

**UNIVERSIDADE FEDERAL DO PARANÁ**

**ANDRÉA BOÇOIS**

**DIAGNÓSTICO DE DOENÇAS DERMATOLÓGICAS USANDO A REDE NEURAL  
DE KOHONEN**

**CURITIBA  
2012**

**ANDRÉA BOÇOIS**

**DIAGNÓSTICO DE DOENÇAS DERMATOLÓGICAS USANDO A REDE NEURAL  
DE KOHONEN**

Dissertação apresentada ao Programa de Pós-Graduação em Métodos Numéricos em Engenharia, área de concentração em Programação Matemática, Setor de Tecnologia, Departamento de Construção Civil e Setor de Ciências Exatas, Departamento de Matemática da Universidade Federal do Paraná.

Orientador: Prof. Dr. Paulo Henrique Siqueira

Co-orientador: Prof. Dr. Flávio de Queiroz  
Telles Filho

**CURITIBA  
2012**

## TERMO DE APROVAÇÃO

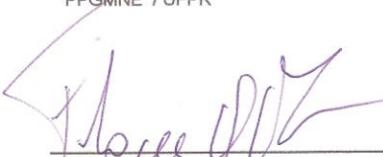
**Andréa Boçois**

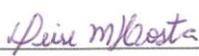
**“Diagnóstico de Doenças Dermatológicas usando a Rede Neural de Kohonen”**

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Curso de Pós-Graduação em Métodos Numéricos em Engenharia – Área de Concentração em Mecânica Computacional, Setores de Tecnologia e de Ciências Exatas da Universidade Federal do Paraná, pela seguinte banca examinadora:

Orientador:

  
\_\_\_\_\_  
**Prof. Paulo Henrique Siqueira, D. Sc.**  
Programa de Pós-Graduação em Métodos Numéricos em Engenharia -  
PPGMNE / UFPR

  
\_\_\_\_\_  
**Prof. Flávio de Queiroz Telles Filho, D.Sc.**  
Departamento de Saúde Comunitária da UFPR

  
\_\_\_\_\_  
**Profª. Deise Maria Bertholdi Costa, D.Sc.**  
Programa de Pós-Graduação em Métodos Numéricos em Engenharia -  
PPGMNE / UFPR

Curitiba, 28 de junho de 2012.

## **AGRADECIMENTOS**

Primeiramente, a Deus.

A meus pais, Neide e Pedro, que me apoiaram e entenderam quando não pude estar presente em alguns momentos;

Ao meu noivo André, por todo seu carinho, apoio e compreensão;

A Regina e Rose, pela colaboração e incentivo;

Ao meu orientador, Prof. Dr. Paulo, por toda ajuda e compreensão e principalmente pela confiança depositada em mim;

Ao meu co-orientador, Prof. Dr. Flávio, pelos ensinamentos e valiosas sugestões e por dispor seu tempo me auxiliando no recolhimento dos dados necessários;

Ao Hospital de Clinicas da UFPR, por fornecer os dados necessários ao desenvolvimento deste trabalho.

## RESUMO

O diagnóstico médico consiste num conjunto de técnicas que rotula o paciente e classifica sua doença, identifica o prognóstico provável e define o melhor tratamento disponível. É, portanto, um processo de classificação, isto é, um esforço para se reconhecer a classe à qual determinado paciente pertence. Vários estudos tratam o problema do diagnóstico médico através do uso de métodos de agrupamento e classificação. Visando observar o comportamento de Redes Neurais para esta tarefa, foi escolhida a abordagem pela Rede Neural de Kohonen, cuja especialidade é o agrupamento de dados. Foram abordados seis diagnósticos: Impetigo, Cromoblastomicose, Esporotricose, Herpes Labial, Larva Migrans Cutânea e Leishmaniose Tegumentar Americana, consideradas doenças infecciosas da pele. Os dados foram coletados de textos e de prontuários médicos, primando pela privacidade do paciente, e de conversas com um dos infectologistas do Hospital de Clínicas da Universidade Federal do Paraná. Este trabalho propõe avaliar os sintomas dos pacientes e as características de suas lesões, detectados por meio de exames clínicos, bem como dados epidemiológicos das doenças, a fim de sugerir possíveis diagnósticos. Para a identificação dos agrupamentos foi utilizado o método de visualização da U-matriz, definindo as fronteiras entre os agrupamentos, e o sistema de cores primárias RGB, definindo a cor do neurônio disposto em uma estrutura de mapa. Verificou-se que o modelo apresentou um bom desempenho, onde os percentuais de acerto para os padrões de teste foram de 66,7 % para Esporotricose e 100% para as demais. A baixa taxa de acerto para Esporotricose deve-se ao fato de ter muitas características comuns com as doenças Cromoblastomicose e Leishmaniose Tegumentar Americana, classificando-a erroneamente como uma dessas doenças. No geral, a rede obteve 94,5% de acerto no conjunto de testes. A Rede de Kohonen mostrou-se uma ferramenta robusta para a classificação dos dados, apresentando resultados rápidos, com uma boa visualização dos agrupamentos, facilitando a interpretação dos resultados. A Medicina pode se beneficiar dos sistemas de informação, como o estudado aqui, inclusive como ferramenta de suporte em consultório e clínicas médicas auxiliando e reafirmando o diagnóstico, bem como ferramenta de treinamento para futuros profissionais da área. Convém ressaltar que a decisão final será sempre do médico.

Palavras-chave: Redes Neurais Artificiais. Rede de Kohonen. Diagnóstico. Doenças Infecciosas da Pele.

## ABSTRACT

The medical diagnosis consist in a set of techniques that label the patient, classify your disease, identify the probables prognosis and define the best treatment available. Thus, this method is a process of classification, this is, a effort to recognize the class that certain patient belongs. Several studies treat the medical diagnostic problem through use of grouping and classification methods. Aim to note the comportament of Neural Networks to this task, was chosen a approach by Kohonen Neural Network, which specialty is information's grouping. Six diagnoses were discussed: Impetigo, Chromoblastomycosis, Sporotrichosis, Labial Herpes, Larva Migrans Skin and Cutaneous Leishmaniasis, considered skin infectious diseases. The datas were coleted from texts and medical records, excelling by patient's privacy and dialogs with infectologist from Hospital Clinics of Federal University of Parana. This dissertation propose evaluate the symptoms of patients and characteristic of his injuries, detected by clinical tests, as well as the epidemiological diseases data and suggest possible diagnoses. To identification of groups was used the visualization method of U-matrix, to define the borders between groups, and the system RGB primary colors to define the neuron's color at the map's structure. It was found that the model has a performed well, where the percentage of accuracy for the test patterns were 66.7% for Sporotrichosis diseases and 100% for the others. The low to hit rate for Sporotrichosis was due to the fact that there is many common characteristics between Chromoblastomycosis's diseases and Cutaneous Leishmaniasis, wrongly classifying it as one of those diseases. In general, the network obtained 94.5% hit in test's set. The Kohonen network has proved a robust tool for classification of data, providing rapid results, with a good view of the groups, facilitating the interpretation of results. Medicine can benefit from information systems, as studied here, even as a support tool in medical offices and confirming the diagnosis as well as a training tool for future professionals. It is worth nothing that the final decision will always be the doctor.

Keywords: Artificial Neural Networks. Kohonen network. Diagnosis. Infectious diseases of the Skin.

## LISTA DE ILUSTRAÇÕES

FIGURA 1 – LESÕES DE LEISHMANIOSE CUTÂNEA .....	20
FIGURA 2 – LESÕES DE ESPOROTRICOSE .....	21
FIGURA 3 – LESÕES DE IMPETIGO .....	23
FIGURA 4 – LESÕES DE CROMOBLASTOMICOSE .....	24
FIGURA 5 – LESÕES DE LARVA MIGRANS CUTÂNEA .....	26
FIGURA 6 – LESÕES DE HERPES LABIAL .....	27
FIGURA 7 - ESQUEMA DE UM NEURÔNIO .....	36
FIGURA 8 - ANALOGIA ENTRE OS NEURÔNIOS NATURAIS E OS NEURÔNIOS ARTIFICIAIS .....	37
FIGURA 9 - FUNÇÕES DE ATIVAÇÃO .....	40
FIGURA 10 - REDE ALIMENTADA ADIANTE COM UMA ÚNICA CAMADA .....	42
FIGURA 11 - REDES ALIMENTADAS ADIANTE COM MÚLTIPLAS CAMADAS .....	42
FIGURA 12 - REDES RECORRENTES .....	43
FIGURA 13 – PARÂMETROS TOPOLÓGICOS DE VIZINHANÇA E RAIOS TOPOLÓGICOS .....	46
FIGURA 14 - REPRESENTAÇÃO DOS COMPONENTES $dx$ , $dy$ , $dz$ E $du$ DA U-MATRIZ PARA UMA REDE 3X4 RETANGULAR. OS CÍRCULOS REPRESENTAM OS NEURÔNIOS E OS QUADRADOS REPRESENTAM OS NEURÔNIOS INTERMEDIÁRIOS.....	54
FIGURA 15 - EXEMPLO DE REPRESENTAÇÃO DE AGRUPAMENTOS DE MAPAS AUTO- ORGANIZÁVEIS ATRAVÉS: (B) DA U-MATRIZ COLORIDA E (C) EM ESCALA DE CINZA .....	56
FIGURA 16 - REDE 3X4 PARTICIONADA DE FORMA QUE 3 GRUPOS FORAM CONSTITUÍDOS.....	56
FIGURA 17 - (A) REPRESENTAÇÃO DA U-MATRIZ E (B) DO MAPA DE DENSIDADE .....	58
FIGURA 18 – INTERFACE DO SOFTWARE QUE GERA OS VETORES NUMÉRICOS .....	65
FIGURA 19 – INTERFACE DO SOFTWARE DE TREINAMENTO DA REDE DE KOHONEN ...	66
FIGURA 20 – INTERFACE DO SOFTWARE DE VISUALIZAÇÃO DO MAPA DE SAÍDA .....	67
FIGURA 21 – INTERFACE DO SOFTWARE DE TESTE DA REDE DE KOHONEN .....	68
FIGURA 22 – MAPEAMENTO DAS CLASSES DA BASE DE DADOS IRIS POR: (A) COSTA E (B) PELA REDE TREINADA DESTE TRABALHO .....	73
FIGURA 23 – MAPEAMENTO DOS DADOS DA TABELA 8 POR: (A) KOHONEN E (B) PELA REDE TREINADA DESTE TRABALHO .....	74
FIGURA 24 – AGRUPAMENTOS DE ACORDO COM A SIMILARIDADE DOS DADOS DA TABELA 9 POR: (A) KOHONEN E (B) PELA REDE TREINADA NESTE TRABALHO .....	76
FIGURA 25 – TEMPO COMPUTACIONAL .....	77
FIGURA 26 – ERRO DE QUANTIZAÇÃO – FASE DE TREINAMENTO .....	78
FIGURA 27 – ERRO MÉDIO QUADRÁTICO– FASE DE TREINAMENTO .....	78
FIGURA 28 – ERRO DE QUANTIZAÇÃO – FASE DE TESTE .....	79
FIGURA 29 – ERRO MÉDIO QUADRÁTICO – FASE DE TESTE .....	79

FIGURA 30 – ERRO TOPOLÓGICO – FASE DE TREINAMENTO .....	80
FIGURA 31 – ERRO TOPOLÓGICO – FASE DE TESTE .....	80
FIGURA 32 – REDE DE NEURÔNIOS APÓS 6000 ITERAÇÕES .....	83
FIGURA 33 – ROTULAGEM DOS NEURÔNIOS .....	83
FIGURA 34 – U-MATRIZ APÓS 6000 ITERAÇÕES .....	84
FIGURA 35 – SEPARAÇÃO MANUAL DOS AGRUPAMENTOS .....	85
FIGURA 36 – MAPA DE TESTE APÓS TREINAMENTO DA REDE .....	86
FIGURA 37 – MAPA DE TESTE APÓS TREINAMENTO .....	87

## LISTA DE TABELAS

TABELA 1 – DESCRIÇÃO DA LESÃO DE LEISHMANIOSE CUTÂNEA .....	20
TABELA 2 – DESCRIÇÃO DA LESÃO DE ESPOROTRICOSE .....	22
TABELA 3 – DESCRIÇÃO DA LESÃO DE IMPETIGO .....	23
TABELA 4 – DESCRIÇÃO DA LESÃO DE CROMOBLASTOMICOSE .....	25
TABELA 5 – DESCRIÇÃO DA LESÃO DE LARVA MIGRANS CUTÂNEA .....	27
TABELA 6 – DESCRIÇÃO DA LESÃO DE HERPES LABIAL .....	28
TABELA 7 – DADOS IRIS .....	72
TABELA 8 – MATRIZ DE DADOS .....	73
TABELA 9 – NOMES DE ANIMAIS E SEUS ATRIBUTOS .....	75
TABELA 10 – ERROS NA FASE DE TREINAMENTO .....	81
TABELA 11 – ERROS NA FASE DE TESTE .....	81
TABELA 12 – ERROS DO MAPA 10X10 .....	82
TABELA 13 – NEURÔNIO VENCEDOR PARA CADA PADRÃO DE TESTE .....	86

## LISTA DE SIGLAS

BMU	- Best Match Unit
HC	- Hospital de Clínicas
LVQ	- Learning Vector Quantization
RGB	- Red-Green-Blue, padrão de cores
RNA	- Redes Neurais Artificiais
SOM	- Self Organizing Maps
UFPR	- Universidade Federal do Paraná

## SUMÁRIO

<b>1 INTRODUÇÃO</b>	12
1.1 APRESENTAÇÃO DO PROBLEMA	12
1.2 OBJETIVOS DO TRABALHO	14
1.3 ESTRUTURA DO TRABALHO	15
<b>2 DESCRIÇÃO DO PROBLEMA</b>	16
2.1 DIAGNÓSTICO MÉDICO	16
2.2 DOENÇAS INFECCIOSAS	18
2.2.1 <i>Introdução</i>	18
2.2.2 <i>Leishmaniose Tegumentar Americana</i>	19
2.2.3 <i>Esporotricose</i>	21
2.2.4 <i>Impetigo</i>	22
2.2.5 <i>Cromoblastomicose</i>	24
2.2.6 <i>Larva Migrans Cutânea</i>	25
2.2.7 <i>Herpes Labial</i>	27
2.3 OBTENÇÃO DOS DADOS	29
2.4 TRATAMENTO DOS DADOS	31
<b>3 REFERENCIAL TEÓRICO</b>	34
3.1 REDES NEURAIS	34
3.2 COMUNICAÇÃO NO CÉREBRO	35
3.3 REDES NEURAIS ARTIFICIAIS	37
3.3.1 <i>Introdução</i>	37
3.3.2 <i>Processo de treinamento</i>	39
3.3.3 <i>Arquitetura de uma rede neural artificial</i>	41
3.3.4 <i>Formas de aprendizagem</i>	43
3.4 REDE DE KOHONEN	44
3.4.1 <i>Introdução</i>	44
3.4.2 <i>Procedimento para formação do mapa auto-organizável</i>	46
3.4.3 <i>Métricas de precisão e preservação da topologia</i>	51
3.4.4 <i>Representação gráfica de mapas auto-organizáveis de Kohonen</i>	53
3.4.4.1 <i>U-matriz</i>	54
3.4.4.2 <i>U-altura</i>	55
3.4.4.3 <i>Grafos</i>	56
3.4.4.4 <i>Densidade</i>	57
3.4.4.5 <i>Normalização tipo min-max</i>	59
3.4.4.6 <i>Mapa contextual</i>	59
3.4.5 <i>Normalização dos dados de entrada</i>	60
3.4.6 <i>Aplicações da rede neural artificial</i>	61
<b>4 IMPLEMENTAÇÃO E ANÁLISE DOS RESULTADOS</b>	65
4.1 FERRAMENTA DESENVOLVIDA	65
4.2 IMPLEMENTAÇÃO DA REDE NEURAL DE KOHONEN	69
4.3 TESTES	71
4.3.1 <i>Comparando Resultados</i>	71
4.3.2 <i>Testando a rede implementada</i>	76
4.4 RESULTADOS	82
<b>5. CONSIDERAÇÕES FINAIS</b>	88
5.1 CONCLUSÕES	88

5.2 TRABALHOS FUTUROS .....	90
<b>REFERÊNCIAS</b> .....	91
<b>ANEXO</b> .....	96

## CAPÍTULO I

### 1 INTRODUÇÃO

#### 1.1 APRESENTAÇÃO DO PROBLEMA

A utilização de computadores como ferramenta de auxílio a tomada de decisões encontra na medicina uma das principais áreas de sua aplicação. Inúmeras atividades relacionadas à informática podem ser encontradas na área médica, citando-se os sistemas de apoio ao diagnóstico como uma das mais marcantes. Esses sistemas têm como principal objetivo auxiliar o profissional da área no processo de tomada de decisões, o qual pode ocorrer em diferentes etapas de sua atividade.

O processo de decisão médica depende da análise de dados e informações de diversas fontes e de natureza muito diferente, incluindo a experiência prévia do médico em realizar diagnósticos do mesmo tipo, bem como o senso comum e a intuição. Os problemas de decisão em Medicina têm se tornado cada vez mais complexos nos recentes anos, tendo em vista a rápida expansão do conhecimento, o volume de informações cada vez maiores, dificultando a tarefa do clínico ter em mente todas as alternativas relevantes a serem consideradas. Junte-se a isto o fato da incapacidade humana de manipular, num senso estatístico, grandes quantidades de dados e descobrir padrões complexos em situações multivariadas e interdependentes.

Podemos definir o processo diagnóstico tal como Massad (2003, p. 29): “um conjunto de técnicas que rotula o paciente e classifica sua doença, identifica o prognóstico provável e define o melhor tratamento disponível”. Do ponto de vista da lógica quantitativa, o diagnóstico é um processo de redução de incertezas. O ato do diagnóstico clínico é, portanto, um processo de classificação, isto é, um esforço para se reconhecer a classe à qual determinado paciente pertence.

Várias tentativas têm sido feitas para se identificar os caminhos cognitivos que levam ao diagnóstico médico: estratégias de arborização, estratégia de

exaustão, estratégia hipotético-dedutiva e o reconhecimento de padrões (SOUZA, 2004).

Recentemente, a inteligência artificial vem sendo utilizada como uma ferramenta de auxílio ao diagnóstico. A Rede Neural Artificial (RNA) é uma das técnicas da inteligência artificial que consiste na simulação, através de um software, de alguns aspectos do sistema nervoso biológico, na tentativa de permitir a realização de tarefas cognitivas de forma mais eficaz do que as obtidas através do processamento serial. O reconhecimento de padrões é uma de suas principais aplicações.

Este estudo trata da aplicação de recursos tecnológicos de inteligência artificial, em específico, Redes Neurais Artificiais, aplicado à ciência médica no diagnóstico baseado no conhecimento experiencial de um conjunto de dermatologias. Os dados foram coletados de textos médicos (BRASIL, 2005; BRASIL, 2000; COURA, 2005; GONTIJO, 2003; MACHADO-PINTO, 1994; MUNIZ, 2009; PERUCA, 2009; REY, 2001; RIBEIRO, 2006), prontuários do Hospital de Clínicas (HC) da Universidade Federal do Paraná, do período de 1995 a 2011 e de conversas com o Prof. Dr. Flávio de Queiroz Telles Filho, infectologista da instituição. No estudo, foram analisadas características, local, início e progressão das lesões dermatológicas bem como sintomas e dados epidemiológicos das doenças.

O modelo de RNA utilizado neste trabalho é um mapa auto-organizável (SOM – Self-Organizing Maps) proposto por Kohonen. Essa rede é baseada na aprendizagem competitiva. De acordo com Haykin (2001, p. 483), um mapa auto-organizável é “caracterizado pela formação de um mapa topográfico dos padrões de entrada, no qual as localizações espaciais dos neurônios na grade de saída são indicativas das características estatísticas intrínsecas, contidas nos padrões de entrada”, ou seja, o mapa é capaz de realizar o agrupamento de padrões mediante diferentes valores das variáveis de entrada, e com isso fazer uma classificação entre elas.

Este trabalho busca analisar a relevância dos dados coletados no diagnóstico de Esporotricose, Cromoblastomicose, Impetigo, Larva Migrans Cutânea, Herpes Labial e Leishmaniose Tegumentar Americana, e através desta análise, verificar se o tratamento desses dados pode auxiliar nos diagnósticos de

novos pacientes, usando a Rede Neural de Kohonen como ferramenta para o tratamento e a classificação dos dados.

## 1.2 OBJETIVOS DO TRABALHO

O objetivo deste trabalho é verificar se a aplicação de Redes Neurais Artificiais como técnica de reconhecimento de padrões pode auxiliar o diagnóstico médico de algumas infecções da pele. Mais especificamente:

- Estudar a rede de Kohonen;
- Aplicar a rede de Kohonen ao conjunto de dados;
- Desenvolver uma RNA para o diagnóstico de doenças dermatológicas, e
- Utilizando casos reais, avaliar o desempenho da Rede Neural desenvolvida.

A implementação da Rede Neural Artificial para o diagnóstico de doenças dermatológicas pode apresentar as seguintes vantagens:

- Método de auxílio no diagnóstico para orientação de médicos generalistas e profissionais que atuem em atenção primária à saúde;
- Método de auxílio na formação de novos profissionais na área médica;
- Método para agilizar e complementar o trabalho do médico especialista;
- Menor subjetividade no diagnóstico, e
- Direcionamento mais eficaz do tratamento.

A característica mais importante de uma Rede Neural Artificial é a sua capacidade de aprender e melhorar seu desempenho. Uma Rede Neural baseia-se em dados reais para extrair um modelo geral na tentativa de construir padrões detectados nesses dados (TATIBANA, 2006).

### 1.3 ESTRUTURA DO TRABALHO

O presente trabalho está estruturado em cinco capítulos.

O primeiro capítulo trata da introdução ao trabalho. A descrição do problema é tratada no Capítulo II.

O Capítulo III descreve, em detalhes, os conceitos das Redes Neurais Artificiais.

O Capítulo IV descreve a implementação da Rede Neural e a análise dos resultados obtidos pela rede.

Finalmente, no Capítulo V encontram-se as conclusões obtidas pela análise dos resultados do Capítulo IV e as sugestões para futuros trabalhos.

## CAPÍTULO II

### 2. DESCRIÇÃO DO PROBLEMA

#### 2.1 DIAGNÓSTICO MÉDICO

A área mais complexa e difícil da tomada de decisão médica é o diagnóstico. As principais razões para isto são as seguintes:

1 - O diagnóstico médico depende da análise de dados e informações de diversas fontes de naturezas muito diferentes, incluindo a experiência prévia do médico em realizar diagnósticos do mesmo tipo, bem como o senso comum e a intuição.

2 - Os mecanismos mentais e o processo de raciocínio pelo qual os clínicos chegam ao diagnóstico envolvem, simultaneamente, processos lógicos, avaliação probabilística, encadeamento causal, e muitos outros.

Hipócrates foi o primeiro a usar a palavra *diagnóstico*, que significa discernimento, formada pelo prefixo **dia**, através de, em meio de, + **gnosis**, conhecimento. Diagnóstico, portanto, é discernir pelo conhecimento. Inicialmente, o médico só dispunha de seus sentidos para exame do paciente. Com a visão, observava o enfermo, com o tato realizava a palpação e a tomada do pulso; com a audição ouvia as suas queixas e ruídos anormais; com o olfato podia sentir odores característicos. Como ensinava Hipócrates, o exame clínico deve começar pelas coisas mais importantes e mais facilmente reconhecíveis. Verificar as semelhanças e as diferenças com o estado de saúde, observar tudo que se pode ver, ouvir, tocar, sentir, tudo que se pode reconhecer pelos nossos meios de conhecimento, e também se examinava os excretos, especialmente a urina.

O diagnóstico, de certa forma, é um exercício de comparação: o médico precisa confrontar os dados que reuniu (através da anamnese, do exame físico e dos exames complementares) com as informações disponíveis a respeito das diversas doenças existentes.

O estudo sobre a utilização de sistemas computacionais de apoio à decisão médica ou de auxílio a diagnósticos está se tornando cada vez mais frequente.

Existem diversos trabalhos que fazem uso de técnicas relacionadas à área da inteligência artificial, como sistemas especialistas, Lógica *Fuzzy*, Algoritmos Genéticos, ou mesmo a tecnologia das Redes Neurais Artificiais.

Os sistemas computadorizados de apoio ao diagnóstico médico têm como função básica auxiliar o profissional principalmente no aspecto de armazenamento e processamento da grande quantidade de dados e informações tratados na etapa de diagnóstico. Esses sistemas tentam imitar o raciocínio do médico através de princípios de análises de decisões, com a capacidade de elaborar um raciocínio automático e realizar inferências lógicas, como induções e deduções.

A primeira experiência bem sucedida de se construir um sistema de diagnóstico médico foi o programa MYCIN (SHORTLIFFE, 1976), desenvolvido nos Estados Unidos no início da década de 1970 pelo Dr. Edward Shortliffe, da Universidade de Stanford. Esse sistema tem a função de apoio ao diagnóstico e terapia de infecções provocadas por microorganismos.

Vários estudos tratam o problema do diagnóstico médico através do uso de métodos de agrupamento e classificação. Visando observar o comportamento de Redes Neurais para esta tarefa, foi escolhida a abordagem pela Rede Neural de Kohonen, cuja especialidade é o agrupamento de dados. Este trabalho propõe avaliar os sintomas dos pacientes, detectados por meio de exames clínicos, a fim de sugerir possíveis diagnósticos.

Por motivos de simplicidade na implementação desta tarefa, restringiu-se a um subconjunto de diagnósticos da área de conhecimento da medicina denominada infectologia, em especial aquelas que acometem a pele: Esporotricose, Cromoblastomicose, Impetigo, Herpes Labial, Larva Migrans Cutânea e Leishmaniose Tegumentar Americana. Cabe lembrar que o sistema proposto, programado na linguagem Visual Basic versão 6.0 da Microsoft, será ferramenta auxiliar para o médico, e não um sistema decisivo no processo de tomada de decisão.

## 2.2 DOENÇAS INFECCIOSAS

### 2.2.1 Introdução

Coura (2005) define *infecção* como penetração, multiplicação e/ou desenvolvimento de um germe ou parasito em um determinado hospedeiro e *doença infecciosa* como as manifestações pelos danos causados pelo agente infeccioso no organismo e sua exteriorização clínica através de sintomas e sinais. Em outras palavras, infecção é o estabelecimento da interação parasito-hospedeiro e doença infecciosa é o conjunto das manifestações clínicas e patológicas quando ocorre dano na relação parasito-hospedeiro.

O acesso de um germe ou parasito a um hospedeiro suscetível ocorre geralmente através do contato direto com a pele ou mucosas, através de aerossóis, por ingestão, inoculação por vetores, inoculação acidental por seringas ou transfusão de sangue e por via sexual. Picadas de insetos ou mordidas de animais são outra forma de transmissão.

