

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO


**UMA REDE NEURAL ARTIFICIAL PARA
CLASSIFICAÇÃO DE IMAGENS MULTIESPECTRAIS DE
SENSORIAMENTO REMOTO**

Dissertação submetida à Universidade Federal de Santa Catarina
para obtenção do grau de
Mestre em Engenharia de Produção



0.290.314-0

WALESKA NISHIDA



UFSC-BU

Florianópolis, Fevereiro de 1998

**UMA REDE NEURAL ARTIFICIAL PARA
CLASSIFICAÇÃO DE IMAGENS MULTIESPECTRAIS DE
SENSORIAMENTO REMOTO**

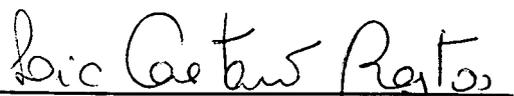
WALESKA NISHIDA

Esta dissertação foi julgada para obtenção do título de **Mestre em Engenharia de Produção**, área de concentração **Inteligência Aplicada**, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia de Produção

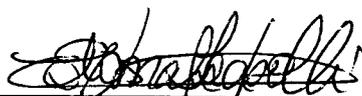


Prof. Ricardo Miranda Barcia, Ph.D.
Coordenador do Curso

BANCA EXAMINADORA:



Prof. Lia Caetano Bastos, Dra.
Orientadora



Prof. Edis Mafra Lapolli, Dra.



Prof. Fernando A. O. Gauthier, Dr.



Prof. Silvana Pezzi, MSc.

Aos meus pais Lintaro e Terezinha Nishida

AGRADECIMENTOS

À Prof. Lia Caetano Bastos, pela orientação, dedicação e amizade, que contribuíram para o desenvolvimento desta dissertação.

Aos membros da banca examinadora, que auxiliaram no aprimoramento deste trabalho com críticas e sugestões.

À CAPES, pelo imprescindível auxílio financeiro.

À Deus.

À minha família, meus pais Lintaro Nishida e Terezinha de Jesus Nishida e minhas irmãs Danielle Nishida e Aleksandra Nishida, pelo amor, dedicação, apoio e incentivo em todos os momentos.

Aos amigos Gladis T. Borges Oliveira e Emerson Pereira Raposo, pela convivência, companheirismo e dedicação.

À João Artur, Gertrudes Dandolini e Gilda Maria Friedlander, pela amizade e disposição em ajudar sempre.

Ao Prof. José Leomar Todesco, Tite, por toda a ajuda e tempo dedicados durante o desenvolvimento desta dissertação.

À Rodrigo B. Cabral e Edgar Fernandes, pelo auxílio prestado.

E à todos que contribuíram, de forma direta ou indireta, para a realização deste trabalho.

SUMÁRIO

| | |
|---|------|
| RESUMO | viii |
| ABSTRACT | ix |
| LISTA DE FIGURAS | x |
| LISTA DE TABELAS | xii |
| | |
| CAPÍTULO 1 | |
| INTRODUÇÃO | |
| 1.1. Origem do Trabalho | 01 |
| 1.2. Justificativa e Importância | 01 |
| 1.3. Objetivos | 02 |
| 1.4. Limitações | 02 |
| 1.5. Estrutura do Trabalho | 03 |
| | |
| CAPÍTULO 2 | |
| SENSORIAMENTO REMOTO | |
| 2.1. Introdução | 04 |
| 2.2. Definição de Sensoriamento Remoto | 04 |
| 2.3. Processo Fundamental do Sensoriamento Remoto | 05 |
| 2.3.1. A Fonte e o Alvo | 06 |
| 2.3.2. Os Sensores | 07 |
| 2.3.3. As Plataformas de Transporte | 09 |
| 2.4. Processamento Digital de Imagens | 11 |
| 2.4.1. Classificação de Imagens | 13 |
| a) Técnicas de Classificação Supervisionada | 14 |
| b) Técnicas de Classificação Não Supervisionada | 16 |
| c) Técnicas de Classificação Híbrida | 17 |
| 2.4.2. Precisão da Classificação | 18 |
| 2.5. Conclusão | 19 |

CAPÍTULO 3

REDES NEURAIS ARTIFICIAIS

| | |
|---|-----------|
| 3.1. Introdução | 21 |
| 3.2. Definições de Redes Neurais Artificiais | 21 |
| 3.3. O Modelo de Neurônio Artificial | 23 |
| 3.4. Estrutura e Funcionamento das RNAs | 27 |
| 3.5. Treinamento e Teste | 29 |
| 3.5.1. Aprendizado Supervisionado | 30 |
| 3.5.2. Aprendizado Não Supervisionado | 37 |
| 3.5.3. Aprendizado Híbrido | 38 |
| 3.6. Arquiteturas de RNAs Utilizadas em Problemas de Classificação de Dados | 38 |
| 3.6.1. Rede Neural com Função de Base Radial | 42 |
| 3.7. Classificador Neural x Classificador Estatístico | 46 |
| 3.8. Redes Neurais Artificiais para a Classificação de Imagens Multiespectrais | 47 |
| 3.9. Conclusão | 49 |

CAPÍTULO 4

UTILIZAÇÃO DE UMA RBF PARA A CLASSIFICAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO

| | |
|--|-----------|
| 4.1. Introdução | 51 |
| 4.2. Arquitetura de RNA Proposta | 51 |
| 4.3. Aplicação Prática da Arquitetura Proposta | 53 |
| 4.3.1. Preparação dos Dados Utilizados | 54 |
| 4.4. Resultados Obtidos da Classificação | 56 |
| 4.4.1. Resultados Obtidos para a Imagem de Florianópolis | 56 |
| a) RBF-Kohonen/Pseudo-inversa | 57 |
| b) RBF-K-médias/Pseudo-inversa | 60 |
| 4.4.2. Resultados para a Imagem de São Francisco do Sul | 61 |
| a) RBF-Kohonen/Pseudo-inversa | 63 |
| b) RBF-K-médias/Pseudo-inversa | 65 |

| | |
|---|----|
| 4.4.3. Classificações Utilizando Conjuntos de Treinamento Mínimos | 66 |
| 4.5. Discussão dos Resultados | 68 |
| CAPÍTULO 5 | |
| CONCLUSÕES E RECOMENDAÇÕES | |
| 5.1. Conclusões | 71 |
| 5.2. Recomendações a Trabalhos Futuros | 73 |
| ANEXO | 74 |
| REFERÊNCIAS BIBLIOGRÁFICAS | 83 |

RESUMO

A classificação de imagens provenientes de sensoriamento remoto tem se mostrado um dos mais importantes métodos na obtenção das informações utilizadas em processos como os de monitoramento de recursos terrestres, de gerenciamento de recursos renováveis, ou de mapeamento de uso do solo.

Como consequência das inovações tecnológicas constatou-se um aumento no volume dos dados manuseados e sistemas computacionais mais poderosos tornaram-se necessários para viabilizar a extração dessas novas informações disponíveis.

As dificuldades encontradas na obtenção de informações *a priori* a respeito dos dados a serem classificados apresenta-se como uma limitação à utilização de classificadores tradicionalmente empregados, baseados em conceitos estatísticos.

Neste trabalho, propõe-se a utilização de um classificador para imagens de satélites baseado na tecnologia das Redes Neurais Artificiais como uma alternativa aos classificadores habitualmente empregados. A arquitetura da Rede Neural com Função de Base Radial é desenvolvida, e aplicações práticas envolvendo imagens multiespectrais das regiões de Florianópolis e São Francisco do Sul, no estado de Santa Catarina, são apresentadas.

ABSTRACT

The classification of images from Remote Sensing has been one of the most important methods to get the information, which are used in procedures like the terrain resources monitoring, or the ground use mapping.

With the technological advances, the processed data had grown and powerful computer systems became needful.

Traditionally implemented classifiers, based on statistics concepts, presents limitations regarding the disposal *a priori* of information about data to be classified.

In this work, the utilization of satellite images classifier, based on the Artificial Neural Networks technology, are posed as an alternative to the more common classifiers. The Radial Basis Function is applied, and practical applications about the multispectral images of Florianópolis and São Francisco do Sul, at the Santa Catarina state, are presented.

LISTA DE FIGURAS

| | |
|---|----|
| Figura 2.1. Fases do Sensoriamento Remoto | 05 |
| Figura 2.2. Regiões do Espectro Óptico | 07 |
| Figura 2.3. Formação de vetores de pixels a partir de níveis de cinza das bandas | 13 |
| Figura 3.1. Neurônio biológico | 23 |
| Figura 3.2. Neurônio artificial | 24 |
| Figura 3.3. Estrutura básica de uma RNA | 28 |
| Figura 3.4. Padrões linearmente separáveis | 32 |
| Figura 3.5. Aprendizado pela Regra Delta | 34 |
| Figura 3.6. Padrões não linearmente separáveis | 35 |
| Figura 3.7. Algoritmo Backpropagation | 36 |
| Figura 3.8. (a) Mapa Auto-organizável de Kohonen com topologia linear | 40 |
| (b) Mapa Auto-organizável de Kohonen com topologia Bidimensional | 40 |
| Figura 3.9. Aprendizado de Kohonen | 41 |
| Figura 3.10. Arquitetura da RBF | 42 |
| Figura 3.11. Representação do campo receptivo do neurônio | 45 |
| Figura 4.1. Arquitetura de RNA proposta | 51 |
| Figura 4.2. Esquema de funcionamento da RBF proposta | 53 |
| Figura 4.3. Extração de cortes em imagens multiespectrais | 54 |
| Figura 4.4. Polígonos de amostras extraídas para o conjunto de treinamento | 55 |
| Figura 4.5. Processo de manipulação dos arquivos de imagem | 55 |
| Figura 4.6. Área selecionada para classificação da imagem de Florianópolis | 56 |
| Figura 4.7. (a) Imagem classificada pela RBF-Kohonen/Pseudo-inversa para a região Norte de Florianópolis | 59 |
| (b) Imagem classificada pela Máxima Verossimilhança para a região Norte de Florianópolis | 59 |

| | |
|--|----|
| Figura 4.8. (a) Imagem classificada pela RBF-K-médias/Pseudo-inversa para a região Norte de Florianópolis | 61 |
| (b) Imagem classificada pela Máxima Verossimilhança para a região Norte de Florianópolis | 61 |
| Figura 4.9. Área selecionada para classificação da imagem de São Francisco do Sul | 62 |
| Figura 4.10. (a) Imagem classificada pela RBF-Kohonen/Pseudo-inversa para São Francisco do Sul | 64 |
| (b) Imagem classificada pela Máxima Verossimilhança para São Francisco do Sul | 64 |
| Figura 4.11. (a) Imagem classificada pela RBF-K-médias/Pseudo-inversa para São Francisco do Sul | 66 |
| (b) Imagem classssificada pela Máxima Verossimilhança para São Francisco do Sul | 66 |
| Figura 4.12. (a) Imagem classificada pela RBF-Kohonen/Pseudo-inversa para a região Norte - Conjunto de treinamento mínimo | 67 |
| (b) Imagem classssificada pela Máxima Verossimilhança para a região Norte - Conjunto de treinamento mínimo | 67 |
| Figura 4.13. (a) Imagem classificada pela RBF-K-médias/Pseudo-inversa para São F. do Sul - Conjunto de treinamento mínimo | 68 |
| (b) Imagem classssificada pela Máxima Verossimilhança para São F. do Sul - Conjunto de treinamento mínimo | 68 |

