




Figura 2.3 – Mapa citoarquitetural do córtex cerebral.

Áreas de Broadman para o córtex humano. As diferentes áreas são identificadas pela espessura de suas camadas e tipos de células nelas contidas. Algumas das áreas específicas mais importantes são como segue. Córtex motor: banda motora, área 4; área pre-motora, área 6; campos oculares frontais, área 8. Córtex somestésico: áreas 3, 1, 2. Córtex visual: área 17, 18, 19. Córtex auditivo: áreas 41 e 42 (De A. Brodal, 1981; com permissão da Oxford University Press)

O cérebro está organizado em vários lugares de modo que entradas sensoriais diferentes são representadas por *mapas computacionais ordenados topologicamente*. Assim, o mapa computacional constitui um bloco construtivo básico na infra-estrutura de processamento de informação do sistema nervoso. Os mapas topográficos são organizados para responder à informação sensorial incidente. Estes mapas são freqüentemente arranjados em folhas, como um *colículo superior*, onde os mapas visual, auditivo e somestésico estão empilhados em camadas adjacentes de tal modo que

estímulos advindos de pontos correspondentes no espaço se localizem acima ou abaixo de cada um deles (HAYKIN, 2001).

Uma característica importante dos sistemas motor e sensorial é a existência de mapas topológicos no cérebro. Por exemplo, existem múltiplas representações ou mapas no córtex que correspondem a partes particulares do corpo para atividades somasensoriais ou motoras. No caso do sistema visual, grande parte da área visual do córtex é organizada de tal forma que estímulos provenientes de posições próximas à retina ativam posições próximas na superfície do córtex. No sistema auditivo, áreas do córtex auditivo são organizadas de tal forma que tons similares estimulam atividades em posições justapostas ou próximas. No mapa motor, posições próximas ativam áreas musculares que estão próximas umas das outras.

Mapas topológicos tendem a dedicar as maiores áreas para as atividades que são mais utilizadas. Por exemplo, a fóvea da retina é a área central da retina. É muito mais enervada; a acuidade visual é melhor lá. O mapa da retina no córtex dedica mais área para a fóvea.

A Figura 2.4 mostra o mapa da retina no córtex visual situado na parte mais de trás do cérebro. Metade do campo visual é desenhado à direita com diferentes áreas hachuradas que combinam com as correspondentes áreas do mapa à esquerda. O formato geral da extremidade de trás do cérebro e suas fissuras e convoluções são mostradas no desenho. A área do córtex dedicada à fóvea aparece numa área bem na extremidade traseira do córtex. É desproporcionalmente larga quando comparada com as outras áreas. Pode-se observar também uma distorção elástica que deve ser feita no campo visual com o propósito de caber nas saliências e convoluções do córtex.




Figura 2.4: Do lado esquerdo – Lobo occipital do cérebro, contendo o córtex visual, vista lateral; Do lado direito – O campo visual do olho direito dividido em diferentes áreas.

Fonte: M.Glickstein. The discovery of the visual cortex. *Scientific American* Sept.1998

O cérebro é um sistema de comunicação complexo. Este sistema transmite mensagens como impulsos elétricos que parecem sempre os mesmos, aparecem em monótonas sucessões. Um impulso nervoso simples carrega consigo muito pouca informação, entretanto o processamento de informações complexo só é possível pela interação do grupo de muitos neurônios e fibras nervosas, as quais são enormes em número e tamanho. O tamanho total de todas as ramificações nervosas dentro do corpo humano é cerca de  $10^{14}$  m. A presença de tal número de elos determina o alto grau de paralelismo massivo, que é específico ao mecanismo do cérebro (KASABOV, 1998).

O cérebro tem a capacidade de reagir adequadamente a situações não familiares devido a sua faculdade de heurística de tomar decisões baseadas em conhecimento previamente armazenado e sua habilidade em se adaptar. O cérebro tem a capacidade de aprender e de generalizar. O resultado do aprendizado é armazenado nas sinapses sob a forma de substâncias químicas concentradas.

O processo de lembrar é caracterizado pela generalização, ou seja, estímulos similares recordam padrões similares de atividades. O cérebro pode reagir a um estímulo não visto da melhor forma de acordo com padrões aprendidos anteriormente. A “distância” entre um padrão aprendido e o que é apresentado, define o nível de generalização.

O processo de desenvolvimento de sistemas computadorizados biologicamente inspirados envolve a verificação da funcionalidade e da arquitetura do cérebro com ênfase nas atividades de processamento da informação. Os mesmos utilizam evidências experimentais para criar sistemas de computadores inspirados na neurociência.

### **2.3 Redes Neurais Artificiais**

O Estudo das Redes Neurais Artificiais surgiu da inspiração dos modelos de neurônios biológicos e no sistema nervoso, apesar de hoje estarem muito distantes daquele modelo construído por McCulloch e Pitts em 1943, em que eles certamente estavam tentando imitar a realidade biológica, o que hoje em dia já não é a intenção nem interesse dos muitos pesquisadores que trabalham na área. O que leva os cientistas a serem motivados ao estudo das RNA, é modelar o sistema nervoso com precisão suficiente a se observar um comportamento emergente, que sendo semelhante ao comportamento do ser vivo modelado, possa servir de apoio às hipóteses usadas na modelagem, e construir computadores com alto grau de paralelismo. Este é um desejo mais recente, aquele já começou há cerca de um século (RUSSEL, 1993).

Uma Rede Neural Artificial (RNA) consiste num conjunto de unidades de processamento (neurônios) que se comunicam, enviando sinais uns para os outros sob um número muito grande de conexões .

Uma Rede Neural Artificial é uma variação da idéia de processamento distribuído (KRÖSE & SMAGT, 1996)

A RNA é um processador maciço paralelamente distribuído, constituído de unidades de processamento simples, que tem a propensão natural de armazenar conhecimento experimental e torná-lo disponível para uso. Assemelha-se ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
2. Forças de conexão entre os neurônios, conhecidas como pesos sinápticos são utilizados para armazenar o conhecimento adquirido.

Usa-se um algoritmo de aprendizado para o processo de aprendizagem cuja função é modificar os pesos sinápticos da rede de uma forma ordenada para alcançar um objetivo de projeto desejado.

As redes neurais artificiais também são conhecidas como redes conexionistas, neurocomputação ou processadores paralelamente distribuídos (HAYKIN, 2001).

Uma rede artificial consiste num conjunto de unidades de processamento simples que se comunicam umas com as outras, enviando sinais. Estão sob um grande número de conexões altamente ligadas através dos pesos de suas conexões. Estas unidades de processamento são conhecidas por neurônios. As conexões entre eles são conhecidas por conexões sinápticas. Alguns neurônios recebem excitações do exterior e são chamados neurônios de entrada, correspondem aos neurônios dos órgãos do sentido. Alguns têm respostas usadas para alterar de alguma forma o mundo exterior e são chamados de neurônios de saída, correspondem aos motoneurônios que são os neurônios biológicos os quais excitam os músculos. Os neurônios que não são nem de entrada nem de saída são classificados como neurônios intermediários, ou *hidden* (BARRETO, 1999). Uma ilustração de uma RNA é mostrada na Figura 2.5




Figura 2.5: Modelo de uma RNA

Cada unidade de processamento executa uma tarefa relativamente simples. Recebe entrada das unidades vizinhas ou fontes externas e as usa para computar um sinal de saída o qual é propagado para as outras unidades. Além deste processo, uma segunda tarefa é o ajuste dos pesos das conexões. O sistema é inerentemente paralelo já

que muitas unidades realizam suas tarefas computacionais ao mesmo tempo (KRÖSE & SMAGT, 1996).

Estas unidades de processamento são muito mais simples que uma Unidade Central de Processamento (UCP) típica. Em uma Rede Neural, cada processador está conectado com muitos de sua vizinhança (tipicamente centenas ou milhares) de tal forma que existem muito mais interconexões que processadores. O poder das Redes Neurais reside justamente na quantidade de números de interconexões.

O que causa espécie aos engenheiros e cientistas é o fato de modelos semelhantes aos do sistema nervoso biológico poderem atualmente ser implementados para uso computacional além da capacidade dos sistemas resultantes em fornecer uma aproximação efetiva para os problemas previamente insolúveis.

As redes neurais são usadas para resolver problemas que são intratáveis ou ineficientes pelos métodos tradicionais.

Se for comparada a arquitetura de uma Rede Neural com a arquitetura dos computadores tradicionais (arquitetura de Von Newmann), verificar-se-á que na arquitetura de Von Newmann há uma UCP simples que executa todas as tarefas computacionais e tem a capacidade de executar centenas ou mais comandos, o que é feito em seqüência, um de cada vez em passos sucessivos de um *clock* de tempo. Em Redes Neurais, ao contrário, uma unidade de processamento pode executar somente uma ou quando muito alguns cálculos. Uma função soma é realizada em suas saídas: mudanças incrementais são feitas para parâmetros associados com a interconexão. Esta estrutura simples, contudo, fornece uma Rede Neural com capacidade para classificar e reconhecer padrões, para realizar mapeamento de padrões, e ser útil como ferramenta computacional.

O poder de processamento de uma Rede Neural é medida, principalmente, pelo número de interconexões atualizadas por segundo; em contraste com as máquinas de Von Newmann que são pelo número de instruções e executadas por segundo, em seqüência por um simples processador (DAYHOFF, 1990).

### 2.3.1 Redes Auto-organizáveis

Outras topologias de redes neurais são treinadas para executar o mapeamento  $\mathfrak{S} : \mathfrak{R}^n \longrightarrow \mathfrak{R}^m$ , onde  $\mathfrak{S}$  é o conjunto de funções de ativação através da apresentação de um conjunto de exemplos  $(X^p, O^p)$ , com  $O^p = F(X^p)$ . Entretanto existem problemas em que a única informação disponível é fornecida por um conjunto de padrões  $X^p$ , ou seja, as saídas são desconhecidas. Nestes casos, a informação relevante deve ser encontrada dentro deste (redundante) treinamento de exemplos  $X^p$ .

Alguns exemplos desse tipo de problemas são: clusterização, quantização vetorial, redução de dimensionalidade e extração de características. Existem diversos tipos de redes auto-organizáveis, aplicadas a uma larga área de problemas, dentre os quais a topologia proposta por Kohonen, chamada de Mapas Auto-Organizáveis de Kohonen. Outras são: Aprendizado Competitivo proposto por Rumelhart e Zipser (Rumelhart e Zipser, 1985), ART (Arquiteture Resonancy Theory) proposta por Carpenter (Carpenter & Grossberg, 1987a; Grossberg, 1976), e Fukushima's cognitron (Fukushima, 1975, 1988) (KRÖSE & SMAGT, 1995) e o modelo de Von Der Malsburg (1976).

### 2.3.2 Aprendizado Não Supervisionado

Redes que utilizam o aprendizado não supervisionado são também conhecidas como auto-organizadas (*Self organizing*) em que uma unidade (saída) é treinada para responder a grupos ou padrões na entrada. Neste paradigma, o sistema deve descobrir estatisticamente características evidentes da população de entrada. Ao contrário do paradigma do aprendizado supervisionado, não existe um conjunto de categorias a priori conhecidas para dentro das quais o conjunto deva ser classificado. Ou seja, o sistema deve desenvolver sua própria representação dos estímulos de entrada (KRÖSE, 1995).

Este processo de aprendizado não envolve um professor externo, baseia-se apenas em informações locais e controle interno. Neste processo de aprendizado, os pesos dos neurônios são auto-organizados em função dos dados apresentados, para descobrir suas

propriedades coletivas emergentes e separá-los em classes de padrões. (AZEVEDO apud ROISENBERG, 1999).

### 2.3.3 Mapas Topológicos de Kohonen

Conforme discutido no capítulo anterior, o cérebro humano possui uma parte bastante extensa que o envolve, chamada córtex cerebral. É uma “folha” larga (1 a 2 metros) e fina (2 a 4 milímetros), possui em média 6 camadas de neurônios de vários tipos e densidade. Para que caiba na caixa craniana, ele é todo dobrado e amassado. É talvez mais complexa que qualquer outra estrutura conhecida no universo. É dividido em diversas regiões que correspondem a diferentes estímulos sensoriais tais como a fala, a acústica, o controle motor, o tátil, o visual. De modo que entradas sensoriais diferentes são representadas por mapas computacionais organizados topologicamente e mapeados para diferentes áreas do córtex cerebral. Observa-se que neurônios topologicamente próximos, tendem a responder a padrões ou estímulos semelhantes. Sabe-se também que esta ordenação topológica é fruto do *feedback* lateral entre as células do córtex cerebral, cuja representação matemática é conhecida como função chapéu mexicano. Foi nesta parte do cérebro humano que Tuevo Kohonen foi buscar inspiração biológica para o desenvolvimento das redes SOM (HAYKIN, 2001, ROISENBERG, 1999).

Os Mapas topológicos de Kohonen são mapas topográficos artificiais que aprendem através de auto-organização de uma maneira inspirada na neurobiologia, emergindo daí o princípio da formação de mapas topográficos formulado por Kohonen (KOHONEN, 1990a apud HAYKIN, 1999):

**“A localização espacial de um neurônio de saída em um mapa topográfico corresponde a um domínio ou característica particular de um dado retirado do espaço de entrada”.**

Deste princípio, surgiram dois modelos de mapeamento de característica diferentes: o modelo proposto por Wilshaw e von Der Malsburg em 1976 e o modelo proposto por Kohonen em 1982. Este trabalho utiliza-se do segundo modelo, o de Kohonen. Vejamos brevemente os dois modelos.



A Figura 2.6 mostra os modelos dos dois mapas auto-organizados de características.





Figura 2. 6: Mapa de Von Der Malsburg. e de Kohonen

O modelo de Von der Malsburg foi um dos primeiros modelos “self-organizing” a surgir. Este foi proposto inicialmente no campo biológico para tratar o problema do mapeamento da retina para o córtex visual. É um modelo de rede neural, treinado com o auxílio de um algoritmo, possui treinamento muito simples, reproduz as propriedades funcionais de algumas células encontradas no córtex visual (BRAGA, 2000). Especificamente, há duas grades bidimensionais separadas de neurônios conectadas entre si, uma delas se projetando sobre a outra. Uma grade representa os neurônios pré-sinápticos (de entrada) e, a outra, representa os neurônios pós-sinápticos (de saída). A

grade pós-sináptica utiliza um *mecanismo excitatório de curto alcance* bem como um *mecanismo inibitório de longo alcance*; mecanismos estes de natureza local e cruciais para a auto-organização.

As grades são conectadas entre si por sinapses modificáveis do tipo hebbiano. Não sendo os neurônios pós-sinápticos do tipo, o vencedor leva tudo. Ou seja, é usado um limiar para assegurar que apenas alguns poucos neurônios pós-sinápticos sejam ativados em um determinado instante. Além disso, a fim de evitar a instabilidade da rede com o constante aumento de pesos, o peso total associado à rede é limitado a uma condição de limite superior. Assim para cada neurônio alguns pesos aumentam, enquanto outros diminuem. A idéia básica deste modelo é que a proximidade geométrica de neurônios pré-sinápticos seja codificada na forma de correlação na sua atividade elétrica, e usar estas correlações na grade pós-sináptica de forma a conectar neurônios pré-sinápticos vizinhos com neurônios pós-sinápticos vizinhos. Dessa forma, um mapeamento topologicamente ordenado é produzido por auto-organização. O modelo de Von Der Malsburg, no entanto, se limita em mapeamentos onde a dimensão de entrada é a mesma da saída (HAYKIN, 2001).

O modelo de Kohonen captura características essenciais dos mapas computacionais do cérebro e ainda se mantém tratável sob o ponto de vista computacional. O modelo de Kohonen é mais geral que o modelo de Wilshaw von der Malsburg visto ser capaz de realizar compressão de dados (i.e., redução da dimensionalidade na entrada).

As redes auto-organizáveis de Kohonen são do tipo não supervisionado em que os algoritmos de adaptação dos pesos sinápticos são baseados em alguma forma de competição global entre os neurônios. Assim os neurônios de saída competem entre si para serem mais ativados pelos padrões de entrada. Estas são também conhecidas como Mapas Auto-organizáveis de Kohonen (*Self Organizing Maps*) ou Mapas de Características de Kohonen (*Self organizing feature maps*) ambas desenvolvidas pelo finlandês Teuvo Kohonen na década de 80, apesar de ser a época considerada das trevas no desenvolvimento das redes neurais.

Os mapas auto-organizáveis usam uma topologia em duas camadas: uma, a camada de entrada da rede e, a outra, a camada competitiva organizada como uma grade uni ou bidimensional. A camada competitiva pode possuir mais dimensões. Uma

topologia de Rede SOM em duas dimensões pode ser visualizada na Figura 2.7 e para ilustrar um modelo em 3 dimensões, tem-se a Figura 2.8. Trata-se de uma rede cujo aprendizado é do tipo competitivo e não supervisionado. É altamente interconectada, posto que cada neurônio da camada de entrada está conectado a todos os neurônios da camada competitiva. Cada neurônio da camada competitiva está conectado a todos os neurônios de sua vizinhança.




Figura 2.7 Topologia de uma Rede SOM em 2 dimensões

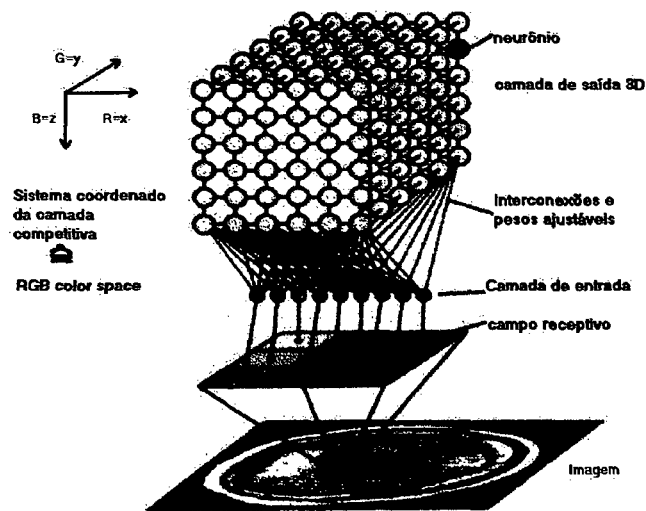


Figura 2.8: Topologia de uma Rede SOM em 3 dimensões

Os neurônios tornam-se seletivamente sintonizados a vários padrões de entrada (estímulos) ou classes de padrões de entrada durante o processo de aprendizagem. Entende-se por característica, a formação de um mapa topográfico dos padrões de entrada no qual as localizações espaciais (coordenadas) dos neurônios na grade são

indicativas das características estatísticas intrínsecas contidas nos padrões de entrada. Por isso, o nome mapa auto-organizável (DAYHOFF, 1990).

As redes Auto-organizáveis de Kohonen serão referenciadas neste trabalho simplesmente por SOM. Esta rede modela o feedback lateral, comentado na introdução desta seção, empregando uma função conhecida por chapéu mexicano. Através da introdução do conceito de vizinhos topológicos o algoritmo de treinamento da Rede SOM simula o efeito desta função, que a título de ilustração tem o gráfico reproduzido na Figura 2.9 a seguir:




Figura 2.9: Tipos de estímulos produzidos de acordo com a Função Chapéu Mexicano

As redes SOM funcionam basicamente da seguinte maneira: quando um padrão de entrada  $x$  é apresentado, a rede procura a unidade mais parecida com  $x$ . Durante seu treinamento, a rede aumenta a semelhança do neurônio escolhido e de seus vizinhos ao padrão  $x$ . Desta forma, a rede constrói um mapa topológico em que neurônios que estão topologicamente próximos respondem de forma semelhante a padrões de entrada semelhantes. Como a SOM tem respaldo biológico, neurônios ativos apresentam conexões mais fortes com neurônios que estão fisicamente mais próximos. Assim a rede SOM se apresenta como um modelo do córtex cerebral, uma vez que seus neurônios estão localmente interconectados e o processo de adaptação está restrito ao neurônio vencedor e seus vizinhos (BRAGA, 2000).