Embora exista um grande número de microorganismos que causam doenças, o corpo humano aprende a se defender deles. As defesas do organismo contra a infecção incluem barreiras naturais, como a pele, mecanismos inespecíficos, como certos tipos de glóbulos brancos e a febre, e mecanismos específicos, como os anticorpos. Se um microorganismo atravessa as barreiras naturais do corpo, os mecanismos de defesa específicos e inespecíficos procuram destruí-lo antes que se multiplique.

A pele é a primeira barreira que protege os tecidos subjacentes do corpo. E nos locais onde ficam aberturas naturais, como o canal lacrimal, as glândulas lacrimais dos olhos secretam e banham os olhos com um fluido que contém componentes que combatem as bactérias. Já as glândulas salivares da boca e as amígdalas da garganta ajudam a impedir que os microorganismos causem doenças penetrando no organismo pela boca ou pela garganta.

Muitas aberturas do corpo, assim como passagens internas, são revestidas com membranas mucosas. Essas delicadas camadas produzem muco, uma secreção escorregadia que umedece e protege repelindo ou aprisionando os

microorganismos. E no que se refere ao interior do nosso corpo, há certos órgãos que conseguem combater infecções, como o fígado e o baço.

Vencidas as primeiras barreiras, o germe ou o parasito ao penetrar no organismo do hospedeiro inicia o processo de estabelecimento através de sua localização, multiplicação e/ou desenvolvimento, com manifestações clínicas características da doença causada pelo parasito.

Nas subseções a seguir é apresentada uma sinopse das doenças utilizadas para o desenvolvimento deste trabalho.

### 2.2.2 *Leishmaniose Tegumentar Americana* - CID 10 B55.1

Doença infecciosa causada por protozoários do gênero *Leishmania* e transmitida através da picada de insetos de diferentes espécies da família *Phlebotominae*. Possui uma diversidade de aspectos clínicos relacionados às diferentes espécies do parasito, à resposta imune do hospedeiro e de fatores resultantes da interação parasito-hospedeiro. A Leishmaniose Cutânea é a forma clínica mais freqüente e restrita a pele (BRASIL, 2005; COURA, 2005; GONTIJO, 2003). Outras manifestações da Leishmaniose não serão abordadas nesse trabalho, pois este se limita a doenças infecciosas da pele.

A lesão inicial é pequena, eritematosa, consistente e elevada, e aumenta gradualmente em diâmetro. Freqüentemente ulcera, está coberta por crosta e neste momento os linfonodos são palpáveis. A lesão ulcerada progride e atinge de 3 a 12 centímetros de diâmetro, com bordos elevados bem definidos, em moldura de quadro e base granulosa que sangra facilmente. São lesões indolores, únicas ou múltiplas, onde a infecção secundária é comum. As lesões não ulceradas também aumentam e tornam-se nodulares ou verrucosas. As lesões vegetantes caracterizam-se pelo aspecto papilomatoso, úmido e de consistência mole. As lesões verrucosas caracterizam-se por superfície seca, áspera, com presença de pequenas crostas e de descamação. O diagnóstico clínico da Leishmaniose Cutânea é sugerido na anamnese e baseia-se nas características da lesão associada aos dados epidemiológicos do doente (pacientes de áreas endêmicas ou que lá estiveram recentemente). A Figura 1 mostra exemplos de lesões causadas pela Leishmaniose Cutânea.



FIGURA 1 – LESÕES DE LEISHMANIOSE CUTÂNEA

FONTE: <<http://leishmanioses.blogspot.com.br/2010/02/forma-cutanea.html>> Acesso em 16/05/12

As lesões surgem no local da picada do inseto e, portanto, localizam-se em áreas expostas. O período de incubação varia entre 1 a 3 meses, podendo se estender a um ano.

A Tabela 1 descreve as características da doença que foram observadas no desenvolvimento deste trabalho.

TABELA 1 – DESCRIÇÃO DA LESÃO DE LEISHMANIOSE CUTÂNEA

<b>CARACTERÍSTICAS DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Bordas elevadas bem definidas</li> <li>• Ulceradas</li> <li>• Purulentas</li> <li>• Granulosas</li> <li>• Verrucosa</li> <li>• Amarronzada</li> </ul>	<ul style="list-style-type: none"> <li>• Crostas</li> <li>• Secreção fétida (quando há infecção secundária).</li> <li>• Eritematosas</li> <li>• Descamação</li> </ul>
<b>SINTOMAS</b>	<ul style="list-style-type: none"> <li>• Dor na lesão</li> </ul>	
<b>LOCAL DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Membros inferiores e superiores</li> </ul>	<ul style="list-style-type: none"> <li>• Face</li> </ul>
<b>INÍCIO DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Vesículas</li> <li>• Úlcera</li> <li>• Mácula</li> <li>• Eritema</li> <li>• Pápula</li> </ul>	<ul style="list-style-type: none"> <li>• Início entre 1 a 6 meses</li> <li>• Início entre 6 meses e 1 ano</li> <li>• Início há mais de 1 ano</li> </ul>
<b>PROGRESSÃO DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Aumento da extensão da lesão</li> <li>• Aumento da profundidade da lesão</li> <li>• Formação de crostas</li> </ul>	<ul style="list-style-type: none"> <li>• Úlceras</li> <li>• Verrugas</li> <li>• Múltiplas lesões pelo corpo (houve mais picadas)</li> </ul>
<b>DADOS EPIDEMIOLÓGICOS</b>	<ul style="list-style-type: none"> <li>• Viajou, morou ou mora em região com dados epidemiológicos de Leishmaniose</li> </ul>	<ul style="list-style-type: none"> <li>• Houve inserção em áreas florestais</li> <li>• Picada de inseto</li> </ul>

FONTE: Brasil (2000); Brasil (2005); Coura (2005); Gontijo (2003)

### 2.2.3 Esporotricose - CID 10 B42

Doença infecciosa, subaguda ou crônica, causada por implantação do fungo dimorfo *Sporothrix schenckii*. As lesões costumam ser restritas a pele, tecido celular subcutâneo e vasos linfáticos adjacentes (COURA, 2005; MUNIZ, 2009).

De início, evidencia-se através de um pequeno nódulo indolor que, à medida que vai aumentando de tamanho, vai-se tinindo à pele, a qual fica vermelha e forma uma úlcera, propiciando a secreção de um líquido amarelado. Em simultâneo, vão-se produzindo pequenos abscessos ao longo dos vasos linfáticos e nos gânglios linfáticos que drenam o tecido onde se encontra a lesão inicial, com uma evolução semelhante, já que tem a tendência para se unirem à pele, propiciando a formação de úlceras. O aspecto morfológico das lesões cutâneas varia: nódulos, tubérculos, pústulas, lesões císticas, gomas, úlceras verrucosas e placas, acompanhadas ou não de linfangite nodular e de dor local. A Figura 2 mostra exemplos de lesões causadas pela Esporotricose.



FIGURA 2 – LESÕES DE ESPOROTRICOSE

FONTE: < <http://www.dermatologia.net/novo/base/doencas/esporotricose.shtml>>  
< <http://infungicas.blogspot.com.br/2010/12/infeccoos-fungicas-subcutaneas.html>>  
Acesso em 16/05/12

A lesão geralmente surge nas extremidades superiores, face ou membros inferiores, correspondendo aos locais mais expostos a traumas.

O fungo causador da Esporotricose habita a natureza (solo, palha, vegetais, madeira) e a instalação da doença se dá através de ferimentos com material contaminado, como farpas ou espinhos. Animais contaminados, principalmente gatos, também podem transmitir a Esporotricose através de mordeduras ou arranhaduras. O período de incubação varia de 3 a 30 dias, mas pode estender-se por meses.

A Tabela 2 descreve as características da doença que foram observadas no desenvolvimento deste trabalho.

TABELA 2 – DESCRIÇÃO DA LESÃO DE ESPOROTRICOSE

<b>CARACTERÍSTICAS DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Ulcerada</li> <li>• Eritematosa</li> <li>• Se pressionar, sai pus</li> <li>• Ínguas próximas à lesão</li> <li>• Nódulos</li> <li>• Crostosa</li> <li>• Verrucosa</li> </ul>	<ul style="list-style-type: none"> <li>• Pode formar um cordão endurecido de nódulos (forma de um rosário), na direção dos vasos linfáticos</li> <li>• Placa eritematosa</li> </ul>
<b>SINTOMAS</b>	<ul style="list-style-type: none"> <li>• Prurido</li> <li>• Dor na lesão</li> </ul>	<ul style="list-style-type: none"> <li>• Febre</li> </ul>
<b>LOCAL DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Face</li> </ul>	<ul style="list-style-type: none"> <li>• Membros inferiores e superiores</li> </ul>
<b>INÍCIO DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Entre 15 dias e 12 meses</li> <li>• Pápula</li> </ul>	<ul style="list-style-type: none"> <li>• Nódulo</li> <li>• Eritema</li> </ul>
<b>PROGRESSÃO DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Aumento da extensão da lesão</li> <li>• Formação de crostas</li> </ul>	<ul style="list-style-type: none"> <li>• Úlceras</li> <li>• Ínguas</li> </ul>
<b>DADOS EPIDEMIOLÓGICOS</b>	<ul style="list-style-type: none"> <li>• Traumatismo causado por animal</li> <li>• Traumatismo por fragmento vegetal</li> <li>• Traumatismo por ferramenta agrícola</li> </ul>	<ul style="list-style-type: none"> <li>• Traumatismo no local da lesão (diferente dos anteriores)</li> <li>• Teve contato com vegetais, solo, madeira putrificada</li> </ul>

FONTE: Coura (2005); Muniz (2009)

#### 2.2.4 Impetigo – CID 10 L01

Infecção bacteriana superficial da epiderme que pode ser causada por dois tipos de bactérias: *Streptococcus pyogenes* ou *Staphylococcus aureus*. Ambas as bactérias costumam viver em nossa pele sem nos causar danos. Entretanto, através de uma pequena ferida, corte ou mesmo de uma picada de mosquito, elas podem alcançar camadas internas da pele e provocar infecção (COURA, 2005; SCHECHTER, 1994).

Clinicamente, existem as formas bolhosa e não bolhosa. O impetigo comum (não bolhoso) se inicia com pequenas pápulas vermelhas, semelhantes a picadas de inseto, que evolui rapidamente para pequenas pústulas. Estas pústulas estouram e formam lesões crostosas com coloração dourada ou cor de mel. Podem coçar, e com o tempo as crostas desaparecem sem cicatriz. No impetigo bolhoso, a lesão inicial é igual ao impetigo comum, com pequenas pápulas, porém evolui rapidamente para bolhas com conteúdo amarelado. A pele ao redor das bolhas costuma ficar avermelhada e com coceira. As bolhas geralmente rompem-se deixando uma crosta amarelo-avermelhada, que costuma ser maior e mais duradoura que o impetigo comum. A Figura 3 mostra exemplos de lesões causadas pelo Impetigo.



FIGURA 3 – LESÕES DE IMPETIGO

FONTE: < <http://www.mdsaude.com/2011/05/impetigo-bolhoso.html>> Acesso em 16/05/12

As lesões, que surgem preferencialmente na face e nos membros, reproduzem-se por auto-inoculação, muitas vezes confluentes e com bordas circinadas. Pode haver febre, mal-estar e falta de apetite.

O contágio se dá pelo contato direto, principalmente por meio de lesões cutâneas, como picadas de inseto, arranhões ou cortes preexistentes nesta região (pois se rompe a barreira de proteção da pele). O período de incubação varia de 3 a 5 dias.

A Tabela 3 descreve as características da doença que foram observadas no desenvolvimento deste trabalho.

TABELA 3 – DESCRIÇÃO DA LESÃO DE IMPETIGO

<b>CARACTERÍSTICAS DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Pápulas</li> <li>• Eritematosa</li> <li>• Crostas</li> <li>• Bolhosa</li> <li>• Vesículas</li> </ul>	<ul style="list-style-type: none"> <li>• Pustulosa</li> <li>• Ulcerada</li> <li>• Secreção transparente</li> <li>• Circinada (forma de anel)</li> </ul>
<b>SINTOMAS</b>	<ul style="list-style-type: none"> <li>• Prurido</li> <li>• Febre</li> </ul>	<ul style="list-style-type: none"> <li>• Mal estar</li> <li>• Anorexia</li> </ul>
<b>LOCAL DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Face</li> <li>• Membros inferiores e superiores</li> </ul>	<ul style="list-style-type: none"> <li>• Tronco</li> </ul>
<b>INÍCIO DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Início entre 1 e 30 dias</li> <li>• Com pápulas</li> <li>• Com mácula</li> </ul>	<ul style="list-style-type: none"> <li>• Eritema</li> <li>• Vesículas</li> </ul>
<b>PROGRESSÃO DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Aumento do número de lesões</li> <li>• Formação de crostas</li> <li>• Secreção</li> <li>• Ruptura espontânea (das bolhas ou vesículas)</li> </ul>	<ul style="list-style-type: none"> <li>• Vesículas</li> <li>• Pústulas</li> <li>• Disseminação por contigüidade</li> </ul>
<b>DADOS EPIDEMIOLÓGICOS</b>	<ul style="list-style-type: none"> <li>• Havia trauma no local da lesão</li> <li>• Teve contato com solo</li> <li>• Contato com pessoa doente</li> </ul>	<ul style="list-style-type: none"> <li>• Trauma na pelo por algum fragmento vegetal</li> </ul>

FONTE: Coura (2005); Schechter (1994)

### 2.2.5 Cromoblastomicose - CID 10 B43.0

Doença infecciosa crônica da pele e tecido subcutâneo, decorrente da implantação traumática transcutânea de propágulos de diversas espécies de fungos pertencentes à família *Dematiaceae*. Entre os agentes causadores dessa doença, os principais são: *Fonsecaea pedrosoi*, *Fonsecaea monophora*, *Phialophora verrucosa*, *Clodophialophora carrionii* e *Rhinocladiella aquaspersa*, os quais se encontram com mais freqüência no solo, em vegetais, espinhos de plantas, em vegetações em decomposição e em madeiras putrefatas, sob a forma saprofítica (ARAÚJO, 2008; RIBEIRO, 2006).

Observa-se inicialmente no local de implantação dos agentes da Cromoblastomicose, a presença de lesão(ões) papular(es) de superfície eritematosa e descamativa, podendo gradativamente aumentar de tamanho, com a presença de pontos negros sobre a lesão. Em seguida, um notável polimorfismo clínico é geralmente observado, tendo como tipos básicos de lesão os aspectos: nodular, verrucosa, em placa (infiltrativa ou eritematosa), tumoral e cicatricial. Embora haja o predomínio dos tipos verrucoso e tumoral. Há a sensação de dor e prurido na lesão. A Figura 4 mostra exemplos de lesões causadas pela Cromoblastomicose.



FIGURA 4 – LESÕES DE CROMOBLASTOMICOSE  
FONTE: Araújo (2008)

O fungo penetra na pele usualmente por implantação traumática, especialmente em áreas desprotegidas de vestimentas, como face, membros superiores e inferiores. As lesões se desenvolvem no local da inoculação, acometendo a pele e algumas vezes o tecido subcutâneo.

A Tabela 4 descreve as características da doença que foram observadas no desenvolvimento deste trabalho.

TABELA 4 – DESCRIÇÃO DA LESÃO DE CROMOBLASTOMICOSE

<b>CARACTERÍSTICAS DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Presença de pontos negros na lesão</li> <li>• Eritematosa</li> <li>• Ulcerada</li> <li>• Descamativa</li> <li>• Secreção fétida</li> <li>• Granulosa</li> </ul>	<ul style="list-style-type: none"> <li>• Nódulos</li> <li>• Placa</li> <li>• Edema</li> <li>• Verrucosa</li> <li>• Lesão semelhante à couve-flor</li> <li>• Purulenta</li> </ul>
<b>SINTOMAS</b>	<ul style="list-style-type: none"> <li>• Prurido</li> </ul>	<ul style="list-style-type: none"> <li>• Dor na lesão</li> </ul>
<b>LOCAL DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Face</li> </ul>	<ul style="list-style-type: none"> <li>• Membros inferiores e superiores</li> </ul>
<b>INÍCIO DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Entre 15 dias e 12 meses</li> <li>• Pápula</li> <li>• Eritema</li> </ul>	<ul style="list-style-type: none"> <li>• Edema</li> <li>• Descamação</li> </ul>
<b>PROGRESSÃO DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Aumento da extensão da lesão</li> <li>• Descamação</li> <li>• Crostas</li> <li>• Úlceras</li> <li>• Ínguas</li> </ul>	<ul style="list-style-type: none"> <li>• Verrugas</li> <li>• Múltiplas lesões pelo corpo</li> <li>• Disseminação por contigüidade</li> </ul>
<b>DADOS EPIDEMIOLÓGICOS</b>	<ul style="list-style-type: none"> <li>• Traumatismo causado por animal</li> <li>• Traumatismo por fragmento vegetal</li> <li>• Traumatismo por ferramenta agrícola</li> </ul>	<ul style="list-style-type: none"> <li>• Traumatismo no local da lesão (diferente dos anteriores)</li> <li>• Teve contato com vegetais, solo ou madeira putrificada</li> </ul>

FONTE: Araújo (2008); Ribeiro (2006)

### 2.2.6 Larva Migrans Cutânea – CID 10 B83

Dermatite parasitária, também conhecida como “bicho geográfico”, causada pela penetração e migração de larvas de alguns ancilostomídeos no extrato epitelial da pele humana. Como os humanos são hospedeiros acidentais, as larvas não conseguem finalizar o ciclo e continuam migrando na epiderme por várias semanas. *Ancylostoma brasilienses* e *Ancylostoma caninum* são os principais agentes de Larva Migrans Cutânea no Brasil, pertencem à família Ancylostomidae, estão presentes principalmente em areias contaminadas (MACHADO-PINTO, 1994; PERUCA, 2009).

Animais domésticos, como cães e gatos, são seus vetores e hospedeiros. O homem é considerado hospedeiro acidental. Infecta-se ao entrar em contato direto com areias de praias, bancos de areias em praças públicas, jardins, creches e escolas, locais contaminados com ovos desses nematódeos, que são eliminados junto com as fezes dos cães e gatos, infectados com a forma adulta do verme.

As larvas entram em contato com a pele humana, perfuram o estrato epitelial, mas não conseguem atravessar as camadas subjacentes, com isso,

caminham ao acaso, abrindo um túnel. O momento da penetração das larvas infectantes pode passar despercebido, entretanto em pessoas sensibilizadas surgem pontos eritematosos ou pápulas, acompanhados de prurido. Desses pontos partem os túneis que desenham um trajeto irregular e caprichoso, avançando 2 a 5 centímetros por dia. Algumas vezes, a linha serpeante restringe-se a uma pequena área e em outras, alonga-se como o traçado de um mapa. No trajeto ocorre reação inflamatória onde se observa infiltrado de células eosinófilas e mononucleares. Com o deslocamento da larva, a lesão vai ficando como um cordão eritematoso, saliente, irregular e pruriginoso, podendo estar recoberto por vesículas. Com o passar dos dias, a parte antiga do trajeto tende a desinflamar, deixando em seu lugar apenas uma faixa hiper pigmentada, que desaparecerá mais tarde. Infecções microbianas secundárias podem transformar essas lesões em uma piodermite, principalmente pelas escoriações da pele, devido ao ato de coçar, provocado pelo intenso prurido. A Figura 5 mostra exemplos de lesões causadas pela Larva Migrans Cutânea.



FIGURA 5 – LESÕES DE LARVA MIGRANS CUTÂNEA

FONTE: < <http://www.educadores.diaadia.pr.gov.br/modules/mylinks/singlelink.php?cid=6&lid=19066>>  
< <http://www.brasilecola.com/doencas/dermatose.htm>> Acesso em 16/05/12

As regiões mais atingidas da pele são aquelas de maior contato com a areia ou terra poluída, principalmente os pés, pernas, coxas, nádegas, mãos e antebraços. O período de incubação varia de dias a semanas.

A Tabela 5 descreve as características da doença que foram observadas no desenvolvimento deste trabalho.

TABELA 5 – DESCRIÇÃO DA LESÃO DE LARVA MIGRANS CUTÂNEA

<b>CARACTERÍSTICAS DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Bordas elevadas.</li> <li>• Secreção transparente</li> <li>• Eritematosa</li> </ul>	<ul style="list-style-type: none"> <li>• Linhas sinuosas, semelhantes a traçado de mapa.</li> <li>• Com edema</li> </ul>
<b>SINTOMAS</b>	<ul style="list-style-type: none"> <li>• Prurido</li> </ul>	
<b>LOCAL DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Nádegas</li> </ul>	<ul style="list-style-type: none"> <li>• Membros inferiores e superiores</li> </ul>
<b>INÍCIO DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Entre 15 e 30 dias</li> <li>• Pápula</li> </ul>	<ul style="list-style-type: none"> <li>• Eritema</li> <li>• Edema</li> </ul>
<b>PROGRESSÃO DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Aumento da extensão da lesão</li> </ul>	
<b>DADOS EPIDEMIOLÓGICOS</b>	<ul style="list-style-type: none"> <li>• Esteve em contato com qualquer local freqüentado por cães e gatos</li> </ul>	

FONTE: Machado-Pinto (1994); Peruca (2009)

### 2.2.7 Herpes Labial – CID 10 B00

É uma doença infecciosa muito contagiosa, recorrente, geralmente benigna, causada pelo vírus da família dos *Herpes viridae* (*Herpes simplex vírus 1*), infectando de forma latente (sem atividade destrutiva) alguns neurônios (BRASIL, 2005).

Na maioria dos casos a recorrência produz dor, queimação e prurido no lugar onde irá ocorrer a erupção de 6 a 48 horas depois. Nesse local inicia-se uma pápula eritematosa, evoluindo para vesículas que se rompem dando origem a uma úlcera pustulosa seca ou úmida. A evolução dessa lesão é rápida, variando de horas a dois dias. Ao mesmo tempo em que se formam crostas, surgem novas vesículas, as quais são muito dolorosas. As úlceras formadas após o rompimento das vesículas têm tamanhos variáveis, chegando até centímetros, quando as vesículas e úlceras coalescem. A Figura 6 mostra exemplos de lesões causadas pelo Herpes Labial.



FIGURA 6 – LESÕES DE HERPES LABIAL

FONTE: < <http://www.mdsaude.com/2012/04/herpes-labial.html>> Acesso em 16/05/12

A localização do herpes labial é geralmente na borda do lábio inferior. A frequência das recorrências varia de uma a duas vezes até 10 a 12 episódios por ano, no mesmo local ou em outras localizações do lábio. O vírus encontra-se supostamente adormecido no organismo em certas células nervosas do corpo até ser reativado pela exposição ao sol, febre, período menstrual, traumatismo, stress, uso de determinados medicamentos ou situações de redução da resistência física, voltando a infectar as células sensíveis causando nova doença.

A transmissão do vírus se faz preferentemente por contato direto pessoa – pessoa, mesmo que não haja lesão ativa. A infecção através de objetos pode existir, mas é menos comum. O período de incubação é estimado em duas semanas.

A Tabela 6 descreve as características da doença que foram observadas no desenvolvimento deste trabalho.

TABELA 6 – DESCRIÇÃO DA LESÃO DE HERPES LABIAL

<b>CARACTERÍSTICAS DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Purulenta</li> <li>• Ulcerada</li> <li>• Vesículas</li> <li>• Com crostas</li> <li>• Secreção purulenta</li> <li>• Com sangramento</li> </ul>	<ul style="list-style-type: none"> <li>• Eritematosa</li> <li>• Com edema</li> <li>• Pápula</li> <li>• Pústulas</li> <li>• Placas esbranquiçadas</li> </ul>
<b>SINTOMAS</b>	<ul style="list-style-type: none"> <li>• Prurido</li> </ul>	<ul style="list-style-type: none"> <li>• Febre</li> </ul>
<b>LOCAL DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Lábio</li> <li>• Língua</li> </ul>	<ul style="list-style-type: none"> <li>• Peri oral</li> <li>• Mucosa</li> </ul>
<b>INÍCIO DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Com pápulas</li> <li>• Mácula</li> </ul>	<ul style="list-style-type: none"> <li>• Eritema</li> <li>• Vesícula</li> </ul>
<b>PROGRESSÃO DA LESÃO</b>	<ul style="list-style-type: none"> <li>• Aumento do número de lesões</li> <li>• Aumento da extensão da lesão</li> <li>• Formação de crostas</li> <li>• Ruptura espontânea das vesículas</li> </ul>	<ul style="list-style-type: none"> <li>• Vesícula</li> <li>• Pústula.</li> <li>• Úlceras</li> <li>• Início a menos de 15 dias</li> <li>• Início entre 15 e 30 dias</li> </ul>
<b>DADOS EPIDEMIOLÓGICOS</b>	<ul style="list-style-type: none"> <li>• Contato com pessoas doente.</li> <li>• Exposição solar</li> <li>• Baixa imunidade</li> </ul>	<ul style="list-style-type: none"> <li>• Estresse emocional</li> <li>• Menstruação</li> </ul>

FONTE: Brasil (2005)

Existe um grupo de diagnósticos possível bem maior do que o apresentado, contudo este estudo se limita a este conjunto de doenças dermatológicas.

A Leishmaniose Cutânea, a Eporotricose e a Cromoblastomicose desenvolvem-se em áreas do corpo que estão descobertas pelo vestuário, devido ao agente transmissor, conforme descrito em cada seção das respectivas doenças. Este trabalho se restringe às regiões do corpo mais comuns de acometimento destas doenças, desconsiderando a possibilidade do paciente se encontrar sem vestuário em áreas consideradas sempre cobertas. O intuito é verificar a

aplicabilidade da Rede Neural em estudo nos casos considerados comuns para depois, em trabalhos futuros, ampliar os casos considerados.

### 2.3 OBTENÇÃO DOS DADOS

Os dados de entrada da rede neural deste trabalho foram obtidos após leitura de textos médicos (BRASIL, 2005; BRASIL, 2000; COURA, 2005; GONTIJO, 2003; MACHADO-PINTO, 1994; MUNIZ, 2009; PERUCA, 2009; REY, 2001; RIBEIRO, 2006), análise de prontuários do Hospital de Clínicas (HC) da Universidade Federal do Paraná (UFPR) do período de 1995 a 2011, e conversas com um dos infectologistas do HC, Prof. Dr. Flavio de Queiroz Telles Filho. Dr. Telles Filho sugeriu o nome de várias doenças infecciosas, entre elas a Conjuntivite, a Candidíase Oral, Tinha, Onicomicose, Leishmaniose Cutânea, Leishmaniose Cutâneo-mucosa, Impetigo, Cromoblastomicose, Esporotricose, Larva Migrans Cutânea e Herpes Labial. Após estudos quanto às formas de manifestações e sintomas, optou-se trabalhar com Leishmaniose Cutânea, Impetigo, Cromoblastomicose, Esporotricose, Larva Migrans Cutânea e Herpes Labial por se tratarem de infecções que acometem a pele.