LISTA DE TABELAS

| | |
|--|----|
| Tabela 2.1. Processamento Digital de Imagens - Préprocessamento | 11 |
| Tabela 2.2. Processamento Digital de Imagens - Técnicas de Realce | 12 |
| Tabela 4.1. Tabulação cruzada - Alvo x TESTE - Região Norte (RBF-Kohonen) | 58 |
| Tabela 4.2. Tabulação cruzada - RBF-Kohonen x Máx Ver (Região Norte) | 59 |
| Tabela 4.3. Tabulação cruzada - Alvo x TESTE - Região Norte (RBF-K-médias) | 60 |
| Tabela 4.4. Tabulação cruzada - RBF-K-médias x Máx Ver (Região Norte) | 61 |
| Tabela 4.5. Tabulação cruzada - Alvo x TESTE - São F. do Sul (RBF-Kohonen) | 63 |
| Tabela 4.6. Tabulação cruzada - RBF-Kohonen x Máx Ver (São F. do Sul) | 64 |
| Tabela 4.7. Tabulação cruzada - Alvo x TESTE - São F. do Sul (RBF-K-médias) | 65 |
| Tabela 4.8. Tabulação cruzada - RBF-K-médias x Máx Ver (São F. do Sul) | 66 |

Capítulo 1

INTRODUÇÃO:

1.1. ORIGEM DO TRABALHO:

A obtenção de informações específicas, através de técnicas de classificação de imagens provenientes de sensoriamento remoto, tem se mostrado fundamental no auxílio a tomada de decisões advindas de processos como o monitoramento de recursos naturais e o mapeamento de uso do solo.

Com o desenvolvimento tecnológico, dados adicionais, essenciais a obtenção de novos subsídios aos processos citados anteriormente, tornam-se disponíveis e sistemas mais poderosos, capazes de manusear, com certa agilidade, maiores quantidades de informação, são requeridos.

Classificadores tradicionais, baseados em informações estatísticas a respeito dos dados a serem classificados, são os que habitualmente encontram-se implementados na maioria dos softwares utilizados em processos de extração de informações de imagens provenientes de sensoriamento remoto.

Neste trabalho, propõe-se o desenvolvimento de uma Rede Neural Artificial utilizada para a classificação de imagens de satélites, como uma alternativa aos classificadores habituais baseados em conceitos estatísticos.

1.2. JUSTIFICATIVA E IMPORTÂNCIA DO TRABALHO:

Uma das características principais dos classificadores de imagens de satélites tradicionalmente empregados é que eles necessitam de informações detalhadas a respeito das estatísticas sobre as imagens a serem classificadas.

Este fato, mostra-se como uma limitação na utilização dos mesmos, já que processos de manipulação dos dados, anteriores à classificação propriamente dita,

tornam-se indispensáveis, ou, principalmente, quando nenhuma informação *a priori* a respeito dos dados está disponível.

A utilização de Redes Neurais Artificiais emerge como uma alternativa vantajosa aos classificadores baseados em conceitos estatísticos, uma vez que além de sua facilidade de implementação, nenhuma informação prévia sobre as estatísticas dos dados a serem classificados é exigida.

1.3. OBJETIVOS:

No presente trabalho, tem-se como objetivo principal, o desenvolvimento de uma Rede Neural Artificial com Função de Base Radial aplicada a classificação de imagens provenientes de Sensoriamento Remoto. Como objetivos específicos tem-se:

- 1) Desenvolver uma Rede Neural Artificial para a classificação de imagens de satélites, visando alcançar melhores subsídios para os processos de tomada de decisão procedentes do Sensoriamento Remoto;
- 2) Avaliar a performance de classificação desta Rede Neural em comparação ao classificador estatístico de Máxima Verossimilhança;

1.4. LIMITAÇÕES:

Durante o desenvolvimento do trabalho, algumas limitações apresentaram-se, dificultando uma avaliação mais precisa dos resultados obtidos.

A não disponibilidade de um estudo mais elaborado sobre as áreas utilizadas nos processos de classificação inibe uma avaliação mais precisa do desempenho dos classificadores estudados.

A dificuldade na aquisição de imagens captadas em diferentes situações climáticas e ambientais, bem como a não disponibilidade de um número maior de bandas, também limitaram avaliações mais completas dos classificadores utilizados.

Apenas duas imagens, provenientes de regiões e épocas diferentes foram utilizadas.

1.5. ESTRUTURA DO TRABALHO:

Esse trabalho está estruturado em cinco capítulos.

O primeiro capítulo apresenta a origem, importância, objetivos, limitações e estrutura do trabalho.

O Capítulo 2 descreve conceitos sobre a tecnologia de Sensoriamento Remoto.

No Capítulo 3 é realizada uma revisão de Redes Neurais Artificiais. São apresentadas definições, conceitos básicos e arquiteturas de redes existentes. Ênfase é dada à arquitetura da Rede Neural com Função de Base Radial. O capítulo apresenta, ainda, vantagens e desvantagens dos classificadores neurais em relação aos classificadores estatísticos tradicionais.

No Capítulo 4 é apresentada uma arquitetura de rede para processos de classificação de imagens de sensoriamento remoto. Uma aplicação prática é realizada e seus resultados são discutidos.

O Capítulo 5 apresenta as principais conclusões, recomendações e extensões para trabalhos futuros.

Finalmente, são apresentadas as referências bibliográficas utilizadas no desenvolvimento do presente trabalho.

Capítulo 2

SENSORIAMENTO REMOTO

2.1. INTRODUÇÃO

Informações sobre a superfície terrestre são de grande relevância. Inúmeras atividades estão diretamente relacionadas com essas informações; por exemplo, o gerenciamento de recursos renováveis, a classificação e a avaliação de recursos terrestres, o mapeamento de uso do solo e o monitoramento de áreas de vegetação e plantações.

Muitas destas informações podem ser obtidas da interpretação e análise de dados provenientes de sensoriamento remoto.

2.2. DEFINIÇÃO DE SENSORIAMENTO REMOTO

Sensoriamento remoto pode ser entendido como o meio pelo qual dados sobre determinado objeto, área ou fenômeno são obtidos através de dispositivos (sensores) colocados em satélites ou aeronaves.

Segundo JENSEN (1986), o sensoriamento remoto difere de outras técnicas de aquisição de dados sobre recursos terrestres, devido à utilização do sensor, que não está em contato físico direto com o alvo sob investigação.

Grande parte dos sensores remotos registram a radiação eletromagnética refletida ou emitida pelo alvo, entretanto, dependendo da aplicação para a qual se destinam, podem registrar também outros tipos de energia como a acústica ou a gravitacional.

De acordo com o escopo deste trabalho, enfatizaremos os sensores que trabalham em função da radiação eletromagnética, esclarecendo pontos

fundamentais do comportamento desta energia em relação ao alvo, à atmosfera e às fontes de radiação.

De forma sucinta, o sensoriamento remoto envolve as fases de aquisição e análise de dados.

O objetivo principal do sensoriamento remoto é expandir a percepção sensorial do ser humano, seja através da visão panorâmica proporcionada pela aquisição de informações aéreas ou espaciais, seja pela possibilidade de se obter informações inacessíveis à visão humana (CRÓSTA e SOUZA, 1997).

2.3. PROCESSO FUNDAMENTAL DO SENSORIAMENTO REMOTO

O processo fundamental do sensoriamento remoto pode ser visualizado na Figura 2.1.

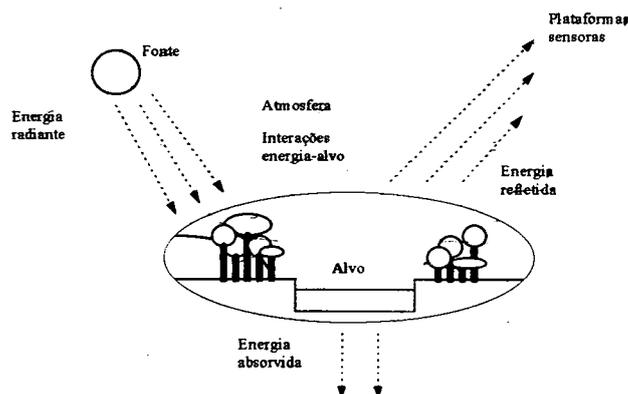


Figura 2.1: Esquema processual do sensoriamento remoto. Adaptado de JENSEN (1986)

Da análise da Figura 2.1 destacam-se alguns componentes básicos da fase de aquisição de dados:

1. a fonte de radiação eletromagnética;
2. o alvo que recebe, absorve e reflete esta radiação (e em alguns casos a emite);
3. o sensor;

4. a plataforma que transporta o sensor;
5. a atmosfera por onde se propaga a energia e, finalmente,
6. o produto resultante das interações entre radiação e alvo.

A fonte emite a energia que atinge o alvo após sua propagação na atmosfera. O alvo reflete porções de energia (que atingem as plataformas sensoras) e/ou absorve parte da energia recebida. Tais plataformas registram a energia proveniente do alvo que será processada para posterior análise e interpretação.