Na rede SOM, a atualização ou aprendizado é realizado, quando se usa não somente o neurônio vencedor, mas todos os neurônios em uma vizinhança ao redor do neurônio vencedor. O resultado do treinamento é um mapa discreto onde dados de entrada formam agrupamentos. O conceito de vizinhança é introduzido, arranjando-se os neurônios em um formato geométrico ao redor do neurônio vencedor. A vizinhança pode ter qualquer formato, não necessariamente regular, dependendo do tipo de problema a ser solucionado e da distribuição dos seus dados, mas geralmente o formato

quadrado é o mais utilizado. Os vizinhos de um determinado neurônio são então definidos como neurônios adjacentes no formato da vizinhança escolhido. A Figura 2.10 mostra os diferentes formatos que uma vizinhança pode apresentar.




Figura 2.10 Formatos de vizinhança

Na Figura. 2.11 tem-se um vetor  $x$  em três dimensões  $x = (x_1, x_2, x_3)$ . Todas as entradas são totalmente interconectadas para cada um dos 16 neurônios através dos 16 vetores de pesos tridimensionais  $w = (w_1, w_2, w_3)$ .




Figura 2.11 Rede de Kohonen com grade de 4 x 4

O nível de ativação (i.e. a saída) de cada neurônio é dada pela distância euclidiana entre o vetor de peso  $w = (w_1, w_2, w_3)$  e o vetor de entrada  $x$ :

$$d_j = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2} = \|x - w_j\|$$

No aprendizado competitivo cada conjunto é apresentado a rede um por um. Os níveis de ativação são computados e a saída mais bem sucedida é selecionada para ser atualizada. Neste caso, o vencedor é o neurônio que apresentar o nível de ativação menor, ou seja, o que tiver o vetor de peso  $w$  mais próximo do vetor de entrada  $x$  (HELLSTRÖM, 1998).

Assim a cada padrão de entrada apenas um neurônio de saída ou por grupo se torna ativo, sendo esta competição denominada de *Winner takes al*. O vencedor leva tudo. Um modo de implementar esta competição é através da utilização de conexões laterais inibitórias entre os neurônios de saída. Como visto anteriormente esta competição é realizada na Rede SOM através da simulação da função chapéu mexicano, segundo o qual, quando um neurônio vence a competição produzindo a maior saída na rede, não somente ele mas toda uma vizinhança a seu redor tem seus pesos atualizados. Com isso, ele chega a resultados semelhantes ao obtido com a utilização da função chapéu mexicano.

Definido o neurônio vencedor, começa a atualização dos pesos. Neste processo apenas o neurônio vencedor e seus vizinhos dentro de um certo raio de ação têm seus pesos ajustados. Durante o treinamento tanto a taxa de aprendizado como o raio de vizinhança são continuamente decrementados. O ajuste de pesos do neurônio vencedor e sua vizinhança são feitos segundo a equação:

$$w_j(t+1) = w_{ji}(t) + \alpha(t).(x - w_{ji}(t)) \forall j \in N_t$$

Onde  $N_t$  é a área de vizinhança

$\alpha$  é a taxa de aprendizado

$$w_j(t+1) = w_{ji}(t) \forall j \notin N_t$$

Cada vetor de peso que participa do processo de aprendizado rotaciona um pouco na direção do vetor de entrada  $x$ .

Esta equação faz parte do algoritmo de treinamento desenvolvido por Kohonen e apresentado na Tabela 2.1 a seguir:

Tabela 2.1: Algoritmo de Kohonen	
K0	Atribuir pequenos números randômicos para iniciar os vetores de peso $w_j (t=0)$ , para cada neurônio $j$ do mapa de saída.
K1.	Aplicar um vetor de entrada $x$ no momento consecutivo de tempo $t$ .
K2.	Calcular a distância euclidiana $d_j$ (num espaço $n$ -dimensional) entre $x$ e os vetores de pesos $w_j (t)$ de cada neurônio $j$ . No espaço euclidiano esta distância é calculada por: $d_j = \sqrt{\sum_{i=1}^n (x_i - w_{ji})^2} = \ x - w_j\ $
K3.	O neurônio $K$ que for mais próximo a $x$ é declarado o vencedor da competição. Ele se torna o centro de uma vizinhança de área $N_t$ .
K4.	Atualizar os vetores de peso de todos os neurônios dentro da área de vizinhança: $w_j(t+1) = w_{ji}(t) + \alpha(t) \cdot (x - w_{ji}(t)) \forall j \in N_t$ $w_j(t+1) = w_{ji}(t) \forall j \notin N_t$
K5	Todos estes passos de K1 a K4 são repetidos para todos os exemplos de treinamento. $N_t$ e $\alpha$ decrescem com o tempo. O mesmo procedimento de treinamento é repetido com o mesmo conjunto de treinamento até convergir. (KASABOV, 1998)

Existem dois parâmetros que precisam ser especificados: a taxa de aprendizado  $\alpha$  e área de vizinhança  $N_t$ .

A taxa de aprendizado inicia com valores relativamente grandes. Durante o processo de aprendizagem o valor de  $\alpha$  é diminuído após muitas interações. O valor inicial é atribuído e denominado aqui de  $\alpha_0$ . Valores típicos variam entre 0,2 – 0,5. O valor de  $\alpha$  é decrementado à proporção que o treinamento se processa. Uma taxa de decrescimento aceitável para  $\alpha$  é dado segundo a equação:

$$\alpha_t = \alpha_0(1-t/T)$$

Onde  $t$  é a iteração de treinamento corrente e  $T$  é o total de iterações de treinamento a ser executada. O valor de  $\alpha$  começa com  $\alpha_0$  e decresce até 0. O decrescimento é linear e em relação ao número de iterações de treinamento completadas.

O tamanho da vizinhança é outro parâmetro a ser especificado. Normalmente a vizinhança começa com um tamanho bem grande e é decrementado à medida que o número de iterações aumenta. Considerando a vizinhança traçada na Figura 2.12, a qual é centralizada no neurônio vencedor  $c$ , na posição  $(x_c, y_c)$ . Considerando ainda que  $h$  seja a distância de  $c$  até o canto da vizinhança, a vizinhança é então definida por todo  $(x, y)$  tal que :




Figura 2.12: Modelo de vizinhança

Vizinhança  $N_c$ , com centro no neurônio  $c$ , com  $h=1,2,$  e  $3$  e

$$c-h < y < c+h$$

$$c-h < x < c+h$$

Que é um quadrado em volta do neurônio vencedor. Algumas vezes este cálculo faz com que a vizinhança caia fora da grade, neste caso a vizinhança fica sendo toda a grade.



Já que o tamanho da vizinhança diminui com o número de iterações, o valor de  $h$  decresce. Inicialmente temos um valor  $h_0$  atribuído ao valor inicial de  $h$ . Valores típicos são metade ou um terço do tamanho da camada competitiva. O valor de  $h$  então decresce de acordo com a equação:

$$h = [h_0 (1 - t/T)]$$

Onde  $t$  é a iteração de treinamento corrente e  $T$  é o total de iterações de treinamento a ser executada. Este processo assegura o decréscimo do  $h$  começando em  $h_0$  e chegando em 1 (DAYHOFF, 1990).

Kohonen desenvolveu uma brilhante maneira de ilustrar a dinâmica do aprendizado para o processo dos exemplos como o do tipo descrito na Figura 2.13. Ao invés de plotar a posição dos elementos de processamento de acordo com a sua localização física, eles podem ser plotados de acordo com a sua localização no espaço de pesos. Então são desenhadas as linhas conectadas entre as unidades que são vizinhas no espaço físico. Conforme o treinamento prossegue, o mapa evolui (FREEMAN, 1992).

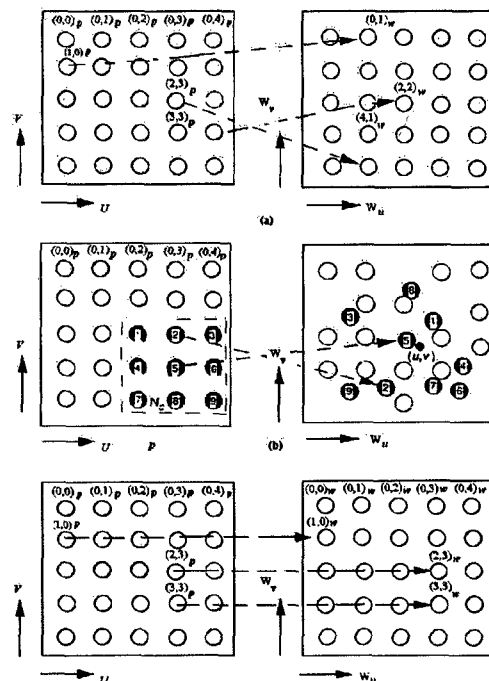


Figura 2.13 Dinâmica do Aprendizado das Redes de Kohonen  
Fonte: Freeman, 1992.

## Capítulo 3

### Redes Neurais Artificiais para Auxílio ao Diagnóstico Médico

#### 3.1 Introdução

Redes Neurais tem sido extensamente utilizadas, nas suas mais diversas arquiteturas, como ferramenta principal para a implementação de sistemas especialistas, neste caso, também chamados de Sistemas Especialistas Conexionistas (SEC).

A idéia de utilização dos SECs advém da capacidade intrínseca das Redes Neurais Artificiais de aprenderem através de exemplos, sendo especialmente indicadas para problemas mal definidos, onde existem muitas exceções, e onde é extremamente difícil extrair conhecimento do especialista para poder definir com precisão regras de decisão.

A área médica parece ser um domínio onde a forma de raciocínio do especialista é extremamente difícil de ser traduzida em regras, e onde a experiência propicia melhores condições de diagnósticos corretos, razão pela qual a utilização de SECs parece ser extremamente promissora.

Existem vários trabalhos publicados na área da Inteligência Artificial para o desenvolvimento de sistemas especialistas para auxílio ao diagnóstico médico. Diversos modelos de redes neurais têm sido utilizados, dentre estes o modelo de redes auto-organizáveis de Kohonen. Alguns dos trabalhos realizados neste setor usando Redes Neurais Artificiais estão abaixo descritos:

#### 3.1 Algumas Aplicações de SECs Desenvolvidas no Brasil

COIMBRA, A. J. F. *et. al.* Automatic detection of sleep-waking states using kohonen neural network. In: CONGRESSO BRASILEIRO DE REDES NEURAI, 1, 1994, Itajubá. **Anais...** Itajubá, 1994. p. 327-331.

Este artigo apresentado no 1º Congresso Brasileiro de Redes Neurais – Outubro de 1994, descreve o desenvolvimento e testes preliminares de um método para análise de

sinais eletrográficos de sonambulismo e reconhecimento de padrões usando a topologia de Redes Neurais Artificiais Auto-organizáveis de Kohonen (KNN).

BARRETO, J. M. et al A Neural network approach for medical diagnosis. Proceedings of the ISSM International Conference, California, USA, 1991. p. 78-81.

Redes Neurais são usadas como memórias associativas para construir um sistema especialista para diagnóstico. Semelhante aos sistemas especialistas que usam representação simbólica para manipular conhecimento, aqui o conhecimento é introduzido por um engenheiro do conhecimento usando uma coleção de casos conhecidos, bem como as possíveis relações entre variáveis consideradas. Este conhecimento é armazenado como pesos de conexões entre blocos de construções elementares, imitando os neurônios biológicos do cérebro. O significado semântico dos valores das conexões é dado pela função associação no conjunto fuzzy, interpretando as relações fuzzy entre sintomas, doenças, casos e exames de laboratório. Como principal resultados é mostrado que a rede neural proposta permite não somente encontrar uma solução para diversos casos, mas também advertir o usuário a obter mais dados clínicos se os dados disponíveis são insuficientes para conclusão do diagnóstico. Para ilustrar a abordagem e mostrado o caso para quatro doenças com sintomas semelhantes (dificuldade de diagnóstico).

COIMBRA, A.J.F, MARINO-NETO J., DE AZEVEDO F.M., FREITAS C.G., BARRETO J.M.: Brain electrographic state detection using combined unsupervised and supervised neural networks. Artificial neural nets and genetic algorithms. . In: PEARSON, D.W., N.C.Steele & R.F. Albrecht (eds.) "Artificial Neural Nets and Genetic Algorithms". Wien: Springer, 1995. p. 76-79.

Este trabalho descreve o desenvolvimento de novas abordagens para Redes Neurais no processamento de sinais eletrográficos do cérebro durante o sono usando duas topologias distintas uma supervisionada (camada widrow-Höff - WHNN) e uma não supervisionada (Kohonen – KNN). Doze parâmetros extraídos de dados fisiológicos

EEG, EMG e EOG, obtidos de ratos durante diversos períodos de sono. Foram primeiramente processados por KNN, que detectou diferentes modelos de sinais. Esses modelos foram posteriormente examinados por especialista em EGG que os identificou como pertencentes a um dos estágios de sono (*sleep-waking*) conhecidos, ou sinais de transição ou sinais desconhecidos combinados. Saídas selecionadas de KNN classificadas neste modo formaram vetores de entradas para a WHNN, que permitiu localização de mudanças rápidas e seguras neste estados (ambos conhecidos e detectados recentemente) durante prolongados períodos de tempo. Tal abordagem pode representar uma importante ajuda para exploração de simulações, detecção e também temporal dos eventos eletrográficos durante o ciclo de *sleep-waking*.

GARCIA, Ojeda Renato. Técnicas de inteligência artificial aplicadas ao apoio à decisão médica na especialidade de anestesiologia. 1992. Tese (Doutorado) em Engenharia Biomédica – Departamento de Engenharia elétrica, Universidade Federal de Santa Catarina, Florianópolis .

Este trabalho aborda o uso de um sistema especialista integrado, onde cada conhecimento é representado pela técnica que melhor se adapte às características do domínio de aplicação. Esta estrutura integrada, com processo semântico-numérico, reúne redes neurais, regras de produção, modelos clínicos e bases de dados, atuando sinergisticamente para dar apoio à decisão médica na proposta e avaliação de procedimentos anestésicos. Destina-se ao auxílio no ensino da anestesiologia, assim como apoio aos médicos.

BRASIL, Lourdes Matos. Aquisição de conhecimento aplicada ao diagnóstico de epilepsia. 1994. Dissertação (Mestrado) em Ciências – Engenharia Biomédica – Universidade Federal de Santa Catarina, Florianópolis.

Esse trabalho realiza uma análise das técnicas de elicitación de conhecimento aplicada ao diagnóstico da epilepsia. Para tal, foi escolhida Epilepsia do Lobo Temporal e utilizadas técnicas de elicitación e representação do conhecimento.

CASSA, José C. *et al.* Diagnóstico médico de tuberculose em sintomáticos respiratórios a partir da história clínica do paciente usando redes neurais artificiais. In: CONGRESSO BRASILEIRO DE REDES NEURAIAS, 3, 1997, Florianópolis. **Anais...** Florianópolis: Fundação Biblioteca Nacional, 1997.

Este trabalho foi apresentado no III congresso Brasileiro de Redes Neurais, realizado em Florianópolis em 1997 e tem como objetivo desenvolver um sistema computacional fundamentado em Redes Neurais Artificiais (RNA) que permita a identificação e triagem dos portadores de Tuberculose que apresentem sintomas respiratórios e o rápido encaminhamento destes para o tratamento adequado, enquanto se aguarda o diagnóstico definitivo. Esta estratégia deve contribuir para a racionalização da demanda e exames laboratoriais confirmatórios, mantendo-os apenas para aqueles que realmente necessitam. Para esta finalidade foi desenvolvida, a partir de uma base de dados relacionando a história clínica dos pacientes e o diagnóstico laboratorial de Tuberculose, uma rede do tipo GRNN (*General Regression Neural Network*) que apresentou 100% de respostas corretas para os casos positivos e negativos do conjunto de dados de avaliação.

PASSOLD, Fernando. Sistema especialista híbrido em Anestesiologia para pacientes críticos/problemáticos. 1995. Dissertação (Mestrado) em Ciências – Engenharia Biomédica – Departamento de Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis.

Este trabalho apresenta uma expansão introduzida no sistema especialista híbrido em anestesiologia, PROVANES, e busca auxiliar o processo de tomada de decisão dos anestesiológicos, para procedimentos cirúrgicos em cavidade abdominal, vasos e membros. Sua principal base de conhecimentos é formada por dez redes neurais que imitam o planejamento anestésico realizado pelo especialista na área.

SIGATI, Nanci Akemi. Estudo da influência de bases de caso em redes IAC (*Interactive Activation and Competition*) na implementação de sistema especialista para diagnóstico médico. 1997. Dissertação(Mestrado) em Ciências – Engenharia Biomédica –

Departamento de Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis.

Neste trabalho foi estudado o problema do aprendizado (baseado em casos) em redes conexionistas IAC (“*Interactive Activation and Competition*”). Foi desenvolvido um “*software*” para a implementação da rede IAC, contendo as versões de Rumelhart e McClelland, de Grossberg e a versão proposta por de Azevedo. Para validar o sistema e exemplificar o estudo da abordagem, foi construído um Sistema de apoio à Decisão Médica, utilizando um problema de Diagnóstico diferencial em Reumatologia. A seguir foi estudado o comportamento deste tipo de rede quando considerados casos reais clínicos diagnosticados por um especialista da área em comparação com uma rede contendo somente as relações entre doenças e sintomas. Discute-se finalmente, o desempenho comparativo das duas redes: aquela contendo somente as relações doenças sintomas e aquela contendo também os casos clínicos reais.

### **3.3 Algumas Aplicações de Sistemas Especialistas Que Usam Redes de Kohonen**

CHAGAS, Alexandre Viana; BOSSAN, Marcelo C; NADAL, Jurandir. Agrupamentos de Batimentos Cardíacos do eletrocardiograma utilizando uma camada de Kohonen. In: CONGRESSO BRASILEIRO DE REDES NEURAIS, 3, 1997, Itajubá. *Anais...* Florianópolis, 1997. p. 185-189.

Este artigo apresenta um sistema que visa extrair de um registro eletrocardiográfico de longa duração um sub-conjunto de batimentos que seja representativo do estado clínico do paciente. Para tal, é utilizada a análise de componentes principais, como técnica de redução de dimensionalidade, e uma camada de Kohonen, com treinamento não supervisionado, para o agrupamento de batimentos e separação daqueles mais representativos. Os resultados preliminares, obtidos utilizando-se registros do *MIT/BIH Arrhythmia Database*, demonstram que a técnica é potencialmente adequada para a utilização de monitores de arritmia e em eletrocardiografia ambulatorial.

CHEN, Dar-Ren; CHANG, Ruey-Feng; HUANG, Yu-Len. Breast cancer diagnosis using self-organizing map for sonography. **Ultrasound in Med & Biol.**, vl. 26, n. 3, p.405-411, 2000.

A intenção deste trabalho é avaliar a performance do modelo da Rede Neural Self Organising Maps (SOM) na classificação de lesões malignas e benignas da mama. São utilizados 243 casos de câncer (tumores) de mama sendo 82 malignos e 161 benignos que foram avaliados. Os sinais analógicos em vídeo foram capturados e foram obtidas imagens digitalizadas. O médico selecionou as regiões de interesse na sonografia. O modelo SOM utilizou 24 características de texturas autocorrelacionadas que classificam o tumor como maligno ou benigno. A performance do sistema ficou em 85%. Este sistema especialista para diagnóstico médico pode ser de grande ajuda para evitar biopsias benignas.