Ao todo, existem 68 padrões de entrada, sendo 15 de Impetigo, 12 de Cromoblastomicose, 10 de Esporotricose, 5 de Larva Migrans Cutânea, 10 de Herpes Labial e 16 de Leishmaniose Tegumentar Americana.

Foram analisados 60 prontuários do HC-UFPR. Dentre as doenças algumas são clinicamente mais simples, como a Larva Migrans Cutânea. Seu prontuário não foi encontrado no HC, pois, segundo o infectologista da instituição, é uma doença diagnosticada nos Postos de Saúde e não encaminhada ao hospital e por isso seus atributos foram extraídos de textos médicos e de experiências relatadas por profissionais da área encontrados em textos durante a pesquisa.

O banco de dados é composto de 83 variáveis que podem ser organizadas basicamente do seguinte modo:

- a) características da lesão – purulenta; com secreção transparente; secreção purulenta; secreção fétida; há secreção somente se pressionar a lesão; pápulas; pústulas; vesículas; bolhas; nodular; verrucosa; crostas; com

descamação; ulcerada, máculas; forma de uma placa; eritematosa; com edema; esbranquiçada; granulosa; amarronzada; com sangramento; bordas elevadas; bordas elevadas bem definidas; ínguas próximas a lesão; serpentiforme (linhas sinuosas); presença de pontos negros na lesão; semelhante à couve-flor; forma anelar; formou um cordão endurecido de nódulos (semelhante a um rosário);

b) sintomas – febre; prurido; dor na lesão; mal estar; anorexia;

c) local da lesão – tronco; membros superiores ou inferiores; perioral; lábio; mucosa; face; ombro; nádegas;

d) início da lesão – com pápula; mácula; eritema; vesícula; úlcera; edema; nódulo; forma de placa; início há 15 dias; entre 15 e 30 dias; entre 1 e 6 meses; entre 6 meses e um ano; mais de um ano;

e) progressão da lesão – aumentou o número de lesões; aumentou a extensão da lesão; aumentou a profundidade da lesão; para pústulas, vesículas, crosta, verrugas, úlcera, secreção; ruptura espontânea (das vesículas ou bolhas); disseminação por contigüidade; para múltiplas lesões pelo corpo;

f) dados epidemiológicos – teve contato com pessoa doente; viajou, morou ou mora em região com dados epidemiológicos da doença; havia trauma no local da lesão ocasionado por animal, por ferramenta agrícola, por fragmento vegetal, ou outro tipo de trauma; houve inserção em áreas florestais; teve contato com solo ou plantas; teve contato com local freqüentado por gatos; exposição solar; estresse emocional; está menstruada; imunidade baixa (por alguma doença ou imunodeficiência).

Pode-se constatar que as entradas dizem respeito às características da lesão e de seu sintoma. As múltiplas alternativas de resposta podem ser escolhidas isoladamente ou de maneira múltipla, já que a lesão pode ter característica variável.

## 2.4 TRATAMENTO DOS DADOS

A escolha e adequação dos dados utilizados para treinar e testar uma Rede Neural Artificial é de fundamental importância. É necessário que se disponha de dados em quantidade e qualidade suficientes. Caso a quantidade de dados seja pequena, a rede não conseguirá criar um modelo suficientemente representativo para se ter um desempenho satisfatório quando aplicado em situações reais após o seu desenvolvimento. Além disto, os dados devem englobar todos os aspectos do problema em questão, a fim de que o modelo criado seja genérico. Em geral, tais dados precisam ser convertidos para um formato padrão para utilização pelas Redes Neurais Artificiais (MENDES, 2008).

Se um experimento é composto de N variáveis, para considerar todas as possibilidades de seleção das entradas teríamos que verificar todas as possibilidades de combinação executando  $2^N$  experiências. Em nosso caso, teríamos que trabalhar com  $2^{83}$  Redes Neurais (pois temos 83 variáveis) para selecionar a combinação das variáveis de entrada que fornecesse a melhor performance. Como estamos trabalhando com doenças, sabemos que estas se manifestam de várias maneiras, e podem ser encontradas em vários estágios. Há síndromes que se restringem a uma doença específica, algumas particularidades estão sempre presentes em todos os quadros clínicos de uma moléstia, enquanto outras estão presentes concomitantemente com outros atributos, por isso não é viável combinar as 83 variáveis, pois criaríamos quadros irrealistas. Basta combinar aquelas características presumíveis de cada doença e assim o número de combinações diminui.

Por exemplo, para a doença Larva Migrans Cutânea basta combinar:

- a)** Características da lesão – edema; eritematosa; bordas elevadas; secreção transparente; linhas sinuosas;
- b)** Sintomas – prurido;
- c)** Local da lesão – nádegas; membros superiores e inferiores;
- d)** Início da lesão – entre 15 e 45 dias; com: pápula, eritema e/ou edema;
- e)** Progressão da lesão – aumentou a extensão da lesão;

f) Dados epidemiológicos – esteve em contato com qualquer local freqüentado por cães e gatos.

Teremos como dados de entrada:

1. Edema, eritematosa, vesículas, linhas sinuosas; prurido; membro inferior; pápula, há 15 dias; aumentou a extensão da lesão; esteve em contato com qualquer local freqüentado por cães e gatos.

2. Eritematosa, vesícula, linhas sinuosas; prurido; nádegas; pápula, há 30 dias; esteve em contato com qualquer local freqüentado por cães e gatos.

3. Edema, eritematosa, bordas elevadas, linhas sinuosas; prurido; membro inferior; pápula, há 15 dias; aumentou a extensão da lesão; esteve em contato com qualquer local freqüentado por cães e gatos.

4. Eritematosa, bordas elevadas, com secreção, linhas sinuosas; prurido; nádega; pápula, há 40 dias; aumentou a extensão da lesão; esteve em contato com qualquer local freqüentado por cães e gatos.

5. Bordas elevadas, linhas sinuosas; prurido, dor; pápula, há 30 dias; aumentou a extensão da lesão; esteve em contato com qualquer local freqüentado por cães e gatos.

As características *linhas sinuosas*, *prurido*, a informação de que *aumentou a extensão da lesão* e de que o paciente *esteve em contato com qualquer local freqüentado por cães e gatos* são particularidades presentes em todos os quadros clínicos da Larva Migrans Cutânea. As demais podem ou não estar presentes na descrição da doença pelo paciente, reduzindo-se, assim, o número de combinações.

O mesmo ocorre com as outras infecções analisadas, justificando o porquê de não fazer  $2^{83}$  combinações.

As variáveis explicativas são do tipo qualitativas (características, local, início e progressão da lesão; sintomas e dados epidemiológicos) e representam as características descritas pelo paciente.

A codificação “trata” as entradas transformando-as em coordenadas binárias, atribuindo o valor “0” quando o paciente não possui a característica e o valor “1” caso contrário. Tem-se um vetor de entradas com 83 coordenadas binárias, que correspondem aos seis atributos de cada paciente. A matriz de entrada de

dados, disponível no ANEXO, é de ordem 68 x 83, já que foram considerados os dados referentes a 68 pacientes.

A resposta (saída da Rede Neural) é o diagnóstico do paciente. Foram consideradas seis saídas para a RNA: Leishmaniose Cutânea, Impetigo, Cromoblastomicose, Esporotricose, Larva Migrans Cutânea e Herpes Labial, cada uma delas correspondendo a um dos diagnósticos das infecções. A resposta é determinada pelo neurônio vencedor, verificando a qual agrupamento do mapa de saída ele pertence.

## CAPÍTULO III

### 3 REFERENCIAL TEÓRICO

#### 3.1 REDES NEURAIS

Segundo Fausett (1994) uma Rede Neural Artificial é um sistema de processamento de informação com características semelhantes às redes neurais biológicas e seu desenvolvimento consiste na generalização das atribuições da cognição humana ou biologia neural através de modelos matemáticos que levam em consideração as seguintes suposições:

- O processamento da informação ocorre em muitos elementos simples chamados neurônios;
- Os sinais são passados entre neurônios por links de conexão;
- Para cada link de conexão há um peso associado, o qual, em uma rede neural típica, multiplica os sinais transmitidos;
- Cada neurônio aplica uma função de ativação (geralmente não linear) na sua rede de entrada para determinar seu sinal de saída.

Podemos caracterizar uma Rede Neural por Arquitetura (padrão de conexão entre neurônios), Treinamento/Aprendizagem/Algoritmo (método para determinar os pesos das conexões) e função de ativação (função de saída).

Ao escrevermos um programa de computador com o objetivo de nos dar uma resposta diante de um fato, teremos que prever todas as situações possíveis para associá-las as ações pertinentes o que é demasiadamente oneroso, pois, na maioria das vezes, o número de situações é muito grande ou enumerável e, dessa forma, quando acontece uma situação inesperada, o programa tomaria uma atitude inopinada ou não tomaria atitude. Já o cérebro humano tomaria uma atitude perante uma nova situação, ponderando pelo julgamento dos elementos que aprendeu.

O cérebro tem uma grande estrutura e a habilidade de desenvolver suas próprias regras através do que denominamos de experiência. Possui a capacidade de reconhecer padrões e relacioná-los, usar e armazenar conhecimento pela experiência, além de interpretar informações. É um sistema de processamento de informações altamente complexo, não-linear (distribuído por toda a rede neural) em

paralelo, e é capaz de realizar certos processamentos mais rapidamente que qualquer computador (HAYKIN, 2001).

Uma Rede Neural também possui a capacidade reconhecer padrões e relacioná-los, aprender e generalizar, além da capacidade de auto-organização. Desta forma, assim como o cérebro humano, também forneceria uma resposta baseada no que aprendeu. Ela tenta reproduzir as funções das redes biológicas, buscando implementar seu comportamento básico e sua dinâmica, aproximando o processamento dos computadores ao cérebro.

A semelhança entre a Rede Neural e o cérebro se dá basicamente pela forma de aquisição do conhecimento, ambos o fazem através da aprendizagem e pelas forças (pesos) de conexão entre os neurônios utilizados para armazenar conhecimento.

Adiante, segue uma descrição da maneira pela qual o cérebro realiza suas operações e, na seqüência, ao delinear as características das Redes Neurais, traça-se um paralelo entre esta e o cérebro humano.

### 3.2 COMUNICAÇÃO NO CÉREBRO

As células fundamentais do cérebro são os neurônios, o ser humano possui cerca de 86 bilhões deles, os quais processam e se comunicam com vários outros continuamente e em paralelo, ou seja, realizam ininterruptamente transferência simultânea das diversas unidades de um conjunto de informações.

Na concepção de Haykin (2001), os neurônios são de cinco a seis ordens de grandeza mais lentas que as portas lógicas, construídas em silício. Os eventos em um circuito de silício acontecem na ordem de nanossegundos ( $10^{-9}$  s), enquanto que eventos neurais acontecem na ordem de milissegundos ( $10^{-3}$  s). Entretanto, o cérebro compensa a taxa de operação relativamente lenta de um neurônio pelo número realmente espantoso de neurônios, com densas interconexões entre si.

Os neurônios possuem entre 1.000 e 10.000 conexões com neurônios adjacentes, as chamadas sinapses. São divididos em três seções: o corpo da célula, os dendritos e o axônio, conforme ilustra a figura abaixo, cada um com funções específicas, porém complementares.

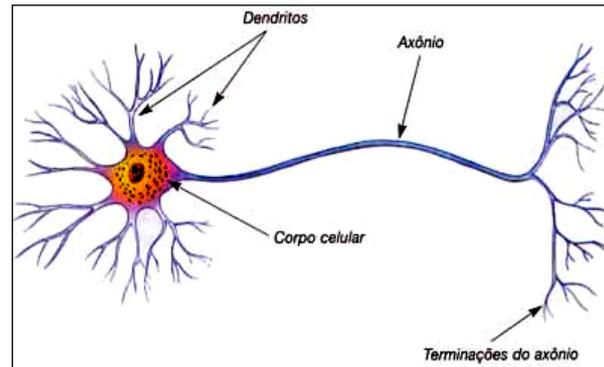


FIGURA 7 - ESQUEMA DE UM NEURÔNIO

FONTE: Soares, 2006

Os axônios (do grego *axoon*, que significa eixo), linhas de transmissão, têm uma superfície mais lisa, menos ramificação e maior comprimento, enquanto os dendritos, zonas receptoras, têm uma superfície irregular e mais ramificações. Os dendritos (do grego *dendron*, que significa árvore) têm por função receber as informações (impulsos nervosos) oriundas de outros neurônios e conduzi-las até o corpo celular. Ali a informação é processada e novos impulsos são gerados e transmitidos a outros neurônios, passando através do axônio até os dendritos do neurônio seguinte. Basicamente, o neurônio capta o estímulo nos dendritos e o transmite pelo axônio para que atinja um neurônio adjacente ou outros tipos de células.

O ponto de contato entre a terminação axônica de um neurônio e o dendrito de outro é chamado de sinapse (do grego *synapsis*, ação de juntar). É ela que medeia a interação entre os neurônios e é pelas sinapses que os neurônios se unem funcionalmente formando as redes neurais. Cada neurônio pode ser estimulado ou inibido por grande quantidade de neurônios, através de suas sinapses. O somatório dos estímulos e inibições determinará se o neurônio transmitirá o impulso ou não.

O exterior do corpo do neurônio é envolto de uma membrana com a capacidade de gerar impulsos nervosos (elétricos). O corpo, por sua vez, combina os sinais recebidos e, se o valor resultante for acima do limiar de excitação do neurônio, um impulso elétrico é produzido e propagado através do axônio para os neurônios seguintes (CARVALHO, 1998).

### 3.3 REDES NEURAIIS ARTIFICIAIS

#### 3.3.1 Introdução

Rede Neural Artificial é uma coleção de neurônios artificiais, unidades de processamento da informação, dispostos de forma a configurar um aspecto específico.

Em nosso cérebro, os neurônios se comunicam continuamente e em paralelo, transferindo informações através de sinapses. Um neurônio recebe informação de outro através dos dendritos e passa-a adiante pelo axônio. As Redes Neurais Artificiais tentam reproduzir estas funções das redes biológicas, buscando programar seu comportamento básico e sua dinâmica (Figura 8). As entradas, apresentadas à rede durante o processo de treinamento, representam os dendritos e as conexões entre os neurônios procuram simular as conexões sinápticas biológicas fazendo uso de uma variável chamada *peso*.

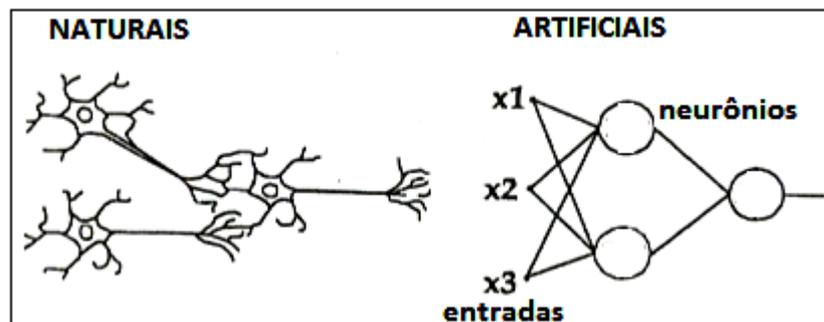


FIGURA 8 - ANALOGIA ENTRE OS NEURÔNIOS NATURAIS E OS NEURÔNIOS ARTIFICIAIS  
 FONTE: Tafner, 1995

Aprender é uma capacidade que a rede possui graças aos seus neurônios e o processo de aprendizagem está associado à alteração dos pesos durante o treinamento da rede, onde os pesos sinápticos, que representam as forças de conexão entre neurônios são responsáveis pelo armazenamento do conhecimento.

Os neurônios de uma RNA possuem, geralmente, uma ou mais entradas e uma saída. Essas entradas podem ser comparadas aos estímulos dos neurônios naturais, e todos esses estímulos são levados as unidades de processamento paralelamente. A Rede Neural extrai seu poder computacional de sua estrutura maciçamente paralelamente distribuída e de sua habilidade de aprender e

generalizar. A generalização se refere ao fato de produzir saídas adequadas para entradas que não estavam presentes durante o treinamento (aprendizagem).

A aprendizagem incide no treinamento da rede apresentando a ela um conjunto de dados (padrões de entrada), denominado conjunto de treinamento. Segundo Tatibana (2009), 50 a 90% do total de padrões devem ser separados para o treinamento da RNA, escolhidos aleatoriamente para que a rede realmente "aprenda" as regras. O restante dos dados só é apresentado à RNA na fase de testes, a fim de averiguar a capacidade de generalização da rede, ou seja, o quanto a rede, de fato, "aprendeu".

Para o desenvolvimento de aplicações usando redes neurais devem-se seguir os seguintes passos:

- coletar dados e separá-los em um conjunto para testes e em um conjunto para treinamento;
- definir a configuração da rede (topologia da rede a ser utilizada, que consiste na determinação do número de camadas e o número de unidades em cada camada, detalhados adiante, e a determinação de parâmetros do algoritmo de treinamento);
- treinar a rede (ajuste dos pesos sinápticos), e
- testar da rede, onde o seu desempenho na última fase é um indicativo do desempenho real da rede.

O processo de aprendizagem ocorre basicamente da seguinte forma: apresenta-se à rede um exemplo escolhido ao acaso do conjunto de treinamento e alteram-se os pesos sinápticos com o intuito de minimizar a diferença entre a resposta desejada daquela fornecida pela rede, de acordo com um critério estatístico apropriado. O treinamento é repetido para todas as entradas do conjunto de treinamento até que a rede alcance um estado onde não haja modificações significativas nos pesos sinápticos. Segundo Haykin (2001), os exemplos de treinamento podem ser reaplicados durante a fase de aprendizagem, mas em uma ordem diferente.

O treinamento deve ser interrompido quando a rede apresentar uma capacidade apropriada de generalização e quando a taxa de erro for suficientemente pequena, ou seja, menor que um erro admissível. Assim, deve-se encontrar um ponto ótimo de parada com erro mínimo e capacidade de generalização máxima.

No treinamento de uma Rede Neural, várias amostras diferentes são apresentadas, o erro é computado e os pesos atualizados. Essas amostras fazem parte do conjunto de treinamento e quando todas forem apresentadas uma vez, o erro calculado e os pesos atualizados (também uma única vez) diz-se que ocorreu uma iteração (ou uma época). Desta forma, podemos dizer que uma iteração pode ser definida como uma única passagem dos dados de entrada e uma atualização dos pesos da rede. Costuma-se usar o número de iterações para minimizar o erro global da RNA.

### 3.3.2 Processo de treinamento

Os pesos, geralmente representados por  $w$  (weight), representam o grau de importância que determinada entrada possui em relação aquele determinado neurônio. Podem ser vistos como um vetor de pesos ( $w_1, w_2, \dots$ ) ou, havendo mais de um neurônio, como uma matriz de pesos. Quando as entradas são apresentadas aos neurônios, são multiplicadas pelos pesos respectivos e a soma desses resultados é o sinal de excitação do neurônio, com o nome específico, segundo Tafner (1996), de *soma ponderada* ou, segundo Carvalho, 1998, de *função soma*. Seja  $n$  o número de entradas do neurônio,  $w_i$  o peso associado à entrada  $x_i$ , temos para a função soma (equação 1):

$$\sum_{i=1}^n x_i w_i \quad (1)$$

Depois que o valor da função soma foi determinado, a função do neurônio é comparar esse valor com um limiar, um valor estipulado  $\theta$ , procedimento conhecido como *função de ativação* (equação 2), e se atingido, o valor é passado adiante através da saída, pelo processo conhecido como *função de transferência*.

$$\sum_{i=1}^n x_i w_i \geq \theta \quad (2)$$

A função de transferência é importante para o comportamento de uma RNA, pois é ela que define a saída do neurônio artificial e, portanto, o caminho pelo qual a informação é conduzida. As funções mais utilizadas são as gaussianas, sigmóides, senoidais, lineares, tangentes hiperbólicas, logarítmicas, degrau, entre outras (MENDES, 2008). Veja na figura abaixo o gráfico dessas funções:

Função	Gráfico	Equação
<b>Degrau</b>		$\begin{cases} \text{se } n \geq 0 \Rightarrow y = 1 \\ \text{senão } y = -1 \end{cases}$
<b>Linear c/ saturação</b>		$\begin{cases} \text{se } n < 0 \Rightarrow y = 0 \\ \text{se } n > 1 \Rightarrow y = 1 \\ \text{se } 0 < n \leq 1 \Rightarrow y = n \end{cases}$
<b>Linear</b>		$y = n$
<b>triangular</b>		$\begin{cases} \text{se } -1 \leq n \leq 1 \Rightarrow y = 1 - \text{abs}(n) \\ \text{senão } y = 0 \end{cases}$
<b>Tangente hiperbólica</b>		$y = \frac{2}{(1 + e^{-2n})} - 1$
<b>Logarítmica</b>		$y = \frac{1}{(1 + e^{-n})}$
<b>Base radial</b>		$y = e^{-n}$

FIGURA 9 - FUNÇÕES DE ATIVAÇÃO  
 FONTE: Lima, 2006

Na seqüência do funcionamento de uma RNA o ajuste sináptico é realizado. Este procedimento consiste no aprendizado em cada neurônio do fato apresentado que, conjuntamente com todos os outros, representa a informação que passou pela rede. Nenhum neurônio guarda em si todo o conhecimento, mas faz parte de uma malha que retém a informação graças a todos os seus neurônios (TAFNER, 1996).

O ajuste sináptico é resultado de um cálculo matemático que visa somar ao peso atual um valor que corresponde à quantidade de erro gerado pela rede, e desta forma corrigir o valor do peso, com objetivo de produzir a saída desejada diante da respectiva entrada. Segundo Tafner (1996), existem vários cálculos para este fim,

mas o mais comum é chamado de “Regra Delta”, onde o valor do novo peso é determinado pela seguinte equação:

$$w_i(n+1) = w_i(n) + c * \delta * x_i \quad (3)$$

onde:  $w_i(n+1)$  = o novo valor do peso

$w_i(n)$  = o valor velho do peso

$c$  = constante de aprendizado

$\delta$  = saída obtida

$x_i$  = entrada

### 3.3.3 Arquitetura de uma rede neural artificial

A maneira pela qual os neurônios de uma RNA estão estruturados, sua arquitetura, está diretamente relacionada ao algoritmo de aprendizagem usado para treinar a rede. Uma rede neural organizada em camadas é dita rede neural em camadas. Essas camadas referem-se às entradas apresentadas a rede (camada de entrada), as saídas fornecidas pela rede (camada de saída) e, em alguns casos, há as camadas ocultas, que possuem neurônios ocultos com a função de intervir entre a camada de entrada e a de saída. Adiciona-se uma ou mais camadas ocultas para tornar a rede capaz de extrair estatísticas de ordem elevada embora um número grande de camadas ocultas não signifique deixar o algoritmo mais eficiente. Quando uma rede possui todos os neurônios de uma camada conectados a todos os neurônios da camada adjacente seguinte, a rede é dita totalmente conectada.

Em geral podem-se identificar três classes diferentes de arquitetura de rede neural: redes alimentadas adiante com camada única, redes alimentadas adiante com múltiplas camadas e redes recorrentes.

- *Redes alimentadas adiante com camada única*: Na sua forma mais simples, possuem a camada de entrada que se projeta na camada de saída, mas não o contrário (Figura 10). Ela é estritamente alimentada adiante ou acíclica e com camada única, ou seja, possui apenas a camada de saída,

que contem os neurônios de computação. A camada de entrada não é contada, pois nela não é realizada qualquer computação.

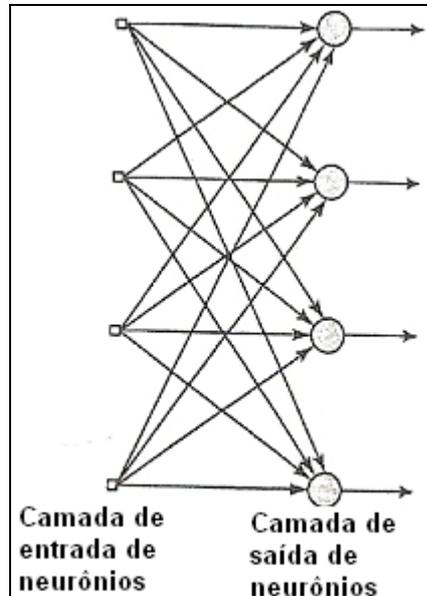


FIGURA 10 - REDE ALIMENTADA ADIANTE COM UMA ÚNICA CAMADA  
 FONTE: Haykin, 2001

- *Redes alimentadas adiante com múltiplas camadas:* Se distinguem da classe anterior pela presença de camadas ocultas, que podem variar de zero a  $n$  camadas (Figura 11). Os neurônios da camada de entrada fornecem informações para a 1ª camada oculta. Esta computa as informações e as saídas servem como entrada para a 2ª camada oculta e assim sucessivamente para o restante da rede. O conjunto das saídas da última camada (camada de saída) constitui a resposta global da rede para o padrão fornecido.

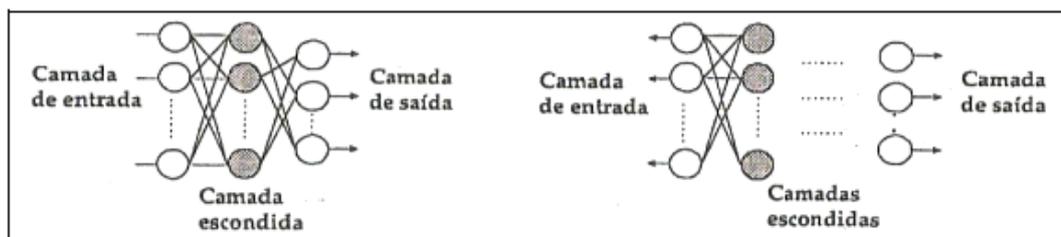


FIGURA 11 - REDES ALIMENTADAS ADIANTE COM MÚLTIPLAS CAMADAS  
 FONTE: Tafner, 1995

- *Redes recorrentes*: Diferente das outras, possui pelo menos um laço de realimentação, ou seja, o sinal de saída de um neurônio serve como entrada para a mesma camada, uma camada anterior ou entre camadas alternadas (Figura 12). Essa conexão (realimentação) pode ser realizada tanto para frente quanto para trás.