A seguir, serão descritos todos os elementos citados, constituintes do esquema processual do sensoriamento remoto.

2.3.1. A Fonte e o Alvo

Todo corpo com temperatura absoluta acima de zero Kelvin deve ser considerado como uma fonte emissora de energia em forma de radiação (MARTINS, 1994). Esta radiação, segundo a teoria do "Modelo Ondulatório" (ROSA, 1992), é propagada sob a forma de ondas eletromagnéticas que, de acordo com seu comprimento e frequência, representam a quantidade de energia¹ associada aos processos de emissão ou absorção pela matéria, ou alvo.

Qualquer fonte de radiação, caracteriza-se pelo comportamento de sua energia ao longo do espectro eletromagnético.

O alvo que recebe a radiação proveniente de uma fonte, tanto absorve como reflete certa quantidade de energia. No sensoriamento remoto da superfície terrestre, este fluxo radiante que deixa a Terra (alvo) em direção ao sensor, ou seja, o produto das interações ocorridas entre a radiação e o alvo, é o que se quer registrar.

¹ A energia emitida pela fonte (energia radiante), chega ao alvo (energia irradiante) com características diferentes das originais, devido às perdas ocorridas durante a propagação atmosférica. O mesmo ocorre com a energia captada pelo sensor.

2.3.2. Os Sensores

Os sensores atualmente disponíveis, podem ser classificados segundo vários critérios (NOVO, 1992): quanto à fonte de energia, quanto à região do espectro em que operam e quanto ao produto final obtido da transformação sofrida pela radiação detectada.

Quanto à fonte de energia, os sensores podem tanto ser denominados sensores ativos, que emitem sua própria radiação, como sensores passivos que captam a energia refletida pelo alvo.

Quando classificados segundo a região espectral na qual operam, os sensores que atuam na região óptica do espectro podem ser denominados de duas formas: como sensores termais ou como sensores de energia solar refletida. Sendo que os primeiros operam em uma faixa espectral que vai de $7\mu\text{m}$ a $15\mu\text{m}$, conhecida como infravermelho distante; e os demais, sensores de energia solar refletida, operam numa faixa de $0,38\mu\text{m}$ a $3,0\mu\text{m}$, que se subdivide em visível (de $0,38$ a $0,72\mu\text{m}$), infravermelho próximo (de $0,72$ a $1,3\mu\text{m}$) e infravermelho médio (de $1,3$ a $3,0\mu\text{m}$). A figura 2.2 ilustra o espectro óptico.

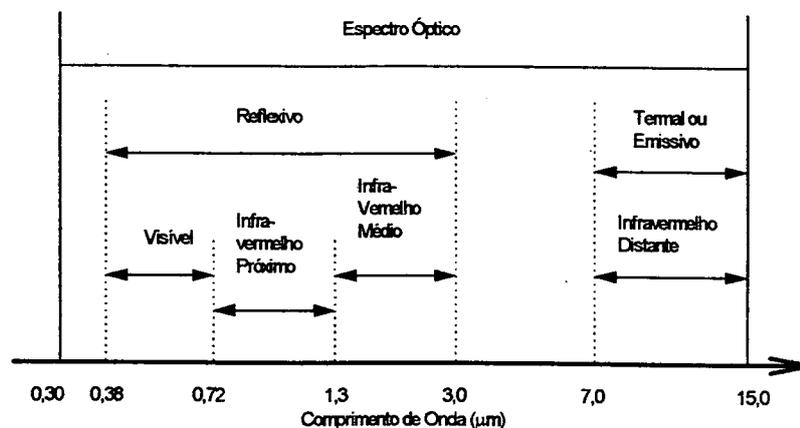


Figura 2.2: Regiões do Espectro Óptico. (NOVO, 1992).

Os sensores classificados em função do produto final obtido podem ser não imageadores ou imageadores. Os sensores não imageadores, como o próprio nome sugere, não produzem uma imagem da superfície investigada, mas dados numéricos ou gráficos importantes na aquisição de informações mais detalhadas a

respeito dos objetos encontrados na superfície. Entre os sensores não imageadores mais conhecidos estão os radiômetros de banda e os espectrorradiômetros. No caso de sensores imageadores, o processamento da radiação registrada pelo sensor, acarreta em imagens multiespectrais da superfície observada. A informação, neste caso, é obtida de forma mais global, a respeito de toda a região sob investigação.

Alguns sistemas imageadores conhecidos são os sensores fotográficos, os sensores de imageamento eletro-óptico e os sistemas de microondas.

Sensores fotográficos geram fotografias aéreas, e apesar de serem os primeiros equipamentos desenvolvidos para captura de dados, ainda possibilitam excelente informação espacial a respeito da superfície permitindo a produção de mapas em grandes escalas (STAR & ESTES, 1990).

Os sensores de imageamento eletro-óptico registram os dados em forma de sinal elétrico transmissível à distância. Caracterizam-se por possuir dois componentes básicos: o sistema óptico e o detector. O sistema óptico focaliza a energia proveniente da cena, sobre o detector, que produz o sinal elétrico que será processado. Os sensores eletro-ópticos podem ser classificados em dois subgrupos: os sensores de quadro (ou *frame*) e os de varredura.

Os sistemas de quadro, captam a cena toda em uma única operação, enquanto os de varredura captam a imagem num modo pixel a pixel. Os satélites da série LANDSAT, 1, 2, e 3, transportam sensores imageadores de quadro. Sensores MSS (Multispectral Scanner Subsystem) e TM (Thematic Mapper), transportados pelos LANDSAT 4 e 5, são de varredura mecânica. Os satélites dos programas SPOT (França), MOMS e MEOSS (Alemanha), transportam sensores de varredura eletrônica.

Os sistemas de microondas, são sensores imageadores ativos, bastante utilizados no sensoriamento remoto de recursos naturais. O mais conhecido exemplo de um sistema de microondas é o dos Radares de Visada Lateral (ROSA,

1992), nos quais a energia refletida na faixa de microondas, pode ser registrada em energia na faixa do visível e gravada em um filme.

Os sensores imageadores caracterizam-se também por parâmetros de operação utilizados na captura da imagem. As resoluções utilizadas, espacial e espectral, determinam quais as características da imagem final, determinantes na hora da compra (CRÓSTA, 1992).

A resolução espacial é uma medida inversamente proporcional à nitidez da imagem. Quando um sensor possui resolução espacial maior, significa que mais elementos da superfície imageada serão representados por um único pixel na imagem resultante, que, portanto, terá menor nitidez. Para sensores com resolução espacial de 30m, elementos do terreno dentro de áreas de 900m² (30x30m) terão resposta espectral idêntica.

A resolução espectral é medida em relação à largura das faixas espectrais, que quanto mais estreitas aumentam a capacidade do sensor de registrar pequenas variações do comportamento espectral.

2.3.3. As Plataformas de Transporte

Existem três níveis nos quais as plataformas que transportam os sensores podem estar localizadas (NOVO, 1992):

- o nível de laboratório,
- o nível de aeronaves (ou semi-orbital) e
- o nível orbital.

As plataformas em nível laboratorial, na prática, são pouco utilizadas. As proporções são bastante reduzidas e quase não há interferências ambientais nas interações energia-matéria. A área de estudo é bastante pequena, resumindo-se a praticamente um objeto como alvo.

A nível de aeronave, o alvo torna-se um arranjo de objetos numa cena. As plataformas utilizadas, neste caso, são aviões.

A nível orbital, uma região do terreno, determinada pela resolução espacial utilizada pelo sensor, é interpretada de acordo com a resposta espectral da integração dos diferentes objetos localizados no terreno. Neste nível os sensores são transportados por plataformas orbitais: os satélites artificiais e espaçonaves.

Dependendo do nível de aquisição dos dados, o tipo de produto resultante será diferente e, conseqüentemente, a metodologia de análise mudará.

Os dois principais sistemas orbitais de sensoriamento remoto de recursos naturais são: o LANDSAT e o SPOT.

O sistema LANDSAT, desenvolvido pela National Aeronautics and Space Administration (NASA), opera no Brasil desde 1973 (ROSA, 1992). O Instituto Nacional de Pesquisas Espaciais (INPE), é o responsável pela recepção, processamento e distribuição destes dados no Brasil.

Atualmente o satélite em operação é o LANDSAT 5 que transporta um sensor MSS (Multispectral Scanner Subsystem) e um sensor TM (Thematic Mapper).

O satélite do sistema SPOT (Sistem E Proboitoire de Observation de La Terre), lançado em 1986, foi concebido pelo Centre National d'Etudes Spatiales (CNES) e construído através de parcerias entre indústrias francesas (FRANZONI, 1993).

Os componentes principais do sistema orbital SPOT são basicamente os mesmos do sistema LANDSAT, um satélite para a captura dos dados e uma ou mais estações terrestres responsáveis pela recepção e processamento destes dados.

2.4. PROCESSAMENTO DIGITAL DE IMAGENS

Os sensores utilizados em sensoriamento remoto, desenvolveram-se paralelamente à área computacional. Atualmente, proporcionam produtos que incluem, além de fotografias aéreas e gráficos estatísticos sobre a região a ser analisada, imagens digitais ou passíveis de serem digitalizadas.

A função primordial do processamento digital de imagens é fornecer ferramentas computacionais para facilitar a identificação e a extração das informações contidas nas imagens, objetivando sua posterior análise e interpretação (CRÓSTA, 1992).

As tabelas 2.1 e 2.2, apresentam as etapas de pré-processamento e realce de imagens.