PAPADIMITRIOU, S. *et al.* Ischemia detection with a self-organizing map supplemented by supervised learning. **IEEE Transactions on Neural Networks**, v. 12, n. 3, p. 503-515, May 2001.

O problema de maximizar a performance da detecção de episódios de ischemia é um problema de classificação de padrão difícil. O espaço de estado para este problema consiste de regiões que caem perto de uma fronteira de separação e requer a construção de discriminantes complexos enquanto para o resto das regiões a tarefa de classificação é uma tarefa significativamente mais simples. A motivação em desenvolver este modelo de Rede, uma rede auto-organizável supervisionada (sNET-SOM) é explorar este fato para projetar uma solução computacional efetiva tanto para um problema de isquemia quanto para qualquer outro problema que compartilhe características semelhantes. Esta rede usa o aprendizado não supervisionado para as regiões “simples” e o supervisionado para as regiões ditas “difíceis” em dois estágios de processo de aprendizado. A abordagem não supervisionada usa o algoritmo de Kohonen, enquanto a Segunda fase (treinamento supervisionado) objetiva a construção de melhores limites de decisão nas regiões ambíguas. Nesta fase uma rede supervisionada é treinada para realizar a

classificação somente das regiões ambíguas. O treinamento supervisionado é baseado na função base radial e “*support vector machines*”.

### 3.4 Outros Sistemas Especialistas Conexionistas

Além desses, podemos citar também as seguintes publicações:

ACCIANI, G. *et al.* Validation of neural network analysis to predict prognosis in breast cancer patients. In: MIDWEST SYMPOSIUM ON CIRCUITS AND SYSTEMS (MWSCAS '93), 37, 1993, Detroit. **Proceedings...** New York: IEEE, 1993. v.1, p. 453-456.

AHMED, Mohamed N.; FARAG, Aly A. Two-stage neural network for volume segmentation of medical images. In: INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, 1997. **Proceedings...** Piscataway, NJ: IEEE Service Center, 1997. v. III, p. 1373-1378.

AHMED, Mohamed N.; FARAG, Aly A. 3D segmentation and labeling using unsupervised clustering for volumetric measurements on brain CT imaging to quantify TBI recovery. ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 18, St. Louis, Missouri, 1997. New York: IEEE, 1997. p. 738-739.

ARA, M. *et al.* Application of self-organizing feature map to failure diagnosis through sound data. **Research Reports of Kogakuin University**, v. 4, n. 82, p. 129-133, 1997.

ASHUTOSH K. *et al.* Prediction criteria for successful weaning from respiratory support: statistical and connectionist analyses. **Critical Care Medicine**, v. 20, n. 9, Sep. 1992. p. 1295 - 1301.

BAILEY, M. *et al.* Hybrid systems for medical data analysis and decision making: a case study on varicose vein disorders. In: NEW ZEALAND INTERNATIONAL TWO-STREAM CONFERENCE ON ARTIFICIAL NEURAL NETWORKS AND EXPERT SYSTEMS (ANNES '95), 2, 1995, Dunedin, New Zealand. **Proceedings...** Los Alamitos: IEEE, 1995. p.265-268.



DORFFNER, Georg; RAPPELSBERGER, Peter; FLEXER, Arthur. Using selforganizing feature maps to classify EEG coherence maps. In: INTERNATIONAL CONFERENCE ON ARTIFICIAL NEURAL NETWORKS (ICANN'93), 1993, Amsterdam. **Proceedings...** Heidelberg: Springer-Verlag, 1993. p. 882-887.

ELO, Pekka *et al.* Classification of epileptic EEG by using self-organizing maps. In: ARTIFICIAL NEURAL NETWORKS, 2, 1992, [cidade]. **Proceedings...** Amsterdam: North-Holland, 1992. p. 1147-1150

GIULIANO, F. *et al.* Potentially functional regions of nucleic acids recognized by a Kohonen's self-organizing maps. **Comput. Applic. Biosci**, v. 9, n. 6, p. 687-693, 1993.

HARRIS, Tom. A Kohonen S. O. M. based, machine health monitorin system which enables diagnosis of faults not seen in the training set. In: INT. JOINT CONF. ON NEURAL NETWORKS, 1993, Nagoya. **Proceedings...** Piscataway, NJ: IEEE Service Center, 1993. v. I, p. 947-950.

KALLIO, K. *et al.* Classification of lung sounds by using self-organizing feature maps. In: ARTIFICIAL NEURAL NETWORKS, 1, 1991, Amsterdam. **Proceedings...** Amsterdam: North-Holland, 1991. v. I, p. 803-808.

KASKI, Samuel; JOUTSINIEMI, Sirkka-Liisa. Monitoring EEG signal with the self-organizing map. In: INT. CONF. ON ARTIFICIAL NEURAL NETWORKS, 1993. **Proceedings...** London: Springer, 1993. p. 974-977.

KÖHLE, Monika; MERKL, Dieter. Identification of gait pattern with self-organizing maps based on ground reaction force. In: EUROPEAN SYMP. ON ARTIFICIAL NEURAL NETWORKS, Bruges, Belgium, 1996. **Proceedings...** p.73-78.

LIU, Xiaohui; CHENG, Gongxian; WU, John. Managing the noisy glaucomatous test data by self-organizing maps. In: INT. CONF. ON NEURAL NETWORKS, 1994. **Proceedings...** Piscataway, NJ : IEEE Service Center. p. 649-652.

MORASSO, Pietro *et al.* Self-organizing neural network for diagnosis. In: INT. CONF. ON ARTIFICIAL NEURAL NETWORKS, 1993. **Proceedings...** London: Springer, 1993. p. 806-809.

OSDOL, William W. van *et al.* The Kohonen Self-Organizing Map applied to in vitro screening data for chemotherapeutic agents. In: WORLD CONGRESS ON NEURAL NETWORKS, 1995. **Proceedings...** v. II, p. 762-766.

PORTIN, K.; SALMELIN, R.; KASKI, S. Analysis of magnetoencephalographic data with self-organizing maps. In: ANNUAL CONF. OF THE FINNISH PHYSICAL SOCIETY, 27, 1993, Turku, Finland. **Proceedings...** Helsinki: Finnish Physical Society, 1993. p. [15. 2 ?]

ROBERTS, S.; TARASSENKO, L. Analysis of the human EEG using self-organising neural nets. In: IEE COLLOQUIUM ON NEUROLOGICAL SIGNAL PROCESSING, 1992. **Digest No. 069.** London: IEE, 1992. p. 6/1-3.

RODRÍQUEZ, Mariá José; DEL POZO, Francisco; ARREDONDO, María Teresa. Use of unsupervised neural networks for classification of blood pressure time series. In: WORLD CONGRESS ON NEURAL NETWORKS, 1993. **Proceedings...** Hillsdale, NJ: Lawrence Erlbaum, 1993. v. II, p. 469-472.

## Capítulo 4

### Metodologia e Implementação dos Modelos

#### 4.1 Introdução

Os Sistemas Especialistas Conexionistas são sistemas computacionais que buscam por meio de aprendizado por exemplos, imitar a atuação de um determinado especialista no domínio da aplicação, além de obter conhecimento para responder com eficiência, questões de problemas específicos do conhecimento adquirido e, dessa forma, comportar-se como o especialista humano.

Conforme abordado no capítulo 3, a área médica apresenta forte tendência para o desenvolvimento deste tipo de Sistema por ser uma ciência, ou seja, que pesquisa o funcionamento orgânico, psíquico-social humano, portanto probabilístico. Apresenta um raciocínio bastante complexo para a busca do diagnóstico correto.

Atualmente os Sistemas Conexionistas ainda não atingiram a capacidade cognitiva dos humanos, apesar de ser um sonho acalentado pelos pesquisadores no assunto, mas na falta do especialista humano podem ser utilizados como instrumentos de grande valia nas áreas direcionadas.

Com base nestas considerações iniciais, pretende-se neste capítulo comprovar a capacidade de utilização das Redes Auto-Organizáveis de Kohonen ou SOM (*Self-Organizing Maps*) no auxílio ao diagnóstico médico, usado como caso prático em que a finalidade desta é aprender a encontrar as quatro possibilidades de diagnóstico conforme a Tabela 4.1.

Tabela 4.1: Diagnóstico possíveis para aos dados obtidos

<i>Código</i>	<i>Diagnóstico</i>
1	Espondilite Anquilosante (EA)
2	Artrite da Gota ou Artrite Gotosa (AG)
3	Artrite Reumatóide (AR)
4	Saudável

O objetivo geral desta pesquisa é verificar a capacidade das Redes auto-organizáveis de Kohonen como uma metodologia viável para o desenvolvimento de um sistema especialista para auxílio ao diagnóstico e capaz de ser viabilizada. Não é objetivo construir uma ferramenta prática, a ser implantada num sistema de saúde real, pelo menos no escopo deste trabalho.

## 4.2 Base de Dados

A pesquisa é realizada trabalhando-se com um universo amostral de 50 casos clínicos, distribuídos entre as três patologias a diagnosticar.

Esses dados são de origem secundária, buscados em Órgão de Saúde Credenciado qual seja a Clínica *EMONT GODINE* da Universidade Católica de Lovain, na Bélgica<sup>1</sup> (EPPRECHT, 1999). Considerando o princípio ético de sigilo em relação à identidade dos pacientes pesquisados.

Na amostra representada trabalha-se com as variáveis: idade (Id), sexo (Sx), dor lombar(Dl), rigidez na coluna (Rc), deformação na coluna (Dc), mobilidade (Mb), dor ao toque no sacroilíaco (Ds), artrite (Ar), rigidez matinal (Rm), bursite (Br), tofos (Tf), sinovite (Sn), artralgia (Ag), nódulos reumáticos (Nr), HLA-B27, deformação nas juntas (Dj), alterações laboratoriais (Al), evidências radiológicas (Er) e tomografia computadorizada (Tc). As duas primeiras variáveis não são consideradas sintomas, bem como as três últimas, que são exames clínicos, num total de 19 variáveis que de acordo com a tabela 4.2 e 4.3 a seguir. A tabela 4.4 apresenta a lista de abreviaturas usadas nas tabelas 4.2 e 4.3.

---

<sup>1</sup> Essa base de casos foi compilada e cedida gentilmente pela Dra. Lycia Epprecht, atualmente na Universidade Estadual do Rio de Janeiro.

**Tabela 4.2:** Casos Clínicos de Reumatologia

Cs	Sx	Id	Di	Rc	Dc	Mb	Ds	Al	Er	Tc	Diagnóstico	Ar	Rm	Br	Tf	Sn	Ag	Nr	Hb	Dj	
1	M	30	s	s	s	li	s	a	m	m	Espondilite Anquilosante	n	n	n	n	n	n	n	n	n	n
2	F	23	n	n	n	nl	n	a	m	n	Artrite Gotosa	s	n	n	n	n	s	n	n	n	n
3	M	30	n	n	n	li	n	m	m	n	Artrite Gotosa	s	s	s	s	s	s	n	n	n	n
4	M	70	n	n	n	li	n	a	m	n	Artrite Gotosa	n	n	n	s	n	s	n	n	n	n
5	F	63	n	n	n	nl	n	m	i	m	Artrite Reumatóide	n	n	n	n	n	s	n	n	n	n
6	M	59	n	n	n	li	n	mi	mi	j	Artrite Gotosa	s	n	n	s	s	s	n	n	n	n
7	F	61	n	n	n	li	n	m	mi	n	Artrite Reumatóide	s	n	n	n	s	s	n	n	n	n
8	M	21	s	n	s	nl	s	m	i	i	Espondilite Anquilosante	n	n	n	n	n	n	n	n	p	n
9	F	56	s	s	n	li	s	i	mi	i	Artrite Reumatóide	s	s	n	n	s	s	n	n	n	n
10	F	72	n	n	n	li	n	mi	a	m	Artrite Reumatóide	s	s	n	n	s	s	s	n	n	n
11	M	24	s	s	s	li	s	m	i	n	Espondilite Anquilosante	n	n	n	n	n	n	n	n	p	n
12	F	77	n	n	n	li	n	l	m	n	Artrite Reumatóide	s	n	n	n	s	s	n	n	n	n
13	M	57	n	n	n	li	n	mi	a	n	Artrite Gotosa	s	n	n	n	s	s	n	n	n	n
14	F	74	n	n	n	li	n	i	a	l	Artrite Reumatóide	s	s	n	n	s	s	n	n	n	n
15	F	35	n	n	n	nl	n	n	n	n		n	n	n	n	n	n	n	n	n	n
16	F	21	s	n	n	nl	n	l	mi	n	Espondilite Anquilosante	n	n	n	n	n	n	n	n	n	n
17	M	46	n	n	n	li	n	m	m	n	Artrite Gotosa	s	n	n	s	n	s	n	n	n	n
18	F	70	n	n	n	nl	n	l	i	n	Artrite Reumatóide	s	s	n	n	s	s	n	n	n	n
19	M	57	s	s	s	li	n	m	mi	m	Espondilite Anquilosante	s	n	n	n	n	s	n	p	s	s
20	M	41	s	n	n	nl	n	m	a	n	Espondilite Anquilosante	s	n	n	n	s	s	n	p	n	n
21	F	72	n	n	n	li	n	i	a	m	Artrite Reumatóide	s	s	n	n	s	s	n	n	s	s
22	M	59	n	n	n	nl	n	l	i	n	Artrite Gotosa	s	n	n	s	s	s	n	n	n	n
23	F	18	s	n	n	nl	n	a	m	m	Espondilite Anquilosante	n	n	n	n	n	s	n	p	n	n
24	M	28	s	s	n	nl	s	a	m	l	Espondilite Anquilosante	n	s	n	n	n	n	n	p	n	n
25	M	22	s	n	s	nl	n	a	i	n	Espondilite Anquilosante	n	n	n	n	n	n	n	p	n	n

**Tabela 4.3:** Casos Clínicos de Reumatologia – (Continuação da Tabela 4.2)

Cs	Sx	Id	DI	Rc	Dc	Mb	Ds	Al	Er	Tc	Diagnóstico	Ar	Rm	Br	Tf	Sn	Ag	Nr	Hb	Dj
26	M	27	n	n	n	nl	n	i	a	n	Artrite Reumatóide	n	n	s	n	n	s	s	n	n
27	M	40	s	s	n	nl	n	l	i	i	Espondilite Anquilosante	n	n	n	n	n	n	n	p	n
28	F	63	s	s	n	nl	n	a	a	n	Artrite Reumatóide	n	s	n	n	n	s	n	n	n
29	M	69	n	n	n	li	n	m	m	m	Artrite Gotosa	s	n	n	n	n	s	n	n	n
30	M	65	n	n	n	li	n	i	i	m	Artrite Gotosa	s	n	s	s	s	s	n	n	n
31	M	32	s	s	s	nl	n	a	i	n	Espondilite Anquilosante	n	n	n	n	n	n	n	p	n
32	M	50	n	n	n	nl	n	i	i	n	Artrite Gotosa	s	s	s	s	n	s	n	n	n
33	M	38	s	n	n	nl	s	m	i	n	Espondilite Anquilosante	n	s	n	n	n	n	n	p	n
34	F	54	n	n	n	li	n	l	i	n	Artrite Reumatóide	s	s	n	n	s	s	n	n	n
35	M	55	n	n	n	li	n	l	m	n	Artrite Reumatóide	s	s	n	n	s	s	n	n	n
36	M	39	s	s	n	nl	s	a	i	i	Espondilite Anquilosante	n	s	n	n	n	s	n	p	n
37	M	38	n	n	n	nl	n	i	m	n	Artrite Gotosa	s	n	s	s	s	s	n	n	n
38	M	57	n	n	n	li	n	m	a	n	Artrite Gotosa	n	n	s	s	n	n	n	n	n
39	F	64	n	n	n	li	n	m	i	n	Artrite Reumatóide	s	n	n	n	s	s	n	n	n
40	M	70	n	n	n	nl	n	i	i	n	Artrite Reumatóide	s	n	n	n	s	s	n	ñ	n
41	F	36	n	n	n	li	n	i	m	m	Artrite Reumatóide	s	n	n	n	s	s	n	n	n
42	M	36	s	n	n	nl	n	m	i	n	Espondilite Anquilosante	n	n	n	n	n	n	n	p	n
43	F	48	n	n	n	nl	n	i	i	n	Artrite Reumatóide	n	s	n	n	n	s	n	n	n
44	F	24	n	n	n	li	n	a	a	n	Artrite Reumatóide	s	n	n	n	s	s	n	ñ	n
45	M	69	s	n	n	nl	n	l	i	n	Artrite Gotosa	s	n	n	n	s	s	n	n	n
46	F	32	s	s	n	li	s	l	i	n	Espondilite Anquilosante	n	s	n	n	n	n	n	ñ	n
47	M	63	n	n	n	li	n	i	m	n	Artrite Reumatóide	s	s	n	n	s	s	n	n	n
48	F	39	n	n	n	nl	n	m	i	n	Artrite Reumatóide	n	s	n	n	n	s	n	n	n
49	F	33	s	s	n	li	n	i	m	n	Espondilite Anquilosante	n	n	n	n	n	n	n	p	n
50	M	33	s	n	n	nl	n	a	m	m	Artrite Gotosa	n	n	n	n	n	s	n	n	n

**Tabela 4.4:** Casos Clínicos de Reumatologia - Abreviaturas

Abreviação	Texto Original	Abreviação	Texto Original
a	Ausente	Ag	Artralgia
i	Importante	Al	Alterações Laboratoriais
l	Leve	Ar	Artrite
li	Limitado	Br	Bursite
m	Moderado	Cs	Caso
mi	Muito Importante	Dc	Deformação na coluna
n	Não	Dj	Deformação nas juntas
ñ	Negativo	DI	Dor lombar
nl	Normal	Ds	Dor ao toque no sacroilíaco
p	Positivo	Er	Evidências Radiológicas
s	Sim	Hb	HLA - B27
		Id	Idade
		Mb	Mobilidade
		Nr	Nódulos Reumáticos
		Rc	Rigidez na coluna
		Rm	Rigidez Matinal
		Sn	Sinovite
		Sx	Sexo
		Tc	Tomografia Computadorizada
		Tf	Tofo

### 4.3 Descrição Qualitativa das Variáveis Pesquisadas (Doenças)

Segundo Epprecht (1999) existem critérios para a classificação das doenças objeto desta pesquisa que de maneira sucinta são qualificadas em decorrência de sintomas e que a seguir serão elencados sendo necessário subdividi-las ou catalogá-las:

a) Na AR, Artrite Reumatóide, existem critérios diagnóstico que a classificam em AR Clássica, AR Definida, AR Provável ou AR Possível:

Na AR clássica são necessários 7 dos critérios abaixo, sendo que de 1 a 5 dos critérios, os sinais e sintomas devem persistir pelo menos 6 semanas.

- 1- Rigidez matinal
- 2- Dor ao movimento, ou hipersensibilidade em pelo menos uma articulação
- 3- Edema (aumento de volume) em pelo menos uma articulação
- 4- Edema em pelo menos em uma outra articulação (intervalo entre os dois episódios menor que 3 meses)
- 5- Edema articular simétrico, com envolvimento simultâneo da mesma articulação de ambos os lados do corpo
- 6- Nódulos subcutâneos
- 7- Alterações radiológicas típicas de AR, que devem incluir no mínimo uma descalcificação óssea localizada ao redor das articulações envolvidas, não somente alterações degenerativas
- 8- Fator reumatóide positivo (alterações laboratoriais)
- 9- Líquido sinovial com precipitado de mucina
- 10- Alterações histológicas característica na membrana sinovial
- 11- Alterações histológicas nos nódulos

NA “AR Definida” tem que existir 5 dos critérios acima descritos e os sinais e sintomas devem persistir pelo menos 6 semanas. A AR provável requer 3 dos critérios e em pelo menos um dos critérios de 1 a 5 os sinais e sintomas devem persistir pelo menos 6 semanas.