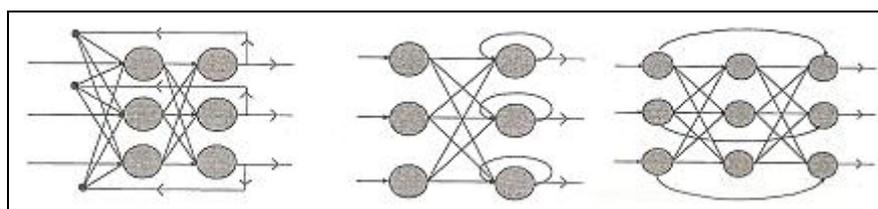


FIGURA 12 - REDES RECORRENTES  
 FONTE: Tafner, 1995

### 3.3.4 Formas de aprendizagem

A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros, os pesos das conexões entre as unidades de processamento, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando. Pode advir de forma supervisionada, não-supervisionada ou competitiva.

Na aprendizagem supervisionada são fornecidas à rede, por um supervisor externo, a entrada e a saída desejada. A cada entrada, é comparada a saída obtida pela rede com a saída esperada. Se forem diferentes, são feitos ajustes sinápticos buscando minimizar o erro (diferença entre resposta da rede e saída desejada). A resposta desejada é o valor ótimo que a rede deveria apresentar para aquele valor de treinamento. O empecilho deste tipo de aprendizado de rede é que na ausência do supervisor a rede fica impedida de dar continuidade ao seu processo de aprendizagem com novos modelos, se limitando às situações já conhecidas pela rede (SEWO, 2003).

Na aprendizagem não-supervisionada, não há supervisor para acompanhar o processo de aprendizagem, pois não requer o conhecimento da saída desejada. Durante o treinamento, somente padrões de entrada são fornecidas a RNA até que a rede se torne “sincronizada” às regularidades estatísticas dos dados de entrada. A partir desta condição, a rede desenvolve a habilidade de formar representações

internas para codificar características de entrada e, por meio disto, agrupar os padrões de entrada em grupos com características similares ou criar novos grupos automaticamente.

Na aprendizagem competitiva, os neurônios de saída competem entre si para se ativarem em um determinado instante, sendo que, somente um poderá ser o vencedor. A principal função de uma RNA com aprendizado competitivo é prover um classificador simples de padrões com treinamento não-supervisionado, sendo aconselhável um conjunto de treinamento com padrões suficientemente distintos (SEWO, 2003).

A escolha de um determinado algoritmo de aprendizagem está intimamente relacionada com a tarefa que a rede deverá realizar. O tipo de conexão, o número de camadas de neurônios e o tipo de treinamento são os aspectos que diferem os tipos (arquiteturas) de redes neurais. Existem dezenas de modelos de redes neurais, sendo que os mais conhecidos são: o Perceptron, o Backpropagation, Adaline, Kohonen, Boltzman entre outros.

O objeto deste estudo foi a utilização de uma Rede Neural competitiva e não supervisionada, para classificar e realizar agrupamentos dos sintomas das doenças infecciosas: Leishmaniose Cutânea, Esporotricose, Larva Migrans Cutânea, Cromoblastomicose, Impetigo e Herpes Labial. A Rede de Kohonen apresenta um algoritmo de agrupamento de dados e realiza uma projeção não-linear dos dados multivariados num espaço bidimensional, sendo indicada para solucionar o problema proposto.

### 3.4 REDE DE KOHONEN

#### 3.4.1 Introdução

A rede de Kohonen, também conhecida como rede SOM (Self-Organizing Map) ou rede de mapas auto-organizáveis, foi desenvolvida pelo finlandês Teuvo Kohonen na década de 80. Seu algoritmo parte da auto-organização, processo semelhante ao que ocorre com o cérebro.

O cérebro humano possui áreas responsáveis por funções específicas, como ouvir, ver, falar. Dentro dessas áreas, os neurônios estão topologicamente organizados, onde os neurônios próximos tendem a responder a padrões ou estímulos semelhantes. De maneira análoga, quando uma entrada (estímulo) é apresentada à rede SOM, ela procura a unidade mais parecida com a entrada. Ela constrói um mapa topológico semelhante a padrões de entrada semelhantes, assim como no córtex cerebral, onde neurônios ativos apresentam conexões mais fortes com neurônios que estão fisicamente mais próximos.

A rede de Kohonen tem a propriedade de modificar a si própria, é do tipo feed-forward (alimentada adiante com camada única), transforma conjuntos de sinais de entrada em conjuntos de sinais de saída, com aprendizado competitivo e não supervisionado. Freitas (2003) afirma que os mapas auto-organizáveis diferem dos modelos habituais de RNA, principalmente, pelo fato de possuírem apenas duas camadas: a de entrada e a de saída.

O esquema básico de um modelo de Kohonen faz com que neurônios da camada de saída disputem entre si a representação da informação apresentada aos neurônios de entrada. Serão considerados “vencedores” os neurônios que mais se assemelharem ao padrão de entrada, ou seja, o neurônio que possui os valores dos pesos mais parecidos com os pesos da entrada apresentada, sendo que para esta comparação são utilizadas medidas de distâncias (normalmente utiliza-se a distância Euclidiana). Definido o neurônio vencedor, este é reajustado para responder ainda melhor ao estímulo recebido. Dentro deste modelo não supervisionado, não somente os pesos do vencedor, mas também dos seus vizinhos (dentro de um senso físico) são ajustados e desta forma responderão melhor do que antes a entrada apresentada.

Os neurônios em uma rede de Kohonen são colocados nos nós de uma grade (que apresenta uma topologia particular, que pode ser retangular, hexagonal etc.), que é usualmente de uma ou duas dimensões. Mapas de dimensões maiores são também possíveis, porém de aplicação e compreensão mais difíceis. É apresentado um exemplo na Figura 13 abaixo:

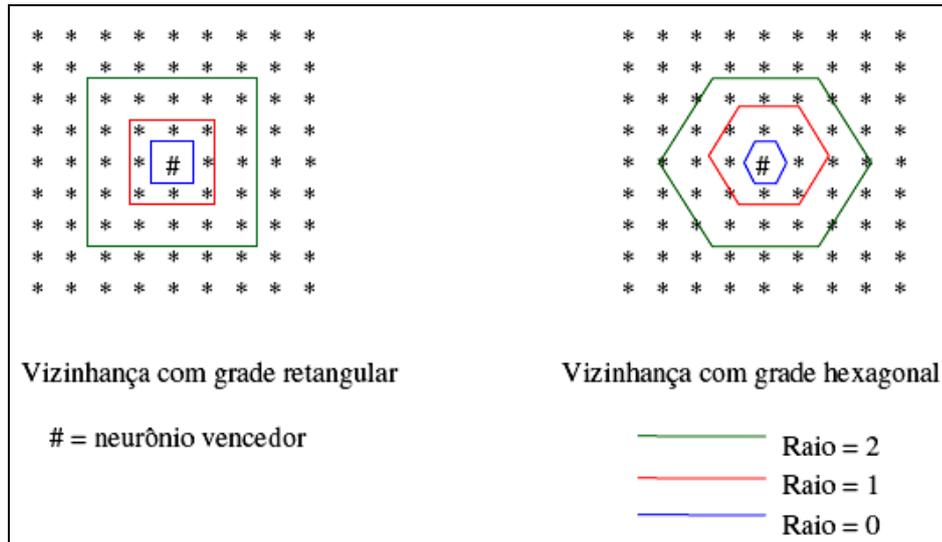


FIGURA 13 – PARÂMETROS TOPOLÓGICOS DE VIZINHANÇA E RAIOS TOPOLÓGICOS  
 FONTE: Francisco, 2004

Kohonen enfatiza a importância de se levar em consideração, nos modelos de redes neurais, a disposição física dos neurônios e as relações entre vizinhanças dos neurônios no processamento da informação do sistema nervoso (KOHONEN, 1995).

Cada neurônio representa uma saída e está amplamente conectado com as entradas onde cada conexão sináptica representa um peso sináptico. Depois de muitos fatos terem sido apresentados à rede, os pesos especificam grupos ou centros que respondem de forma similar.

### 3.4.2 Procedimento para formação do mapa auto-organizável

A disputa entre os neurônios da camada de saída para ser o vencedor é conhecido como processo competitivo. Os neurônios competem entre si para verificar qual possui os pesos sinápticos mais parecidos com aqueles da entrada apresentada à rede. Geralmente usa-se a distância Euclidiana (KOHONEN, 1995; HAYKIN, 2001) para determinar o neurônio vencedor, conforme equação 4:

$$d_j(t) = \sum_{j=1}^n (x_j(t) - w_{ij}(t))^2 \quad (4)$$

onde  $d_j$  é a distância do neurônio  $j$   
 $n$  é o número de entradas  
 $x_j(t)$  é a entrada  $j$  no tempo  $t$   
 $w_{ij}(t)$  é o peso  $j$  do neurônio  $i$  no tempo  $t$ .

Outra forma de avaliar a semelhança entre o padrão de entrada e o neurônio vencedor é o produto interno dos vetores de entrada e peso normalizados, que pode ser interpretado como a correlação entre o vetor de entrada e o vetor peso (FRANCISCO, 2004).

Determinado o neurônio vencedor, inicia-se o processo de ajuste dos pesos sinápticos do neurônio e dos seus vizinhos. Conforme observações de Kohonen, os ajustes de pesos devem ser realizados, não somente no neurônio vencedor, mas também, sobre toda sua vizinhança e a melhor auto-organização ocorre quando o conjunto de vizinhos começa extenso e diminui com o tempo. Segundo Tafner (1996), esse ajuste é uma espécie de estímulo aos neurônios que ficam em torno do vencedor para que possam vir a ter as mesmas condições de disputa com o neurônio vencedor e, dessa forma, responder também à entrada apresentada à rede em uma determinada iteração. Ainda segundo o autor, se a vizinhança começar muito pequena em relação ao mapa, este não se organizará globalmente.

Um neurônio classificado como vencedor tende a excitar mais os neurônios em sua vizinhança imediata, do que aqueles neurônios que estão mais distantes. Assim, pode-se afirmar que o ajuste sináptico dos neurônios pertencentes à vizinhança topológica ao redor do neurônio vencedor  $i$  decai suavemente com a distância lateral (distância entre o neurônio vencedor e os neurônios topologicamente próximos ao neurônio vencedor no mapa).

Dado o vetor de pesos sinápticos  $w_j(t)$  do neurônio  $j$  no tempo  $t$ , o vetor de peso atualizado  $w_j(t+1)$  no tempo  $t+1$  é definido por (KOHONEN, 1995):

$$w_j(t+1) = w_j(t) + \alpha(t)\Lambda_{ji}(t)(x(t) - w_j(t)) \quad (5)$$

onde  $\Lambda_{ji}(t)$  é a função de vizinhança centrada no neurônio vencedor no tempo  $t$

$x(t)$  é o vetor de entrada no tempo  $t$

$\alpha(t)$  é a taxa de aprendizagem no tempo  $t$ .

Esta equação é aplicada a todos os neurônios da grade que se encontram dentro da vizinhança do neurônio vencedor  $i$ . Para trabalhar com a rede de Kohonen sem efetuar a alteração sináptica nos vizinhos dos neurônios vencedores, basta retirar a função de vizinhança da equação 5, ou seja, tomá-la com valor unitário.

Geralmente usa-se a função Gaussiana para determinar a função de vizinhança, pois ela é independente da posição do neurônio vencedor, alcança seu valor máximo no neurônio vencedor para o qual a distância é zero e a amplitude da vizinhança topológica decresce monotonamente com o aumento da distância lateral decaindo para zero. O uso da função Gaussiana, segundo Haykin (2001) faz com que o algoritmo SOM convirja mais rapidamente. Abaixo segue a equação da função Gaussiana:

$$\Lambda_{ji}(t) = e^{-\frac{d_{ji}^2}{2R^2(t)}} \quad (6)$$

onde  $\Lambda_{ji}(t)$  representa a vizinhança topológica centrada no neurônio vencedor  $i$  e que contém um conjunto de neurônios excitados no tempo  $t$ , sendo um neurônio típico deste conjunto representado por  $j$ , e  $R(t)$  é a “largura efetiva” (raio) da vizinhança topológica, que decresce com a iteração;  $d_{ji}$  representa a distância do neurônio  $j$  ao neurônio vencedor  $i$ , onde usa-se a distância Euclidiana quadrada para calculá-la, pois esta tem a vantagem de não tomar a raiz quadrada, o que aumenta sensivelmente a velocidade computacional (NOLETO, 2007).

Com  $t$  iterações, a função de vizinhança decresce, em geral, com um raio ( $R$ ) definido pela equação exponencial:

$$R(t) = R_0 \cdot e^{-\frac{t}{T_1}} \quad (7)$$

onde  $R_0$  é o valor de  $R$  na inicialização do algoritmo e  $T_1$  é uma constante de tempo definida na equação 8 (HAYKIN, 2001).

$$T_1 = \frac{1000}{\log R_0} \quad (8)$$

Há também outras equações para atualizar o raio, como a equação linear descrita abaixo, porém a mais utilizada é a equação exponencial, que juntamente com a função de vizinhança, são adequadas para a formação do mapa de características de uma forma auto-organizável (HAYKIN, 2001).

$$R(t) = R_0 \left( 1 - \frac{t}{R_0} \right) \quad (9)$$

A técnica de começar com uma vizinhança grande, que é reduzida modificando-se a variância da curva de Gauss têm o seguinte efeito: primeiramente a rede aprende de maneira geral a organizar padrões similares em grupos localizados em regiões específicas da rede, depois a rede passa a refinar este mapeamento de maneira cada vez mais localizada (WANGEHEIM, 2005).

O parâmetro da taxa de aprendizagem deve ser variável no tempo. Deve começar em um valor inicial  $\alpha_0$  e então decrescer gradualmente com o aumento do tempo  $t$ . Esta exigência pode ser satisfeita escolhendo-se um decaimento exponencial para  $\alpha(t)$ , como mostrado por:

$$\alpha(t) = \alpha_0 e^{-\frac{t}{T}} \quad (10)$$

onde  $\alpha_0$  é a taxa de aprendizagem inicial e  $T$  é uma aproximação do número de iterações, como na equação que atualiza o raio de vizinhança.

O treinamento da rede SOM é afetado pela taxa de aprendizagem e pela taxa de redução da região de vizinhança. É dividido em duas fases:

#### 1. Ordenação:

Segundo Haykin (2001), a fase de ordenação pode exigir 1000 iterações do algoritmo SOM. Busca agrupar os neurônios do mapa topológico em agrupamentos, de modo a refletir a distribuição dos padrões de entrada. A rede descobre quantos grupos ela deve identificar e suas posições relativas no mapa. A taxa de aprendizado é alta no início, aproximadamente ou igual a um, e

reduzida gradualmente até um valor próximo de 0,01. A função de vizinhança deve inicialmente incluir quase todos os neurônios da grade, centrados no neurônio vencedor e diminuir lentamente com o tempo, restando apenas um par de neurônios vizinhos em torno do vencedor ou restando apenas o neurônio vencedor. Kohonen (1995) afirma que o raio pode iniciar equivalente a metade do diâmetro da rede. Nesta fase ocorre grande mudança nos pesos.

## 2. Convergência:

Requer de 100 a 1000 vezes mais iterações que a fase anterior. Segundo Haykin (2001), o número de iterações deve ser no mínimo 500 vezes o número de neurônios na grade. Essa fase sofisticou o mapeamento realizado na fase de ordenação, aprimorando o agrupamento realizado. A taxa de aprendizagem deve ser mantida em um valor pequeno, da ordem de 0,01, mas não chegando a zero para que a rede não fique em um estado metaestável (configuração do mapa de características com um defeito topológico). A função de vizinhança deve permanecer apenas com os vizinhos mais próximos de um neurônio vencedor, que pode eventualmente se reduzir a um ou a zero neurônio vizinho.

Pode-se ainda melhorar o desempenho da rede tomando os seguintes cuidados (CARVALHO, 1998):

- a) Normalizar os vetores de pesos, pois a utilização de vetores de pesos com magnitudes diferentes prejudica a competição entre os neurônios, desviando a atenção da rede para a magnitude ao invés da orientação dos vetores de peso;
- b) Inicializar todos os pesos com o mesmo valor, para garantir a atualização do maior número possível de neurônios. Os padrões de treinamento seriam, no início, tornados semelhantes entre si;
- c) Reduzir a vizinhança dos neurônios durante o treinamento;
- d) Utilizar a técnica conhecida como *consciência*, onde se utiliza um limiar para cada nó. Neurônios que fossem selecionados nas competições teriam seu limiar aumentado e assim reduziria a chance de ser selecionado novamente, permitindo a utilização de outros neurônios.

Segundo Kohonen, a rede SOM não foi criada para reconhecimento de padrões, mas para agrupamento, visualização e abstração. Ainda assim, as redes SOM podem ser utilizadas para o reconhecimento ou classificação de padrões.

Neste caso, aconselha-se que a rede seja utilizada junto com um modelo de aprendizado supervisionado. Pode ser utilizada na saída, por exemplo, uma rede Adaline ou Perceptron Múltiplas Camadas. Esta rede receberia como entrada a saída gerada pela rede SOM. Outra possibilidade, mais comum, é a utilização da técnica de aprendizado de quantização de vetor LVQ – Learning Vector Quantization (KOHONEN, 1989 apud CARVALHO, 1998).

### 3.4.3 Métricas de precisão e preservação da topologia

Segundo Heaton (2005), não há um método oficial para o cálculo de erro para a rede neural de Kohonen. O erro é um percentual que mede quão bem a rede neural está classificando dados de entrada nos grupos de saída. O erro não é usado para modificar os pesos.

Com o intuito de gerar uma configuração estável e organizada do mapa de saída, deve-se realizar uma seleção criteriosa dos parâmetros taxa de aprendizagem e largura da vizinhança topológica. Devido à ausência de uma fundamentação teórica sólida do algoritmo de Kohonen, na literatura há algumas heurísticas que auxiliam nesta escolha, entretanto, geralmente restritas a um domínio específico de aplicação. De forma geral, três métricas principais são empregadas na avaliação da precisão do mapeamento e da preservação topológica.

A primeira medida tem o propósito de avaliar a precisão do mapeamento através do *erro de quantização* (EQ), que corresponde à média da distância Euclidiana entre cada vetor do conjunto de dados e seu neurônio vencedor, ou seja, a resolução do mapa, dado por (KOHONEN, 2001):

$$EQ = \frac{1}{n} \sum_{k=1}^n \|x_k - w^*\| \quad (11)$$

onde  $n$  é a quantidade de padrões de entrada e  $w^*$  é o vetor peso do neurônio vencedor para o padrão  $x_k$ .

A segunda medida, o *erro médio quadrático* (EMQ), foi proposto por Gauss, que o definiu como a raiz quadrada da média dos quadrados dos erros verdadeiros. Como os erros verdadeiros são desconhecidos, o erro médio quadrático pode ser

expresso em função dos resíduos relativos à média. É calculado da seguinte forma (LEE; VERLEYSSEN, 2002):

$$EMQ = \frac{1}{n} \sum_{k=1}^n \|x_k - w^*\|^2 \quad (12)$$

A terceira medida tem a finalidade de quantificar a capacidade do mapa em representar o arranjo geométrico do espaço de entrada. O valor do *erro topológico* (ET) representa o percentual de neurônios vencedores que não possuem o segundo vencedor em uma vizinhança de raio unitário centrada no neurônio vencedor (equação 13). Este erro mede quanto o mapa aproxima os padrões de entrada com vetores peso próximos.

$$ET = \frac{1}{n} \sum_{k=1}^n u_k \quad (13)$$

onde

$$u_k = \begin{cases} 1, i^{**} \notin V_{i^*} \\ 0, i^{**} \in V_{i^*} \end{cases}$$

onde  $i^{**}$  é o segundo neurônio vencedor para o padrão  $k$ , e  $V_{i^*}$  é o conjunto de neurônios vizinhos imediatos do vencedor  $i^*$ .

Todos os erros são inversamente proporcionais ao número de neurônios da rede, ou seja, diminuem com o aumento de neurônios. No entanto, quando existe um número elevado de neurônios pode ocorrer um fenômeno chamado sobre-ajuste (*overfitting*), tal que a rede perde sua capacidade de generalização. Por outro lado, quando há um número reduzido de neurônios, pode acontecer o fenômeno inverso denominado sub-ajuste (*underfitting*), tal que a rede se torna rígida demais para lidar com variados padrões de entrada (BASTOS, 2007).

### 3.4.4 Representação gráfica de mapas auto-organizáveis de Kohonen

Uma vez concluído o processo de aprendizagem da rede, o mapa discreto de saída apresenta características importantes do espaço de entrada. De acordo com Haykin (2001), podem-se enumerar as seguintes propriedades do mapa de características resultantes da aplicação do algoritmo de Kohonen:

1. *Aproximação do espaço de entrada:* O mapa de características, representado pelo conjunto de vetores de pesos sinápticos no espaço de saída, fornece uma boa aproximação para o espaço de entrada. Cada neurônio da grade é responsável por uma região do espaço de entrada. Todos os padrões de treinamento que ativam determinado neurônio compõem um grupo ou uma categoria.
2. *Ordenação Topológica:* O mapeamento é ordenado de forma topológica, no sentido de que a localização espacial de um neurônio na grade corresponde a uma característica particular dos padrões de entrada.
3. *Casamento de densidade:* O mapa de características reflete variações na estatística da distribuição de entrada: regiões do espaço de entrada de onde vetores de amostra são retirados com uma alta probabilidade de ocorrência são mapeados para domínios maiores do espaço de saída e, portanto com melhor resolução que regiões das quais vetores de amostra são retirados com uma baixa probabilidade de ocorrência.
4. *Seleção de características:* A partir de dados do espaço de entrada com uma distribuição não-linear, o mapa auto-organizável é capaz de selecionar um conjunto das melhores características para aproximar a distribuição subjacente. (HAYKIN, p. 495, 2001)

Uma vez obtido o mapeamento pela rede de Kohonen, pretende-se visualizar os agrupamentos eventualmente formados pelos neurônios após o processo de auto-organização. Esses agrupamentos são resultantes da atualização dos pesos na direção dos neurônios vencedores formando assim, agrupamentos de neurônios com características semelhantes. A tarefa de interpretação dos resultados é a mais difícil, em função das variadas formas de análise disponível.

### 3.4.4.1 U-matriz

A técnica mais utilizada para visualização de mapas Auto-Organizáveis é denominada U-matriz (matriz de distância unificada), criada por Ultsch nos anos 80. Essa técnica é utilizada na visualização do mapa para posterior separação manual dos agrupamentos, a idéia básica é utilizar a mesma métrica que foi usada durante o treinamento para calcular distâncias entre pesos sinápticos de neurônios adjacentes do mapa.

Dado um mapa de tamanho  $L \times C$ , a U-matriz é representada pela imagem desse mapa em outro mapa de dimensão  $(2L - 1) \times (2C - 1)$  onde o nível de intensidade de cada pixel corresponde a uma distância calculada. São representados os neurônios do mapa, além das distâncias intermediárias entre os neurônios do mapa original através de cores, de acordo com os coeficientes do vetor peso de cada neurônio (ULTSCH, 2003). Valores altos correspondem a neurônios vizinhos dissimilares e valores baixos correspondem a neurônios vizinhos similares.

Segundo Noletto (2007), dado um mapa bidimensional retangular encontra-se a U-matriz calculando-se as distâncias  $dx$ ,  $dy$ ,  $du$  e  $dz$  (vide Figura 14), para cada neurônio. O valor  $du$  da U-matriz é calculado em função dos valores dos elementos circunvizinhos do neurônio relativo ao  $du$ , pode ser a média, mediana, valor máximo ou mínimo destes valores.

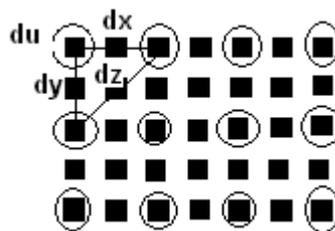


FIGURA 14 - REPRESENTAÇÃO DOS COMPONENTES  $dx$ ,  $dy$ ,  $dz$  E  $du$  DA U-MATRIZ PARA UMA REDE 3X4 RETANGULAR. OS CÍRCULOS REPRESENTAM OS NEURÔNIOS E OS QUADRADOS REPRESENTAM OS NEURÔNIOS INTERMEDIÁRIOS

FONTE: O autor (2012)

Considerando distâncias Euclidianas, no caso da topologia da grade de neurônios ser retangular, e considerando  $[b_{xy}]$  a matriz de neurônios e  $[w_{i,x,y}]$  a matriz de pesos, as distâncias  $dx$ ,  $dy$  e  $dz$  podem ser definidas como:

$$dx(x, y) = \|b_{x,y} - b_{x+1,y}\| = \sqrt{\sum_i (w_{i,x,y} - w_{i,x+1,y})^2} \quad (14)$$

$$dy(x, y) = \|b_{x,y} - b_{x,y+1}\| = \sqrt{\sum_i (w_{i,x,y} - w_{i,x,y+1})^2} \quad (15)$$

$$dz(x, y) = \frac{1}{2} \left( \frac{\|b_{x,y} - b_{x+1,y+1}\|}{\sqrt{2}} + \frac{\|b_{x,y+1} - b_{x+1,y}\|}{\sqrt{2}} \right) = \frac{1}{2\sqrt{2}} \times \left[ \sqrt{\sum_i (w_{i,x,y} - w_{i,x+1,y+1})^2} + \sqrt{\sum_i (w_{i,x,y+1} - w_{i,x+1,y})^2} \right] \quad (16)$$

Segundo Silva (2004), para mapas pequenos a U-matriz gerada tende a ser pouco compreensível e de difícil identificação visual dos agrupamentos, e ainda afirma que a U-matriz só pode ser gerada a partir de mapas com grade bi-dimensional. Para mapas com dimensões de grade maior que dois o processo de visualização da matriz de distância torna-se complexo.

#### 3.4.4.2 U-altura

A U-matriz também pode ser representada pela medida de distanciamento para cada neurônio, denominada U-altura (equação 17), que apresenta valores altos para neurônios que se distanciam muito dos vizinhos imediatos, ou valores baixos para neurônios com vizinhos próximos que contem vetores peso similares (ULTSCH, 2003).

$$U - altura(i) = \sum_{j \in V_i} \|w_i - w_j\| \quad (17)$$

O termo  $V_i$  identifica o conjunto dos neurônios vizinhos ao neurônio  $i$ .

A imagem de um mapa  $b \times q$  é um mapa de mesma dimensão, com a atribuição de cores em escalas de cinza, com as tonalidades calculadas através da U-altura de cada neurônio. Os agrupamentos são separados pelas tonalidades mais

escuras de cinza. Em mapas com um número reduzido de neurônios torna-se difícil a visualização dos agrupamentos, conforme se pode observar na Figura 15.