Tabela 2.1: Processamento Digital de Imagens - Pré-processamento

| Técnica | Objetivo | Formas |
|----------------------|--|---|
| Eliminação de Ruídos | Minimizar ruídos que afetam a qualidade da imagem | Técnicas de correção radiométrica minimizam as diferenças entre os níveis de cinza registrados. Algumas destas técnicas são: os filtros verticais, os filtros passa-baixa e o ajuste do histograma |
| Correção Atmosférica | Redução nos efeitos resultantes da interferência atmosférica sobre os níveis de cinza registrados | A técnica de correção mais elementar baseia-se na suposição de que o efeito atmosférico é aditivo. Com a determinação do sinal adicionado à imagem, é feita a subtração do mesmo, na área escolhida, em cada uma das bandas disponíveis |
| Registro de Imagens | Alinhar os pixels de duas ou mais imagens de geometria similar e que contenham os mesmos conjuntos de elementos. | Através da utilização de pontos de controle, que correspondem ao mesmo objeto nas duas imagens, novos níveis de cinza são calculados (reamostragem). As técnicas mais comuns de reamostragem são: vizinho mais próximo, interpolação bilinear e convolução cúbica |

Tabela 2.2: Processamento Digital de Imagens - Técnicas de Realce

| Técnica | Objetivo | Formas |
|--|---|--|
| Manipulação de Contraste | Redistribuição dos valores de níveis de cinza da imagem de forma que o contraste seja intensificado) | Ampliação de contraste, transformação linear por partes e realce linear com um percentual de saturação |
| Filtragem Espacial | Transformação nos valores de níveis de cinza de uma imagem, levando em consideração a vizinhança na qual o dado pixel está inserido | Filtros passa-baixa ou filtros passa-alta |
| Transformação IHS | Realçar as imagens intensificando as sensações de brilho, cor e saturação | Com a utilização dos valores referentes aos canais RGB originais, faz-se o cálculo para os canais IHS, e a partir de então calcula-se os novos canais RGB, transformados. Esta nova informação define as cores por três atributos (Intensidade, Matiz e Saturação), ao invés de três cores primárias (Vermelho, Verde e Azul). |
| Transformação por Componentes Principais | Melhorar a visualização dos objetos de interesse, reduzindo a correlação existente entre as várias bandas | Através da combinação linear, obtém-se uma diminuição na quantidade de informações redundantes |

Como citado anteriormente, para se tornarem informações realmente úteis, os dados provenientes de sensoriamento remoto necessitam ser processados. A classificação de imagens multiespectrais pode ser considerada como um dos processamentos mais efetivamente empregados e que melhores recursos oferece para a fase de análise e interpretação.

2.4.1. Classificação de Imagens

De forma geral, as técnicas de classificação de imagens de sensoriamento remoto atuam sobre uma determinada cena considerando suas várias bandas espectrais.

Os vetores de níveis de cinza para cada pixel nas bandas selecionadas são “comparados”, e os pixels com níveis de cinza mais similares segundo uma regra de decisão, tendem a ser classificados em uma mesma categoria. A figura 2.3 ilustra a formação de um vetor de níveis de cinza de um pixel multiespectral.

Durante o processo de classificação digital podem ser distintas três fases: a fase de identificação das classes, a fase de atribuição dos pixels a determinada classe e a fase que apresenta os resultados obtidos.

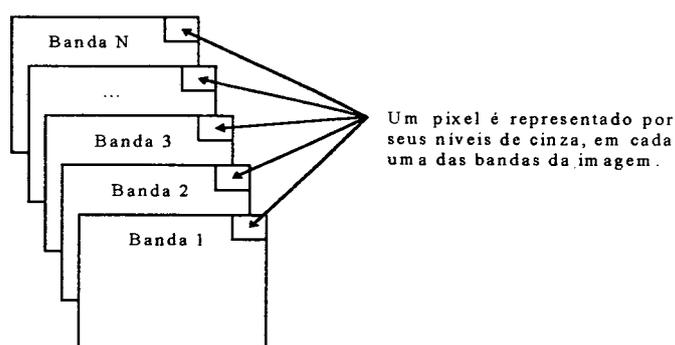


Figura 2.3: Um pixel é formado pela consideração de seus níveis de cinza em todas as bandas selecionadas para a classificação (RICHARD, 1986).

Na identificação das possíveis classes em uma cena, há a necessidade de estudar a área imageada e através de informações geográficas, fotografias aéreas, mapas e pesquisas de campo, definir as classes existentes naquela região.

A fase de atribuição dos pixels a determinada classe é de grande importância e complexidade no processo classificatório. Atualmente são muito empregados sistemas de decisão que utilizam conceitos de estatística. Entretanto, com o aumento no volume de informações obtidas por sensoriamento remoto, advindas do recente desenvolvimento das técnicas de coletas de dados, técnicas de classificação inovadoras, mais poderosas e baseadas em conceitos da ciência de computadores, têm emergido (BENEDIKTSSON, SWAIN & ERSOY, 1990; BINAGHI & RAMPINI, 1993, KIM & KIM, 1994; YOSHIDA & OMATU, 1994; CHAKRABARTI,

BINDAL & THEAGHARAJAN, 1995; KIM *et all*, 1995, CHENG *et all*, 1995; CHONG, JIA & MITAL, 1995; HOLMSTRÖM *et all*, 1997, entre outros).

Pode-se dividir as técnicas de classificação em três grupos principais: o das técnicas de classificação supervisionada, o de classificação não supervisionada e o de classificação híbrida.

a) Técnicas de Classificação Supervisionada

As técnicas de classificação supervisionadas baseiam-se na disponibilidade de uma amostra representativa de cada classe identificada. Estas amostras são informações a respeito do comportamento médio das classes e podem ser denominadas como "pixels de treinamento" do sistema (NOVO, 1992). Tais pixels de treinamento são, portanto, exemplos que o sistema de classificação toma como referência para decidir a qual classe cada pixel da imagem deve ser designado.

A seleção das amostras de treinamento é essencial para que o processo classificatório seja bem sucedido, é importante que as amostras sejam bastante homogêneas.

Quando são utilizadas técnicas estatísticas de classificação, as amostras de treinamento devem ser grandes o suficiente para que possa ser feita a estimativa das características espectrais da classe de interesse. A partir de então, no processo de classificação, todos os pixels, pertencentes ou não às amostras de treinamento deverão ser designados à classe para a qual a "probabilidade" de pertencerem é maior (LAPOLLI, 1994).

Alguns dos métodos estatísticos de classificação supervisionada mais conhecidos são, segundo JENSEN (1986): o da máxima verossimilhança, o do paralelepípedo e o da distância mínima.

Entre estes métodos, o da máxima verossimilhança é o mais difundido; ele pressupõe que os níveis de cinza de cada classe seguem uma distribuição normal multivariada. Este classificador avalia as probabilidades que um determinado pixel tem de pertencer às classes identificadas e o designa àquela cuja a probabilidade é maior.

No método do paralelepípedo os pixels classificados dentro de uma categoria (C) são aqueles com níveis de cinza que encontram-se dentro de um certo limite, determinado pelo cálculo do valor médio dos níveis de cinza para cada classe (M_C) e seu desvio padrão (DP_C). Assim, os pixels que estiverem dentro do limite que vai de ($M_C - DP_C$) até ($M_C + DP_C$), são classificados como pertencentes à classe C. Este método é bastante eficiente, entretanto, pode haver sobreposição de áreas limítrofes, gerando ambigüidade na classificação. Neste caso o pixel normalmente é atribuído à primeira classe ou à classe para a qual possui a distância mínima em relação à média dos níveis de cinza.

O método da distância mínima também considera o pixel resultante da média dos níveis de cinza para cada classe em todas as bandas. São calculadas as distâncias Euclidianas entre determinado pixel (x) apresentado ao sistema e o pixel médio de cada uma das classes. Como o próprio nome sugere, o pixel apresentado é classificado na categoria para a qual a distância Euclidiana resultou num valor mínimo. Há casos, no entanto, em que este mínimo valor da distância Euclidiana ainda é muito elevado e mesmo o pixel estando muito distante de todas as categorias ele é classificado. Para evitar este inconveniente, é necessário que seja estabelecido uma distância máxima que permita ao pixel ainda ser classificado. Caso este limite seja ultrapassado, o pixel é atribuído a uma categoria não classificada.

A dificuldade no estabelecimento de funções de probabilidade adequadas para as variáveis envolvidas nos processos de classificação estatísticos é um fator de descontentamento na elaboração destes sistemas. A grande quantidade de dados necessários, o levantamento das estatísticas sobre os dados obtidos e, em

certas ocasiões, as informações insuficientes, são responsáveis pela não obtenção de uma boa performance de classificação.

Classificadores não baseados em conceitos estatísticos, gradativamente vem se estabelecendo e resultados satisfatórios têm sido apresentados (LOGAN, RITTER & BRYANT, 1990; FIERENS, *et all*, 1994; HEPNER *et all*, 1990; CHEN *et all*, 1995; HOLMSTRÖM *et all*, 1997).

b) Técnicas de Classificação Não Supervisionada

A classificação não supervisionada é a opção mais adequada quando a área investigada é desconhecida, ou quando suas características não são bem definidas.

Neste método de classificação, os padrões dominantes que ocorrem em uma imagem são extraídos e agrupam-se “naturalmente” definindo as classes existentes no terreno.

Alguns dos algoritmos estatísticos de classificação não supervisionada mais conhecidos são o das k-médias (*k-means*), o do líder, e o da busca pelo pico do histograma.

O algoritmo das k-médias (ANDERBERG, 1973 e HARTIGAN, 1975), inicialmente particiona o conjunto de pixels em k grupos, faz a média de cada grupo, e em seguida calcula a distância Euclidiana entre cada pixel do grupo e a média calculada. O erro, referente ao somatório destas distâncias, tende a ser minimizado pela movimentação de pixels entre os grupos até que se atinja o mínimo erro possível e os pixels não possam mais ser movimentados. No algoritmo das k-médias, para diferentes partições iniciais dos pixels têm-se diferentes agrupamentos finais.

Na classificação pelo algoritmo do líder (BASTOS *et all*, 1993), uma partição também é construída e distâncias são calculadas. Entretanto, ao invés da média, define-se um pixel líder em cada grupo. Os pixels são então designados ao grupo

que possui o líder para o qual estão a uma distância inferior a um limite estipulado. Os pixels que não estiverem suficientemente próximos a nenhum dos líderes existentes são designados a uma nova classe criada com um novo líder. Um inconveniente deste algoritmo é que os primeiros grupos analisados são sempre maiores pois são comparados a uma quantidade de pixels maior.

A técnica da seleção pelo pico do histograma (EASTMAN, 1995) equivale a buscar picos em um histograma, onde um pico é definido como um valor com maior frequência que a de seus vizinhos laterais. Uma vez que os picos tenham sido identificados, todos os valores observados são associados ao pico mais próximo. Em consequência, as divisões entre as classes tendem a cair no ponto médio entre os picos.

c) Técnicas de Classificação Híbrida:

Técnicas de classificação de dados híbridas, são a utilização conjunta das duas formas de classificação inicialmente descritas: a supervisionada e a não supervisionada.