A “AR Possível” requer dois dos critérios abaixo e a duração total dos sintomas deve ter pelo menos 3 semanas:

- 1- rigidez matinal
- 2- dor ao movimento, ou hipersensibilidade em pelo menos uma articulação
- 3- história ou observação de edema articular
- 4- nódulos subcutâneos
- 5- as seguintes alterações laboratoriais: VHS elevada ou proteína C reativa
- 6- irite

b) “AG”, ou “Artrite Gotosa”, pode aparecer sem indícios, podendo ser precipitada por pequeno trauma, excesso alimentar ou alcóolico, cirurgia, fadiga, stress etc. As características clínicas são distintas e geralmente um diagnóstico presuntivo pode ser feito, via exame físico e laboratorial, além do perfil histórico do paciente. A presença de urato no sangue apoia o diagnóstico mas não é específico. A presença de cristais de urato em forma de agulha no líquido sinovial é patognomônico. O exame radiológico das articulações afetadas pode mostrar lesões perfurantes no osso subcondral. Os tofos gotosos são visíveis no RX após um determinado tamanho. Essas lesões são não específicas ou diagnóstica.

c) “EA”, ou “Espondilite Anquilosante”: O sintoma que se apresenta com maior frequência é a dor lombar, mas a doença pode iniciar atipicamente nas articulações periféricas e irite. Não existem exames laboratoriais específico para EA. No RX o diagnóstico pode ser confirmado com anormalidades nas articulações sacroilíacas. Porém algumas alterações precoces podem ser observadas como desmineralização difusa na coluna e calcificações ligamentares isoladas. Alterações precoces são as de desmineralização difusa na coluna e calcificações ligamentares isoladas. A clássica “coluna em bambu” só ocorre depois de anos de doença.

O sintoma Inflamações laboratoriais - são as alterações laboratoriais que comprovam um processo inflamatório.

Evidências radiológicas - são alterações no RX compatíveis com determinadas Patologias.

Conforme Epprecht (1999) “A medicina não é uma ciência exata, cada organismo responde de um jeito às pressões e doenças. Sempre existirão casos de difícil diagnóstico.”

“...O sexo e a idade são critérios razoavelmente relevantes no diagnóstico diferencial da AR e da AG...”

#### 4.4 Topologia da Rede

A rede neural utilizada neste trabalho é a rede de Kohonen, ou mais especificamente Mapas Auto-organizáveis de Kohonen ou SOM. A rede é do tipo competitivo e não supervisionado. Usa-se nesta dissertação o algoritmo de aprendizado típico de Rede Auto-Organizável de Kohonen.

A topologia da rede é formada por um conjunto de 19 neurônios na camada de entrada, e uma grade bidimensional de 10 X 10 perfazendo um conjunto de 100 neurônios na camada de saída, como pode ser visto na Figura 4.1.




Figura 4.1: Topologia da Rede de Kohonen

A escolha da grade de 100 neurônios foi uma escolha aleatória. Têm-se, portanto 100 saídas possíveis para as entradas a que rede for submetida.

Durante os experimentos tem-se uma variação do conjunto de entrada, ora contendo 19 neurônios, ora 18 ou na segunda parte das experiências, 17 neurônios, exceto para a experiência 6.

Os neurônios de entrada correspondem às informações contidas na ficha do paciente como sexo, idade, respostas aos sintomas, aos exames de laboratório e radiológicos e na camada de saída, ou seja no mapa topológico obtém-se, após o treinamento, que a rede forme agrupamentos (*clusters*) de neurônios indicativos dos padrões de entrada, possibilitando os diagnósticos das patologias.

Os neurônios das camadas de entrada e da camada de saída são amplamente conectados, ou seja para cada um dos 19 ou 18 ou 17 neurônios de entrada haverá 19, 18 ou 17 conexões sinápticas para cada neurônio na camada de saída e correspondentemente 19 pesos sinápticos para cada um.

O conhecimento da rede reside no peso de suas conexões e o aprendizado é realizado através dos ajustes destes pesos. Os pesos são ajustados utilizando-se o algoritmo de Kohonen apresentado no capítulo 2.

O aprendizado é um processo estocástico e o número de interações para o processo deve ser relativamente grande, não se tem uma regra partindo-se de pressupostos básicos fundamentadas em observações de pesquisadores que sinalizam como tal, um número razoável é tomar o valor de 500 iterações e multiplicar pelo número de neurônios da camada de saída. No caso em questão seriam 50.000. Nesta dissertação as redes foram treinadas para vários números de iterações ou épocas com o objetivo de avaliar o aprendizado da rede e não apenas 10.000 e 50.000.

Após o treinamento a rede está apta a classificar qualquer uma das quatro saídas possíveis a que for submetida, incluída ou não no conjunto de treinamento.

Em todas as experiências considera-se a taxa de aprendizado iniciando com o valor 0.9 e decrementando monotonicamente até 0.

O aprendizado da rede é obtido ajustando-se seus pesos sinápticos, este ajuste como visto anteriormente no capítulo 2, é dado pela menor distância euclidiana entre o vetor de peso e o vetor de entrada da rede.

## 4.5 Implementação dos Modelos

Diversos modelos de Rede de Kohonen foram implementados para averiguar a capacidade destas redes de *clusterizarem* os dados de entrada no mapa topológico de saída permitindo o aprendizado da rede.

### 4.5.1 Parte 1

A base amostral de 50 casos é utilizada como conjunto de treinamento na entrada da rede SOM, bem como para os testes da rede nesta primeira parte dos experimentos, que são realizados conforme descrito abaixo:

#### 4.5.1.1 Experiência 1

Consideram-se todos os parâmetros de entrada: sintomas, exames laboratoriais, idade e sexo.

Treina-se a rede SOM com 50 casos e testa-se a rede com os mesmos. As fases de treinamento e teste são feitas para 200, 1.000, 10.000 e 50.000 épocas.

Para se verificar se a metodologia usada poderia ter sucesso optou-se por começar treinando a rede usando todos os casos da tabela de exemplos. Usou-se também um total de 10.000 iterações pois que seria um número de iterações razoável para treinar a rede. Incorporou-se todos os sintomas, inclusive o perfil sexo e a idade dos pacientes. Testou-se a rede com todos os casos, ou seja a base de treinamento foi similar a base de testes.

Feito isso, partiu-se para averiguar outras possibilidades de treinamento da rede.

Outros treinamentos foram desenvolvidos variando-se o número de iterações, primeiro com 200 que é um número bem pequeno e foi observado o comportamento da rede. Depois com um número maior, por exemplo 1.000 e novamente verificou-se o comportamento da rede.

Finalmente foi feita uma experiência usando um número de iterações bem grande ou que fosse de acordo com o que é recomendado pelos pesquisadores: 50.000 e analisamos o resultado comparando com as respostas obtidas nas experiências anteriores

Observa-se se a rede foi capaz de *clusterizar* os padrões de entrada de modo a ser possível distinguir entre os quatro diagnósticos propostos.

#### **4.5.1.2 Experiência 2**

Busca-se com essa experiência verificar a relevância dos parâmetros sexo e idade para o diagnóstico e confirmar o que diz a literatura a respeito do assunto.

Consideram-se todos os parâmetros de entrada, menos sexo e idade.

A rede SOM é treinada para os 50 casos. A rede SOM é testada para os mesmos 50 casos.

Observa-se se a rede foi capaz de aprender os padrões de entrada e os resultados serão comparados aos obtidos na experiência 1.

As fases de treinamento e teste são feitas considerando 10.000 épocas.

#### **4.5.1.3 Experiência 3**

Pretende-se verificar a relevância do fator sexo no diagnóstico. Serão considerados todos os parâmetros menos o sexo.

A rede SOM é treinada para os 50 casos.

A rede SOM é testada para os 50 casos.

As fases de treinamento e teste são feitas considerando 10.000 e 50.000 épocas.

Observa-se se a rede foi capaz de aprender os padrões de entrada e os resultados são comparados aos obtidos na experiência 1 e 2.

### **4.5.2 Parte 2**

A base amostral de 50 casos é utilizada dividindo-a em duas : uma contendo 32 casos escolhidos aleatoriamente entre os 50 casos da amostra e outra contendo os 18 casos restantes.. A Tabela 4.6 traz os 32 casos que serviram de base treinamento já com os parâmetros normalizados no intervalo de  $[-1,1]$ , exceto a última coluna que fornece o diagnóstico, conforme a Tabela 4.1. A base com os 32 casos é usada para treinamento e a base de 18 casos como base de teste da rede SOM, os experimentos são realizados conforme descrito abaixo:

#### 4.5.2.1 Experiência 4

Consideram-se todos os parâmetros menos sexo e idade.

A rede SOM é treinada para os 32 casos.

A rede SOM é testada para os 18 casos.

As fases de treinamento e teste são realizadas considerando 10.000 e 50.000 épocas.

Analisa-se se a rede é capaz de aprender os padrões de entrada, onde em princípio, nesta experiência os dados de teste não são apresentados a rede à priori e é analisada a capacidade de generalização da rede. Os resultados são comparados aos obtidos nas experiências realizadas na parte 1.

#### 4.5.2.2 Experiência 5

Nesta experiência começa-se considerando a base de treinamento contendo apenas os 8 primeiros casos da base de treinamento da Tabela 4.6 como exemplo, e repete-se a experiência para 10, 12, 14, 16, 18 e 20, 26 e 32 exemplos. Para a base de teste usam-se os 18 exemplos utilizados na experiência 1.

Todos os 19 parâmetros ou sejam sintomas, exames de laboratório, sexo e idade são considerados.

As fases de treinamento e teste são feitas considerando 10.000 épocas.

Como no caso da experiência 4 os dados da base teste são desconhecidos para a rede e dessa forma, é possível analisar se a rede foi capaz de aprender padrões que não haviam sido mostrados à priori, além de verificar a capacidade de generalização da rede para poucos exemplos.

### 4.5.3 Implementação

Na primeira fase dos experimentos procura-se modelar os dados para poderem ser utilizados no sistema. Esta modelagem se dá através da normalização dos vetores de entrada para valores no intervalo  $[-1,1]$ . Este procedimento é necessário pois para que os valores dos produtos dos vetores de entrada pelos respectivos pesos produzam valores que possam orientar os neurônios vencedores para valores próximos do vetor de entrada e o processo de competição possa escolher o neurônio que seja realmente o vencedor. Os vetores de pesos e de entrada sendo normalizados vão ter a mesma magnitude pois o que interessa no processo é a orientação do vetor e dessa forma o processo de aprendizado torna-se mais rápido e eficiente. A função da normalização é tentar dar a mesma dimensionalidade a todos os componentes dos vetores de entrada. Uma ilustração do que ocorre quando não se faz a normalização vetorial é mostrada na Figura 4.2.




Figura 4.2: a) Três vetores normalizados b) Os três vetores não normalizados





O segundo passo foi, através da utilização do software MATLAB versão 5.2, implementar um programa para a criação, treinamento e teste das diversas redes configuradas para cada um das experiências conforme colocadas no tópico anterior, utilizando as Tabelas 4.2 e 4.3 já normalizadas, que pode ser vista na Tabela 4.5 sendo esses dados utilizados como conjunto de exemplos de treinamento, na primeira parte dos experimentos e os dados da Tabela 4.6 para a segunda parte. A Tabela 4.7 mostra os dados normalizados que são usados no teste das redes configuradas para a segunda parte dos experimentos.

De posse dos resultados obtidos do treinamento e teste desenvolveu-se outro programa para plotar os gráficos e assim ser possível a visualização dos diversos neurônios ativos formando 4 agrupamentos que identificam os diagnósticos.

Dependendo do número de casos que sejam utilizados para os diversos modelos propostos acima temos então uma matriz de entrada com os sintomas de cada paciente que é dado por:

$$S = \begin{pmatrix} s_{11} & \cdots & s_{1m} \\ \vdots & \ddots & \vdots \\ s_{n1} & \cdots & s_{nm} \end{pmatrix}$$

onde  $n$  é o número de casos a serem utilizados no treinamento da rede, e  $m$  é o número de neurônios que representam os sintomas em cada caso.

Tomando-se então a Rede Neural de Kohonen com os 100 neurônios na camada competitiva ou de saída e com os  $m$  neurônios na camada de entrada, efetua-se o treinamento da rede, de tal forma que ela seja capaz de mapear para superfície bidimensional de saída, ou seja para a grade bidimensional as características dos dados de entrada.

Tabela 4.6: 32 Casos Clínicos de Reumatologia para Treinamento, Normalizados

Sintomas (colunas 2-20) e Diagnóstico (coluna 21)																				
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21
1	1	0,203	1	1	1	-1	1	-1	-0,3	0,3	-1	-1	-1	-1	-1	-1	-1	-1	-1	1
2	-1	0,085	-1	-1	-1	1	-1	-1	-0,3	-1	1	-1	-1	-1	-1	1	-1	0	-1	2
4	1	0,881	-1	-1	-1	-1	-1	-1	-0,3	-1	-1	-1	-1	1	-1	1	-1	0	-1	2
5	-1	0,763	-1	-1	-1	1	-1	0	0,3	0,3	-1	-1	-1	-1	-1	1	-1	0	-1	3
6	1	0,695	-1	-1	-1	-1	-1	1	1	1	1	-1	-1	1	1	1	-1	0	-1	2
7	-1	0,729	-1	-1	-1	-1	-1	0	1	-1	1	-1	-1	-1	1	1	-1	0	-1	3
8	1	0,051	1	-1	1	1	1	0	0,3	1	-1	-1	-1	-1	-1	-1	-1	1	-1	1
11	1	0,102	1	1	1	-1	1	0	0,3	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	1
13	1	0,661	-1	-1	-1	-1	-1	1	-1	-1	1	-1	-1	-1	1	1	-1	0	-1	2
14	-1	0,949	-1	-1	-1	-1	-1	0,5	-1	-0,3	1	1	-1	-1	1	1	-1	-1	-1	3
16	-1	0,051	1	-1	-1	1	-1	-0,5	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1
18	-1	0,881	-1	-1	-1	1	-1	-0,5	0,3	-1	1	1	-1	-1	1	1	-1	0	-1	3
20	1	0,39	1	-1	-1	1	-1	0	-1	-1	1	-1	-1	-1	1	1	-1	1	-1	1
21	-1	0,915	-1	-1	-1	-1	-1	0,5	-1	0,3	1	1	-1	-1	1	1	-1	0	1	3
24	1	0,169	1	1	-1	1	1	-1	-0,3	-0,3	-1	1	-1	-1	-1	-1	-1	1	-1	1
25	1	0,068	1	-1	1	1	-1	-1	0,3	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	1
26	1	0,153	-1	-1	-1	1	-1	0,5	-1	-1	-1	-1	1	-1	-1	1	1	0	-1	3
27	1	0,373	1	1	-1	1	-1	-0,5	0,3	1	-1	-1	-1	-1	-1	-1	-1	1	-1	1
29	1	0,864	-1	-1	-1	-1	-1	0	-0,3	0,3	1	-1	-1	-1	-1	1	-1	0	-1	2
30	1	0,797	-1	-1	-1	-1	-1	0,5	0,3	0,3	1	-1	1	1	1	1	-1	0	-1	2
32	1	0,542	-1	-1	-1	1	-1	0,5	0,3	-1	1	1	1	1	-1	1	-1	0	-1	2
36	1	0,356	1	1	-1	1	1	-1	0,3	1	-1	1	-1	-1	-1	1	-1	1	-1	1
37	1	0,339	-1	-1	-1	1	-1	0,5	-0,3	-1	1	-1	1	1	1	1	-1	0	-1	2
38	1	0,661	-1	-1	-1	-1	-1	0	-1	-1	-1	-1	1	1	-1	-1	-1	0	-1	2
40	1	0,881	-1	-1	-1	1	-1	0,5	0,3	-1	1	-1	-1	-1	1	1	-1	-1	-1	3
41	-1	0,305	-1	-1	-1	-1	-1	0,5	-0,3	0,3	1	-1	-1	-1	1	1	-1	0	-1	3
42	1	0,305	1	-1	-1	1	-1	0	0,3	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	1
44	-1	0,102	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	1	1	-1	-1	-1	3
46	-1	0,237	1	1	-1	-1	1	-0,5	0,3	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	1
47	1	0,763	-1	-1	-1	-1	-1	0,5	-0,3	-1	1	1	-1	-1	1	1	-1	0	-1	3
49	-1	0,254	1	1	-1	-1	-1	0,5	-0,3	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	1
50	1	0,254	1	-1	-1	1	-1	-1	-0,3	0,3	-1	-1	-1	-1	-1	1	-1	0	-1	2

**Tabela 4.7:** 18 Casos Clínicos de Reumatologia para Teste, Normalizados

Sintomas (colunas 2-20) e Diagnóstico (coluna 21)																				
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21
3	1	0,203	-1	-1	-1	-1	-1	0	-0,3	-1	1	1	1	1	1	1	-1	0	-1	2
9	-1	0,644	1	1	-1	-1	1	0,5	1	1	1	-1	-1	1	1	-1	0	-1	3	
10	-1	0,915	-1	-1	-1	-1	-1	1	-1	0,3	1	1	-1	-1	1	1	1	0	-1	3
12	-1	1	-1	-1	-1	-1	-1	-0,5	-0,3	-1	1	-1	-1	-1	1	1	-1	0	-1	3
15	-1	0,288	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	0	-1	4
17	1	0,475	-1	-1	-1	-1	-1	0	-0,3	-1	1	-1	-1	1	-1	1	-1	0	-1	2
19	1	0,661	1	1	1	-1	-1	0	1	0,3	1	-1	-1	-1	-1	1	-1	1	1	1
22	1	0,695	-1	-1	-1	1	-1	-0,5	0,3	-1	1	-1	-1	1	1	1	-1	0	-1	2
23	-1	0	1	-1	-1	1	-1	-1	-0,3	0,3	-1	-1	-1	-1	-1	1	-1	1	-1	1
28	-1	0,763	1	1	-1	1	-1	-1	-1	-1	-1	1	-1	-1	-1	1	-1	0	-1	3
31	1	0,237	1	1	1	1	-1	-1	0,3	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	1
33	1	0,339	1	-1	-1	1	1	0	0,3	-1	-1	1	-1	-1	-1	-1	-1	1	-1	1
34	-1	0,61	-1	-1	-1	-1	-1	-0,5	0,3	-1	1	1	-1	-1	1	1	-1	0	-1	3
35	1	0,627	-1	-1	-1	-1	-1	-0,5	-0,3	-1	1	1	-1	-1	1	1	-1	0	-1	3
39	-1	0,78	-1	-1	-1	-1	-1	0	0,3	-1	1	-1	-1	-1	1	1	-1	0	-1	3
43	-1	0,508	-1	-1	-1	1	-1	0,5	0,3	-1	-1	1	-1	-1	-1	1	-1	0	-1	3
45	1	0,864	1	-1	-1	1	-1	-0,5	0,3	-1	1	-1	-1	-1	1	1	-1	0	-1	2
48	-1	0,356	-1	-1	-1	1	-1	0	0,3	-1	-1	1	-1	-1	-1	1	-1	0	-1	3

## Capítulo 5

### Análise dos Resultados

#### 5.1 Resultados Obtidos

Nos capítulos anteriores tratou-se da possibilidade de utilização das Redes Neurais Artificiais RNA's na construção de Sistemas Conexionistas para auxílio ao diagnóstico médico. O capítulo 2 tratou do estudo das Redes Neurais Artificiais, mais especificamente as Redes Auto-organizáveis de Kohonen. No capítulo 4 escolheu-se a Rede de Kohonen como ferramenta e mostrou-se a metodologia a ser utilizada nesta dissertação. Este capítulo discorre sobre os resultados obtidos após a realização das várias experiências, conforme a metodologia proposta e usando-se a implementação da Rede de Kohonen.