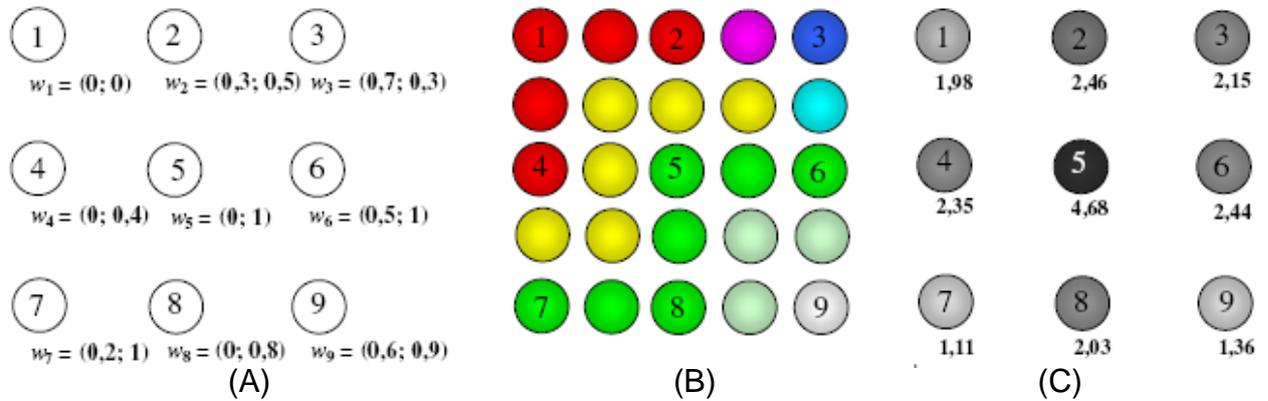


FIGURA 15 - EXEMPLO DE REPRESENTAÇÃO DE AGRUPAMENTOS DE MAPAS AUTO-ORGANIZÁVEIS ATRAVÉS: (B) DA U-MATRIZ COLORIDA E (C) EM ESCALA DE CINZA

FONTE: Siqueira, 2005

#### 3.4.4.3 Grafos

Costa (2003) propõem um método para segmentação do mapa baseado no particionamento de grafos. Neste caso, o algoritmo é independente da U-matriz e da dimensão da grade da rede SOM. O algoritmo proposto baseia-se em informações geométricas de distância entre os neurônios, no erro de quantização e no nível de atividade do neurônio. A estratégia é considerar que todos os neurônios fazem parte de um grafo não orientado, totalmente conectado e, a partir de regras heurísticas, eliminar conexões inconsistentes entre neurônios vizinhos, restando grupos conectados, representando agrupamentos distintos (vide Figura 16).

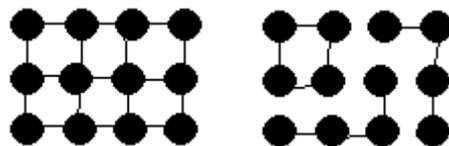


FIGURA 16 - REDE 3X4 PARTICIONADA DE FORMA QUE 3 GRUPOS FORAM CONSTITUÍDOS  
FONTE: O autor (2012)

Para um mapa auto-organizado, tem-se o algoritmo de Costa como segue:

Os parâmetros do algoritmo são:

Ativação média:

$H_{media} = \text{tamanho do conjunto de dados} / \text{número total de neurônios}$

Ativação mínima:

$H_{min} = \sigma * H_{media}$ , onde  $\sigma$  é um valor entre 0,1 e 0,6.

- 1) Dado um mapa treinado, obtenha as distâncias entre os pesos dos neurônios adjacentes  $i$  e  $j$ ,  $d(w_i, w_j)$  e o número de padrões associados a cada neurônio  $i$ ,  $H(i)$ .
- 2) Para cada par de neurônios adjacentes  $i$  e  $j$ , a aresta  $(i,j)$  é considerada inconsistente caso ocorra as condições:
  - i) Se a distância entre os pesos excede em 2 vezes a distância média dos outros neurônios adjacentes a  $i$  ou a  $j$ ;
  - ii) Se os dois neurônios adjacentes  $i$  e  $j$  possuem atividade  $H$  abaixo de 50% da mínima permitida,  $H_{min}$ , ou um dos neurônios for inativo,  $H(i) = 0$ ;
  - iii) Se a distância entre os centróides dos conjuntos de dados associados aos neurônios  $i$  e  $j$  exceder em 2 vezes a distância entre os pesos  $d(w_i, w_j)$ , isto é:
 
$$\text{Se } d(w_i, w_j) > 2 * d(c_i, c_j) \rightarrow \text{ramo } (i, j) \text{ é inconsistente}$$
- 3) Remoção dos ramos (arestas) inconsistentes. Para cada aresta  $(i,j)$  considerada inconsistente resultará em conexão nula no endereço  $(i,j)$  da matriz de adjacência.
- 4) Executar um algoritmo de detecção do número de componentes conexas no grafo podado.
- 5) Remover componentes conexas com menos de 3 neurônios. O número de componentes conexas restantes representa o número de agrupamentos em que foi dividido o conjunto de dados. Os neurônios que compõem cada componente conexa são representantes dos dados do espaço de entrada. Desta forma, obtemos os registros que compõem cada agrupamento. (COSTA, 2003, p. 453).

O algoritmo faz uso de alguns limiares empíricos definidos por meio de experimentações, porém, consegue particionar os dados usando somente as informações inerentes ao mapa treinado, como a distância entre os neurônios, o erro de quantização e o nível de atividade.

#### 3.4.4.4 Densidade

Outra técnica para a visualização do mapa treinado de Kohonen baseia-se na densidade dos neurônios (ZHANG E LI, 1993). Para cada neurônio do mapa, calcula-se o número de padrões associado ao mesmo, criando-se um mapa de

densidade. Os agrupamentos são determinados usando-se os neurônios com densidade nula (ou com número reduzido de padrões associados) como fronteiras (vide Figura 17).

Após a determinação das fronteiras, cada agrupamento possui um neurônio mais representativo, isto é, com o maior número de padrões associado, denominado centróide do agrupamento.

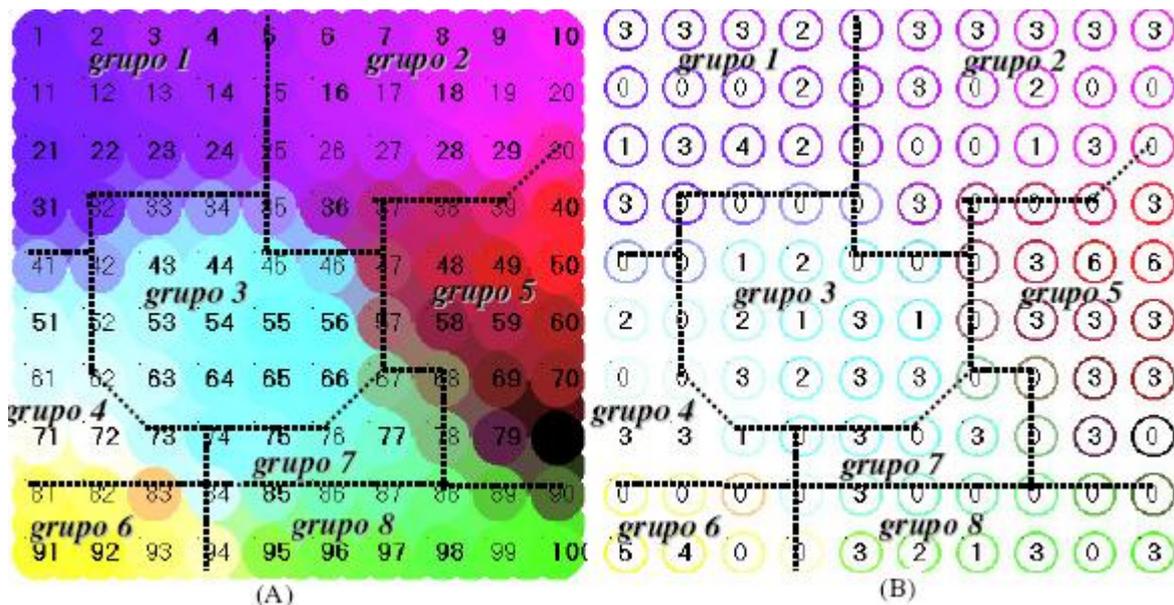


FIGURA 17 - (A) REPRESENTAÇÃO DA U-MATRIZ E (B) DO MAPA DE DENSIDADE  
 FONTE: Siqueira, 2005

A descrição de um algoritmo para a criação de agrupamentos através do mapa de densidade é descrito no trabalho de Siqueira (p. 53, 2005). Segue abaixo:

- 1) Encontre a densidade de cada neurônio do mapa  $M$ . O conjunto de neurônios com densidade não nula forma um conjunto  $P$ , com cardinalidade  $n_P$ . Classifique estes neurônios em ordem crescente, através da densidade dos mesmos. Vá ao Passo 2.
- 2) Determine a distância entre cada par de neurônios  $i$  e  $j$  do conjunto  $P$ :
 
$$\text{dist}(i, j) = \|w(i) - w(j)\|$$
 Se  $\text{dist}(i, j) > E$  (onde  $E$  representa um erro usado para determinar a tolerância de distância entre as características de neurônios do mesmo agrupamento), então  $i$  e  $j$  são considerados membros de agrupamentos distintos. Repita este passo até concluir a comparação entre os elementos do conjunto  $P$ . Vá ao Passo 3.
- 3) O número de agrupamentos encontrados é  $n_A$ . Para cada agrupamento  $A$ , o neurônio com maior densidade é considerado centróide do agrupamento. Pare. (SIQUEIRA, p. 53, 2005).

#### 3.4.4.5 Normalização tipo *min-max*

Gorricha (2009) propõe uma técnica de visualização baseada na normalização do tipo *min-max*: a cada unidade da rede atribui-se uma cor resultante da normalização do tipo *min-max* das coordenadas da rede para valores dentro do intervalo do espectro considerado, que se situa tipicamente entre 0 e 255. O processo de visualização pode ser formalmente descrito da seguinte forma:

1. Efetuar a normalização *min-max* das coordenadas originais do espaço de output do SOM para valores compreendidos entre 0 e 255 (RGB);
2. Colorir a área geográfica correspondente a cada elemento georreferenciado com a cor da sua BMU (Best Match Unit) (GORRICHIA, p. 5, 2009).

Após o término do processo é possível verificar os agrupamentos formados pela disposição das cores no mapa. Neurônios com características similares recebem cores similares, onde se evidencia o grupo formado.

#### 3.4.4.6 Mapa Contextual

Outra forma simples de se visualizar um SOM é através de um Mapa Contextual (HAYKIN, 2001). Para gerá-lo, atribuem-se rótulos aos neurônios do SOM dependendo de como cada padrão excita um neurônio em particular. Assumindo que além da informação dos padrões também disponhamos de suas classes podemos atribuir rótulos a neurônios vencedores na grade de saída da rede as classes cujos dados eles representam. Dados do espaço de entrada são apresentados ao mapa e o neurônio vencedor será o mais similar, ou o mais próximo, de acordo com o critério de similaridade escolhido. A este neurônio atribui-se um rótulo (a classe do dado de entrada). Como resultado, os neurônios na grade de saída do mapa são particionados em um número de regiões coerentes. Regiões vazias no mapa indicam não atividade do neurônio.

Além da visualização, os Mapas Contextuais podem ser utilizados para auxiliar na classificação de padrões. Isto é, a partir deles, é possível identificar a que classe pertence um padrão de teste propagado no SOM.

#### 3.4.5 Normalização dos dados de entrada

Apesar de não obrigatória, grande parte das aplicações na literatura normalizam os dados antes de apresentarem ao SOM.

Variáveis que assumem praticamente o mesmo valor para todos os objetos são pouco discriminatórias e sua inclusão pouco contribuiria para a determinação da estrutura do agrupamento. Por outro lado, a inclusão de variáveis com grande poder de discriminação, porém, irrelevantes ao problema, podem mascarar os grupos e levar a resultado equivocados. Além disso, é desejável que os objetos sejam comparáveis segundo o significado de cada uma delas.

Ao agrupar observações, é necessário combinar todas as variáveis em um único índice de similaridade, de forma que a contribuição de cada variável dependa tanto de sua escala de mensuração como daquelas das demais variáveis.

Existem algumas técnicas responsáveis pelo tratamento dos dados, para que estes estejam em um mesmo intervalo. Geralmente usa-se a norma Euclidiana, como pode ser visto em Kohonen (2001), que equivale ao produto interno quando os padrões e os pesos são normalizados (norma igual a um). A norma Euclidiana para um vetor  $x = (x_1, x_2, \dots, x_n)$ , pode ser definida como:

$$norma = \sqrt{\sum_{k=1}^p x_k^2} \quad (18)$$

e os padrões de entrada podem ser normalizados mudando seus componentes para

$$x'_k = \frac{x_k}{norma} \quad (19)$$

Também se pode fazer a normalização dividindo todas as coordenadas de cada padrão pelo maior valor encontrado, considerando as coordenadas de todos os

padrões de entrada. Desta forma, todas as coordenadas pertencem ao intervalo [0,1].

#### 3.4.6 Aplicações da rede neural artificial

O mapa Auto-Organizável ou Rede Neural de Kohonen é uma rede de duas camadas, que vem sendo utilizada em diversas áreas do conhecimento. A maioria das publicações sobre esta rede trata da resolução de problemas de reconhecimento de padrões, de classificação e de otimização, de acordo com os trabalhos citados a seguir.

No trabalho de Francisco, 2004, a rede de Kohonen foi utilizada como uma metodologia para a classificação das espécies de peixes em categorias tróficas do reservatório de Corumbá – GO, de acordo com a dieta. Entende-se por categorias tróficas, grupos de peixes que fazem uso do mesmo recurso alimentar. Concluiu-se que os mapas auto-organizáveis representaram um recurso muito útil na discriminação dos grupos e na consequente classificação trófica das espécies de peixes analisadas e que a rede de Kohonen é uma ferramenta aplicável para a tarefa de classificação de dados ecológicos.

No trabalho de Oliveira *et al.*, 2009, os autores testaram a aplicabilidade de uma rede de Kohonen para condições semi-áridas brasileiras presentes em uma cena do satélite LANDSAT-5 no município de Iguatu-CE, classificando as imagens em água, agricultura, antropizada, caatinga arbórea densa (de porte mais elevado) e caatinga herbácea arbustiva (de porte baixo e médio) e comparou o seu desempenho com a de um classificador estatístico de máxima verossimilhança. O primeiro método apresentou maiores valores de exatidão específica para as classes agricultura (89,5%) e antropizada (100%) e o mapa auto-organizável de Kohonen apresentou-se mais apto à detecção de áreas com bioma caatinga.

O trabalho de Perobelli, 2009, descreve a investigação da política de distribuição de resultados e a capacidade de alterar os preços das ações de uma empresa. O objetivo era discutir os impactos do pagamento de proventos sobre os preços das ações de empresas maduras e de empresas em expansão, considerando-se ainda o efeito da classe da ação (ordinária ou preferencial) sobre os resultados. Para tal, adotou-se a metodologia de dados em painel, segmentando

a amostra a partir dos mapas auto-organizáveis de Kohonen. No âmbito das empresas, a pesquisa revela que a distribuição de proventos em empresas em expansão é capaz de encarecer seu custo de capital ordinário, pela queda mais que proporcional nos preços das ações (o mesmo não ocorre no custo do capital preferencial). Já para empresas maduras, a política de distribuição não gera grandes quedas nos preços das ações ordinárias, mantendo estável seu custo de capital ordinário (o mesmo não ocorre no custo do capital preferencial, que se eleva).

No trabalho de Martins *et al.*, 2004, os autores utilizaram Redes Neurais com aprendizado não supervisionado de uma rede de Kohonen para modelar o diagnóstico diferencial da doença meningocócica. Dos 100 casos utilizados, 65 foram para o treinamento das redes e 35 para testá-la. A camada de entrada foi formada pelos dados clínicos dos pacientes num total de 34 neurônios, a camada intermediária pelos resultados laboratoriais e a camada de saída foi composta pelos oito diagnósticos possíveis. As Redes de Kohonen apresentaram um percentual de 83% de acerto, considerado bastante alto comparado aos resultados obtidos pelos clínicos.

Em sua dissertação, Sala (2005) usou a Rede de Kohonen como ferramenta para auxiliar no diagnóstico de epilepsia com a finalidade de detectar automaticamente eventos epileptogênicos (espícula e ondas agudas) em sinais de eletroencefalograma. O conjunto de sinais para teste e treinamento foi retirado de nove registros, com duração total de 12 horas, obtido de sete pacientes comprovadamente epiléticos. Os padrões utilizados para treinamento e testes do sistema têm duração de um segundo e não sofreram pré-processamento. O sistema foi capaz de detectar espículas e ondas agudas com aproximadamente 82% de especificidade, 58,0% de sensibilidade e valores preditivo positivo e preditivo negativo de 65,4% e 76,7%, respectivamente. O resultado é aceitável, se comparado ao índice de concordância entre dois especialistas (em torno 50%).

Siqueira, 2005, no seu trabalho de doutorado, usa a Rede de Kohonen como ferramenta auxiliar na resolução do problema de Designação Linear. Na fase inicial do problema, onde os elementos da matriz de custos do problema da Designação devem ser determinados, utilizou Mapas de Kohonen, e na resolução do problema da Designação propriamente dito, a técnica utilizada é a Rede Neural Recorrente de Wang, com a aplicação de um princípio proposto, denominado *Winner Takes All*. A metodologia proposta é aplicada em um estudo de caso: o Problema de Alocação de

Salas de Aula para disciplinas de graduação e pós-graduação da UFPR, onde são testados mapas com diversas dimensões para a determinação dos custos deste problema. Os resultados encontrados com a aplicação desta metodologia no estudo de caso são considerados satisfatórios, com erro médio na solução final da Designação inferior a 3% para os melhores mapas encontrados.

Em um estudo de caso da organização Ser Down, que auxilia os familiares de pessoas portadoras da síndrome de Down, Soares (2006) aplica a Rede de Kohonen no agrupamento de pessoas com características semelhantes, para que o especialista ou pesquisador possa trabalhar ou estudar de acordo com a similaridade dos participantes de cada grupo e também entre os grupos portadores da síndrome de Down. As características de cada pessoa relevantes à análise do algoritmo foram as atividades esportivas que o indivíduo pratica normalmente e que servem como estímulo, a escolaridade, o trabalho, a terapia que é aplicada à pessoa juntamente com o aspecto clínico que ela está enquadrada. Os resultados foram considerados satisfatórios para o espaço amostral utilizado.

Com o objetivo de estudar mecanismos que permitem utilizar uma rede neural para interpretar textos, Babini (2006) realizou vários testes com a Rede de Kohonen para reconhecer padrões lexicais. Segundo o autor, os testes apresentaram bons resultados, sendo necessário trabalhar com conjunto de termos maiores para que a validade do modelo proposto fosse ainda mais eficaz.

Outras aplicações interessantes das Redes de Kohonen estão presentes na área médica, como no artigo de Wyns *et al.* (2004), que mostra a aplicação da Rede de Kohonen para previsão de diagnósticos em pacientes com artrite. Os autores comparam a Rede de Kohonen com a Rede de Múltiplas Camadas, onde os erros de classificação encontrados foram de 25% com a Rede de Kohonen e de 46% com a Rede de Múltiplas Camadas.

Prechelt, 1994, utilizou as redes neurais para o diagnóstico médico de câncer de mama buscando classificar o tumor em maligno ou benigno baseado nas descrições celulares recolhidas pelo exame microscópico. Os atributos de entrada usados foram a espessura do grupo, a uniformidade do tamanho e da forma das células, a quantidade de adesão marginal, entre outros, num total de nove. Usou dois atributos de saída (tumor maligno ou tumor benigno). Das 699 pacientes, 65,5% eram portadoras de tumor benigno.

Massad *et al.*, 2004, usaram redes neurais no auxílio ao diagnóstico médico da doença de Alzheimer. Para isso, utilizaram dados coletados pelo sistema computadorizado de uma avaliação neuropsicológica considerando cinco variáveis. As entradas são as porcentagens de acerto nos testes de reconhecimento de faces, desenhos, palavras, números e tempo de reação no teste dos desenhos. Da população estudada de 90 pacientes, 45 pacientes eram portadores da doença de Alzheimer.

Empregando a rede neural artificial do tipo *Perceptron* com Múltiplas Camadas no diagnóstico preditivo dos tipos mais freqüentes de cefaléia, Mendes (2008) analisou 2.177 pacientes com diagnóstico de cefaléia a partir de 14 atributos, tais como idade, sexo, local da dor e outros. O sistema desenvolvido utilizou o software Matlab 7.0 e o componente Neural Network Toolbox para implementação, treinamento e testes.

Baldin, 2002, aplicou a teoria e os algoritmos de redes neurais como ferramenta auxiliar na Orientação Profissional de Jovens. Utilizou os dados de 122 questionários respondidos por profissionais satisfeitos em sua área de atuação: área biológica, área humana ou área tecnológica. A rede foi programada em Visual Basic, a camada de entrada foi composta por 10 neurônios, a camada escondida foi composta por neurônios variando de 1 a 10 e a camada de saída foi composta por um neurônio dicotômico numa primeira topologia, um neurônio tricotômico numa segunda topologia e três neurônios na terceira topologia. O melhor desempenho foi obtido usando-se a segunda topologia.

## CAPÍTULO IV

### 4. IMPLEMENTAÇÃO E ANÁLISE DOS RESULTADOS

#### 4.1 FERRAMENTA DESENVOLVIDA

A Rede Neural de Kohonen foi programada na linguagem computacional Microsoft Visual Basic, versão 6.0.

Primeiramente, foi desenvolvido o software que transforma os atributos da doença em vetores numéricos. Selecionam-se as alternativas de acordo com as características da doença, escolhidas isoladamente ou de maneira múltipla, e gravam-se essas informações em um arquivo de texto, conforme mostra a Figura 18. Quando o arquivo é gravado, as entradas serão transformadas em vetores de coordenadas binárias. Os detalhes dos sintomas das doenças encontram-se na seção 2.4.

**Obter vetores numéricos**

Característica da lesão	Sintomas	Início da lesão	Progressão da lesão
<input type="checkbox"/> Purulenta	<input type="checkbox"/> Febre	<input type="checkbox"/> Pápula	<input type="checkbox"/> Aumentou o n° de lesões
<input type="checkbox"/> Secreção transparente	<input type="checkbox"/> Prurido	<input type="checkbox"/> Mácula	<input type="checkbox"/> Aumentou a extensão da lesão
<input type="checkbox"/> Secreção purulenta	<input type="checkbox"/> Dor na lesão	<input type="checkbox"/> Eritema	<input type="checkbox"/> Aumentou a profundidade
<input type="checkbox"/> Secreção fétida	<input type="checkbox"/> Mal-estar	<input type="checkbox"/> Vesícula	<input type="checkbox"/> Pústulas
<input type="checkbox"/> Há secreção se pressionar a lesão	<input type="checkbox"/> Anorexia	<input type="checkbox"/> Úlcera	<input type="checkbox"/> Vesículas
<input type="checkbox"/> Pápulas		<input type="checkbox"/> Placa	<input type="checkbox"/> Crostas
<input type="checkbox"/> Pústulosa		<input type="checkbox"/> Edema	<input type="checkbox"/> Verrugas
<input type="checkbox"/> Vesículas		<input type="checkbox"/> Nódulo	<input type="checkbox"/> Úlceras
<input type="checkbox"/> Bolhosa		<input type="checkbox"/> A menos de 15 dias	<input type="checkbox"/> Secreção
<input type="checkbox"/> Nodular		<input type="checkbox"/> Entre 15 e 30 dias	<input type="checkbox"/> Ruptura espontânea (bolha ou vesícula)
<input type="checkbox"/> Verrugosa		<input type="checkbox"/> Entre 1 e 6 meses	<input type="checkbox"/> Disseminação por contiguidade
<input type="checkbox"/> Crostosa		<input type="checkbox"/> Entre 6 meses e 1 ano	<input type="checkbox"/> Múltiplas lesões pelo corpo
<input type="checkbox"/> Descamação		<input type="checkbox"/> Há mais de 1 ano	
<input type="checkbox"/> Ulcerada			
<input type="checkbox"/> Máculas			
<input type="checkbox"/> Forma uma placa			
<input type="checkbox"/> Eritematosa			
<input type="checkbox"/> Com edema			
<input type="checkbox"/> Esbranquiçada			
<input type="checkbox"/> Granulosa			
<input type="checkbox"/> Amarronzada			
<input type="checkbox"/> Com sangramento			
<input type="checkbox"/> Bordas elevadas			
<input type="checkbox"/> Bordas elevadas bem definidas			
<input type="checkbox"/> Ínguas próximas à lesão			
<input type="checkbox"/> Linhas sinuosas			
<input type="checkbox"/> Presença de pontos negros na lesão			
<input type="checkbox"/> Lesão semelhante ao couve-flor			
<input type="checkbox"/> Forma anelar			
<input type="checkbox"/> Formou cordão endurecido de nódulos (semelhante a rosário)			

Local da lesão	Dados epidemiológicos
<input type="checkbox"/> Tronco	<input type="checkbox"/> Contato com pessoa doente
<input type="checkbox"/> Membros	<input type="checkbox"/> Viajou, morou ou mora em região com dados epidemiológicos
<input type="checkbox"/> Lábio	<input type="checkbox"/> Referência de cão ou equino com lesão nas proximidades
<input type="checkbox"/> Língua	<input type="checkbox"/> Trauma na pele causada por animal
<input type="checkbox"/> Mucosa	<input type="checkbox"/> Trauma na pele ocasionado por ferramenta agrícola
<input type="checkbox"/> Peri oral	<input type="checkbox"/> Trauma na pele ocasionado por fragmento vegetal
<input type="checkbox"/> Face	<input type="checkbox"/> Outro tipo de trauma
<input type="checkbox"/> Ombro	
<input type="checkbox"/> Nádegas	

<input type="checkbox"/> Ouve inserção em áreas florestais
<input type="checkbox"/> Teve contato com solo.
<input type="checkbox"/> Esteve em contato com qualquer local frequentado por cães e gatos.
<input type="checkbox"/> Exposição solar
<input type="checkbox"/> Estresse emocional
<input type="checkbox"/> Menstruação
<input type="checkbox"/> Imunidade baixa, por alguma doença ou imunodeficiência

Rótulo do vetor      Gravar dados em arquivo      SAIR

FIGURA 18 – INTERFACE DO SOFTWARE QUE GERA OS VETORES NUMÉRICOS  
 FONTE: O autor (2012)

Os vetores obtidos serão usados como dados de entrada para treinamento e teste da Rede de Kohonen. A interface do software usado para treinar a rede é mostrada na Figura 19.