Normalmente, a utilização de um processo de classificação inicial não supervisionado, favorece a obtenção de informações a respeito dos dados, utilizadas em procedimentos de classificação supervisionada mais elaborados.

Técnicas de classificação híbridas podem, portanto, ser consideradas relativamente mais eficientes e confiáveis do que técnicas de classificação, supervisionada ou não supervisionada, utilizadas isoladamente.

2.4.2. Precisão da Classificação

A fim de avaliar a performance do classificador utilizado, é calculada uma medida de precisão dos resultados, possibilitando a atribuição de um nível de confiança à imagem classificada.

A precisão pode ser medida tomando-se como base a “verdade terrestre”, conhecida a partir de trabalhos de campo, da interpretação de fotografias aéreas e ainda de informações geográficas a respeito do terreno. São comparadas a precisão dos mapas que contenham a verdade terrestre e a dos obtidos pela classificação, num modo pixel a pixel. É necessária a identificação das classes em ambos os mapas, para a formação posterior de uma “matriz confusão”.

Normalmente a matriz confusão é da forma $m \times m$, sendo que m representa o número de classes definidas. Sua diagonal compreende o número de pixels corretamente classificados, suas linhas as classes da verdade terrestre e suas colunas as classes do mapa obtido pela classificação.

Uma das características mais importantes destas matrizes é o fato de resumirem os erros de inclusão (pixels que não pertencem à classe e foram a ela atribuídos) e os erros de omissão (pixels que pertencem à classe em questão e não foram a ela atribuídos).

A partir da matriz confusão, pode-se calcular um índice de precisão da classificação total. O mais conhecido e indicado para classificações temáticas por representar toda a matriz confusão, é o índice Kappa (\hat{k}) (GONG & HOWARTH, 1992):

$$\hat{k} = \frac{p_o - p_c}{1 - p_c} \quad (2.1)$$

onde p_o representa a proporção de unidades observadas com a classificação correta, e p_c representa a proporção esperada de unidades com classificação correta. Sendo,

$$p_o = \sum_{i=1}^m p(i,i) \quad \text{e} \quad (2.2)$$

$$p_c = \sum_{i=1}^m p(i,+)p(+,i) \quad (2.3)$$

onde o índice “ i ” é referente à classe em questão, com $i = 1, \dots, m$ (onde m representa o total de classes avaliadas) e “+” referente ao índice da classe posterior à classe i , ou seja, $i+1$

Sendo assim, se i representa a classe 1, $p(i,i)$ representará o total de pixels classificados na classe 1, $p(i,+)$, o total de pixels classificados na classe 2, mas pertencentes à classe 1, e $p(+,i)$, o total de pixels classificados na classe 1, mas pertencentes à classe 2.

Com o intuito de verificar a precisão da classificação de forma mais específica, classe a classe, GONG & HOWARTH (1992) descrevem o coeficiente Kappa condicional:

$$k_i = \frac{p(i,i) - p(i,+)p(+,i)}{p(i,+) - p(i,+)p(+,i)} \quad (2.4)$$

2.5. CONCLUSÃO

O sensoriamento remoto, desempenha um papel fundamental em áreas bastante distintas de atuação, principalmente no mapeamento, cadastramento e monitoramento de recursos naturais.

Com a utilização de satélites, equipados com sensores de alta precisão, imagens digitais ou digitalizadas tornaram-se produtos acessíveis, gerando a necessidade de se desenvolver sistemas computacionais capazes de manusear um volume de informações mais significativo.

Técnicas de processamento de imagens digitais, tais como as técnicas de pré-processamento (onde os ruídos e distorções são minimizados), técnicas de realce (que melhoram a qualidade visual da imagem) e técnicas de classificação (que possibilitam análises menos subjetivas que as visuais), objetivam viabilizar os

processos de análise e interpretação de dados obtidos em grandes quantidades, extraindo das imagens originais, informações adicionais.

Entre as técnicas de processamento de imagens digitais citadas, a classificação pode ser considerada a mais importante na obtenção de informações específicas.

Para que se estabeleça um nível de confiança no processo classificatório utilizado, os resultados da classificação devem ser avaliados. As formas de avaliação mais comuns são o índice Kappa e a matriz confusão.

Capítulo 3

REDES NEURAIS ARTIFICIAIS

3.1. INTRODUÇÃO

Entender o funcionamento do cérebro humano sempre foi um desafio à comunidade científica. Sua agilidade e eficiência constituem o objetivo a ser alcançado por sistemas da Inteligência Artificial (IA), que baseia seus estudos na simulação computacional de aspectos da inteligência humana.

Os sistemas conexionistas, emergiram como um ramo da IA, cujo propósito primordial era entender o funcionamento do cérebro humano e assim desenvolver uma estrutura artificial nos mesmos moldes, com capacidade de processamento, habilidade e credibilidade semelhantes à da estrutura cerebral biológica.

Tarefas como a classificação de padrões, são executadas pelo cérebro humano, de forma rotineira, entretanto, os sistemas computacionais conhecidos, ainda estão longe de alcançar seu desempenho.

Mesmo tendo como objetivo a modelagem de uma estrutura tão complexa, as Redes Neurais Artificiais (RNAs) são facilmente compreendidas, e mostram-se satisfatórias em diversas aplicações (LIPPMAN, 1989). Neste capítulo será dada uma introdução à definição e a alguns conceitos de RNAs, assim como serão apresentadas características gerais das principais arquiteturas desenvolvidas e a arquitetura da Rede Neural com Função de Base Radial, utilizada neste trabalho.

3.2. DEFINIÇÕES DE REDES NEURAIS ARTIFICIAIS

Desde que as RNAs começaram a surgir como uma nova perspectiva à IA, muitas definições foram elaboradas com o intuito de esclarecer seus objetivos. Abordagens semelhantes e analogias ao sistema nervoso humano prevaleceram em praticamente todas elas. A seguir, algumas definições básicas de Redes Neurais Artificiais serão descritas.

NELSON & ILLINGWORTH (1990), definem as RNAs como sendo técnicas inovadoras de processamento de informações, que têm como objetivo básico, simular, em computadores, o funcionamento do sistema nervoso biológico.

Seguindo a mesma linha, FAUSETT (1994) também define as RNAs como sistemas de processamento de informações que possuem características de funcionamento similares às das redes neurais biológicas; mais especificamente, generalizações de modelos matemáticos da biologia neural.

Ambas as definições citadas anteriormente, podem ser complementadas e melhor compreendidas pela análise da afirmativa de HAYKIN (1994), que diz que:

“As RNAs são processadores massivamente paralelos e distribuídos que têm uma propensão natural para armazenar o conhecimento proveniente da experiência e torná-lo útil. Desta forma, assemelhando-se ao cérebro humano em dois aspectos:

- 1. o de que o conhecimento é adquirido pela rede através de um processo de aprendizado e*
- 2. o de que as intensidades das conexões entre neurônios, conhecidas como pesos sinápticos, são usadas para armazenar o conhecimento.”*

Esta capacidade de “aprender”, destacada por Haykin em sua definição, também é decisiva para TAFNER, XEREZ & FILHO (1996) basearem seus estudos. Segundo os autores, “o modelo neurológico é programado para aprender” e aprender é uma capacidade que a RNA possui devido à interconexão entre seus neurônios, que ocorre em um grau similar ao da interconexão ocorrida com os neurônios biológicos e não encontrado em técnicas de cálculo convencionais.

Portanto, uma RNA pode ser definida como uma estrutura computacional que tem como objetivo permitir a implementação de modelos matemáticos que representem a forma como o cérebro humano processa as informações que adquire.

3.3. O MODELO DE NEURÔNIO ARTIFICIAL

No cérebro humano, dois tipos de células principais podem ser identificadas: os neurônios e a glia. Estudos recentes como o do Dr. Frank Pfrieger e Dra. Barbara Barres (WELLS, 1997), demonstram que grande parte da eficiência do cérebro deve-se a produção pela glia de uma proteína ou fator químico, que “envolve” os neurônios e aprimora a transmissão de impulsos elétricos, fortalecendo as conexões sinápticas.

Segundo os autores, o enfraquecimento das conexões sinápticas, normalmente, é responsável por perdas de memória e outros distúrbios cerebrais, tal como o Mal de Alzheimer. Portanto, o fortalecimento das conexões é desejável e essencial ao correto funcionamento do cérebro.

Apesar das afirmações de que células nervosas conectadas sem a presença do fator glial, normalmente, são enfraquecidas e falhas, as RNAs ainda não oferecem uma modelagem para a atuação da glia, e atribuem as funções primordiais do cérebro aos neurônios.

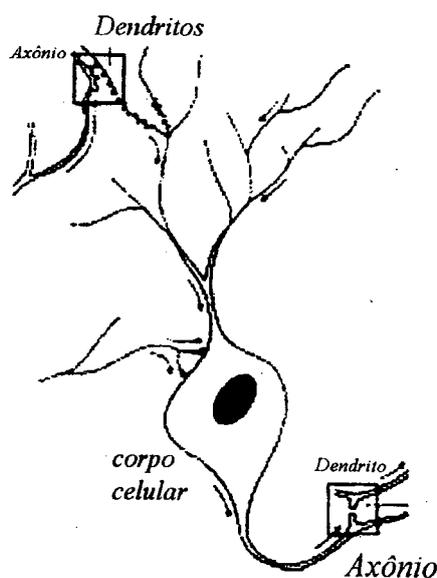


Figura 3.1: O neurônio biológico em uma visão geral (MACHADO, 1980).

Os neurônios biológicos apresentam-se de várias formas, entretanto, de maneira geral, possuem os seguintes elementos principais: o corpo celular, as ramificações de entrada (dendritos), a ramificação de saída (axônio) e as conexões sinápticas que interligam os neurônios, conectando dendritos a axônios (Figura 3.1).

Os neurônios artificiais são estruturas lógicas que têm o objetivo de simular o funcionamento de um neurônio biológico, fazendo com que a rede atue de forma indutiva (PACHECO, 1996).