A utilização das Redes Diretas na construção de Sistemas Conexionistas para Diagnóstico médico parece ser viável, porém no caso de não sabermos a priori a saída da rede pode tornar o aprendizado uma tarefa mais complicada. O modelo proposto pretende mostrar a viabilidade do uso da Rede de Kohonen para esse caso.

A análise dos resultados mapeados pela rede é feita de maneira visual através da utilização dos gráficos plotados para cada experiência, conforme convenção a seguir:

Tabela 5.1: Convenção para os diagnósticos

Diagnóstico	Código do Diagnóstico	Número Diagnóstico
Espondilite Anquilosante	*	1
Artrite da Gota	0	2
Artrite Reumatóide	□	3
Saudável	>	4

A condição de parada do treinamento das redes foi o número de épocas, ou de iterações.

## 5.1.1 Parte 1

### 5.1.1.1 Experiência 1

A base amostral com os 50 casos é usada para o treinamento da rede, que é feito considerando todos os 19 parâmetros de entrada. A mesma base é usada para teste.

Esta experiência foi feita em 4 etapas:

- a. Usando 10.000 épocas de treinamento
- b. Usando 200 épocas de treinamento
- c. Usando 1.000 épocas de treinamento
- d. Usando 50.000 épocas de treinamento

Na etapa a, percebeu-se que para uma quantidade de épocas razoáveis, como a que foi usada, neste caso 10.000, a rede comportou-se de maneira bem interessante do ponto de vista do aprendizado já que se pode observar, por exemplo, a rede foi capaz de *clusterizar* com muita facilidade os 4 grupos diagnósticos.

Mesmo para o caso em que o número de épocas foi bem pequeno 200, a rede já se mostrou aprendendo a agrupar os 4 diagnósticos, ainda que de maneira rudimentar, com dificuldades para os diagnósticos 2 e 3.

A seguir são apresentados os resultados obtidos em cada etapa da experiência 1, cuja análise pode ser acompanhada através das Figuras 5.1 a 5.4, contendo os gráficos com o mapeamento da rede para cada número de épocas de treinamento.

#### **Etapa a.**

A figura 5.1 mostra o gráfico resultante do aprendizado para os 50 casos com todos os sintomas e 10.000 épocas de treinamento.

A rede mostrou-se capaz de aprender, tendo sido observado que para alguns casos, isto é, a rede ficou em dúvida em relação ao diagnóstico correto. Os casos 13 e 40 mostraram que a rede teve problema quanto ao diagnóstico, sendo dado como neurônio vencedor o mesmo par (3,10) para ambos os casos, o mesmo ocorrendo para os casos 20 e 45 em que o neurônio vencedor foi o par (0,6). Observou-se que nestes casos o número de sintomas diferentes entre eles é três.

Para o caso 26, observou-se que este está no limiar entre o diagnóstico 2 e o 3, mas apresenta-se como diagnóstico 3. Já o caso 2 fica no grupo 3, mas bem ao lado deste caso 26. O caso 5 também ficou um pouco deslocado do grupo 3.

Para o caso do paciente saudável não houve problema nenhum.

Então se observando os resultados, vê-se que a rede não dá o diagnóstico correto em 100% dos casos, existindo sempre alguns poucos casos em que a rede pode estar errando. Observa-se que são 4 casos dos 50 que ficam deixando margem a dúvidas, entretanto consultando-se o especialista, viu-se que os diagnósticos 2 (Artrite Gotosa) e 3 (Artrite Reumatóide) podem ser muito semelhantes em alguns casos, permitindo dessa forma que haja dúvida em relação ao diagnóstico correto. A doença 3 (Artrite Reumatóide) entra como diagnóstico diferencial da doença 2 (Artrite Gotosa).

Para os 50 casos, verificou-se que a rede acertou 46, o que dá um percentual de acerto de 92%.

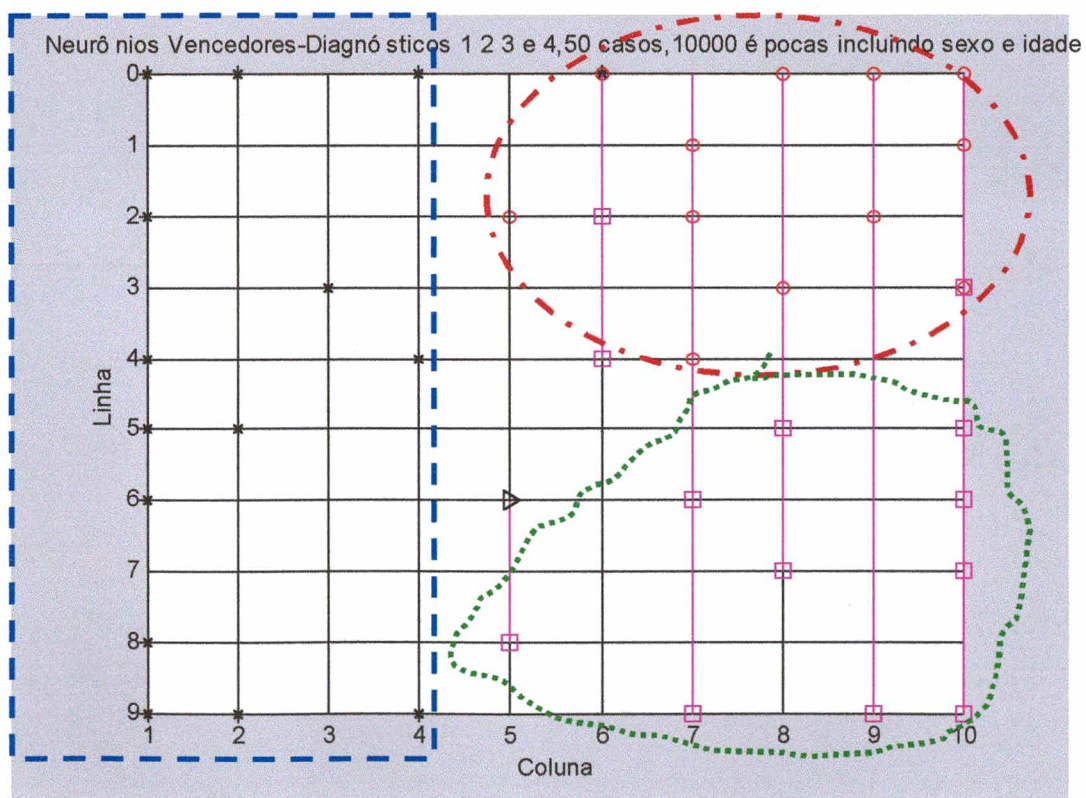


Figura 5.1: Gráfico Resultante para Experiência 1 – etapa a

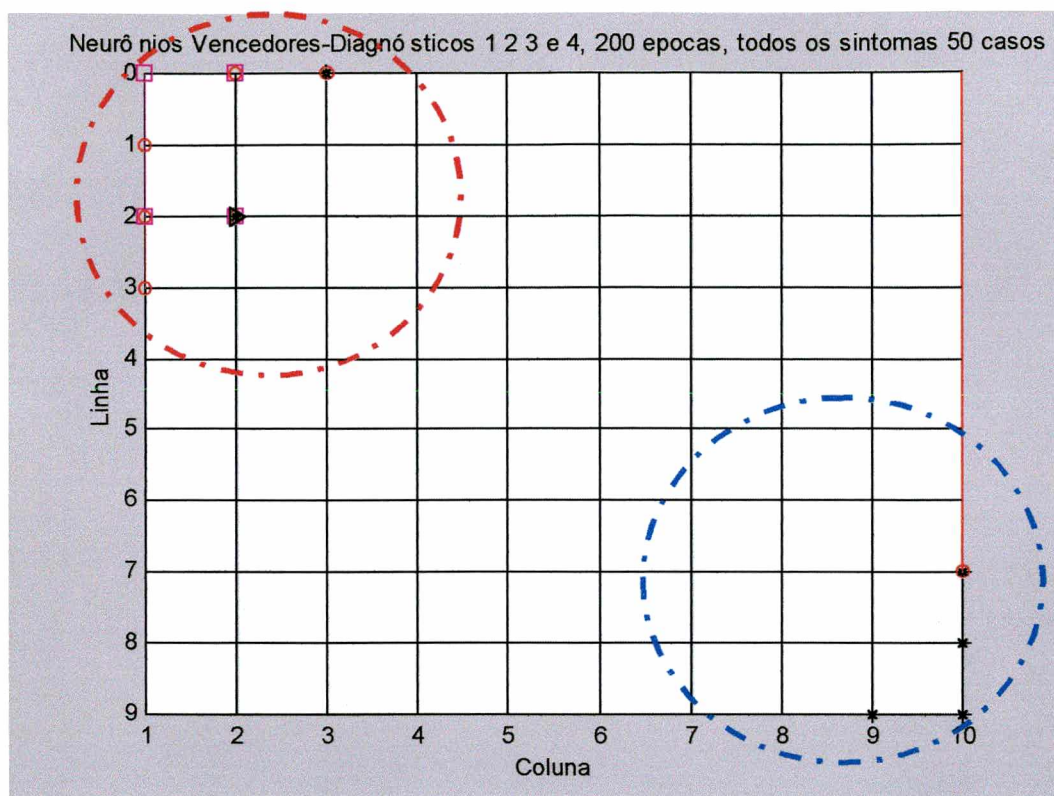


Figura 5.2: Gráfico Resultante para a Experiência 1 – etapa b

### Etapa b.

Na Figura 5.2 pode-se visualizar os resultados obtidos, considerando-se 50 casos com todos os sintomas e 200 épocas de treinamento.

A rede mostrou que nesta fase já está começando a aprender a distinguir os diversos padrões de entrada, buscando *clusterizar*, mesmo com poucas épocas de treinamento, ainda que com dificuldades para os grupos de diagnósticos 2 e 3, mas nota-se que para o grupo de diagnóstico 1, ela já é capaz de agrupar a maioria dos casos. Observa-se que um mesmo neurônio é ativado para diversos casos de mesmo diagnóstico. Observa-se também que de acordo com o gráfico os diagnósticos 2 e 3 ainda não são possíveis de serem distinguidos, ou seja, estão se confundindo dentro de uma mesma região. Isso reforça a crença de que os diagnósticos 2 e 3 fazem parte de um diagnóstico diferencial.



**Etapa c.**

Considerando todos os 50 casos com todos os sintomas e 1.000 épocas de treinamento.

Acompanhando-se pela Figura 5.3 esta etapa, pode-se verificar que a rede comportou-se de maneira superior do que quando submetida a um número de épocas menor, como no caso da experiência da etapa b. Os grupos de diagnósticos iguais já se formam de maneira clara, de modo a se perceber três regiões distintas. Claro que, como visto no caso da experiência com 10.000 épocas, pode-se perceber também nesta experiência o problema do diagnóstico correto para alguns casos. O caso 40 e o caso 13 são de difícil diagnóstico e confundem a rede, que ativa um mesmo neurônio. Deve-se verificar estes dois casos para afastar a possibilidade de um diagnóstico incorreto ou a necessidade de mais dados para o diagnóstico mais preciso.

O caso 26 comportou-se da mesma maneira, ficando no limiar do grupo de diagnóstico 2, mas apresenta diagnóstico 3, bem como o caso 5.

A rede, apesar de poucas iterações para o número de neurônios na grade, comportou-se de maneira satisfatória, mostrando um alto grau de confiabilidade, dando um percentual de acerto da ordem de 92%.




Figura 5.3: Gráfico Resultante para a Experiência 1 – etapa c

#### Etapa d.

Na figura 5.4 mostra-se a grade com os neurônios vencedores considerando todos os sintomas todos os 50 casos para treinamento e 50.000 épocas.

Após todas essas experiências anteriores, buscou-se treinar a rede contando com um número maior de iterações, de acordo com a experiência dos pesquisadores, usando 500 iterações para cada neurônio de saída. Como são 100 neurônios, considerou-se então 50.000 para o número de iterações a serem realizadas para o treinamento da rede.

Verificou-se que após esse treinamento a rede continuou se comportando de maneira semelhante, quando treinada com 10.000 iterações, sem mudar em praticamente nada o seu comportamento. Os casos 20 e 45 continuaram dando o mesmo neurônio como vencedor, par (0,6) bem como os casos 13 e 40, par (3,10). O caso 26, par (2,6) continuou aproximando do grupo de diagnóstico 2 apesar de ser do grupo 3 bem como o caso 5.

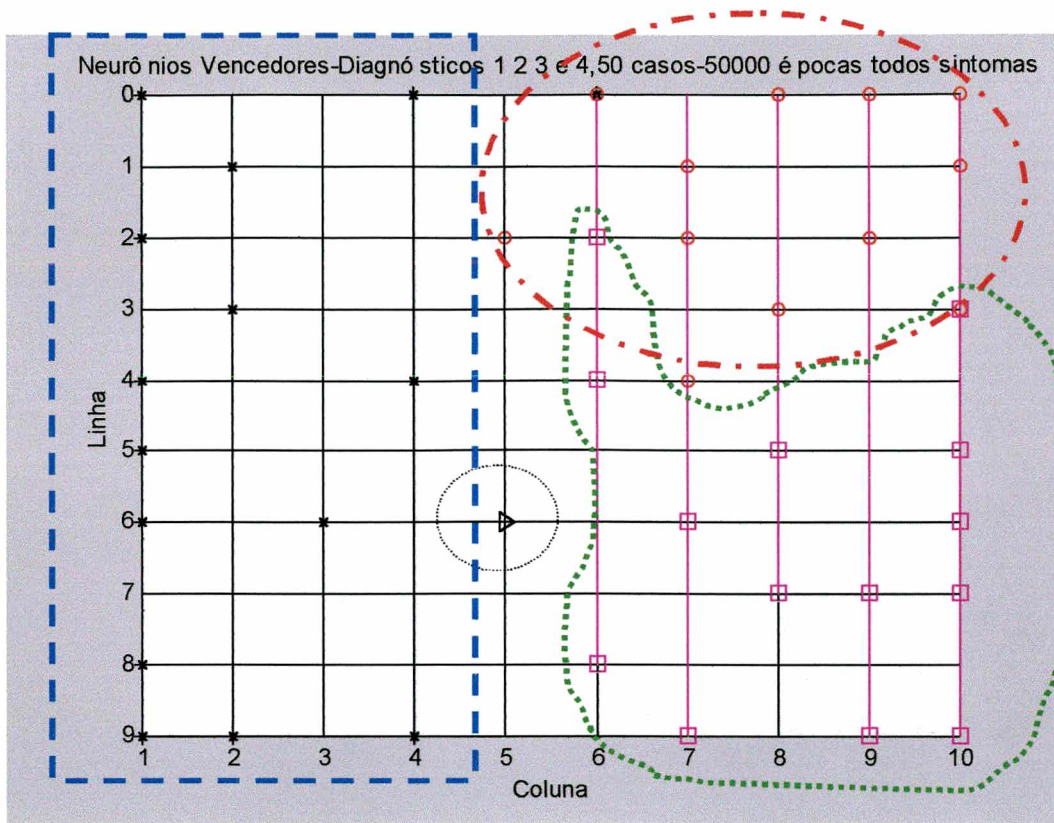


Figura 5.4: Gráfico Resultante para a Experiência 1 – etapa d

### 5.1.1.2 Experiência 2

Nesta experiência utilizou-se os 50 casos para treinamento e teste da rede, considerando todos os sintomas menos o sexo e a idade.

Considerando-se o treinamento para 10.000 épocas ou iterações, verificou-se que a rede continuou *clusterizando*, porém com alguma dificuldade em relação aos grupos diagnósticos 2 e 3, como pode ser observado na Figura 5.5.

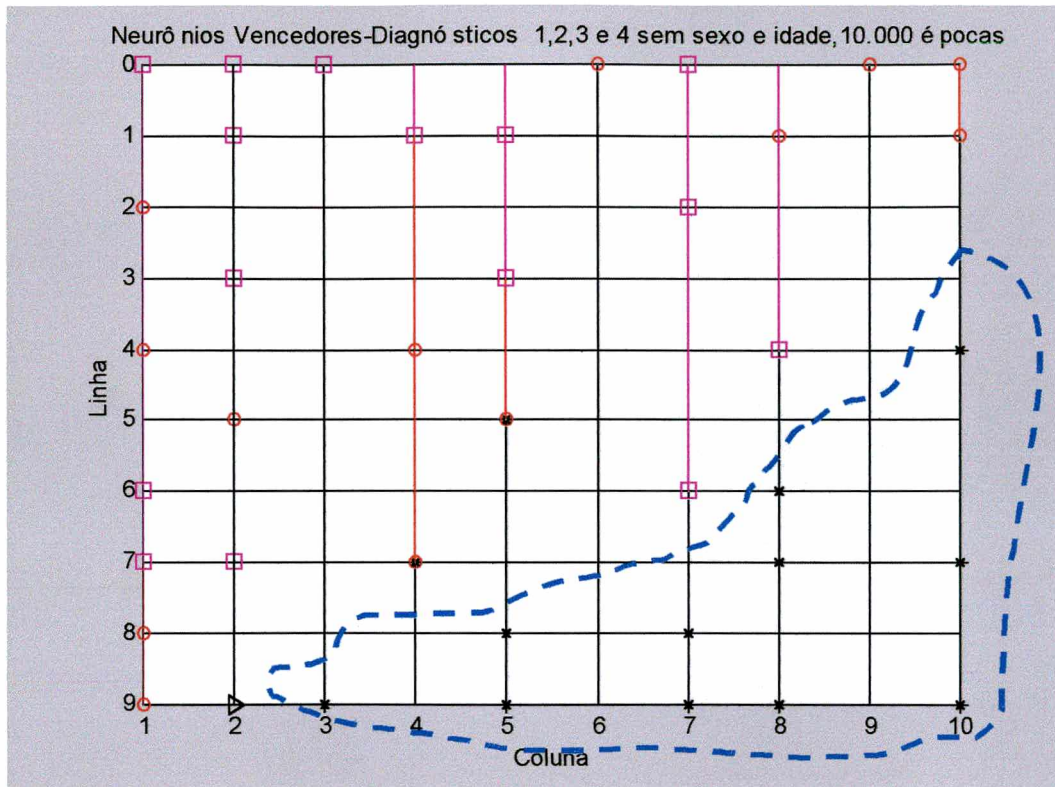


Figura 5.5: Mapeamento da Rede para a Experiência 2

Muitos casos ficaram misturados entre esses dois diagnósticos. Alguns casos ficaram se confundindo com já acontecia anteriormente na experiência 1, considerando sexo e idade, como os casos 20 e 45 que continuaram se comportando da mesma maneira. Portanto há que se verificar a hipótese de serem estes casos muito semelhantes a ponto de ser difícil o diagnóstico ou de ser um erro da rede. Os casos 23 e 50 apresentaram dificuldade nos diagnósticos de EA e AG, percebendo-se nesse caso que a diferença entre os sintomas desses dois casos é somente quanto ao fator HLA-B27 tornando o diagnóstico realmente mais difícil se não forem levado em conta o sexo e a idade.

A experiência mostrou que os dados idade e sexo são muito relevantes para o diagnóstico correto dessas doenças. Conforme escrevem Carvalho & Xavier:

“ ... A AR pode iniciar em qualquer idade nos adultos...”

“... A AR acomete ambos os sexos, mas há predominância do sexo feminino na proporção 3-4:1...”

Segundo ainda Carvalho & Xavier, a Espondilite Anquilosante (EA) pode ser encontrada em ambos os sexos, pois que o HLA-B27 incide igualmente entre homens e mulheres, mas a uma predileção para o caso masculino numa proporção de 2-4:1 e a grande maioria desenvolve a doença entre 25 e 35 anos...”