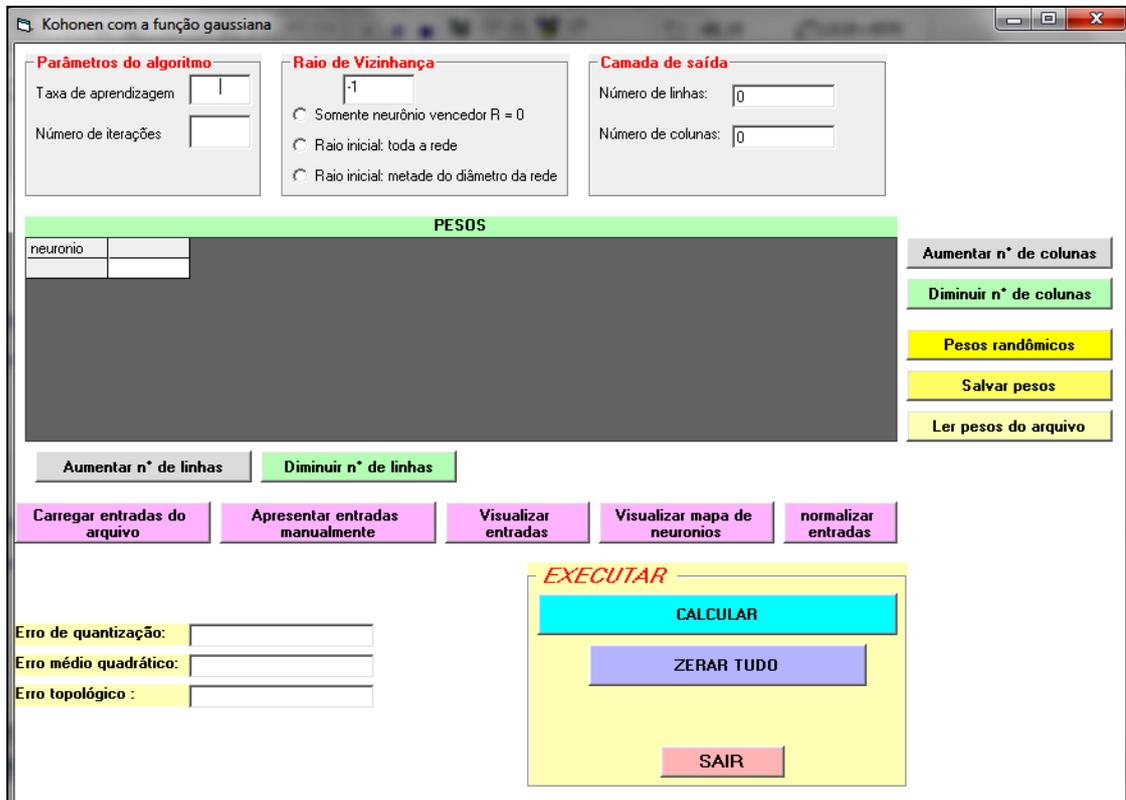


FIGURA 19 – INTERFACE DO SOFTWARE DE TREINAMENTO DA REDE DE KOHONEN  
 FONTE: O autor (2012)

Antes de iniciar o processo de aprendizagem da rede neural, deve-se escolher a taxa inicial de aprendizagem, o número de iterações, o raio de vizinhança e a dimensão do mapa de saída (número de linhas e de colunas). O valor -1 atribuído ao raio de vizinhança é usado para forçar o usuário que treinará a rede a determinar um valor ao mesmo, pois enquanto não for selecionada uma das opções para o raio ou não for digitado um número natural diferente de zero, o software questionará o valor a ser empregado.

Ainda nesta interface, podem-se prover os pesos dos neurônios manualmente (digitando um a um os valores nas células da planilha), de um arquivo de texto ou de forma randômica (quando o programa fornece os valores dentro do intervalo de zero a um). Também se pode obter os vetores dos padrões de entrada de um arquivo ou fornecê-los manualmente; visualizar as entradas fornecidas em

uma tabela, e ainda, se necessário, fazer a normalização dos dados, conforme descrita na seção 3.4.5. Após fornecer ao software todos os dados e parâmetros necessários para treinamento da rede, clica-se em *calcular*. Depois de concluídas todas as iterações, o *erro de quantização*, o *erro médio quadrático* e o *erro topológico* desta fase aparecem na tela, juntamente com o botão *visualizar*, onde, em outra tela (Figura 20), será mostrado o mapa de saída da rede após a fase de treinamento.

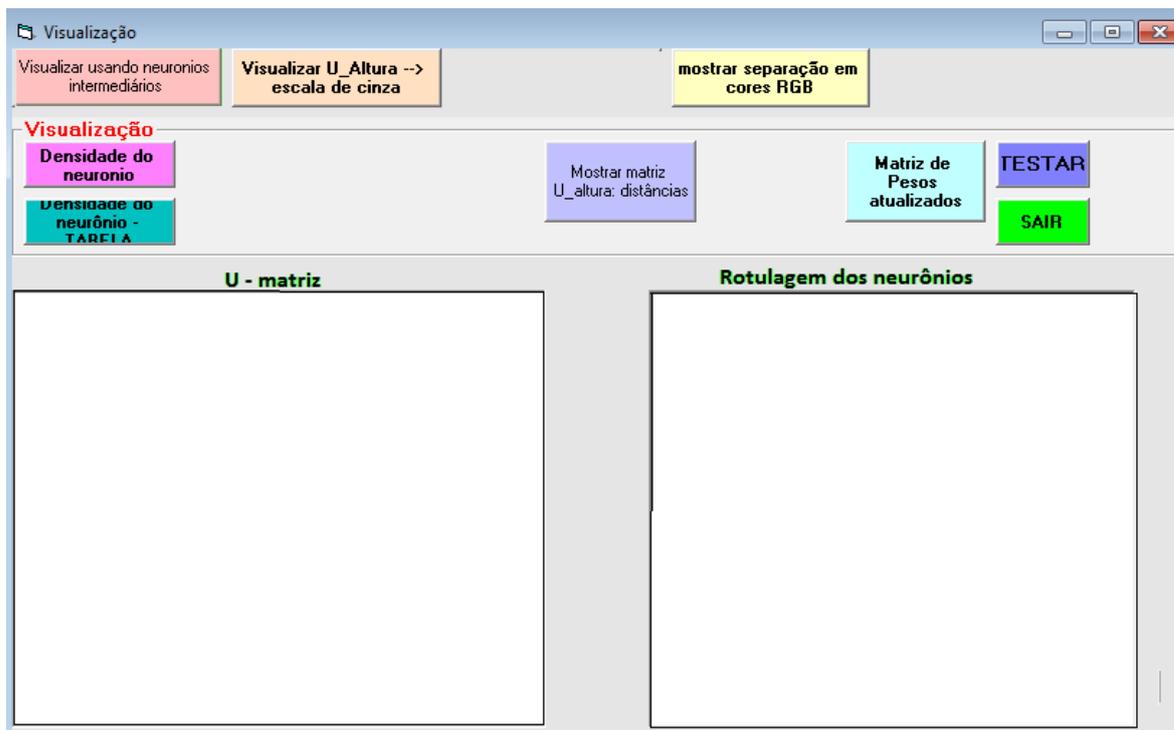


FIGURA 20 – INTERFACE DO SOFTWARE DE VISUALIZAÇÃO DO MAPA DE SAÍDA  
 FONTE: O autor (2012)

Nesta etapa do programa permite-se a escolha da visualização do mapa de saída através da U-matriz (ver seção 3.4.4.1), U-altura (ver seção 3.4.4.2) ou usando a metodologia proposta neste trabalho (ver seção 4.2), usando as cores RGB. Também é possível verificar os valores das distâncias encontradas para cada neurônio enquanto se usa a U-altura ou a U-matriz (opção apresentada ao escolher a U-matriz para visualização); a matriz com os pesos dos neurônios atualizados após todas as iterações; visualizar a densidade de cada neurônio no mapa de saída (clicando em *densidade do neurônio*) ou em uma tabela (clicando em *densidade do neurônio – TABELA*). Depois de concluída essa fase, clica-se em *testar* para dar início a fase de testes da rede (ver Figura 21).

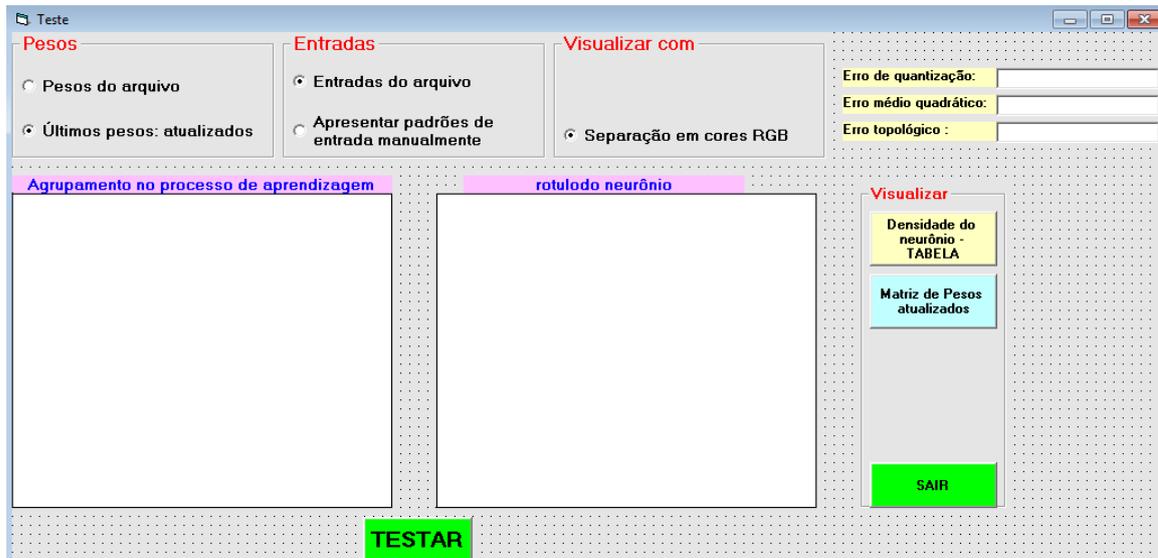


FIGURA 21 – INTERFACE DO SOFTWARE DE TESTE DA REDE DE KOHONEN  
 FONTE: O autor (2012)

Para esta fase, pode-se escolher entre usar os pesos dos neurônios gravados em um arquivo de texto ou os pesos calculados pela rede (atualizados depois de todas as iterações). Também pode-se escolher entre fornecer os dados de teste manualmente (fornecer os valores um a um) ou pegá-los de um arquivo de texto.

O erro de quantização, erro médio quadrático e erro topológico da fase de teste serão mostrados na tela após apresentar todos os padrões para esta fase. Os resultados serão visualizados usando a metodologia de agrupamentos por cores proposta neste trabalho. No primeiro quadro em branco serão mostrados os agrupamentos formados pelos neurônios durante a fase de treinamento, separados por cores e rotulados segundo a doença que possui a menor distância Euclidiana com o neurônio vencedor, e no segundo quadro é mostrado o neurônio vencedor para os dados apresentados à rede para teste. O neurônio vencedor é identificado pela cor preta e rotulado de acordo com a doença apresentada para o teste.

O usuário pode, também na fase de teste, visualizar a densidade de cada neurônio (obtida na fase de treinamento) e a matriz de pesos atualizada, clicando em *densidade do neurônio – TABELA* e *matriz de pesos atualizados* respectivamente.

## 4.2 IMPLEMENTAÇÃO DA REDE NEURAL DE KOHONEN

Para a implementação da Rede Neural de Kohonen do presente trabalho foram analisados 60 prontuários com diagnósticos de Impetigo, Herpes Labial, Leishmaniose Cutânea, Cromoblastomicose e Esporotricose atendidos pelo setor de infectologia do Hospital de Clínicas (HC) da Universidade Federal do Paraná (UFPR), no período compreendido entre 1995 e 2011. De cada diagnóstico foram extraídos os atributos que compõem o vetor de entradas da rede, juntamente com informações consultadas de textos médicos (BRASIL, 2005; BRASIL, 2000; COURA, 2005; GONTIJO, 2003; MACHADO-PINTO, 1994; MUNIZ, 2009; PERUCA, 2009; REY, 2001; RIBEIRO, 2006) e de conversas com o infectologista Prof. Dr. Telles Filho (HC). Não foram encontrados prontuários da doença Larva Migrans Cutânea, por isso seus atributos foram extraídos de textos médicos e de experiências relatadas por profissionais da área encontrados em textos durante a pesquisa.

Os dados foram codificados conforme a descrição já feita no capítulo II, objetivando aplicar valores numéricos para as variáveis qualitativas que representam as características da doença descritas pelo paciente.

A Rede Neural de Kohonen foi criada, treinada e simulada usando como ferramenta o software Visual Basic versão 6.0 da Microsoft.

A taxa de aprendizagem, o raio de vizinhança e a dimensão do mapa de saída devem ser definidos inicialmente. A cada iteração a taxa de aprendizagem e o raio de vizinhança decaem exponencialmente (seção 3.4.2). Em todos os testes desse trabalho, o raio de vizinhança começou com valor igual ao diâmetro da rede (HAYKIN, 2001).

Os 68 padrões que compõe a amostra foram divididos aleatoriamente em dois conjuntos, onde  $2/3$  foram separados para treinamento da rede e  $1/3$  para testá-la, ficando 47 padrões para o treinamento e 21 para teste. Destes existem 10 e 5 padrões de Impetigo, 8 e 4 de Cromoblastomicose, 7 e 3 de Esporotricose, 4 e 1 de Larva Migrans Cutânea, 7 e 3 de Herpes Labial e 11 e 5 de Leishmaniose Cutânea, para treinamento e teste respectivamente.

Após o treinamento da rede, os neurônios são agrupados segundo as doenças pesquisadas e o agrupamento identificado por uma cor. Para determinar a cor de cada neurônio foi usado o sistema de cores RGB (Red-Green-Blue:

Vermelho-Verde-Azul), onde as cores vermelha, verde e azul são misturadas, obtendo-se tonalidades diferentes.

Para utilizar as cores RGB precisamos de três coordenadas, e como cada neurônio possui 83 coordenadas (variáveis), foi necessária a criação de uma combinação dessas para que no final ficássemos com apenas três. Desta forma, o número total de coordenadas do neurônio foi dividido por três, obtendo-se o valor de NVG (número de variáveis por grupo) e as coordenadas foram separadas em três grupos: para o primeiro grupo as coordenadas do neurônio da primeira posição até a NVG-ésima posição, para o segundo grupo as coordenadas da NVG-ésima posição até a 2\*NVPG-ésima e as demais coordenadas ficaram no terceiro grupo.

Neurônio =  $(a_1, a_2, \dots, a_{83})$   $\Longrightarrow$  83 variáveis

NVG =  $83/3 = 27,66$   $\Longrightarrow$  27 variáveis para o 1º grupo  
 $\Longrightarrow$  27 variáveis para o 2º grupo  
 $\Longrightarrow$  29 variáveis para o 3º grupo

Neurônio =  $(\underbrace{a_1, \dots, a_{27}}_{1^\circ \text{ grupo}}, \underbrace{a_{28}, \dots, a_{54}}_{2^\circ \text{ grupo}}, \underbrace{a_{55}, \dots, a_{83}}_{3^\circ \text{ grupo}})$

Para cada grupo encontrado, foi calculada a média de todas as variáveis estipuladas e essas médias passaram a ser as novas coordenadas dos neurônios.

**Média 1** = Média 1º grupo =  $(a_1 + \dots + a_{27}) / 27$

**Média 2** = Média 2º grupo =  $(a_{28} + \dots + a_{54}) / 27$

**Média 3** = Média 3º grupo =  $(a_{55} + \dots + a_{83}) / 29$

Neurônio = (média 1, média 2, média 3)  $\Longrightarrow$  novas coordenadas

Assim, todos os neurônios ficam com apenas três coordenadas, número necessário para usar as cores RGB, onde a média do primeiro grupo (primeira média) de coordenadas determina a intensidade de vermelho, a segunda média determina a intensidade de verde e a média do último grupo, a intensidade de azul.

Mas isso não poderia ser feito de forma direta, pois o intervalo das coordenadas dos neurônios e das cores RGB eram distintos, a intensidade das cores RGB variam de 0 a 255, e as coordenadas dos neurônios variavam entre 0 e 1 (nem sempre atingindo o valor máximo um). Para que uma combinação fosse possível, optou-se trabalhar com a porcentagem.

Fazendo uma comparação entre as médias de todos os neurônios, o maior valor encontrado para cada uma das três coordenadas foi estipulado 100% e aos demais valores, abaixo deste, foi determinada uma porcentagem correspondente, baseada naquela que recebeu 100%, usando uma regra de três simples. Assim, tinha-se uma porcentagem para a intensidade de vermelho, outra para a intensidade de verde e outra para a intensidade de azul.

Finalmente, cada neurônio recebe uma cor, baseada nos valores de suas coordenadas. Neurônios próximos que possuem coordenadas similares recebem cores similares, formando-se agrupamentos visualizados pela distinção das cores.

Após a organização em cores, os neurônios são rotulados segundo o padrão de entrada mais similar a ele. Os neurônios considerados vencedores recebem como rótulo o padrão de entrada que possui a menor distância Euclidiana com o neurônio.

## 4.3 TESTES

### *4.3.1 Comparando resultados*

A rede implementada foi primeiramente testada usando bases de dados de outros trabalhos, comparando os resultados obtidos com aqueles alcançados por outros softwares desenvolvidos com a Rede de Kohonen, no intuito de verificar a eficiência da rede no agrupamento dos dados. Entre os dados testados encontra-se o conjunto de dados Iris (Tabela 7), comparado com a aplicação no trabalho de Costa (1999, p. 255), a base de dados composta pelas letras do alfabeto e os números de um a seis (Tabela 8), proposta e aplicada por Kohonen (1995, p. 114), e

a base de dados de animais e seus atributos (Tabela 9), também proposta e aplicada por Kohonen (1995, p. 116), obtendo-se resultados satisfatórios.

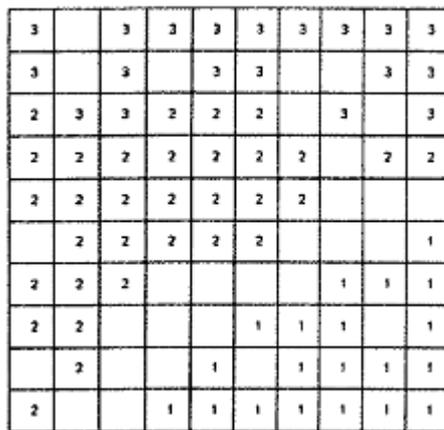
A tabela 7 ilustra o conjunto de dados Iris. Temos 50 amostras de cada uma das três espécies de plantas *Iris setosa*, *Iris versicolour* e *Iris virginica*, mensuradas sob 4 variáveis que são a largura e o comprimento da sépala (*sepal length* e *sepal width*) e comprimento e largura da pétala (*petal length* e *petal width*), todas medidas em centímetros. A primeira classe, (*Iris setosa*) é separável linearmente das outras duas últimas (*Iris versicolor* e *Iris virginica*), que apresentam certo grau de sobreposição (Costa, 1999).

TABELA 7 – DADOS IRIS

<i>Iris setosa</i>				<i>Iris versicolor</i>				<i>Iris virginica</i>			
Sepal length	Sepal width	Petal length	Petal width	Sepal length	Sepal width	Petal length	Petal width	Sepal length	Sepal width	Petal length	Petal width
5.10	3.50	1.40	0.20	7.00	3.20	4.70	1.40	6.30	3.30	6.00	2.50
4.90	3.00	1.40	0.20	6.40	3.20	4.50	1.50	5.80	2.70	5.10	1.90
4.70	3.20	1.30	0.20	6.90	3.10	4.90	1.50	7.10	3.00	5.90	2.10
4.60	3.10	1.50	0.20	5.50	2.30	4.00	1.30	6.30	2.90	5.60	1.80
5.00	3.60	1.40	0.20	6.50	2.80	4.60	1.50	6.50	3.00	5.80	2.20
5.40	3.90	1.70	0.40	5.70	2.80	4.50	1.30	7.60	3.00	6.60	2.10
4.60	3.40	1.40	0.30	6.30	3.30	4.70	1.60	4.90	2.50	4.50	1.70
5.00	3.40	1.50	0.20	4.90	2.40	3.30	1.00	7.30	2.90	6.30	1.80
4.40	2.90	1.40	0.20	6.60	2.90	4.60	1.30	6.70	2.50	5.80	1.80
4.90	3.10	1.50	0.10	5.20	2.70	3.90	1.40	7.20	3.60	6.10	2.50
5.40	3.70	1.50	0.20	5.00	2.00	3.50	1.00	6.50	3.20	5.10	2.00
4.80	3.40	1.60	0.20	5.90	3.00	4.20	1.50	6.40	2.70	5.30	1.90
4.80	3.00	1.40	0.10	6.00	2.20	4.00	1.00	6.80	3.00	5.50	2.10
4.30	3.00	1.10	0.10	6.10	2.90	4.70	1.40	5.70	2.50	5.00	2.00
5.80	4.00	1.20	0.20	5.60	2.90	3.60	1.30	5.80	2.80	5.10	2.40
5.70	4.40	1.50	0.40	6.70	3.10	4.40	1.40	6.40	3.20	5.30	2.30
5.40	3.90	1.30	0.40	5.60	3.00	4.50	1.50	6.50	3.00	5.50	1.80
5.10	3.50	1.40	0.30	5.80	2.70	4.10	1.00	7.70	3.80	6.70	2.20
5.70	3.80	1.70	0.30	6.20	2.20	4.50	1.50	7.70	2.60	6.90	2.30
5.10	3.80	1.50	0.30	5.60	2.50	3.90	1.10	6.00	2.20	5.00	1.50
5.40	3.40	1.70	0.20	5.90	3.20	4.80	1.80	6.90	3.20	5.70	2.30
5.10	3.70	1.50	0.40	6.10	2.80	4.00	1.30	5.60	2.80	4.90	2.00
4.60	3.60	1.00	0.20	6.30	2.50	4.90	1.50	7.70	2.80	6.70	2.00
5.10	3.30	1.70	0.50	6.10	2.80	4.70	1.20	6.30	2.70	4.90	1.80
4.80	3.40	1.90	0.20	6.40	2.90	4.30	1.30	6.70	3.30	5.70	2.10
5.00	3.00	1.60	0.20	6.60	3.00	4.40	1.40	7.20	3.20	6.00	1.80
5.00	3.40	1.60	0.40	6.80	2.80	4.80	1.40	6.20	2.80	4.80	1.80
5.20	3.50	1.50	0.20	6.70	3.00	5.00	1.70	6.10	3.00	4.90	1.80
5.20	3.40	1.40	0.20	6.00	2.90	4.50	1.50	6.40	2.80	5.60	2.10
4.70	3.20	1.60	0.20	5.70	2.60	3.50	1.00	7.20	3.00	5.80	1.60
4.80	3.10	1.60	0.20	5.50	2.40	3.80	1.10	7.40	2.80	6.10	1.90
5.40	3.40	1.50	0.40	5.50	2.40	3.70	1.00	7.90	3.80	6.40	2.00
5.20	4.10	1.50	0.10	5.80	2.70	3.90	1.20	6.40	2.80	5.60	2.20
5.50	4.20	1.40	0.20	6.00	2.70	5.10	1.60	6.30	2.80	5.10	1.50
4.90	3.10	1.50	0.20	5.40	3.00	4.50	1.50	6.10	2.60	5.60	1.40
5.00	3.20	1.20	0.20	6.00	3.40	4.50	1.60	7.70	3.00	6.10	2.30
5.50	3.50	1.30	0.20	6.70	3.10	4.70	1.50	6.30	3.40	5.60	2.40
4.90	3.60	1.40	0.10	6.30	2.30	4.40	1.30	6.40	3.10	5.50	1.80
4.40	3.00	1.30	0.20	5.60	3.00	4.10	1.30	6.00	3.00	4.80	1.80
5.10	3.40	1.50	0.20	5.50	2.50	4.00	1.30	6.90	3.10	5.40	2.10
5.00	3.50	1.30	0.30	5.50	2.60	4.40	1.20	6.70	3.10	5.60	2.40
4.50	2.30	1.30	0.30	6.10	3.00	4.60	1.40	6.90	3.10	5.10	2.30
4.40	3.20	1.30	0.20	5.80	2.60	4.00	1.20	5.80	2.70	5.10	1.90
5.00	3.50	1.60	0.60	5.00	2.30	3.30	1.00	6.80	3.20	5.90	2.30
5.10	3.80	1.90	0.40	5.60	2.70	4.20	1.30	6.70	3.30	5.70	2.50
4.80	3.00	1.40	0.30	5.70	3.00	4.20	1.20	6.70	3.00	5.20	2.30
5.10	3.80	1.60	0.20	5.70	2.90	4.20	1.30	6.30	2.50	5.00	1.90
4.60	3.20	1.40	0.20	6.20	2.90	4.30	1.30	6.50	3.00	5.20	2.00
5.30	3.70	1.50	0.20	5.10	2.50	3.00	1.10	6.20	3.40	5.40	2.30
5.00	3.30	1.40	0.20	5.70	2.80	4.10	1.30	5.90	3.00	5.10	1.80

FONTE: Costa (1999)

Usando a base de dados Iris, Costa (1999) obteve o mapa da Figura 22 (A), e a rede programada neste trabalho obteve o mapa da Figura 23 (B). Ambas foram programadas usando um mapa 10x10, com raio de vizinhança 8 e função de vizinhança Gaussiana. Costa usou o software Matlab com a inicialização de pesos linear (Costa, 1999, p. 96) enquanto que a rede aqui treinada usou a inicialização de pesos randômica.



(A)



(B)

FIGURA 22 – MAPEAMENTO DAS CLASSES DA BASE DE DADOS IRIS POR: (A) COSTA E (B) PELA REDE TREINADA DESTE TRABALHO  
 FONTE: (A) Costa (1999); (B) O autor (2012)

Observa-se nas figuras acima a separação nítida da classe um das demais e uma sobreposição das classes dois e três, resultado tratado na tese de Costa.

Na tabela 8 temos 32 itens, com cinco atributos hipotéticos (definidos artificialmente por Kohonen, 1995) registrados em uma matriz de dados. Cada uma das colunas representa um item e são rotulados segundo uma letra ou um número (entre um e seis). Os rótulos não são referidos durante o treinamento (KOHONEN, 1995).