Há aproximadamente meio século, W. S. McCulloch e W. Pitts (HAYKIN, 1994) iniciaram a modelagem de um neurônio biológico, gerando o modelo de neurônio artificial, atualmente utilizado no desenvolvimento de RNAs.

O neurônio de McCulloch e Pitts pode ser melhor entendido pela análise da Figura 3.2. As entradas recebidas pelo neurônio (x_i com $i=1, \dots, p$) são combinadas através de uma soma ponderada ($u_j = \sum_{i=1}^p w_{ji} x_{ji}$) que serve como argumento para a função de transferência ($\varphi(\cdot)$). Essa função representa a saída do neurônio artificial, que neste modelo é uma saída binária.

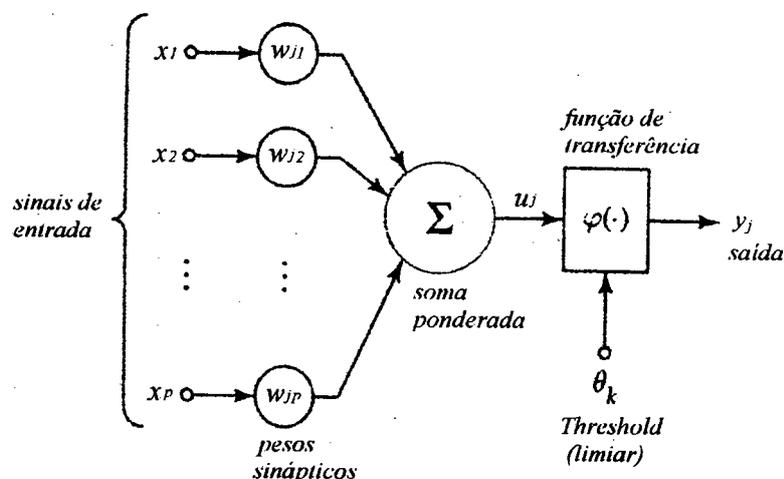


Figura 3.2: Modelo de neurônio artificial. No caso do modelo de McCulloch e Pitts, $\varphi(\cdot)$ é uma função de saída binária, (TODESCO, 1995).

O parâmetro externo θ , definido como “*threshold*” ou limiar, normalmente é utilizado como um valor abaixo do qual a saída do neurônio é nula. Ele pode ser definido como um peso referente a uma entrada de valor constante igual a 1, denominada *bias*. Neste caso, a soma ponderada u_j , torna-se $v_j = \sum_{i=0}^p w_{ji} x_{ji}$, com $w_{j0} = \theta$ e $x_{j0} = 1$.

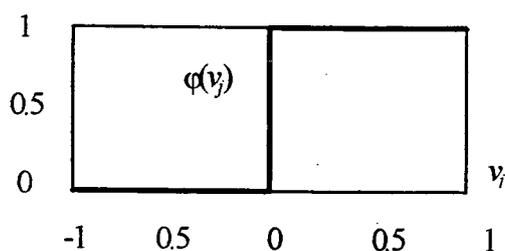
Pode-se encontrar também, a denominação de “função de ativação” para o que até agora foi chamado de função de transferência. Entretanto, há autores que definem a existência de duas funções no neurônio artificial, sendo a soma ponderada das entradas (v_j) denominada de função de ativação e $\varphi(v_j)$ sendo a função de transferência (NELSON e ILLINGWORTH, 1990).

A partir do modelo de neurônio de McCulloch e Pitts, um modelo generalizado, utilizando outras opções de função de transferência, tornou-se padrão no desenvolvimento de RNAs. Este modelo generalizado permite que a resposta do neurônio varie de modo contínuo. A função de transferência limita a amplitude da saída do neurônio, geralmente no intervalo normalizado de $[0,1]$, e em casos específicos $[-1,1]$. A seguir são dados alguns exemplos de funções de transferência comumente utilizadas por neurônios artificiais:

◇ Função Threshold, característica do modelo de McCulloch e Pitts:

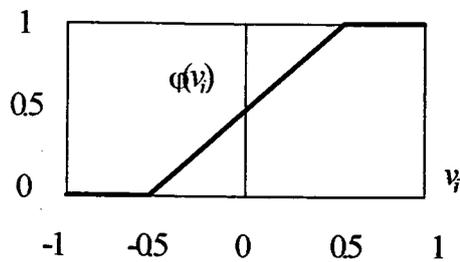
$$\bullet \quad \varphi(v_j) = \begin{cases} 1, & \text{se } v_j \geq 0 \\ 0, & \text{se } v_j < 0 \end{cases} \quad (3.1)$$

no caso de $\theta = 0$;



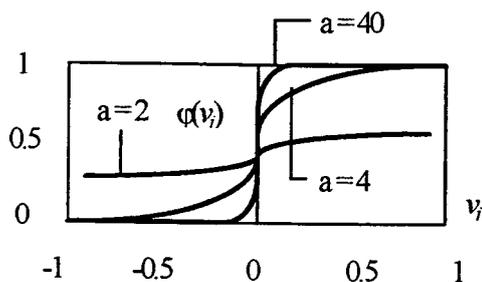
◇ Função Linear:

$$\bullet \varphi(v_j) = \begin{cases} 1, & \text{se } v_j \geq 0.5 \\ v, & \text{se } -0.5 \geq v_j > 0.5 \\ 0, & \text{se } v_j \leq -0.5 \end{cases} \quad (3.2)$$



◇ Função Sigmoid

$$\bullet \varphi(v_j) = \frac{1}{1 + \exp(-a \cdot v_j)} \quad (3.3)$$



Normalmente, as RNAs utilizam a função Sigmoid como função de transferência.

O modelo de neurônio artificial que segue a generalização da definição elaborada por McCulloch e Pitts, terá sua representação, com relação à função de transferência utilizada, descrita em mais detalhes nos próximos tópicos deste capítulo; assim como os demais elementos relacionados ao funcionamento geral de uma RNA.

3.4. ESTRUTURA E FUNCIONAMENTO DAS RNAS

Para entender satisfatoriamente a estrutura e funcionamento de uma RNA, é conveniente que se faça uma analogia com os elementos biológicos do cérebro humano.

Segundo PANDYA & MACY (1996), o sistema nervoso de um ser humano, assim como o de qualquer primata, consiste de três estágios básicos: o estágio inicial, no qual estímulos de entrada externos são captados pelas unidades "sensoras" (os olhos, por exemplo, captam sinais visuais), o estágio de processamento destes sinais pelo sistema nervoso central (o cérebro) e o estágio no qual as respostas aos estímulos de entrada são obtidas (a voz pode ser ativada em resposta a determinada entrada, bem como ações motoras ou orgânicas).

Com base nesta definição, pode-se dizer que o cérebro humano incessantemente recebe informações provenientes do meio exterior, as quais processa, avalia e compara à outras informações que tem armazenadas na memória, tornando-se apto a tomar decisões apropriadas.

Os neurônios biológicos, considerados como as células cerebrais responsáveis pelo processamento das informações, são representados, nas RNAs, como as unidades básicas de processamento, os "neurônios artificiais", e são interligados por conexões tais como as conexões biológicas, denominadas "conexões sinápticas". Assim como ocorre no cérebro humano, todos os dados recebidos pela RNA, são passados entre os neurônios através destas conexões sob a forma de impulsos.

Talvez, o maior desafio no estudo do cérebro humano, seja entender como as informações processadas durante o seu desenvolvimento, são armazenadas ou memorizadas. Ou seja, entender como o cérebro humano aprende.

Com o intuito de simular este aprendizado, pesos são designados às conexões sinápticas entre neurônios artificiais, e representam o conhecimento

armazenado em uma RNA. Através de um processo de aprendizagem, ou “treinamento”, os pesos sinápticos são ajustados e tornam a rede artificial apta a “decidir” com maior ou menor eficiência.

Ainda considerando a definição de PANDYA & MACY (1996) sobre o sistema nervoso humano, a estrutura básica de uma RNA pode apresentar-se da seguinte forma:

- uma camada inicial de unidades sensoras aos estímulos de entrada, que não é composta por neurônios;
- uma ou mais camadas intermediárias de neurônios interligados (formando a estrutura central de processamento da rede neural);
- e uma camada de neurônios de saída, conectada aos neurônios da(s) camada(s) escondida(s), gerando a resposta final da RNA.

A Figura 3.3 ilustra a estrutura básica de uma rede neural artificial. As entradas da rede representam a informação existente. Elas alimentam a primeira camada de neurônios que através do cálculo executado pela aplicação da função de transferência, geram repostas que alimentam a camada seguinte, e assim sucessivamente até atingirem a camada de saída.

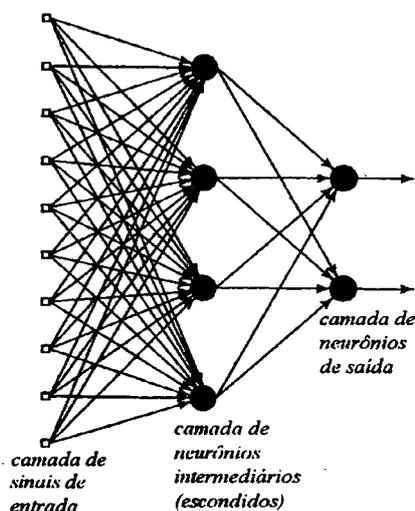


Figura 3.3: Estrutura básica de uma RNA (HAYKIN, 1994).

O número de neurônios e camadas em uma dada estrutura, é função do problema a ser resolvido. A camada de saída, em um problema de classificação de dados, pode representar o número de classes para as quais os padrões podem ser designados. Na classificação de imagens de satélite, por exemplo, se os padrões de entrada estão localizados em uma área onde há a existência de três classes, "Vegetação", "Área Urbana" e "Água", três neurônios de saída serão necessários.

A estrutura apresentada pode variar de acordo com a arquitetura de rede utilizada. Vários modelos foram propostos com o intuito de aprimorar os resultados alcançados em determinadas aplicações. Entre eles, alguns exemplos tais como o Perceptron Multicamadas, o Mapa Auto-Organizável de Kohonen e a Rede Neural com Função de Base Radial, utilizados em problemas de classificação de dados, serão tratados mais adiante neste capítulo.