De acordo com Xavier Júnior, a Artrite gotosa acomete, preferencialmente os homens, cerca de 95% dos casos, sendo na faixa etária de 30 a 60 anos de idade.

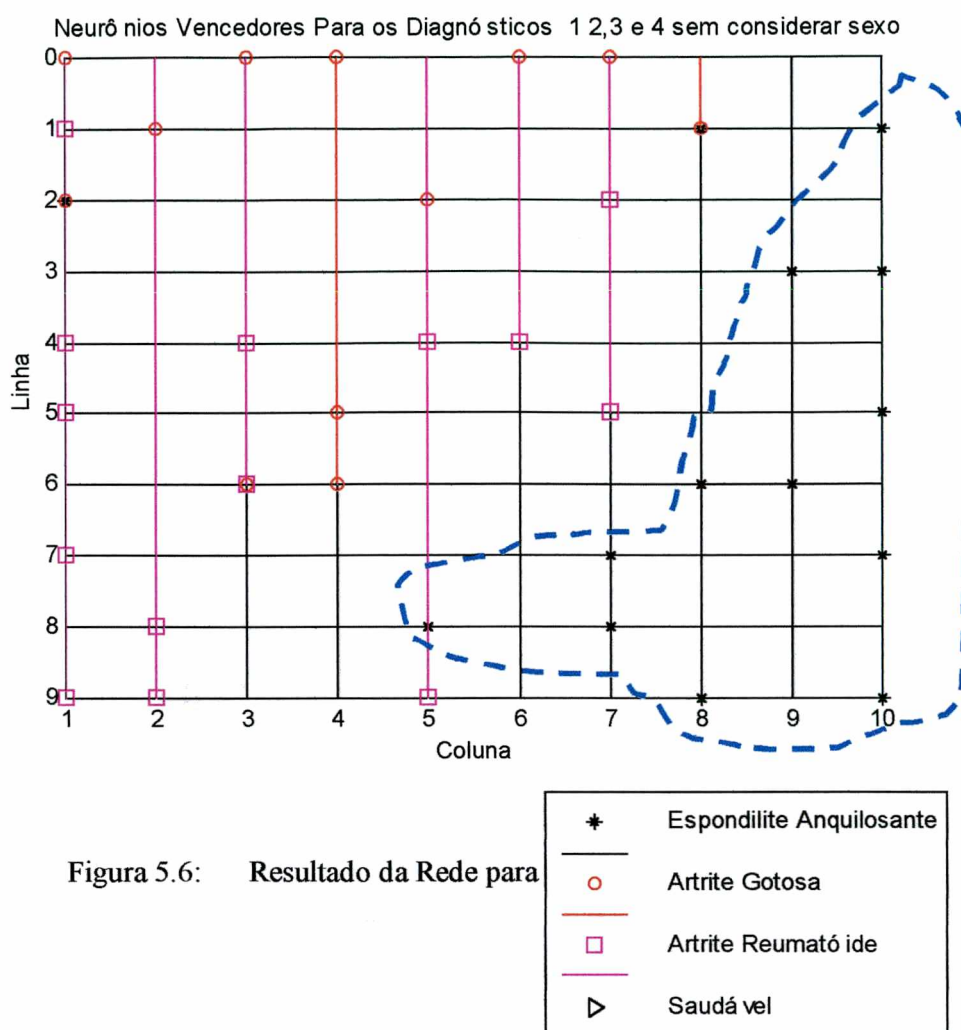
Como pode ser observado da literatura, o fator idade e sexo não deve ser menosprezado para o treinamento da rede, correndo-se o risco, quando não se considera estes parâmetros, ter-se problemas no aprendizado correto.

### **5.1.1.3 Experiência 3**

Utilizou-se todos os 50 exemplos da base para treino e teste sem levar em conta o sexo. A experiência 3 foi dividida em duas partes:

1. Considerando-se 10.000 épocas para treinamento
2. Considerando-se 50.000 épocas para treinamento

As Figuras 5.6 e 5.7 apresentam os dois gráficos resultantes do treinamento da rede. para 10.000 e para 50.000 épocas respectivamente



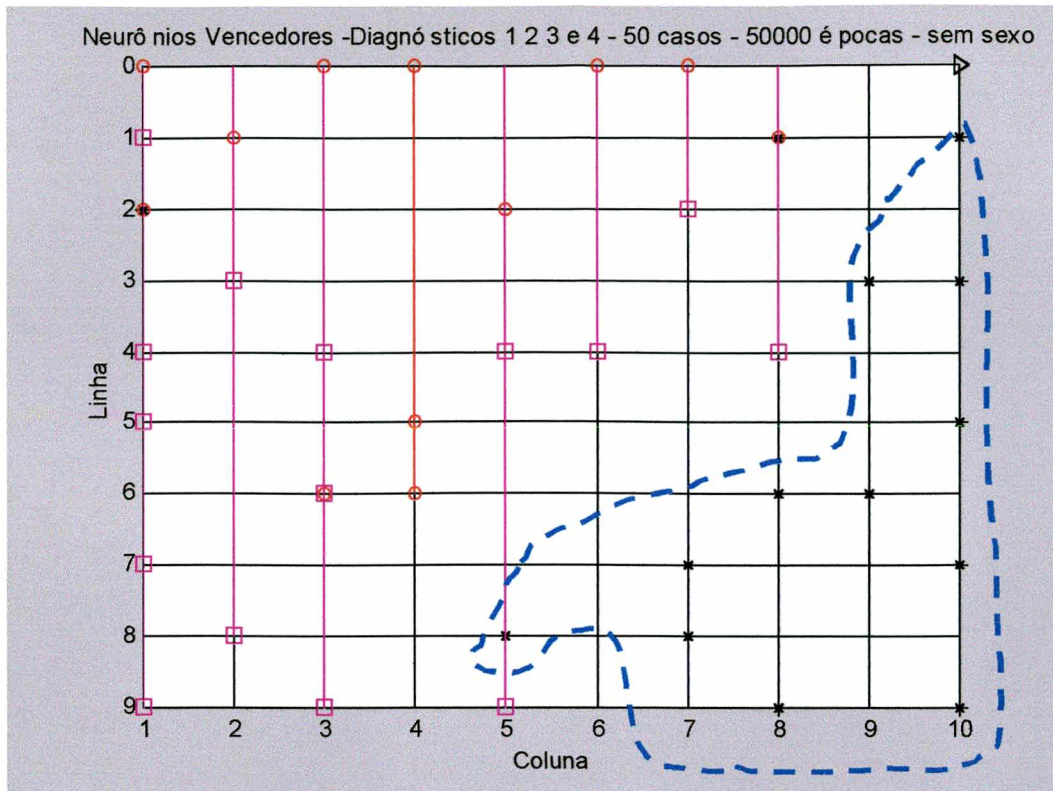


Figura 5.7: Resultado da Rede para a Experiência 3 – etapa 2

Analisando-se os resultados obtidos considerando-se 10.000 épocas e comparando-se com os resultados para 50.000 épocas, pôde-se verificar que a rede não sofreu variações no que diz respeito ao aprendizado. O comportamento da rede ficou muito próximo da realizada, considerando-se 10.000 épocas, exceto para alguns poucos casos que sofreram variação de posição na grade, tanto para 10.000 quanto para 50.000 épocas.

Observou-se que o aprendizado da rede sem considerar o parâmetro sexo, sofreu sérias perdas comparando-se com os resultados obtidos na experiência 1, em que esse parâmetro é considerado. Para o caso do diagnóstico 1 (EA), a rede conseguiu *clusterizar*, apesar de ser observado que houve problema em relação aos casos 23 (EA) e 50 (AG), par de coordenadas matriciais (1,8) o que não ocorria anteriormente na experiência 1. A *clusterização* para o diagnóstico 1(EA) foi melhor na experiência 1. Os casos 20 e 45 -par (0,2) continuaram dando o mesmo neurônio como vencedor, só que nesta experiência o caso 20 ficou totalmente deslocado de seu grupo diagnóstico que é o

grupo 1 (EA). O caso 45 é um caso de AG, grupo diagnóstico 2, não havendo problema de agrupamento, como pode ser observado na Figura 5.7.

Em relação a *clusterização* dos grupos diagnósticos 2 e 3 observou-se que a rede teve problemas para *clusterizar*, ficando os dois grupos meio misturados para alguns casos, inclusive dando o mesmo neurônio para os casos 13 par (6,3) que é um caso de AG e o 41 que é de AR, apesar de serem diferentes em apenas três sintomas.

Os casos 2 (AG) e 29 (AG) ficaram muito deslocados de seu grupo, ficando mais próximos do grupo diagnóstico 3, o mesmo ocorrendo para o caso 40 par (0,1) (AR), que se posicionou junto ao grupo diagnóstico 2.

Após todas essas observações fica clara a importância do parâmetro sexo para uma melhor performance da rede.



## 5.1.2 Parte 2

As experiências nesta parte são realizadas considerando a base de treinamento contendo 32 casos e a base de teste os 18 casos restantes. Os neurônios vencedores para os dados de treinamento são plotados de acordo com a codificação usadas nas experiências anteriores que são: \* - Espondilite Anquilosante 0 - Artrite da Gota □ - Artrite Reumatóide e > - Saudável. Os resultados com os neurônios vencedores para os 18 casos de teste da rede podem ser visualizados no gráfico na cor azul.

### 5.1.2.1 Experiência 4

Nesta experiência considerou-se os 32 casos para treino da rede e, os 18 casos restantes da base de exemplos sendo usadas para teste. Não foram considerados nem o sexo nem a idade do paciente. A rede foi treinada com 10.000 e 50.000 épocas.

Observou-se pelos resultados obtidos que a rede foi capaz de aprender a diagnosticar casos em que não haviam sido submetidos a ela durante o treinamento.

Esses resultados podem ser visualizados na Figura 5.8 e 5.9. Para a experiência considerando 10.000 épocas de treinamento, a *clusterização* para o diagnóstico 1 (EA) foi tranqüila, exceto para o caso 50 que tem como neurônio vencedor o mesmo do caso 23 cujos pares de coordenadas matriciais são (9,5). Observou-se que estes são casos muito parecidos só diferenciando em um sintoma, por exemplo, o exame de HLA-B27. Assim é de se pensar mais uma vez em considerar os parâmetros sexo e idade na hora do treinamento da rede, visto que talvez esses casos seriam mais rapidamente diagnosticados, se esses dois parâmetros fossem levados em conta, já que o caso 23 é um paciente do sexo feminino, com 18 anos e, o paciente do caso 50 é um homem de 33 anos. O caso 50 é de treino, o caso 23 é de teste. Para os grupos diagnósticos 2 e 3, entretanto, percebe-se 2 casos de diagnóstico 3 (AR) que adentram o grupo 1 (EA). São os casos 9 e 28, que possuem o par de coordenadas (0,3) e (4,4), embora busquem se agrupar aos casos 47 par (1,4) e 18 - par (3,5), respectivamente.




Figura 5.8: Saída da Rede Para a Experiência 4 – etapa 1

O caso 45, AR, par de coordenadas (5,4) fica bastante deslocado do seu grupo. Neste caso, considerou-se erro da rede, já no caso 41 (AR), par (0,10), apesar de estar junto a dois casos de diagnóstico 2 (AG) traz para perto de si no teste dois outros casos, continuando a formar o *cluster*. Esses dois casos de AG deveriam estar mais deslocados para baixo, buscando ficar próximos do seu grupo, fato que não ocorreu no treinamento.

Observou-se que existiram alguns casos como os tratados acima em que não ficou clara visualmente a *clusterização*, quando a rede é treinada e, outros casos semelhantes ocorreram quando do teste, e interpretados como casos de diagnósticos duvidosos, ou melhor, uma incapacidade da rede com esta configuração de *clusterizar* adequadamente estes casos.

De uma maneira geral, ressalvados os casos citados, verificou-se a formação dos *clusters* claramente e o aprendizado da rede foi satisfatório.

Pela análise visual considerou-se que existem em 50 casos, 10 casos que ficaram duvidosos. Então se tem um percentual de acerto da ordem de 80%. Se forem

computados apenas os casos de teste, então temos um acerto de 83%, 3 casos tidos como erro.

Considerou-se como erro da rede os casos 23 e 50. Há que se conversar com o especialista para uma análise mais aprofundada desses dois casos, bem como os casos 17 par (2,10), 45 par (5,4), 43 e 48 par (7,5), 26 par (9,8), 13 par (0,9), 29 par (1,10), 5 par (8,6).

Realizou-se esta mesma experiência considerando-se 50.000 épocas de treinamento, observou-se que houve uma melhora na performance da rede. O caso 17, que antes estava deslocado de seu grupo, na posição (2,10), agora está junto aos outros casos na posição de coordenadas (7,7), o mesmo não ocorrendo com os casos 43 e 48, par (7,5) que ficam bem longe de seu grupo diagnóstico - (AR). A visualização desta experiência encontra-se na Figura 5.9 a seguir.

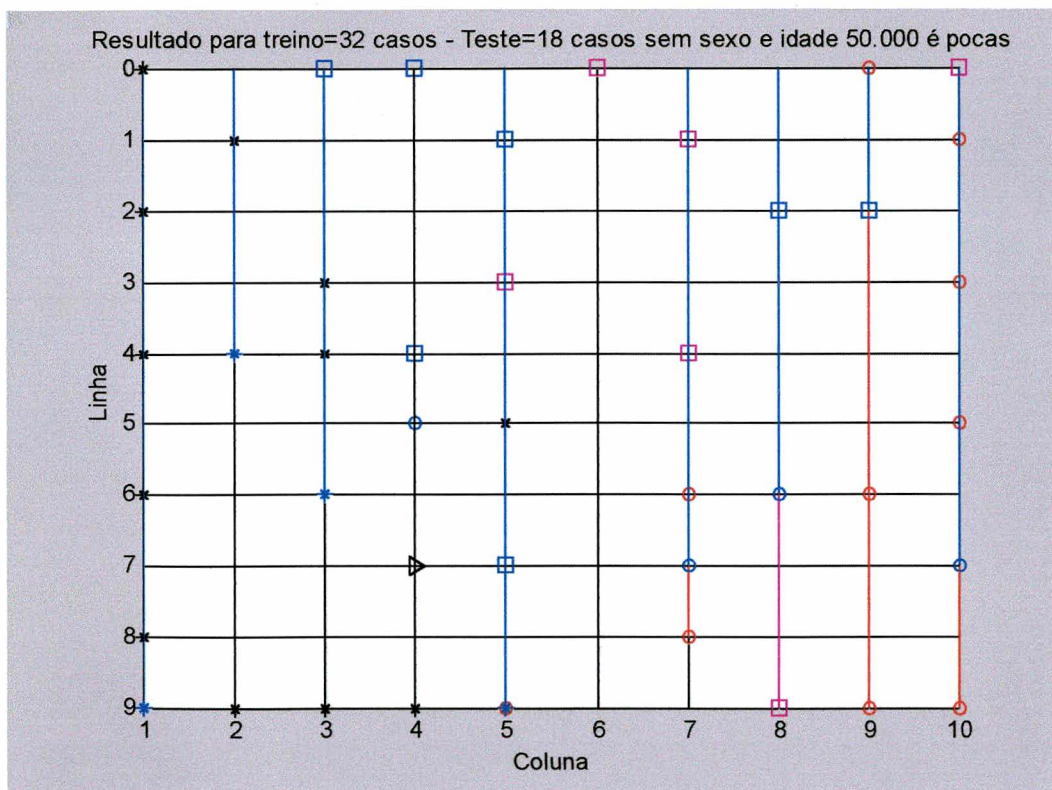


Figura 5.9: Saída da Rede Para a Experiência 4 – etapa 2

Nesta experiência, considerando-se estes dois casos como erro da rede, bem como os casos 23,50,45,26,29,13, tem-se que a performance da rede ficou em torno de 84%. Se for considerado apenas o erro de teste, então serão 15 acertos e 3 erros, dando um percentual de 83%.

### 5.1.2.2 Experiência 5

Diante dos resultados obtidos na experiência da Parte 1, conclui-se que a experiência 5 deveria ser realizada considerando-se os parâmetros sexo e idade, apesar da experiência desenvolvida em que se usou Redes Diretas não ter levado em consideração esses parâmetros. Para certificar-se mais uma vez de que esta fora a decisão mais apropriada, considerou-se para primeiro treino uma rede contendo 32 exemplos da base de treinamento e os 18 exemplos da base de teste, o que também foi feito para 10.000 épocas de treinamento. O resultado foi comparado com o obtido na experiência 4. Notou-se uma melhora significativa na performance da rede, quando considerado os parâmetros sexo e idade.

Como pode ser analisado através da observação da Figura 5.10

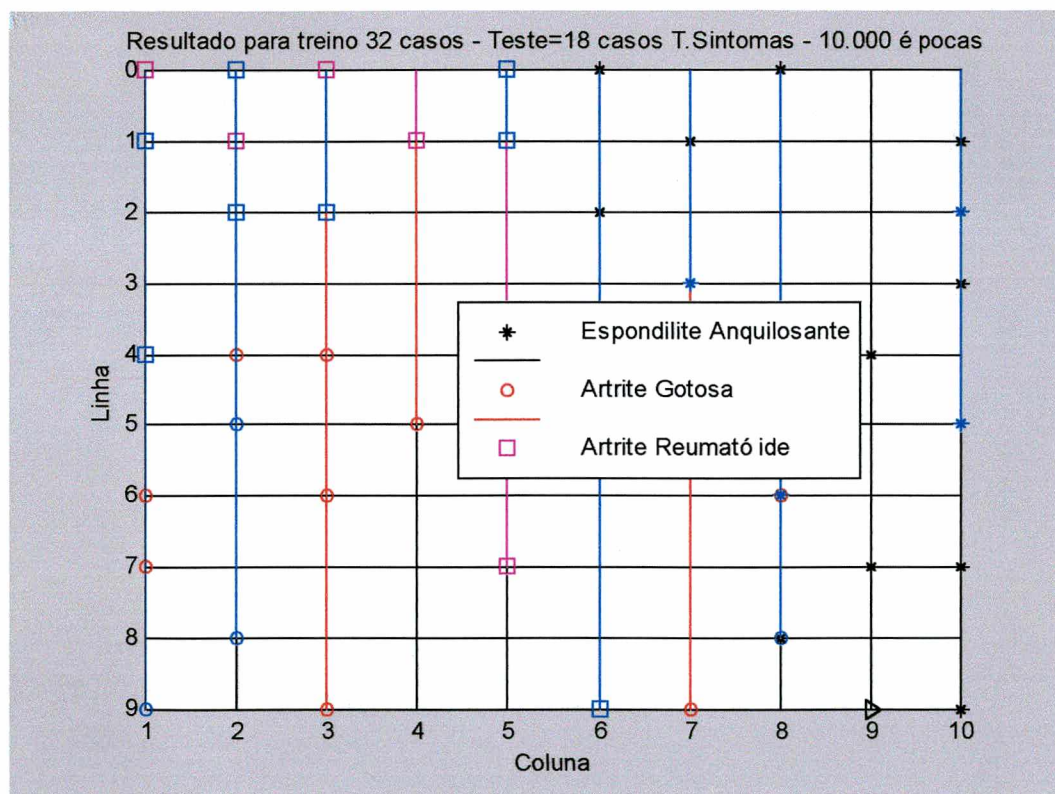


Figura 5.10: Saída da Rede Para a Experiência 5 – 32 casos

Observou-se que os casos 23 (EA) e 50 (AG), par de coordenadas matriciais (6,8) continuaram se confundindo. O caso 50 foi usado para treino da rede, enquanto o caso 23 foi usado para teste da rede. Os casos 20 e 45 par (8,8) também. O de número 20 foi usado no treino e o 45 no teste. Porém a formação dos clusters é bem nítida nessa experiência, quando comparada com a mesma realizada na experiência 4, não se considerando nem sexo nem idade. São considerados casos de diagnósticos duvidosos além dos acima citados, os casos 43 par (9,6) por conta do caso 26 par (7,5), que errou no treinamento. Dessa forma, considerando-se somente os erros no teste dos 18 casos têm-se que a performance da Rede fica em 83% (3 erros).