TABELA 8 – MATRIZ DE DADOS

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	1	2	3	4	5	6		
1	2	3	4	5	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	
0	0	0	0	0	1	2	3	4	5	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	
0	0	0	0	0	0	0	0	0	0	1	2	3	4	5	6	7	8	3	3	3	3	6	6	6	6	6	6	6	6	6	6	6	6	6
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	2	3	4	1	2	3	4	2	2	2	2	2	2	2	2	2
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	2	3	4	5	6	6

FONTE: Kohonen (1995, p. 114)



TABELA 9 – NOMES DE ANIMAIS E SEUS ATRIBUTOS

		p	g			c	f	á	r	c				c	z	v
		o	a	p	g	o	a	g	a	a	l	g	l	a	e	a
		m	i	a	a	r	l	u	p	h	o	a	e	v	b	a
		b	h	t	s	u	c	j	o	r	o	t	ã	a	r	a
		a	a	o	o	a	o	a	a	o	o	e	o	o	a	a
é	pequeno	1	1	1	1	1	1	0	0	0	0	1	0	0	0	0
	médio	0	0	0	0	0	0	1	1	1	1	0	0	0	0	0
	grande	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1
tem	2 patas	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0
	4 patas	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1
	pêlo	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1
	casco	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1
	crina	0	0	0	0	0	0	0	0	0	1	0	0	1	1	0
	pena	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0
gosta de	caçar	0	0	0	0	1	1	1	1	0	1	1	1	1	0	0
	correr	0	0	0	0	0	0	0	0	1	1	0	1	1	1	0
	voar	1	0	1	1	1	1	0	0	0	0	0	0	0	0	0
	nadar	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0

FONTE: KOHONEN (1995, p. 116)

Após o treinamento da rede com os dados da Tabela 9, cada neurônio tornou-se mais sensível a uma das combinações de atributos que ocorrem e, simultaneamente, a um dos 16 nomes de animais, também. Assim, obtemos o mapa mostrado na Figura 24 (os pontos na Figura 24 (A) indicam neurônios com respostas fracas). É muito evidente que a ordenação espacial das respostas captou o essencial das "relações familiares" entre os animais. As células que respondem a "aves" ocupam na Figura 24 (A) e (B) respectivamente o lado esquerdo e direito da rede, "caçadores" como "tigre", "leão" e "gato" estão agrupadas para a direita (Figura 24 (A)) e no canto inferior esquerdo (Figura 24 (B)), e os animais mais "pacíficos" como "zebra", "cavalo" e "vaca" estão situados no meio superior (Figura 24 (A)) e no canto superior esquerdo (Figura 24 (B)). Cada grupo foi formado de acordo com as semelhanças entre os animais.

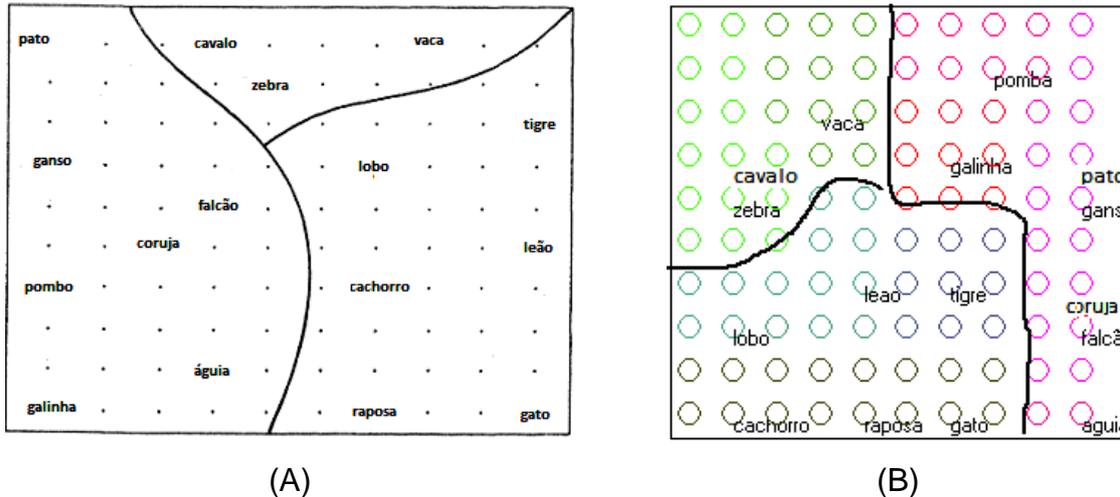


FIGURA 24 – AGRUPAMENTOS DE ACORDO COM A SIMILARIDADE DOS DADOS DA TABELA 9 POR: (A) KOHONEN E (B) PELA REDE TREINADA NESTE TRABALHO  
 FONTE: (A) Kohonen (1995, p. 116); (B) O autor (2012)

Verificado que a rede implementada responde adequadamente aos dados fornecidos para avaliação da mesma, iniciou-se o processo de testes com os dados obtidos nessa pesquisa.

#### 4.3.2 Testando a rede implementada

As dimensões dos mapas testados variam de 3x3 a 20x20, com vizinhança Gaussiana do tipo quadrada, e com a utilização da atualização exponencial para as taxas de aprendizagem e do raio da vizinhança dos mapas, apresentadas na seção 3.4.2.

Para investigações sobre o número de neurônios, foram utilizados 1000, 3000 e 5000 iterações, cada mapa foi executado cinco vezes no programa tomando valores aleatórios para os pesos dos neurônios do mapa, taxa inicial de aprendizado variando entre 0,5 ou 1 e o conjunto de treinamento definitivo, com a entrada dos dados na fase de treinamento de forma aleatória. O número de iterações foi determinado para reduzir o tempo de processamento, mostrado na Figura 25, permitindo assim realizar mais experimentos, além do interesse nestas investigações ser o de testar a influência da variação no número de neurônios na camada competitiva.

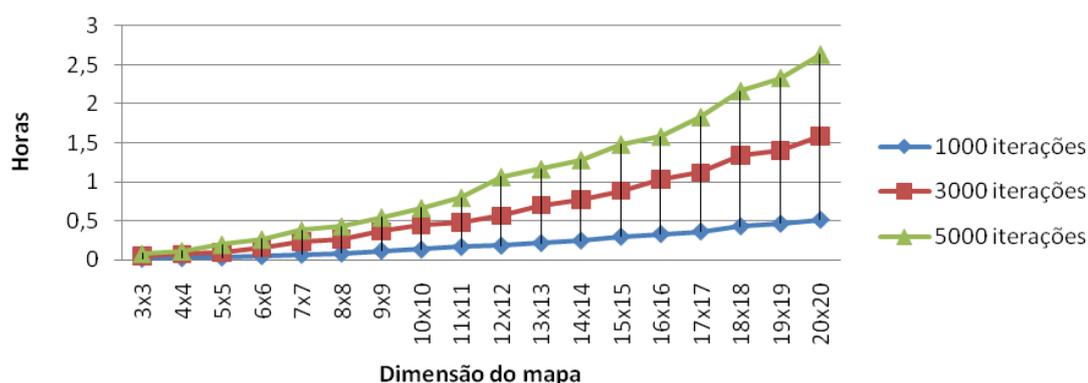


FIGURA 25 – TEMPO COMPUTACIONAL  
 FONTE: O autor (2012)

Os erros, topológico, de quantização e médio quadrático, foram determinados calculando-se a média entre os valores encontrados dos respectivos erros após executar cinco vezes cada mapa. Para cada uma das cinco vezes que um mapa foi executado, usavam-se as mesmas configurações definidas ao programa (taxa de aprendizagem inicial, raio de vizinhança, número de iterações e a dimensão do mapa) e variavam-se aleatoriamente os valores das coordenadas dos pesos de cada neurônio. O objetivo era obter um mapa considerado adequado para a resolução do problema apontado, encontrando um mapa com a melhor visualização dos agrupamentos e os menores valores para os erros citados.

Para a identificação dos agrupamentos foi utilizado o método de visualização da U-matriz, definindo as fronteiras entre os agrupamentos, e o sistema de cores primárias RGB, definindo a cor do neurônio, conforme descrito nas seções 3.4.4.1 e 4.2, respectivamente.

Foram realizados 540 testes e verificou-se que os resultados para o erro de quantização com 1000, 3000 ou 5000 iterações ficavam similares e praticamente tornavam-se estáveis para mapas de dimensão maior do que 8x8. O mesmo ocorre com o erro médio quadrático (Figuras 26 e 27). Os mapas também foram testados variando a taxa de aprendizado inicial entre 0,5 ou 1, mas não mostraram diferença significativa e por isso os gráficos com taxa de aprendizagem inicial igual a 0,5 serão omitidos. A taxa de aprendizado inicial igual a um foi escolhida por apresentar melhores resultados para o erro topológico.

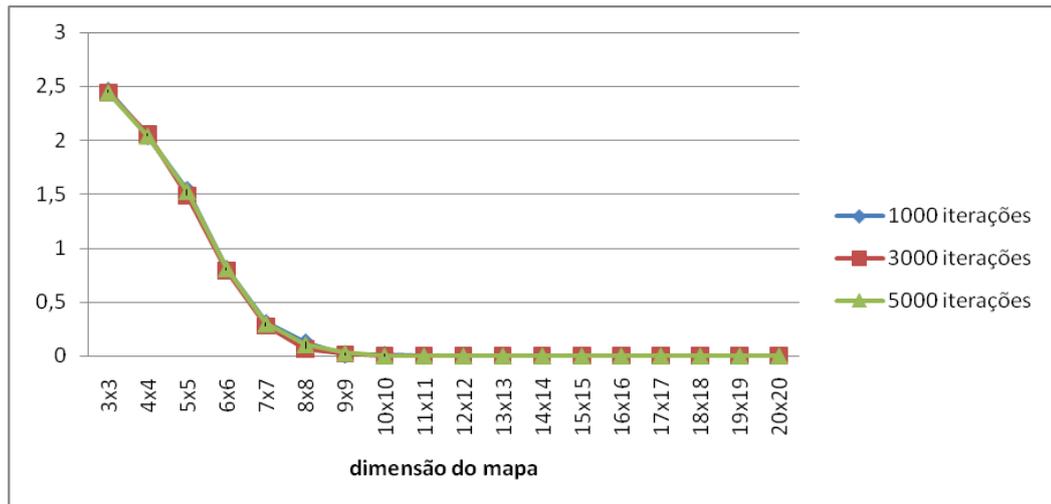


FIGURA 26 – ERRO DE QUANTIZAÇÃO – FASE DE TREINAMENTO  
 FONTE: O autor (2012)

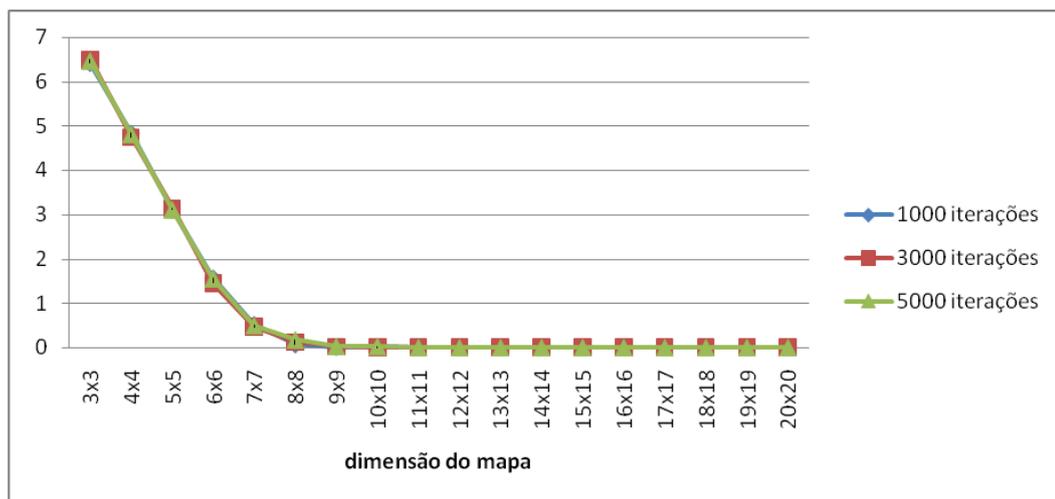


FIGURA 27 – ERRO MÉDIO QUADRÁTICO– FASE DE TREINAMENTO  
 FONTE: O autor (2012)

Nas Figuras 28 e 29 observamos os erro de quantização e o erro médio quadrático, alcançados durante a fase de testes da rede de Kohonen implementada neste trabalho.

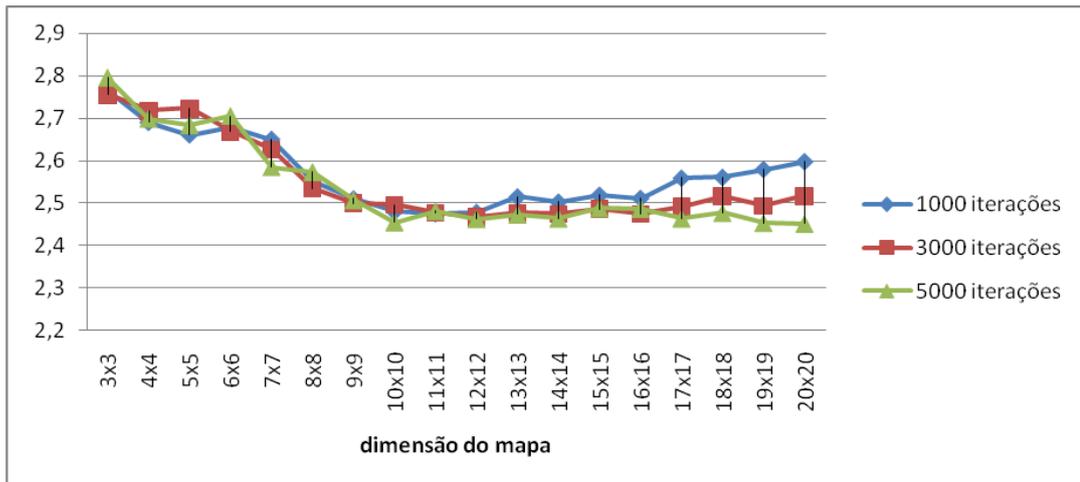


FIGURA 28 – ERRO DE QUANTIZAÇÃO – FASE DE TESTE  
 FONTE: O autor (2012)

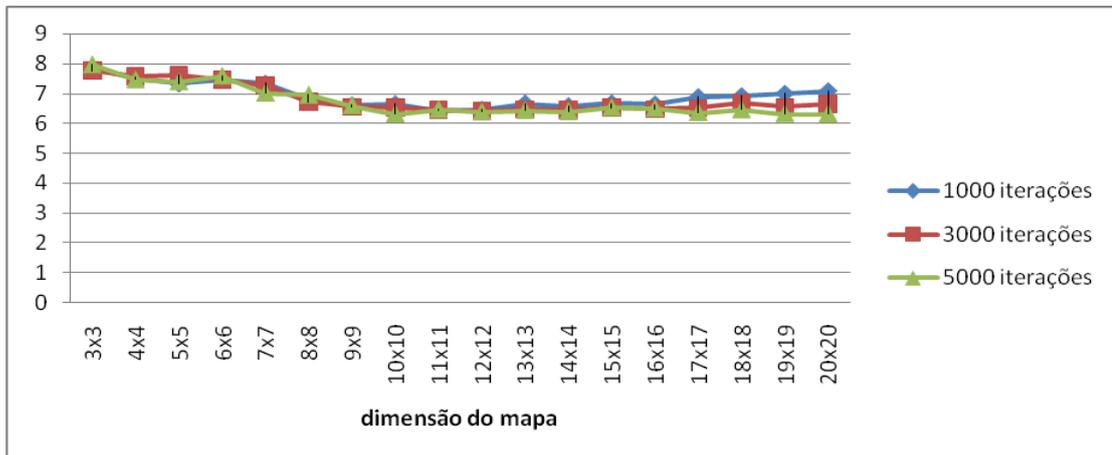


FIGURA 29 – ERRO MÉDIO QUADRÁTICO – FASE DE TESTE  
 FONTE: O autor (2012)

Os menores valores para os erros na fase de testes são verificados com 5000 iterações e seus valores oscilam minimamente para mapas de dimensão entre 10x10 e 20x20, sendo os menores valores verificados no mapa 10x10.

Analisando os gráficos do erro topológico, os menores valores na fase de treinamento (Figura 30) são encontrados em mapas de dimensão entre 10 e 14, com 5000 iterações. Já na fase de teste (Figura 31), o menor erro topológico ocorreu com o mapa 10x10, também com 5000 iterações.

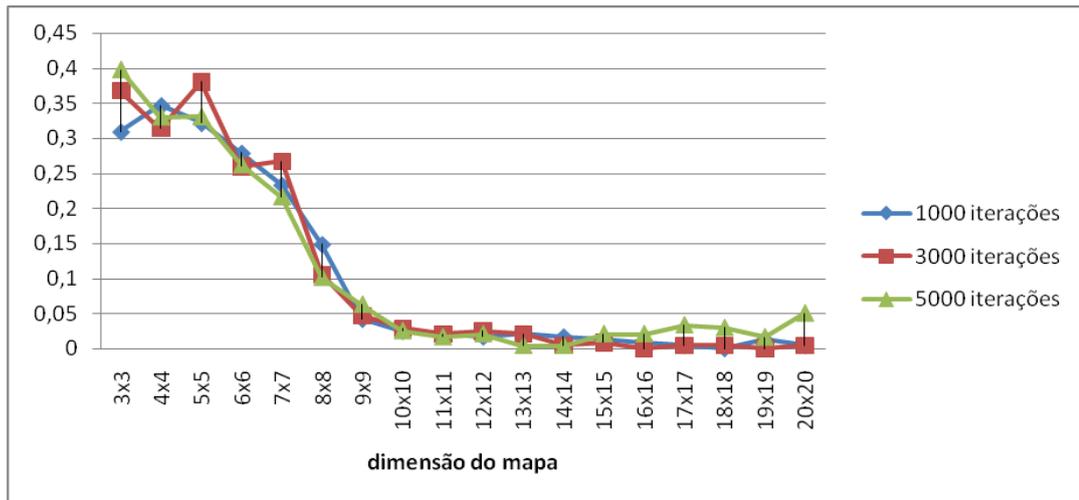


FIGURA 30 – ERRO TOPOLÓGICO – FASE DE TREINAMENTO  
 FONTE: O autor (2012)

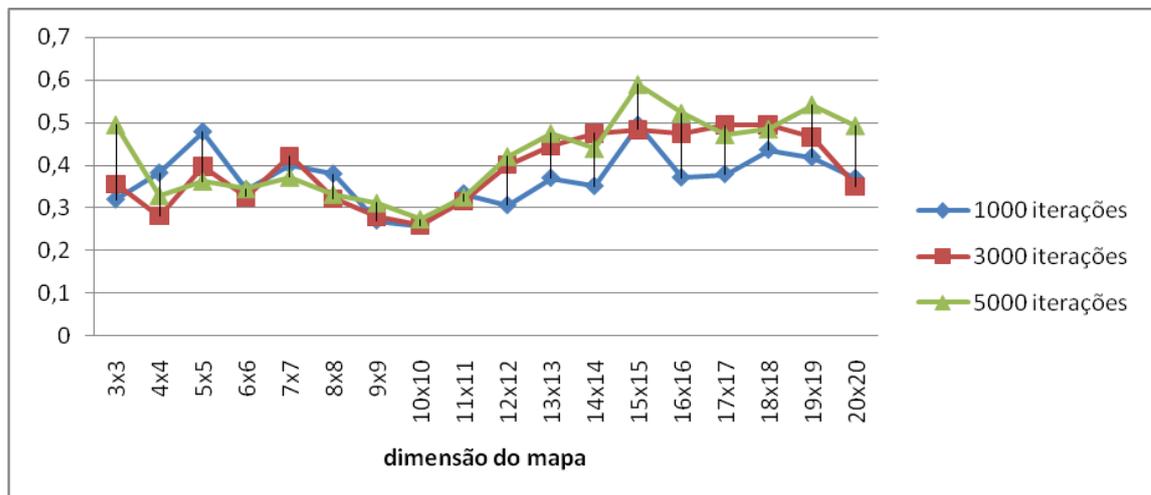


FIGURA 31 – ERRO TOPOLÓGICO – FASE DE TESTE  
 FONTE: O autor (2012)

O erro topológico representa o percentual de neurônios vencedores que não possuem o segundo vencedor em uma vizinhança de raio unitário centrada no neurônio vencedor. É importante que seu valor seja baixo, principalmente na fase de testes, pois mede quanto o mapa aproxima os padrões de entrada com vetores peso próximos.

A escolha do melhor mapa para o problema em estudo deve levar em conta os três erros encontrados. Por isso, neste trabalho optou-se trabalhar com o mapa 10x10, pois apresenta valores satisfatórios (considerando 5000 iterações) para todos os erros avaliados na fase de treinamento e é o que apresenta os menores valores para os três erros analisados, durante a fase de teste.

Nas Tabelas 10 e 11 encontram-se a média dos erros obtidos na fase de treinamento e de teste, respectivamente, após concluir todos os testes variando-se a dimensão dos mapas, o número de iterações e os pesos dos neurônios. Lembrando que os pesos são determinados randomicamente pelo programa, e cada mapa foi executado cinco vezes (usando as mesmas configurações do respectivo mapa durante o treinamento) gerando valores distintos para os pesos e conseqüentemente, encontrados valores distintos também para os três erros em análise.

TABELA 10 – ERROS NA FASE DE TREINAMENTO

	1000 iterações			3000 iterações			5000 iterações		
	Erro de quantização	Erro médio quadrático	Erro topológico	Erro de quantização	Erro médio quadrático	Erro topológico	Erro de quantização	Erro médio quadrático	Erro topológico
<b>3x3</b>	2,46	6,42	0,30	2,444	6,502	0,36	2,443	6,4658	0,39
<b>4x4</b>	2,036	4,838	0,34	2,058	4,753	0,31	2,040	4,8124	0,33
<b>5x5</b>	1,54	3,111	0,32	1,486	3,142	0,38	1,526	3,1104	0,33
<b>6x6</b>	0,81	1,566	0,27	0,792	1,456	0,26	0,808	1,5546	0,26
<b>7x7</b>	0,30	0,517	0,23	0,279	0,468	0,26	0,298	0,4984	0,21
<b>8x8</b>	0,12	0,065	0,14	0,065	0,117	0,10	0,105	0,174	0,10
<b>9x9</b>	0,008	0,009	0,04	0,018	0,021	0,04	0,026	0,02778	0,06
<b>10x10</b>	0,014	0,027	0,02	2,806E-07	1,01E-13	0,02	3,1E-07	0,0244	0,02
<b>11x11</b>	2,07E-07	4,35E-14	0,02	2,069E-07	4,35E-14	0,02	2,079E-07	4,39E-14	0,01
<b>12x12</b>	2,058E-07	4,30E-14	0,01	2,064E-07	4,33E-14	0,02	2,067E-07	4,34E-14	0,02
<b>13x13</b>	2,034E-07	4,21E-14	0,02	2,040E-07	4,23E-14	0,02	2,058E-07	4,31E-14	0,004
<b>14x14</b>	2,015E-07	4,23E-14	0,01	2,023E-07	4,16E-14	0,004	2,041E-07	4,23E-14	0,004
<b>15x15</b>	2,031E-07	4,19E-14	0,01	2,053E-07	4,29E-14	0,008	2,064E-07	4,33E-14	0,02
<b>16x16</b>	2,029E-07	4,19E-14	0,008	2,061E-07	4,32E-14	0	2,067E-07	4,22E-14	0,02
<b>17x17</b>	2,026E-07	4,18E-14	0,004	2,033E-07	4,22E-14	0,004	2,046E-07	4,26E-14	0,03
<b>18x18</b>	2,009E-07	4,12E-14	0	2,040E-07	4,23E-14	0,004	2,011E-07	4,16E-14	0,02
<b>19x19</b>	2,006E-07	4,10E-14	0,012	2,016E-07	4,14E-14	0	2,027E-07	4,19E-14	0,01
<b>20x20</b>	2,007E-07	4,10E-14	0,004	2,02E-07	4,15E-14	0,004	2,027E-07	4,15E-14	0,05

FONTE: O autor (2012)

TABELA 11 – ERROS NA FASE DE TESTE

	1000 iterações			3000 iterações			5000 iterações		
	Erro de quantização	Erro médio quadrático	Erro topológico	Erro de quantização	Erro médio quadrático	Erro topológico	Erro de quantização	Erro médio quadrático	Erro topológico
<b>3x3</b>	2,765	7,832	0,31	2,755	7,766	0,35	2,795	7,979	0,49
<b>4x4</b>	2,690	7,493	0,38	2,717	7,554	0,28	2,6984	7,468	0,32
<b>5x5</b>	2,661	7,325	0,47	2,722	7,624	0,39	2,6832	7,398	0,36
<b>6x6</b>	2,680	7,452	0,34	2,668	7,440	0,32	2,705	7,593	0,34
<b>7x7</b>	2,650	7,342	0,40	2,626	7,244	0,42	2,5848	7,015	0,37
<b>8x8</b>	2,551	6,807	0,37	2,533	6,718	0,32	2,5732	6,953	0,33
<b>9x9</b>	2,510	6,611	0,27	2,499	6,547	0,27	2,5068	6,595	0,31
<b>10x10</b>	2,481	6,647	0,25	2,495	6,518	0,25	2,455	6,309	0,27
<b>11x11</b>	2,476	6,425	0,33	2,476	6,443	0,31	2,4814	6,464	0,32
<b>12x12</b>	2,479	6,458	0,30	2,466	6,396	0,40	2,4628	6,380	0,42
<b>13x13</b>	2,515	6,668	0,37	2,476	6,457	0,44	2,4728	6,435	0,47
<b>14x14</b>	2,503	6,577	0,35	2,473	6,437	0,47	2,4638	6,397	0,43
<b>15x15</b>	2,519	6,673	0,49	2,486	6,518	0,48	2,4878	6,527	0,58
<b>16x16</b>	2,512	6,638	0,37	2,474	6,458	0,47	2,4868	6,499	0,52
<b>17x17</b>	2,559	6,884	0,37	2,491	6,503	0,49	2,4638	6,361	0,47
<b>18x18</b>	2,561	6,917	0,43	2,516	6,672	0,49	2,477	6,452	0,48
<b>19x19</b>	2,58	6,998	0,41	2,493	6,538	0,46	2,4534	6,320	0,54
<b>20x20</b>	2,598	7,087	0,36	2,516	6,647	0,35	2,4512	6,315	0,49

FONTE: O autor (2012)

Como nos testes acima mencionados os valores dos erros diminuíram com o aumento do número de iterações foram feitos novos testes para o mapa 10x10 aumentando o número de iterações para 6000, 7000 e 8000, considerando taxa inicial de aprendizado igual a 1 e raio da vizinhança igual ao diâmetro da rede. Durante o treinamento com o mapa 10x10, com 5000 iterações, observou-se que os menores valores para os erros na fase de teste eram conseguidos com a quinta variação dos pesos, por isso novos testes foram realizados usando esses mesmos pesos.

#### 4.4 RESULTADOS

Os erros encontrados após os novos testes realizados com o mapa 10X10 podem ser visualizados na seguinte tabela.