3.5. TREINAMENTO E TESTE

Assim como uma rede neural biológica desenvolvida deve possuir a capacidade de armazenar novos conhecimentos com o intuito de torná-los úteis à tomadas de decisões, uma RNA deve ser treinada com o mesmo objetivo: aprender.

Segundo HAYKIN (1994), os pesos sinápticos designados às conexões entre os neurônios artificiais, são os responsáveis pelo armazenamento do conhecimento nas RNAs. São eles os parâmetros que devem ser ajustados através do processo de "treinamento", para que a rede habilite-se a responder o mais corretamente possível a quaisquer outros estímulos que lhe forem apresentados em uma fase posterior ao treinamento, denominada de "teste".

Esta capacidade que a RNA tem de classificar os dados de teste, é chamada de capacidade de "generalização". Fica subentendido, portanto, que a generalização da rede deve ser significativa, após seus pesos serem ajustados na fase de treinamento.

Três formas de aprendizado podem ser definidas:

- ⇒ a Supervisionada,
- ⇒ a Não Supervisionada e
- ⇒ a Híbrida.

Para que os valores dos pesos possam ser ajustados, eles devem primeiro ser "inicializados". Entretanto, a forma de designar os pesos iniciais de uma RNA, é muito discutida. Alguns autores defendem a inicialização através de valores randômicos dentro do intervalo de valores das entradas de treinamento (HAYKIN, 1994), outros defendem a tomada das primeiras entradas do conjunto de treinamento como os pesos iniciais da rede (BISHOP, 1995). A inicialização também pode ser feita tomando-se os primeiros elementos de cada classe, disponíveis no conjunto de treinamento, como os primeiros pesos da rede. Entretanto, a escolha apropriada da forma de inicialização dos pesos depende, entre muitos outros fatores, do objetivo para o qual a rede está sendo projetada e da forma de aprendizado utilizada.

3.5.1. Aprendizado Supervisionado

O aprendizado supervisionado das RNAs caracteriza-se pela disponibilidade de um conjunto de treinamento composto por dados de entrada previamente classificados. Ou seja, estímulos de entrada e respostas desejadas à estes estímulos.

O processo de ajuste dos pesos dá-se da seguinte forma: os estímulos de entrada, disponíveis no conjunto de treinamento, são apresentados à rede, que calcula uma resposta, utilizando como parâmetros os valores de pesos atuais, ou seja, sem ajuste.

A partir daí faz-se uma comparação entre a resposta oferecida pela rede atual e a resposta desejada àqueles estímulos. Com base na similaridade entre as

duas respostas, os pesos são ajustados. Esse procedimento ocorre até que os pesos possibilitem à rede classificar o mais corretamente possível as entradas de treinamento, e conseqüentemente as entradas apresentadas durante a fase de teste.

Geralmente estas regras de ajuste supervisionado, baseiam-se na determinação do erro, calculado como a diferença entre a resposta que a rede oferece, utilizando os pesos atuais, e a resposta que deveria oferecer ou resposta desejada, disponível no conjunto de treinamento.

Um fator importante no processo de aprendizado, é definir se a rede será treinada “por padrões” ou “por grupos” (*batch*) (HAYKIN, 1994). No primeiro modo os pesos são ajustados a medida em que os padrões vão sendo apresentados à rede. Assim, em cada apresentação do conjunto de treinamento, tantas alterações de pesos ocorrerão quantos forem os elementos deste conjunto.

No modo “por grupos” ou “*batch*”, os pesos, normalmente, são ajustados após todos os elementos do conjunto de treinamento serem apresentados à rede, ou seja, apenas um cálculo ocorre ao final de cada *época* (intervalo no qual todo o conjunto de treinamento é apresentado à RNA). No aprendizado “por grupos”, há a possibilidade da apresentação de grupos de padrões à rede, desta forma, em uma época ocorrerão tantos ajustes de pesos quantos forem os grupos apresentados.

A regra proposta por Hebb (NELSON e ILLINGWORTH, 1991), é um exemplo básico de aprendizado supervisionado.

Definindo os pesos iniciais da rede iguais a zero e tomando como base o princípio da Facilitação², Hebb desenvolveu sua fórmula de ajuste de pesos, na qual:

² O princípio da Facilitação, afirma que o uso de um órgão favorece seu desenvolvimento. Seguindo esta idéia, Hebb imaginou que, no cérebro humano, cada vez que uma sinapse é ativada, a quantidade de neurotransmissores liberados aumenta, fortalecendo a conexão entre os neurônios. Assim desenvolveu sua regra, na qual os pesos das conexões ativadas recebem a adição de determinadas quantias, visando seu fortalecimento.

$$w_j(\text{nov}) = w_j(\text{anterior}) + x_j y \quad (3.4)$$

onde: $x_j y$ - quantia que reforça a conexão sináptica ativada pela entrada j ;

y - saída atual do neurônio e

x_j - j -ésima entrada apresentada à rede, com $j = 0, 1, \dots, p$.

A regra de Hebb, foi proposta para ajustar pesos de redes lineares. Tais redes têm como característica básica a capacidade de classificar apenas padrões linearmente separáveis, ou seja, padrões que caem em determinadas posições de um hiperplano nas quais podem ser separadas por uma linha reta (Figura 3.4).

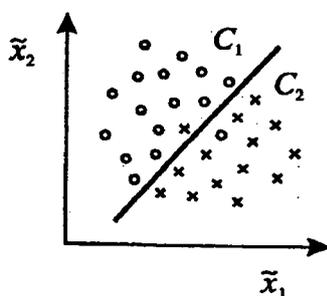


Figura 3.4: Padrões linearmente separáveis: dados que caem em lados opostos do hiperplano e podem ser separados por uma linha reta. Os padrões que não pertencem à determinada classe mas que foram a ela designados, são minoria e representam uma porcentagem de erro admissível (BISHOP, 1995).

Outro exemplo de regra de aprendizado supervisionado para redes lineares muito difundida é a regra de aprendizado do Perceptron (FAUSETT, 1994). Esta regra afirma que os pesos das conexões nas quais o sinal enviado é diferente de zero, são ajustados apenas se um erro ocorre, através da equação:

$$w_j(\text{nov}) = w_j(\text{anterior}) + \alpha x_j \quad (3.5)$$

$$b_j(\text{nov}) = b_j(\text{velho}) + \alpha t \quad (3.6)$$

sendo: t - a resposta desejada,

α - uma constante positiva referente a taxa de aprendizado e

x_j - entradas para o neurônio do Perceptron, com $j = 0, 1, 2, \dots, p$,

A taxa de aprendizado, α , é um parâmetro que determina o "quanto a rede neural deve aprender". É comum que este valor esteja dentro do intervalo de $[0,1]$, sendo que quanto mais próximo de 1 α estiver, mais a rede deverá "aprender".

Métodos dos mínimos quadrados também são bastante utilizados no ajuste de pesos de redes neurais. Nestes casos, a soma dos erros quadrados, E , deve ser minimizada.

Segundo BISHOP (1995), E pode ser calculada através da equação:

$$E = 1/2 \sum_{j=1}^p \sum_{k=1}^c \{y_{kj} - t_{kj}\}^2, \quad (3.7)$$

onde: $j = 1, \dots, p$, - entradas para os neurônios da rede,

$k = 1, \dots, c$, - unidades de saída e

$(y_{kj} - t_{kj})^2$ - erro quadrado.

Com o intuito de solucionar exatamente o problema dos mínimos quadrados, ou seja otimizar os pesos da rede pela redução de E à zero ou a algum valor bem próximo disto, BISHOP (1995), propõe a utilização do método da Pseudo-inversa, no qual o mínimo de E é encontrado através da solução de um sistema de equações lineares, que resulta no ajuste definido como:

$$w(\text{novo}) = [\text{pseudo-inversa}(x_j)](\text{tranposta}(t)), \quad (3.8)$$

$$\text{pseudo-inversa}(x_j) = \{[\text{inversa}(\text{tranposta}(x_j))]x_j\} \text{tranposta}(x_j) \quad (3.9)$$

com: x_j - j -ésimo vetor de entrada, com $j = 1, \dots, p$ e

t - resposta desejada disponível no conjunto de treinamento.

Neste caso, os pesos teoricamente exatos de uma rede linear são fornecidos utilizando-se apenas os vetores de entrada e os vetores de respostas desejadas.

A regra Delta ou Least Mean Squares, ou ainda regra de Widrow e Hoff (HUSH & HORN, 1993) é também um método de minimização do erro quadrado muito difundido. De acordo com ela, o ajuste dos pesos de uma rede neural artificial ocorre da seguinte forma:

$$w_j(\text{nov}) = w_j(\text{anterior}) + \alpha(t - y)x_j \quad (3.10)$$

$$b_j(\text{nov}) = b_j(\text{anterior}) + \alpha(t - y)x_j \quad (3.11)$$

com: y - saída atual da rede;

t - resposta desejada;

$(y - t)$ - erro e

α - taxa de aprendizado.

A Figura 3.5, ilustra o processo de aprendizado aplicando a regra Delta, e o resumo de seu algoritmo é descrito em seguida:

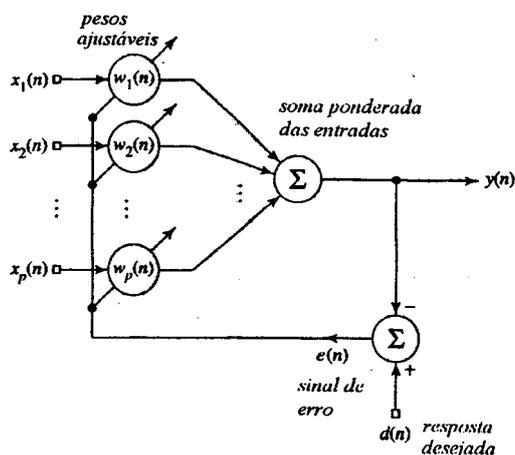


Figura 3.5: Processo de aprendizado ocorrido pela aplicação da Regra Delta. O erro é utilizado no cálculo do ajuste de pesos (HAYKIN, 1994).