Repetiu-se a experiência para 08 casos, 10, 12, 14, 16, 18 e 20. Os resultados obtidos foram plotados nos gráficos que se seguem:

A Figura 5.11 a seguir mostra o resultado obtido após o treinamento com 8 casos;

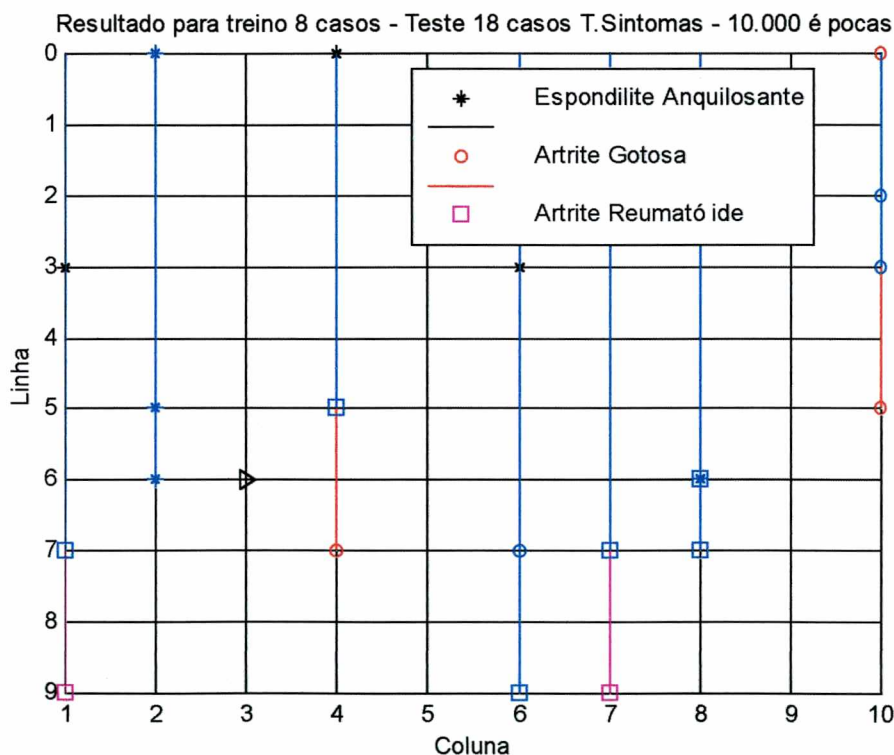


Figura 5.11: Saída da Rede Para a Experiência 5 – 8 casos

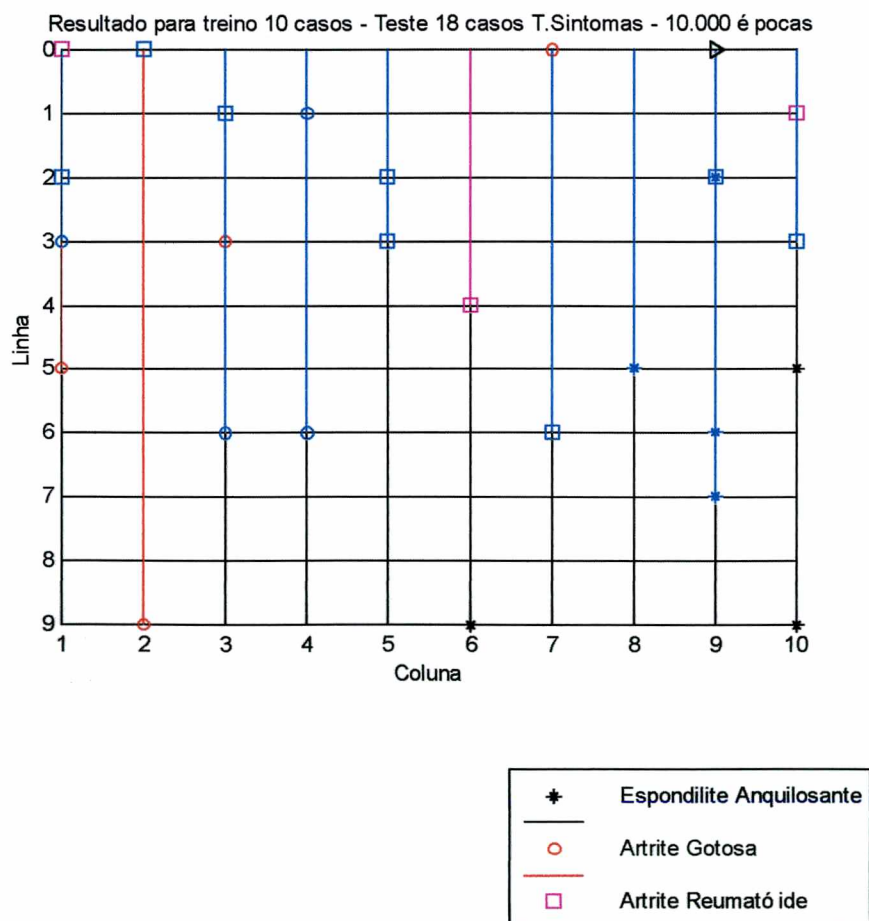
O caso 3 coincide com o 22 no par (3,10), ambos para AG. O caso 10 e o 35 coincidem no par (7,8), ambos para AR, o mesmo ocorrendo para os casos 43 e 48

ambos para AR com o par (7,1), o 34 com o 12 também de AR no par (7,7). Observou-se que apesar de poucos exemplos para treinamento a rede foi capaz de aprender, mostrando dessa forma a capacidade de generalização da Rede de Kohonen. Para um universo de 18 casos tem-se um percentual de acerto da ordem de 88,8%, erros dos casos 9 (AR) e 19 (EA), coincidindo no par (6,8).

A figura 5.12 a seguir mostra o comportamento da rede para os 10 exemplos de treinamento.

Da análise do gráfico percebeu-se que a rede apresentou um comportamento muito interessante, buscando formar os clusters, aproximando os casos de teste dos casos de treinamento, apesar de serem poucos os exemplos de treinamento. Os casos de diagnóstico de EA já se formam de maneira bem clara, ficando como erro da rede apenas um caso de EA que coincide com 2 casos de AR no par de coordenadas (2,9), casos 43, 48 e de EA o 23.

De maneira geral, o resultado é bastante satisfatório, mostrando a capacidade de generalização da rede com um percentual de acerto de 94,4%.



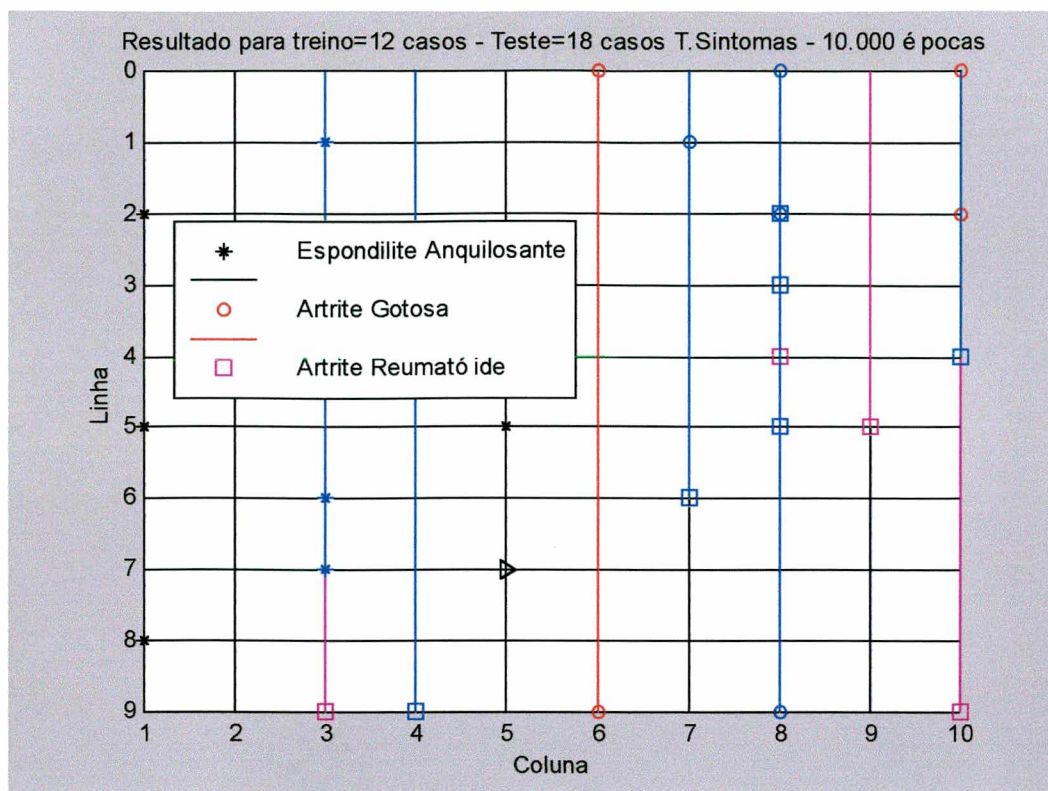


Figura 5.13: Saída da Rede Para a Experiência 5 – 12 casos

Para 12 casos, observou-se que para os casos de diagnóstico 1, a rede se comportou de maneira excelente, ou seja, acertando todos os casos, o que não ocorreu com os diagnósticos 2 e 3, quando a rede apresentou casos que ficaram duvidosos no teste, os casos 3 e 35 cujo par é (2,8).

Considerando o universo de 18 casos de teste, a rede errou no caso 2, dando um percentual de acertos de 88,8%.

O caso 5, par (9,3); o caso 43, par (9,4); caso 2 par (9,6) e o caso 45 par (9,8), ficaram duvidosos no treinamento.



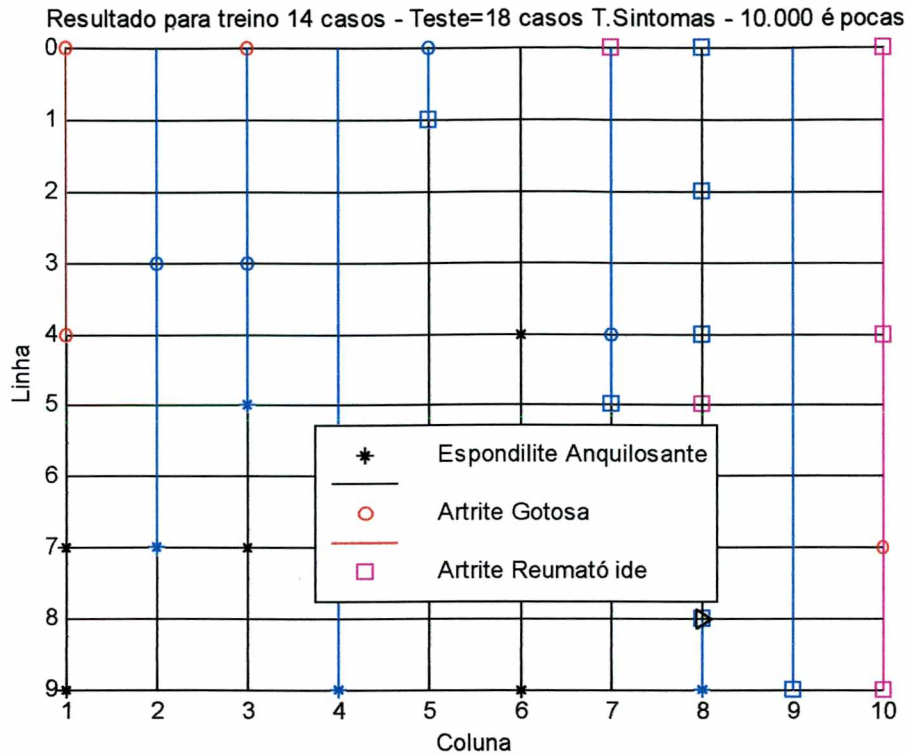


Figura 5.14: Saída da Rede Para a Experiência 5 – 14 casos

O treinamento para 14 exemplos e 18 casos de teste resultou em uma saída conforme o gráfico da Figura 5.14 acima. Os clusters se formaram de maneira evidente apesar de acontecer casos de erro no treinamento como o do caso 2 par (7,10) que ficou totalmente fora do seu grupo, deslocando também o caso 45 par (4,7), ambos de diagnóstico Artrite Gotosa. Quanto ao diagnóstico 3, AR houve um erro evidente: a coincidência de um caso de AR com a do paciente considerado saudável em relação a essas doenças. No gráfico, é o par (8,8) casos 28 (AR) e 15 (Saudável), ambos do grupo de teste. O nível de acerto da rede ficou em 83%(3 erros).

Para 16 casos há uma melhora muito sensível na performance da rede. Há casos duvidosos, por exemplo, os casos 23 e 28 cujo par coincide em (3,7). O caso 2 cujo par é (4,10) é erro no treinamento.

Para os 18 exemplos apresentados, a rede errou 2 dando um percentual de acerto de 88,8%.

Estes dados podem ser analisados, observando-se a Figura 5.15 a seguir:




Figura 5.15: Saída da Rede Para a Experiência 5 – 16 casos

Para 18 casos têm-se como erro da rede os casos 15 e 23 cujos pares de coordenadas são (7,2). O caso 2 par (8,7) que fica deslocado do grupo diagnóstico 2, é erro do treinamento. A performance ficou em 88,8%, já que foram apresentados 18 casos..




Figura 5.16: Saída da Rede Para a Experiência 5 – 18 casos

Para 20 casos, a rede apresentou um comportamento conforme mostrado no gráfico da Figura 5.17 a seguir:

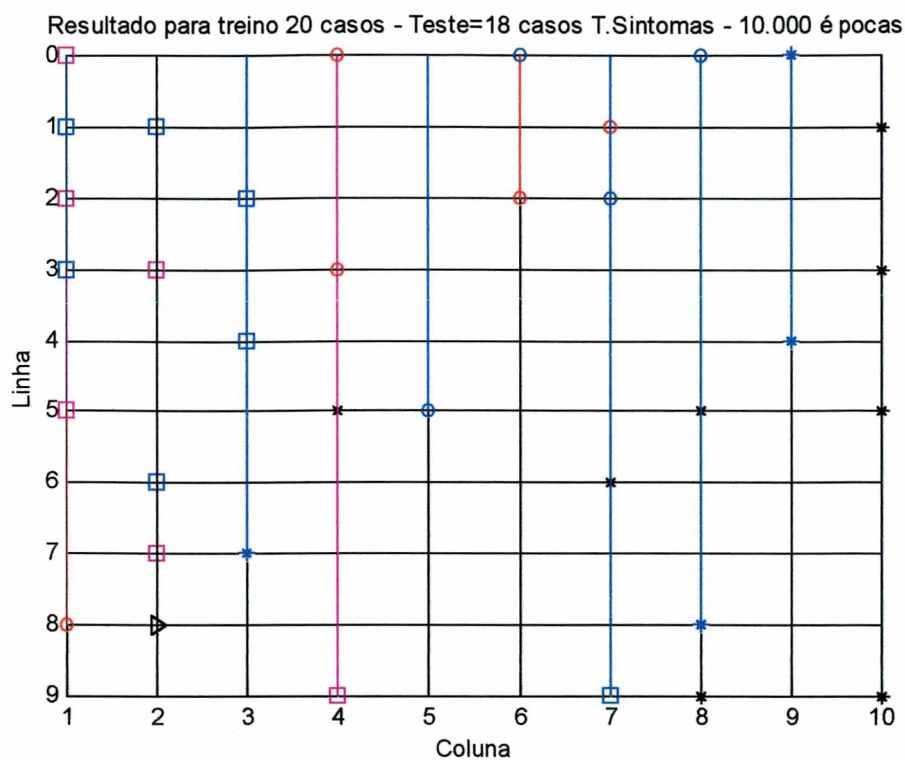


Figura 5.17:Saída da Rede Para a Experiência 5 – 20 casos

A *clusterização* da rede para essa quantidade de exemplos de treinamento (20) foi muito boa. Os casos considerados erros da rede foram em número de 4 a saber: 3 de treinamento e apenas um de teste provocado por um erro de treinamento, por exemplo, os casos 2, de AG, par (8,1); 26 de AR, par (9,4) que provocou o erro do caso 28 par (9,7) no teste e, por fim, o caso 20 de AE, par (5,4) também erro de treinamento, que ficou bastante deslocado de seu grupo diagnóstico. Considerando-se apenas um erro no teste, a rede mostrou uma capacidade de acerto da ordem de 94,4%.

Quando se realizou o treinamento considerando 26 exemplos para treino e os 18 para teste, a rede apresentou o comportamento conforme pode ser visualizado no gráfico da Figura 5.18 a seguir:

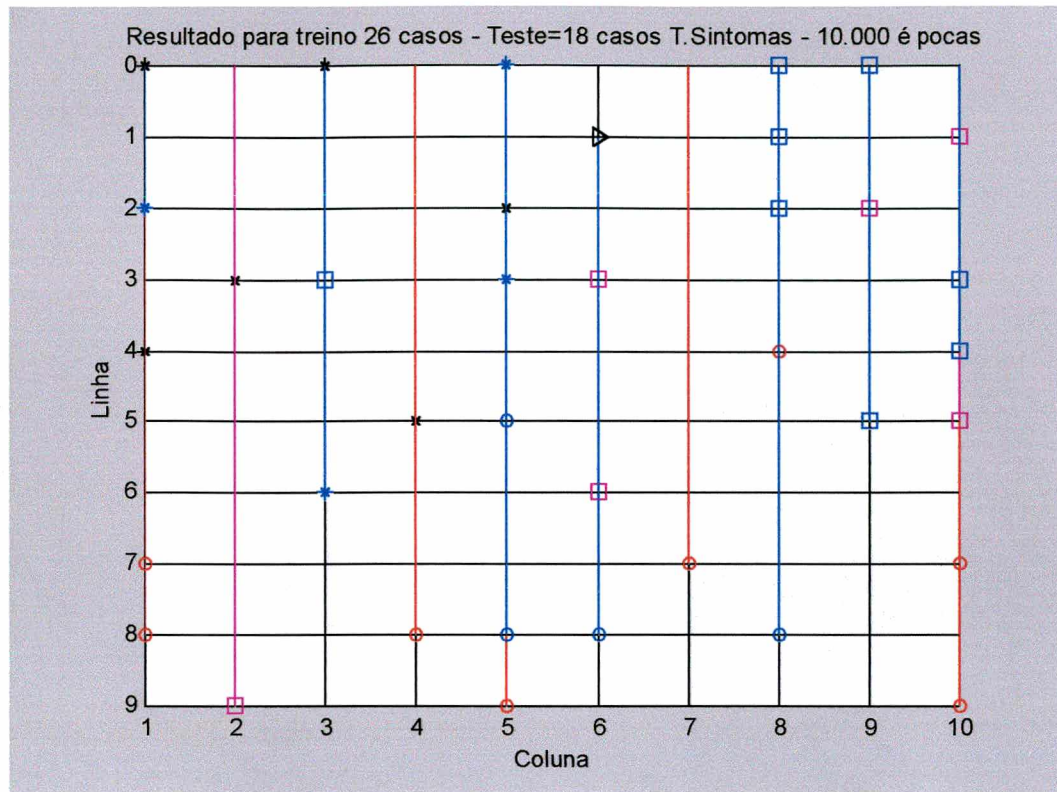


Figura 5.18: Saída da Rede Para a Experiência 5 – 26 casos

Analisando-se o gráfico, verificou-se que a rede apresentou 5 casos de diagnósticos duvidosos, sendo 3 de AR, caso 28 par (3,3); caso 26 par (9,2) e caso 40 par (6,6) e 2 de AG, caso 2 par (4,8) e caso 45 par (5,5), não apresentando nenhum caso duvidoso para EA. Considerando que erro no teste foi somente o do caso 28, pode-se inferir que a rede apresentou um percentual de acerto de 94,4%.