TABELA 12 – ERROS DO MAPA 10X10

	Fase de treinamento			Fase de teste		
	6000 iterações	7000 iterações	8000 iterações	6000 iterações	7000 iterações	8000 iterações
<b>Erro de quantização</b>	2,08E-07	2,08E-07	2,08E-07	2,511	2,509	2,505
<b>Erro médio quadrático</b>	4,39E-14	4,42E-14	4,41E-14	6,582	6,599	6,583
<b>Erro topológico</b>	0,021	0,021	0,063	0,14	0,47	0,28

FONTE: O autor (2012)

Observa-se o menor valor para o erro topológico na fase de teste com 6000 iterações. Os demais erros são considerados aceitáveis, já que estão entre os menores valores tanto para a fase de treinamento quanto para teste. Assim decidiu-se trabalhar com o mapa obtido após 6000 iterações, conforme ilustra a figura 32.

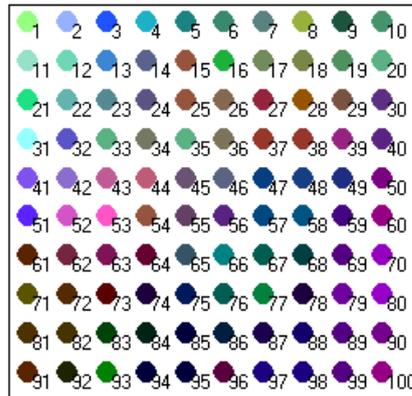


FIGURA 32 – REDE DE NEURÔNIOS APÓS 6000 ITERAÇÕES  
 FONTE: O autor (2012)

Fazendo a rotulagem dos neurônios, onde o neurônio vencedor é classificado segundo o padrão mais semelhante a ele, tem-se o mapa da figura 33, considerando: IMP - Impetigo, LTA - Leishmaniose Tegumentar Americana (Leishmaniose Cutânea), HL – Herpes Labial, ESP - Esporotricose, CBM - Cromoblastomicose e LMC – Larva Migrans Cutânea.

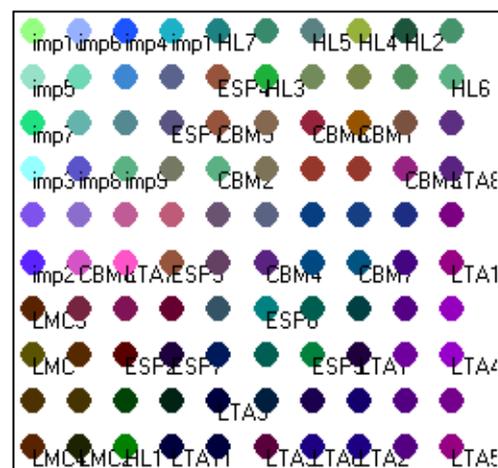


FIGURA 33 – ROTULAGEM DOS NEURÔNIOS  
 FONTE: O autor (2012)

Observa-se no mapa de Kohonen da figura 33 que a doença Impetigo recebeu basicamente a cor azul, a Leishmaniose Tegumentar Americana a cor roxa, variando entre tons claros e escuros, e a Larva Migrans Cutânea a cor marrom. Já o Herpes Labial mesclou tons de verde, e a Cromoblastomicose e a Esporotricose não separaram muito bem as suas cores, mesclando várias delas, entre elas o roxo, o marrom e o azul mais escuro.

A mistura de cores deve-se ao fato de se tratarem de doenças similares, com lesões semelhantes, onde um fator ou outro é o discriminante.

As doenças Cromoblastomicose e Esporotricose possuem lesões muito parecidas, onde apenas o tempo de evolução é diferente. Segundo o infectologista do HC, Prof. Dr. Flávio de Queiroz Telles Filho, ambas são diferenciadas somente após exame laboratorial da lesão. Por isso, no mapa de características percebemos a mistura de cores, parcialmente separadas quanto à localização no mapa. Há alguma semelhança entre elas com a Leishmaniose Cutânea, característica também observada no mapa misturando a cor roxa nas suas identificações.

Para realizar os testes e verificar a eficiência da rede treinada, é necessário fazer um agrupamento com os neurônios segundo a doença que representam. Lembrando que os neurônios representativos da mesma doença devem ter cores semelhantes. Para esta tarefa, usamos a U-matriz, mostrada na seção 3.4.4.1.

A U-matriz apresenta, através das células em escala de cinza do mapa, as distâncias entre os agrupamentos. A matriz apresentada é quase duas vezes maior que o mapa original, isso acontece devido à adição de neurônios entre todos os pares de unidades de mapa vizinhos, onde cada célula é definida como sendo um neurônio central cercado de outros neurônios, para delimitação dos agrupamentos. As cores variam do preto ao cinza claro, de acordo com uma escala de distâncias, onde a cor escura representa as maiores distâncias entre os neurônios e indicam as fronteiras entre os agrupamentos. Na Figura 34 temos a U-matriz formada após o treinamento da rede implementada.

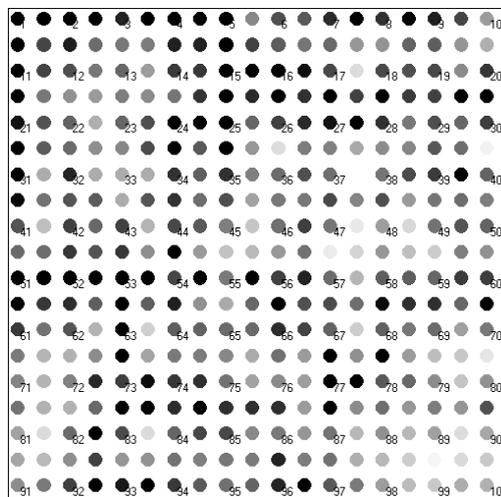


FIGURA 34 – U-MATRIZ APÓS 6000 ITERAÇÕES  
 FONTE: O autor (2012)

Na figura acima, os neurônios escuros indicam as fronteiras entre os agrupamentos. Confrontando esse mapa com aquele da Figura 33, pode-se formar manualmente a divisão entre os grupos (Figura 35). Teremos um total de seis grupos, relativos às seis doenças abordadas. As fronteiras são identificadas pelos círculos pretos, determinados pelos neurônios mais escuros da Figura 35.

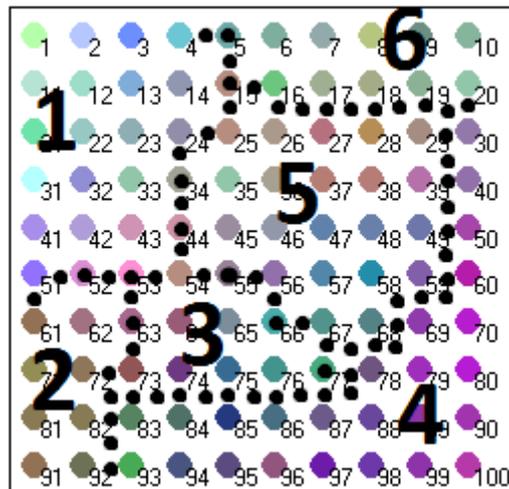


FIGURA 35 – SEPARAÇÃO MANUAL DOS AGRUPAMENTOS  
 FONTE: O autor (2012)

Na figura acima, o grupo 1 refere-se a doença Impetigo, o grupo 2 a Larva Migrans Cutânea, o grupo 3 a Esporotricose, o grupo 4 a Leishmaniose Tegumentar Americana, o grupo 5 a Cromoblastomicose e o grupo 6 ao Herpes Labial.

Na figura 36 são mostrados os neurônios vencedores após a fase de testes da rede usando os padrões reservados para essa finalidade. As fronteiras entre os agrupamentos são constatadas pelos círculos pretos e os neurônios vencedores para os padrões de teste são identificados pelos neurônios amarelos. A seção 4.1 mostra que os neurônios vencedores são destacados pela cor preta, mas para que não exista confusão com os círculos que indicam as fronteiras, optou-se por destacá-los aqui com a cor amarela.

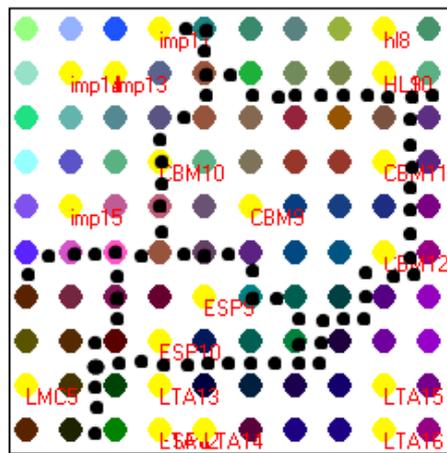


FIGURA 36 – MAPA DE TESTE APÓS TREINAMENTO DA REDE  
 FONTE: O autor (2012)

Na Tabela 13 temos o número do neurônio vencedor para cada padrão de teste e na Figura 37 vemos a rede de neurônio enumerada com o neurônio vencedor destacado de amarelo.

TABELA 13 – NEURÔNIO VENCEDOR PARA CADA PADRÃO DE TESTE

<b>PADRÃO DE TESTE</b>	<b>Nº DO NEURÔNIO VENCEDOR</b>
IMP11	4
IMP12	12
IMP13	13
IMP14	12
IMP15	42
CBM9	46
CBM10	34
CBM11	39
CBM12	59
ESP8	94
ESP9	65
ESP10	74
LMC	81
HL8	9
HL9	19
HL10	19
LTA12	94
LTA13	84
LTA14	95
LTA15	89
LTA16	99

FONTE: O autor (2012)

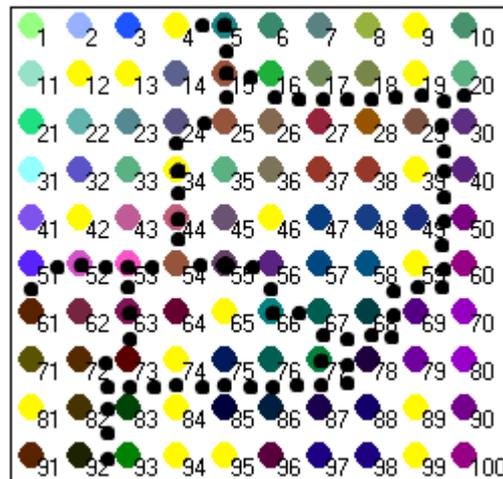


FIGURA 37 – MAPA DE TESTE APÓS TREINAMENTO  
 FONTE: O autor (2012)

Fazendo análise dos resultados da Tabela 13 com os agrupamentos formados pode-se verificar que os padrões de teste de Impetigo, Herpes Labial, Larva Migrans Cutânea, Cromoblastomicose e Leishmaniose Cutânea foram classificadas corretamente, obtendo 100% de acerto enquanto Esporotricose teve 66,7% de acerto, devido a sua semelhança com a Leishmaniose Tegumentar Americana e com a Cromoblastomicose, classificando-a erroneamente como uma dessas doenças. No geral, a rede obteve 94,5% de acerto no conjunto de testes.

Assim, a Rede Neural de Kohonen poderá auxiliar o médico especialista (infetologista) no diagnóstico de doenças infecciosas da pele, porém, nunca serão usadas como uma ferramenta substitutiva, pois a figura do médico é indispensável.

## CAPÍTULO V

### 5. CONSIDERAÇÕES FINAIS

#### 5.1 CONCLUSÕES

As Redes Neurais constituem uma técnica conhecida por simular o comportamento do cérebro humano, utilizando a tentativa e erro no processo de acumulação de novos conhecimentos.

No presente trabalho, as Redes Neurais foram exploradas para resolver o problema de diagnóstico de doenças infecciosas da pele, em particular Impetigo, Cromoblastomicose, Esporotricose, Leishmaniose Cutânea, Herpes Labial e Larva Migrans Cutânea.

Os dados de entrada da rede neural deste trabalho foram arranjados após leitura de textos médicos (BRASIL, 2005; BRASIL, 2000; COURA, 2005; GONTIJO, 2003; MACHADO-PINTO, 1994; MUNIZ, 2009; PERUCA, 2009; REY, 2001; RIBEIRO, 2006), conversas com o Prof. Dr. Flávio de Queiroz Telles Filho, professor e infectologista do Hospital de Clínicas (HC) da Universidade Federal do Paraná e de informações retiradas de prontuários do HC das doenças abordadas, do período de 1995 a 2011. Ressalta-se aqui que os dados dos prontuários são observações de vários profissionais pelos quais o paciente foi atendido; a descrição da doença é, muitas vezes, incompleta e, como o conhecimento a respeito da doença investigada está em constante evolução, informações antes desconsideradas (e por isso ausente no prontuário) passam a ser importantes no diagnóstico.

A Rede Neural foi treinada a partir do aprendizado não supervisionado. Com o objetivo de encontrar a melhor estrutura de rede, foi realizada, empiricamente, a variação dos seguintes parâmetros: taxa inicial de aprendizado, número de neurônios na camada de saída e o número de iterações.

Utilizou-se o algoritmo da Rede de Kohonen, empregada para o reconhecimento e classificação de padrões, baseada na competição dos neurônios pela representação da informação apresentada. É considerado “vencedor” o

neurônio que mais se assemelha ao padrão de entrada e este é reajustado para responder ainda melhor ao estímulo recebido.

Problemas encontrados na prática da clínica médica envolvem, geralmente, associação e reconhecimento de padrões, permitindo a aplicação da Rede Neural de Kohonen em diversas áreas da medicina.

A utilização da Rede Neural de Kohonen apresentou-se adequada no tratamento das informações dos 68 padrões de entrada. A base de dados foi implementada a partir das características das lesões na pele, dos dados (sintomas) de cada paciente, e do conhecimento do especialista (diagnóstico).

Verificou-se que o modelo apresentou um bom desempenho, onde os percentuais de acerto para os padrões de teste foram de 66,7 % para Esporotricose e 100% para as demais. A baixa taxa de acerto para Esporotricose deve-se ao fato de ter muitas características comuns com as doenças Cromoblastomicose e Leishmaniose Cutânea, classificando-a erroneamente como uma dessas doenças. Segundo Dr. Telles Filho (especialista em infectologia), a doença só é diagnosticada após exames laboratoriais. No geral, a taxa de acerto no conjunto de teste foi de 94,5%.

Quanto à separação dos agrupamentos em cores, verificou-se que Impetigo ficou com tons de azul, Herpes Labial com tons de verde, Leishmaniose Cutânea com tons de roxo e Larva Migrans Cutânea recebeu a cor marrom. O objetivo era fazer com que cada doença recebesse uma cor diferente das demais, mas devido à semelhança entre as doenças, seus neurônios receberam cores semelhantes também, fato observado para Esporotricose e Cromoblastomicose. Nesta etapa de validação, a rede errou em sua função de extratora de atributos nos casos em que até mesmo para os médicos especialistas essa diferenciação de padrões é dificultosa e confirmada apenas com exames complementares.

A Medicina pode se beneficiar dos sistemas de informação, como o estudado aqui, inclusive como ferramenta de suporte em consultório e clínicas médicas auxiliando e reafirmando o diagnóstico, bem como ferramenta de treinamento para futuros profissionais da área.

Sendo assim, este trabalho mostra que é possível desenvolver um software para auxiliar o médico na tomada de decisões no momento do diagnóstico. Convém ressaltar que a decisão final será sempre do médico. Os casos avaliados neste trabalho mostram uma boa aproximação entre os resultados obtidos e aqueles

esperados, no que diz respeito ao agrupamento de diagnósticos semelhantes, a partir dos sintomas apresentados à rede. Para que o sistema atue como uma verdadeira ferramenta de auxílio à tomada de decisão médica e se torne abrangente e eficiente, novos diagnósticos, exames laboratoriais e o próprio processo de inferência do software devem ser pesquisados.

## 5.2 TRABALHOS FUTUROS

Durante a realização deste estudo verificou-se a possibilidade de melhorias para possíveis estudos futuros, tais como:

- Treinar a rede ampliando os casos considerados, tal como analisar o local de desenvolvimento das lesões no corpo considerados incomuns;
- A separação dos diagnósticos em mais do que seis grupos distintos;
- Utilizar outras técnicas para visualizar os agrupamentos formados;
- O emprego de outras técnicas de Reconhecimento de Padrões para a resolução do problema, sempre objetivando a comparação dos resultados entre as diversas ferramentas, procurando pelo método que apresente um melhor desempenho;
- Estudar a viabilidade do sistema desenvolvido como ferramenta de ensino para graduandos da área de medicina.

## REFERÊNCIAS

ARAÚJO, D. P. de. **Determinação das concentrações plasmáticas e teciduais de itraconazol em pacientes com cromoblastomicose**. Dissertação (Mestre em Ciências Farmacêuticas) – Instituto de Ciência da Saúde, Universidade Federal do Pará, Belém, 2008.

AZEVEDO, F.M. de, DE OLIVEIRA, R.C. L. **Redes Neurais com Aplicações em Controle e em Sistemas Especialistas**. Florianópolis: Bookstore, 2000.

BALDIN, M. S. Z. **Redes Neurais na Orientação Profissional**. Dissertação (Mestre em Ciências) - Setores de Ciências Exatas e de Tecnologia, Universidade Federal do Paraná, Curitiba, 2002.

BASTOS, E. N. F. **Uma Rede Neural Auto-Organizável Construtiva para Aprendizado Perpétuo de Padrões Espaço-Temporais**. 137 f. Dissertação (Mestre em Ciência da Computação) – Instituto de Informática, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2007.

BRASIL. **Doenças infecciosas e parasitárias**: guia de bolso / Ministério da Saúde, Secretaria de Vigilância em Saúde. 6. ed. rev. Brasília : Ministério da Saúde, 2005.

BRASIL. **Manual de Controle da Leishmaniose Tegumentar Americana** / Ministério da Saúde, Fundação Nacional da Saúde. 5 ed. Brasília: Assessoria de Comunicação e Educação em Saúde, 2000.

CARVALHO, A. C. P. de L. F de. **Fundamentos de Redes Neurais Artificiais**. Rio de Janeiro: DCC/IM, COPPE/Sistemas, NCE/UFRJ, 1998.

COSTA, J.A.F., NETTO, M.L.A., **Segmentação do SOM Baseada em Particionamento de Grafos**. In: Proc.VI Brazilian Conf. on neural networks, São Paulo, pp. 451-456, 2003.

COSTA, J. A. F. **Classificação automática e análise de dados por redes neurais auto-organizáveis**. 345f. Tese (Doutor em Engenharia Elétrica) – Departamento de Engenharia de Computação e Automação Industrial, Universidade Estadual de Campinas, Campinas, 1999.

COURA, José Rodrigues. **Infecção e Doença Infecciosa**. Dinâmica das doenças infecciosas e parasitárias. Rio de Janeiro: Guanabara Koogan, 2005.

FREITAS, A.E. S.; CERQUEIRA, J. J. F.; FERREIRA, N. R.. **Uso de Algoritmos Genéticos no Desenvolvimento de Redes Kohonen**. In: Encontro Nacional de Inteligência Artificial, 4., 2003, Campinas.

FAUSETT, L. **Fundamentals of Neural Networks** – Architectures, Algorithms, and Applications. New Jersey: Prentice-Hall, 1994

FRANCISCO, C. A. C. **Rede de Kohonen**: uma ferramenta no estudo das relações tróficas entre espécies de peixe. 125 f. Dissertação (Mestre em Ciências) - Setores de Ciências Exatas e de Tecnologia, Universidade Federal do Paraná, Curitiba, 2004.

GONTIJO, B.; CARVALHO, M. DE L. R.; Leishmaniose Tegumentar Americana. **Revista da Sociedade Brasileira de Medicina Tropical**, v. 36, n. 1, p. 71-80, jan-fev. 2003.

GORRICHIA, J., & LOBO, V. **Visualização de Clusters em Dados Georreferenciados: uma abordagem com recurso ao Self-Organizing Map 3D**. Paper presented at the JOCLAD 2009, Faro, Portugal.

HAYKIN, S. **Redes Neurais**: Princípios e práticas. 2.ed. Porto Alegre: Bookman, 2001.

HEATON, JEFF. **Introduction to Neural Networks with Java**. Paperback, 2005.

KOHONEN, Teuvo. **Self-Organizing maps**. Berlin: Springer-Verlag, 1995.

LEE, J.A.; VERLEYSEN, M., Self-organizing maps with recursive neighborhood adaptation. **Neural Networks**, v. 15, n. 8-9, p. 993-1003, out. 2002.

MACHADO-PINTO, JACKSON. **Doenças infecciosas com manifestações dermatológicas**. Rio de Janeiro: MEDSI, 1994.

MARTINS, L. W; ASSIS, J. T; MONAT, A S. **Aplicação de Redes Neurais para o Diagnóstico Diferencial da Doença Meningocócica**. In: IX Congresso Brasileiro

em Informática em Saúde, Ribeirão Preto, SP, 2004. Disponível em: <http://www.sbis.org.br/cbis9/arquivos/627.PDF>.

MASSAD, Marin. **O prontuário eletrônico do paciente na assistência, informação e conhecimento médico**. São Paulo : H. de F. Marin, 2003.

MENDES, K.B. **O uso de Redes Neurais Artificiais no Diagnóstico Preditivo dos tipos mais freqüentes de Cefaléia**. 80 f. Dissertação (mestre em Ciências) – Setores de Ciências Exatas e de Tecnologia, Universidade Federal do Paraná, Curitiba, 2008.

MUNIZ, A. S.; PASSOS, J. P. Esporotricose humana: conhecendo e cuidando em enfermagem. **Rev. enferm. UERJ**, Rio de Janeiro, 2009 abr/jun; 17(2):268-72.

NOLETO, L. F.; **Métodos de segmentação de mapas Auto-Organizáveis para análise de agrupamento**. 86 f. Monografia (Bacharel em Ciência da Computação) – Departamento de Informática e Estatística, Universidade Federal de Santa Catarina, Florianópolis, 2007.

OLIVEIRA, D. N. et al. **Aplicação de mapas de Kohonen em imagem de satélite do semi-árido e comparação com o método da máxima verossimilhança**. In: Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 abril 2009, INPE, p. 7877-7884.

PEROBELLI, F. F. C. et al. **Pagamento de proventus versus preços de ações maduras e em expansão segundo Kohonen Maps**. Revista de Administração de Empresas, 2009, v. 49, n. 2, PP. 132-146, São Paulo.

PERUCA, L. C. B. et al. Larva migrans visceral e cutânea como zoonoses: revisão de literatura. **Vet. E Zootec**. P. 601-616, v. 16, n. 4, dez., 2009.

REY, L. **Parasitologia: Parasitos e Doenças Parasitárias do Homem nas Américas e na África**, 3 ed., Rio de Janeiro: Guanabara-Koogan, 2001, 856p.

REZENDE, J. M. **O uso da tecnologia no diagnóstico médico e suas conseqüências**. História da Medicina e Linguagem Médica 2002 Disponível em: <[http:// usuarios.cultura.com.br/jmrezende/tecnologia.htm](http://usuarios.cultura.com.br/jmrezende/tecnologia.htm)> Acesso em: 24 abr. 2012.

RIBEIRO, E. L. et al. Cromoblastomicose: doença presente da realidade populacional brasileira. **RBAC**, vol. 38(3): 189-192, 2006

SALA, Felipe Andrade. **Mapas de Kohonen na detecção de eventos epileptogênicos**. 112 f. Dissertação (Mestre em Engenharia Elétrica) – Curso de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, 2005.

SCHECHTER, M; MORANGONI, D. V. **Doenças infecciosas: Conduta Diagnóstica e Terapêutica**, Rio de Janeiro: Guanabara-Koogan, 1994, 500p.

SEWO, J.; SILVA, P. R. R. **Rede Neural Treinada com Algoritmo Não-Supervisionado no Contexto de Reconhecimento de Padrões**. 89 f. Monografia Final de Cursos. Universidade Federal de Mato Grosso do Sul, 2003.

SHORTLIFE, E. H. **Computer – based medical consultation: Mycin**. Amsterdam: Elsevier Scientific, 1976.

SHORTLIFFE, E. H. et al. **Medical informatics: computer applications in health care**. Reading, Mass.: Addison-Wesley, 1990.

SILVA, M. A. S. **Mapas auto-organizáveis na análise exploratória de dados geoespaciais multivariados**. 117 f. Dissertação (Mestre em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2004.

SIQUEIRA, P. H. **Uma nova abordagem na resolução do problema do caixeiro viajante**. 116 f. Tese (Doutor em Ciências) – Setores de Tecnologia e Ciências Exatas, Universidade Federal do Paraná, Curitiba, 2005.

SOARES, I. F.; SANT'ANA, I. B. **Classificação de padrões usando redes neurais de Kohonen**. 61 f. Monografia (Bacharel em Informática) – Setor de Informática, Universidade Católica de Salvador, Salvador, 2006.

SOUZA, C. G. e, SOUZA, L. de M. e. **O uso de redes neurais no diagnóstico de doenças reumatológicas**. 91 f. Monografia (Bacharel em Sistemas de Informação) – Departamento de Informática e Estatística, Universidade Federal de Santa Catarina, Florianópolis, 2004.

STEINER, M. T. A. **Redes Neurais**. Notas de aula apresentadas na disciplina Aplicações de Pesquisa Operacional, Universidade Federal do Paraná, 2006.

TAFNER, M.A.; XEREZ, M.; RODRÍGUES FILHO, I.W. **Redes Neurais Artificiais: Introdução e princípios da neurocomputação**. Blumenau: Eko e FURB, 1996.

TATIBANA, C. Y; KAETSU, D. Y. **Uma Introdução às Redes Neurais**. Disponível em <http://www.din.uem.br/~ia/neurais/>. Acesso em: 28 de março de 2011.

ULTSCH, A. Maps for the visualization of high-dimensional data Spaces. In: Workshop on Self-Organizing Maps. Kyushu: **Proceedings of Workshop on Self-Organizing Maps - WSOM**, p. 225-230, 2003.

WANGEHEIM, A. V. **Técnicas Subsimbólicas: Redes Neurais**. Notas de Aula. Disponível em: <http://www.inf.ufsc.br/~awangenh/RP/subsimbolicas.html>. Acessado em: 28 de março de 2011.

WYNS, B. et al. Prediction of diagnosis in patients with early arthritis using a combined Kohonen mapping and instance-based evaluation criterion. **Artificial Intelligence in Medicine**, v. 31, n. 1, p. 45-55, mai. 2004.

XU, B.; LI, S., Automatic Color Identification in Printed Fabric Images by a Fuzzy Neural Network. **AATCC Review**, USA, v. 2, n. 9, p. 42-45, 2002.

ZHANG, X.; LI, Y., **Self-Organizing Map as a new method for clustering and data analysis**. International Joint Conference on Neural Networks, 1993, Nagoya: Proceedings of International Joint Conference on Neural Networks – IJCNN'93, p. 2448 -2451.

ZHEN-PING,L.; YAOQI,Y.; BEHNAM, B. Analysis of the convergence properties of topology preserving neural networks. **IEEE Transactions on neural networks**, Irvine, v.4,no.2, p.207-220, March 1993.