## 5.2 Comparação dos Resultados usando Rede de Kohonen com os Resultados Usando rede Direta

Comparando-se os resultados obtidos nessa experiência usando Redes Auto-organizáveis de Kohonen e os resultados obtidos usando Rede Direta (Dazzi,1999), pode-se perceber que as Redes de Kohonen conseguiram um bom desempenho, parecendo ser viáveis para aplicação no diagnóstico médico. A tabela a seguir faz uma comparação dos resultados em termos percentuais entre as duas redes.

A Rede Direta foi implementada usando-se 17 neurônios na camada de entrada, 3 neurônios na camada intermediária e 3 na saída. O algoritmo de treinamento usado foi o retropropagação, com a mesma base de dados clínicos para treinamento, usou-se a função tangente hiperbólica e um número de épocas de 20.000.

**Tabela 5.2: Quadro Comparativo entre Resultado da Rede de Kohonen e Rede Direta**

Nº de Exemplos	Acertos Kohonen	% Kohonen	Acertos Direta	% Direta
8	16	88,8	15	83,3
10	17	94,4	14	77,78
12	16	88,8	13	72,22
14	15	83	14	77,78
16	16	88,8	14	77,78
18	16	88,8	15	83,33
20	17	94,4	14	77,78
26	17	94,4	14	77,78
32	15	83	16	88,89

## Capítulo 6

### Conclusões finais e Trabalhos Futuros

#### 6.1 Conclusões Finais

As redes de Kohonen têm provado ser úteis no reconhecimento de padrões no campo de processamento de sinais em vários tipos de aplicação.

Neste trabalho foi feita uma análise da utilização deste tipo de topologia de rede para uma aplicação na área médica com o objetivo de classificar um conjunto de 50 casos de pacientes reumáticos, para apontar classes de diagnósticos a fim de determinar o diagnóstico correto para cada caso.

Durante todo o processo experimental, alguns questionamentos de ordem técnica foram encontrados e merecem ser colocados aqui, entre eles:

A dimensão da grade na camada competitiva da rede é uma característica subjetiva. Sua escolha foi feita através de um processo de tentativa e erro, quando se usou uma grade de 10 X 10, aleatoriamente e, este número, neste trabalho, mostrou-se suficiente para alcançar um resultado de convergência da rede que fosse considerado satisfatório.

O número de iterações que deviam ser realizadas para a obtenção de resultados satisfatórios, no caso, a convergência da rede. Buscou-se variar o número de iterações e verificar o aprendizado. Para número de iterações pequenos, a rede mostrou que ainda não havia aprendido, embora mas já demonstrasse um aprendizado rudimentar. Segundo Kohonen (Kohonen, 1988), nas primeiras 1.000 iterações é realizada a fase de ordenação topológica em que o valor da taxa de aprendizado é próxima de 1 e, a vizinhança tem um raio grande. Numa segunda etapa, existe a fase de convergência, quando é feito o ajuste fino do mapa. A taxa de aprendizado torna-se próxima de 0, a vizinhança é reduzida lentamente para 1 ou 0 neurônios. Esta fase requer milhares de iterações. Cada modelo requer um número de iterações que seja suficiente para permitir a convergência da rede.

Como referido no capítulo 5, uma sugestão é usar o número de neurônios da camada competitiva multiplicada por 500. Neste trabalho este número de iterações foi de 50.000 e otimizou os resultados, apesar de que para neste caso específico a rede atingiu a convergência já com as 10.000 iterações.

A função de vizinhança bem como a taxa de aprendizado foi atribuída no processo de aprendizagem durante a execução do programa, embutidos na função de treinamento do MATLAB. A taxa de aprendizado variou de 0.9 a aproximadamente 0. A função de vizinhança foi escolhida conforme o algoritmo.

A etapa dos experimentos foi a mais árdua, posto que muitos experimentos foram realizados para se chegar aos resultados.

A rede de Kohonen conforme a topologia e modelo proposto nesta dissertação mostrou-se capaz de *clusterizar* os padrões de entrada em classes distintas de modo a ser possível distinguir com clareza os três diagnósticos propostos, desde os primeiros experimentos.

Durante a experiência 2 tentou-se verificar a relevância dos parâmetros sexo e idade como fatores de influência na saída da rede. Dados que não devem ser descartados, apesar do conjunto total de exemplos utilizados não ter uma variação suficientemente grande nos dados, principalmente, o de idade posto que o sexo só pode assumir dois valores, de tal sorte a se fazer uma avaliação mais apurada desta hipótese. Mas de maneira geral houve uma mudança visível entre os gráficos apresentados com e sem esses parâmetros.

Na experiência 3 testou-se o fator sexo e constatou-se que o sexo por si só já influencia o resultado da rede, uma vez que o mapa de característica apresentou uma sensível diferença em relação ao anterior, que o considerava. Portanto um atributo importante para o diagnóstico diferencial.

Os resultados obtidos nesta primeira etapa foram encorajadores para a continuação dos experimentos, pois que com estes testes verificou-se a capacidade da rede para apontar uma solução viável.

Para que se assegurasse que a etapa seguinte seria tão promissora quanto a anterior, optou-se pela utilização de todos os parâmetros de entrada, sintomas, sexo, idade, exames de laboratório e radiológicos.



Na parte 2 buscou-se constatar a capacidade de generalização da rede, testando-a com casos não vistos durante a fase de treinamento. Esta constatação foi comprovada e os resultados foram bastante satisfatórios.

Na experiência 4 usou-se todos os 32 casos da base de treinamento e os 18 para teste. Na experiência 5 procurou-se observar a capacidade de generalização para os casos em que a rede foi submetida a poucos exemplos no treinamento. Os resultados obtidos foram surpreendentes e encorajadores.

Diante dos resultados obtidos, conclui-se que as Redes Auto-organizáveis de Kohonen mostraram para o modelo proposto, são viáveis para ser utilizadas no auxílio ao diagnóstico médico.

Deve-se ressaltar aqui que este tipo de topologia não visa apontar erros e acertos no diagnóstico, mas antes de tudo, agrupar em classes com características semelhantes aos sinais de entrada de modo a permitir que se obtenha a solução desejada. Neste caso, o diagnóstico. No entanto para efeito de comparação com a metodologia usada, a Rede Direta foi montada uma tabela comparativa com os resultados obtidos na implementação destas duas redes.

O que se conclui é que as Redes de Kohonen, como as Redes Diretas, ambas são viáveis para o objetivo proposto, sendo que com as Redes de Kohonen é possível se chegar a uma solução mesmo não se tendo conhecimento do diagnóstico *a priori*.

## **6.1 Trabalhos Futuros**

Como trabalhos futuros sugere-se:

- Desenvolvimento de um Sistema Conexionista para Auxílio ao Diagnóstico Diferencial de Doenças do Sistema Neurológico: Mielite Transversa, Síndrome de Guillain-Barré e Esclerose Múltipla, usando a metodologia usada nesta dissertação.

- O desenvolvimento da interface homem-máquina para complementar este trabalho e torná-lo um Sistema Especialista Conexionista para auxílio ao diagnóstico médico..
- Comparação desta metodologia com outros Paradigmas de IA para esse tipo de problema, como a utilização de técnicas da Computação Evolucionária usando entre outros os algoritmos genéticos, como o trabalho desenvolvido por Falqueto (Falqueto, 2002)
- Comparação dos resultados obtidos nesse trabalho com outros desenvolvidos usando outras topologias de Redes Neurais Artificiais, como uma revisão no modelo de Rede BAM como proposto no trabalho de (Dazzi,1999) .
- Utilização desta metodologia para a utilização no âmbito da citogenética, como por exemplo, o trabalho desenvolvido por Moreira (Moreira, 2002).
- Utilização da metodologia proposta nessa dissertação para desenvolvimento de um Sistema Conexionista para auxílio à detecção de maiores incidências de determinadas doenças por região geográfica ou por faixa etária, com o objetivo de fazer um tratamento preventivo, para ser utilizado por sistemas de saúde pública ou privada.
- Utilizar técnicas da Computação Evolucionária, algoritmos genéticos, para selecionar a base de exemplos de treinamento da rede, de modo a permitir um aprendizado mais eficiente e rápido antes do uso da metodologia proposta nesta dissertação.
- Fazer uma investigação mais aprofundada dos resultados que ficaram duvidosos ou que tiveram resultados considerados erros da rede. Questionando se poderia

existir uma quarta doença para diagnóstico ou mesmo buscando averiguar a solução apontada pelo especialista para aqueles exemplos mostrados à rede, buscando-se pesquisar na tentativa de uma resposta. Será que a rede errou? Ou será que foi o médico?

## Referências Bibliográficas

ACCIANI, G. *et al.* Validation of neural network analysis to predict prognosis in breast cancer patients. In: MIDWEST SYMPOSIUM ON CIRCUITS AND SYSTEMS (MWSCAS '93), 37, 1993, Detroit. **Proceedings...** New York: IEEE, 1993. v.1, p. 453-456

ADAMS, Raymond. D.; VICTOR, M. **Neurologia** 6. ed. Chile: Addison Wesley, 1998. (Tradução do livro *Principles of Neurology*).

AHMED, Mohamed N.; FARAG, Aly A. 3D segmentation and labeling using unsupervised clustering for volumetric measurements on brain CT imaging to quantify TBI recovery. ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 18, St. Louis, Missouri, 1997. **Proceedings...** New York: IEEE, 1997. p. 738-739.

AHMED, Mohamed N.; FARAG, Aly A. Two-stage neural network for volume segmentation of medical images. In: INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, 1997. **Proceedings...** Piscataway, NJ: IEEE Service Center, 1997. v. III, p. 1373-1378.

ARA, M. *et al.* Application of self-organizing feature map to failure diagnosis through sound data. **Research Reports of Kogakuin University**, v. 4, n. 82, p. 129-133, 1997.

ASHUTOSH K. *et al.* Prediction criteria for successful weaning from respiratory support: statistical and connectionist analyses. **Critical Care Medicine**, v. 20, n. 9, Sep. 1992. p. 1295 - 1301.

AZEVEDO, Fernando Mendes de; BRASIL, Lourdes Mattos; OLIVEIRA, Roberto Célio Limão de. **Redes neurais com aplicações em controles e em sistemas especialistas**. Florianópolis: Bookstore, 2000.

BAILEY, M. *et al.* Hybrid systems for medical data analysis and decision making: a case study on varicose vein disorders. In: NEW ZEALAND INTERNATIONAL TWO-STREAM CONFERENCE ON ARTIFICIAL NEURAL NETWORKS AND EXPERT SYSTEMS (ANNES '95), 2, 1995, Dunedin, New Zealand. **Proceedings...** Los Alamitos: IEEE, 1995. p.265-268.

BARRETO, Jorge Muniz. **Inteligência artificial no limiar do século XXI: abordagem híbrida.** 2 ed. Florianópolis, 1999.

BARRETO, J. M. *et al.* A Neural network approach for medical diagnosis. Proceedings of the ISSM International Conference, California, USA, 1991. p. 78-81.

BRASIL, Lourdes Matos. **Aquisição de conhecimento aplicada ao diagnóstico de epilepsia.** 1994. Dissertação (Mestrado em Engenharia Biomédica) - Universidade Federal de Santa Catarina, Florianópolis.

CASSA, José C. *et al.* Diagnóstico médico de tuberculose em sintomáticos respiratórios a partir da história clínica do paciente usando redes neurais artificiais. In: CONGRESSO BRASILEIRO DE REDES NEURAS, 3, 1997, Florianópolis. **Anais...** Florianópolis: Fundação Biblioteca Nacional, 1997.

CHAGAS, Alexandre Viana; BOSSAN, Marcelo C; NADAL, Jurandir. Agrupamentos de batimentos cardíacos do eletrocardiograma utilizando uma camada de Kohonen. In: CONGRESSO BRASILEIRO DE REDES NEURAS, 3, 1997, Itajubá. **Anais...** Florianópolis, 1997. p. 185-189.

CHEN, Dar-Ren; CHANG, Ruey-Feng; HUANG, Yu-Len. Breast cancer diagnosis using self-organizing map for sonography. **Ultrasound in Med. & Biol.**, v. 26, n. 3, p. 405-411, 2000.

COIMBRA, A. J. F. *et al.* Automatic detection of sleep-waking states using kohonen neural network. In: CONGRESSO BRASILEIRO DE REDES NEURAS, 1, 1994, Itajubá. **Anais...** Itajubá, 1994. p. 327-331.

DAYHOFF, Judith E. **Neural network architectures: an introduction.** USA: Van Nostrand Reinhold, 1990.

DAZZI, Rudimar Luís Scaranto. **Sistemas especialistas conexionistas: implementação por redes diretas e bidirecionais**. 1999. Dissertação (Mestrado em Ciência da Computação) – Departamento de Informática, Universidade Federal de Santa Catarina, Florianópolis.

DORFFNER, Georg; RAPPELSBERGER, Peter; FLEXER, Arthur. Using selforganizing feature maps to classify EEG coherence maps. In: INTERNATIONAL CONFERENCE ON ARTIFICIAL NEURAL NETWORKS (ICANN'93), 1993, Amsterdam. **Proceedings...** Heidelberg: Springer-Verlag, 1993. p. 882-887.

ELO, Pekka *et al.* Classification of epileptic EEG by using self-organizing maps. In: ARTIFICIAL NEURAL NETWORKS, 2, 1992. **Proceedings...** Amsterdam: North-Holland, 1992. p. 1147-1150

GARCIA, Ojeda Renato. **Técnicas de inteligência artificial aplicadas ao apoio à decisão médica na especialidade de anestesiologia**. 1992. Tese (Doutorado em Engenharia Biomédica) – Departamento de Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis .

GIULIANO, F. *et al.* Potentially functional regions of nucleic acids recognized by a Kohonen's self-organizing maps. **Comput. Applic. Biosci**, v. 9, n. 6, p. 687-693, 1993.

HANSELMAN, Duane; LITTLEFIELD, Bruce. **Mastering Matlab: a comprehensive tutorial and reference**. Rio de Janeiro: Prentice-Hall do Brasil, 1996.

HARRIS, Tom. A Kohonen S. O. M. based, machine health monitorin system which enables diagnosis of faults not seen in the training set. In: INT. JOINT CONF. ON NEURAL NETWORKS, 1993, Nagoya. **Proceedings...** Piscataway, NJ: IEEE Service Center, 1993. v. 1, p. 947-950.

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

HELLSTÖM, Ythomas. **Neural networks: a tutorial..** Suíça: Umeå University, Department of Computer Science, 1998.

KALLIO, K. *et al.* Classification of lung sounds by using self-organizing feature maps. In: ARTIFICIAL NEURAL NETWORKS, 1, 1991, Amsterdam. **Proceedings...** Amsterdam: North-Holland, 1991. v. I, p. 803-808.

KASABOV, Nikola K. **Foundations of neural networks, fuzzy systems, and knowledge engineering**. 2. ed. Massachusetts: A. Bradford Book, 1998.

KASKI, Samuel; JOUTSINIEMI, Sirkka-Liisa. Monitoring EEG signal with the self-organizing map. In: INT. CONF. ON ARTIFICIAL NEURAL NETWORKS, 1993. **Proceedings...** London: Springer, 1993. p. 974-977.

KÖHLE, Monika; MERKL, Dieter. Identification of gait pattern with self-organizing maps based on ground reaction force. In: EUROPEAN SYMP. ON ARTIFICIAL NEURAL NETWORKS, Bruges, Belgium, 1996. **Proceedings...** p.73-78.

KOHONEN, Teuvo. **Self-organization and associative memory**. 3. ed. Helsinki: Helsinki University of Technology, 1989.

KOVÁCS, Zsolt László. **O cérebro e sua mente: uma introdução à neurociência computacional**. São Paulo: Edição Acadêmica, 1997.

KRÖSE, Bem J.; SMAGT, Patrick Van der. **An introduction to neural network**. 8 ed. Amsterdam: University of Amsterdam, 1996.

LIU, Xiaohui; CHENG, Gongxian; WU, John. Managing the noisy glaucomatous test data by self-organizing maps. In: INT. CONF. ON NEURAL NETWORKS, 1994. **Proceedings...** Piscataway, NJ : IEEE Service Center. p. 649-652.

LOESCH, Claudio; SARI, Solange. **Redes neurais artificiais: fundamentos e modelos**. Blumenau: Editora da FURB, 1996.

MATSUMOTO, Élia Yathie. **Matlab 6: Fundamentos de programação**. São Paulo: Érica, 2001.

MORASSO, Pietro *et al.* Self-organizing neural network for diagnosis. In: INT. CONF. ON ARTIFICIAL NEURAL NETWORKS, 1993. **Proceedings...** London: Springer, 1993. p. 806-809.

OSDOL, William W. van *et al.* The Kohonen self-organizing map applied to in vitro screening data for chemotherapeutic agents. In: WORLD CONGRESS ON NEURAL NETWORKS, 1995. **Proceedings...** v. 2, p. 762-766.

PAPADIMITRIOU, S. *et al.* Ischemia detection with a self-organizing map supplemented by supervised learning. **IEEE Transactions on Neural Networks**, v. 12, n. 3, p. 503-515, May 2001.

PASSOLD, Fernando. **Sistema especialista híbrido em Anestesiologia para pacientes críticos/problemáticos**. 1995. Dissertação (Mestrado Engenharia Biomédica) – Departamento de Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis.

PORTIN, K.; SALMELIN, R.; Kaski, S. Analysis of magnetoencephalographic data with self-organizing maps. In: ANNUAL CONF. OF THE FINNISH PHYSICAL SOCIETY, 27, 1993, Turku, Finland. **Proceedings...** Helsinki: Finnish Physical Society, 1993. p. [15. 2 ?]

ROBERTS, S.; TARASSENKO, L. Analysis of the human EEG using self-organising neural nets. In: IEE COLLOQUIUM ON NEUROLOGICAL SIGNAL PROCESSING, 1992. **Digest n. 69**. London: IEE, 1992. p. 1-3.

RODRÍQUEZ, Mariá José; DEL POZO, Francisco; ARREDONDO, María Teresa. Use of unsupervised neural networks for classification of blood pressure time series. In: WORLD CONGRESS ON NEURAL NETWORKS, 1993. **Proceedings...** Hillsdale, NJ: Lawrence Erlbaum, 1993. v. 2, p. 469-472.

ROISENBERG, Mauro. **Emergência da inteligência em agentes autônomos através de modelos inspirados na natureza**. 1999. Tese (Doutorado em Engenharia Elétrica) – Universidade Federal de Santa Catarina, Florianópolis.

ROISENBERG, Mauro. **Redes neurais**. Florianópolis: Universidade Federal de Santa Catarina, 1999. (Notas de aula).



RUSSEL, A. **An introduction to artificial intelligence**. 3 ed. Addison Wesley, 1993.

SIGATI, Nanci Akemi. **Estudo da influência de bases de caso em redes IAC (*Interactive Activation and Competition*) na implementação de sistema especialista para diagnóstico médico**. 1997. Dissertação (Mestrado em Engenharia Biomédica) – Departamento de Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis.

TAFNER, Malcon Anderson; XEREZ, Marcos de; FILHO, Ilson W. Rodrigues. **Redes neurais artificiais: introdução e princípios de neurocomputação**. Blumenau: Editora da FURB, 1995.