Resumo do Algoritmo Least-Mean-Square (HAYKIN, 1994):

1. Inicializa os pesos. Define

$$w_j(1) = 0 \quad \text{para } j = 1, 2, \dots, p;$$

2. Ajusta os pesos. Para a iteração $n = 1, 2, \dots, N$, calcula

$$y(n) = \sum_{j=1}^p \hat{w}_j(n) x_j(n)$$

$$e(n) = t(n) - y(n)$$

$$\hat{w}_j(n+1) = w_j(n) + \alpha e(n) x_j(n) \quad \text{para } j = 1, 2, \dots, p.$$

Segundo HAYKIN (1994), a regra Delta só pode ser aplicada sobre um modelo de neurônio linear simples. Portanto, redes não lineares, têm que ser treinadas por processos mais elaborados, tais como a regra Delta generalizada aplicada pelo algoritmo de aprendizado Backpropagation³ (SKAPURA, 1996).

Assim como as redes lineares são capazes de classificar apenas padrões linearmente separáveis, as redes não lineares, em contrapartida, classificam padrões não linearmente separáveis, ou seja, padrões que caem em posições de um hiperplano que não podem ser separadas por uma linha reta (Figura 3.6).

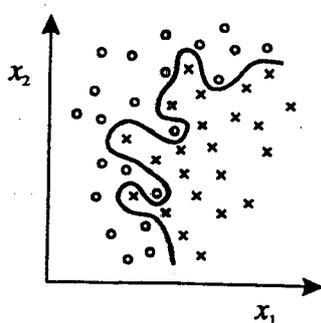


Figura 3.6: Padrões não linearmente separáveis: padrões que caem em determinadas posições do hiperplano que não podem ser separadas por uma linha reta. Soluções não lineares, normalmente, apresentam percentuais de erro na classificação inferiores à soluções lineares para a grande maioria dos problemas (BISHOP, 1995).

³ O algoritmo Backpropagation é o mais utilizado no treinamento de Perceptrons Multicamadas, por este motivo, é comum que redes desta arquitetura, treinadas com este algoritmo, sejam referenciadas como redes Backpropagation.

Em uma estrutura convencional para redes não lineares, composta por duas camadas de neurônios escondidos e uma camada de neurônios de saída, os pesos conectando a camada de saída e a segunda camada de neurônios escondidos são primeiramente ajustados. Os pesos conectando a primeira e a segunda camada de neurônios escondidos são ajustados em seguida, num processo que termina com o cálculo do ajuste dos pesos da conexão entre a camada de entrada e a primeira camada de neurônios escondidos.

De acordo com a Figura 3.7, o ajuste dos pesos da última conexão (entre a camada de saída e a segunda camada escondida), na iteração $(n+1)$, ocorre de forma direta, já que o cálculo do erro depende apenas da saída desejada (d) , disponível no conjunto de treinamento:

$$w_{kj}(n+1) = w_{kj}(n) + \alpha \delta_k(n) y_j(n) \quad (3.12)$$

$$\delta_k(n) = e_k(n) \varphi'_k(v_k(n)) \quad (3.13)$$

com: δ_k - gradiente local que refere-se à mudança requerida nos pesos sinápticos;
 e_k - erro calculado;
 φ'_k - derivada da função de transferência associada;
 $w_{kj}(n+1)$ - peso novo e
 $w_{kj}(n)$ - peso anterior.

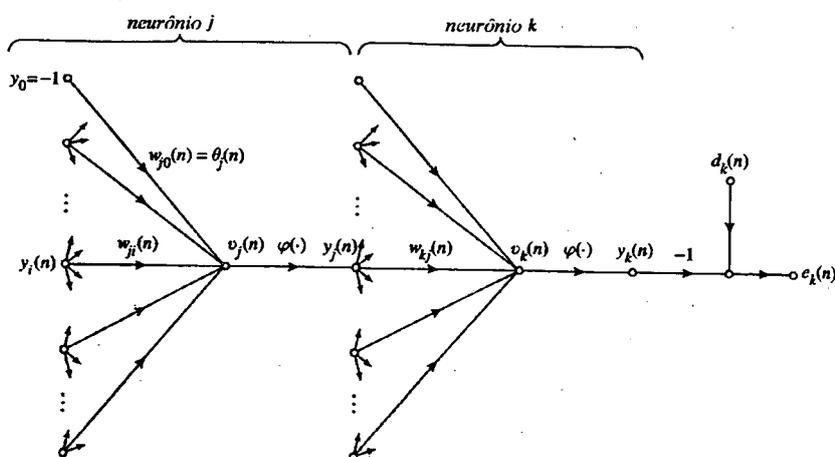


Figura 3.7: Camada de saída (k) conectada à segunda camada escondida (j) em um Perceptron Multicamadas (HAYKIN, 1994).

No ajuste dos pesos da conexão entre a primeira e a segunda camada de neurônios escondidos, analisando a Figura 3.7, considerando i como o neurônio na primeira camada escondida e j como o neurônio na segunda, tem-se:

$$w_{ji}(n+1) = w_{ji}(n) + \alpha \delta_j(n) y_j(n) \quad (3.14)$$

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (3.15)$$

Nesta fase, fica claro o processo “para trás”, no qual o gradiente do neurônio j , é calculado em função da soma dos gradientes dos neurônios na camada seguinte, neste caso, os neurônios da camada k .

Esta iteração termina apenas quando os pesos das conexões entre a camada de entrada e a primeira camada de neurônios escondidos, estiverem ajustados.

3.5.2. Aprendizado Não Supervisionado:

O aprendizado não supervisionado permite à rede aprender sem que haja um conjunto de “respostas desejadas” como referência para as saídas da rede. Neste caso, os pesos são ajustados a medida em que a rede vai sendo provida de padrões de entrada selecionados como representativos de cada classe.

Neste caso, os pesos das conexões, são ajustados de acordo com sua similaridade aos padrões de entrada apresentados à rede. Normalmente, a distância Euclidiana entre ambos é calculada, e o neurônio representando o peso mais próximo do vetor de entrada é considerado como o vencedor. Deste modo, o neurônio vencedor, tem seus pesos ajustados através de:

$$w_{kj}(\text{novo}) = w_{kj}(\text{anterior}) + \alpha(x_j - w_{kj}(\text{anterior})) \quad (3.16)$$

onde: k - neurônio vencedor;

x_j - j -ésimo vetor de entrada para a rede e

α - taxa de aprendizado.

Algumas arquiteturas de rede, ajustam além do neurônio vencedor, seus vizinhos, estabelecidos a partir de um raio pré determinado.

A taxa de aprendizado α , deve diminuir com o tempo, assim como a vizinhança. Em alguns casos, o raio inicial chega a incluir todos os neurônios da rede, e reduz a um mínimo no decorrer das épocas (FAUSETT, 1994).

3.5.3. Aprendizado Híbrido:

A forma de aprendizado híbrida, é a utilização conjunta das duas formas de aprendizado vistas anteriormente: a supervisionada e a não supervisionada. A Rede Neural com Função de Base Radial (BISHOP, 1995), que será apresentada posteriormente, admite este tipo de aprendizado, onde a primeira camada de conexões é treinada de forma não supervisionada e a segunda, de forma supervisionada.

3.6. ARQUITETURAS DE RNAS UTILIZADAS EM PROBLEMAS DE CLASSIFICAÇÃO DE DADOS

Para definir a arquitetura de uma RNA, deve-se analisar, primeiramente, a forma como os neurônios arranjam-se em grafos, criando topologias diversificadas (PACHECO, 1996). Normalmente, as arquiteturas de redes se classificam em função do número de camadas de neurônios e de sua estruturação, além da forma como os sinais calculados são propagados (*feedforward* ou recorrentes).

As redes que permitem uma retroalimentação são chamadas de redes recorrentes. Neste caso, o sinal de saída da camada de neurônios pode ser utilizado como uma nova entrada para os mesmos, até que um equilíbrio seja atingido.

Muitas arquiteturas de RNAs foram desenvolvidas para solucionar problemas de classificação de dados. Segundo SCHALKOFF (1992), o reconhecimento de

padrões, pode ser visto como o particionamento dos dados, representados por pontos em um espaço multidimensional, em regiões indicativas das classes.

Entre as redes com apenas uma camada de neurônios, o Perceptron, desenvolvido por Rosenblatt em 1958, pode ser citado como um exemplo amplamente difundido (HAYKIN, 1994). É definida como uma rede linear e, portanto, classifica apenas padrões que sejam linearmente separáveis (Figura 3.4).

O Perceptron consiste basicamente de um neurônio recebendo várias entradas através de conexões com pesos ajustáveis. Normalmente, tais pesos são ajustados através de um processo de aprendizado supervisionado.

Além de possuir apenas uma camada de neurônios, o Perceptron tem a característica de ser *feedforward*, ou seja, seus sinais calculados apenas passam adiante na rede e não retornam nunca.

Arquiteturas constituídas de várias camadas, também são bastante utilizadas em processos de classificação. O Perceptron Multicamadas (SKAPURA, 1996), é uma rede *feedforward* que se classifica nesta categoria.

Normalmente, esta extensão do Perceptron de Rosenblatt, possui uma arquitetura constituída por duas camadas de neurônios escondidos e uma camada de neurônios de saída, e é normalmente treinada com o algoritmo Backpropagation.

O Perceptron de múltiplas camadas, é utilizado para a classificação de padrões não linearmente separáveis. Ou seja, padrões que caem em determinadas posições de um hiperespaço nas quais não podem ser separados por uma linha reta (Figura 3.6).

Esta capacidade de classificar dados não lineares a posiciona como uma rede adequada a solucionar problemas mais próximos da realidade.

Outra arquitetura de rede bastante utilizada, é a do Mapa Auto-Organizável de Kohonen (PAO, 1989). Ela pode ser classificada de acordo com a estrutura topológica na qual os neurônios estão conectados; este tipo de estrutura procura aumentar a similaridade entre uma RNA e o cérebro humano quanto à disposição dos neurônios. Seu treinamento ocorre de forma não supervisionada.

Os neurônios artificiais existentes em um Mapa Auto-Organizável de Kohonen, podem arranjar-se de forma unidimensional, no caso de uma estrutura linear; ou bidimensional, para estruturas “em grade”. A Figura 3.8 descreve a topologia linear e um exemplo da bidimensional: a topologia quadrangular.

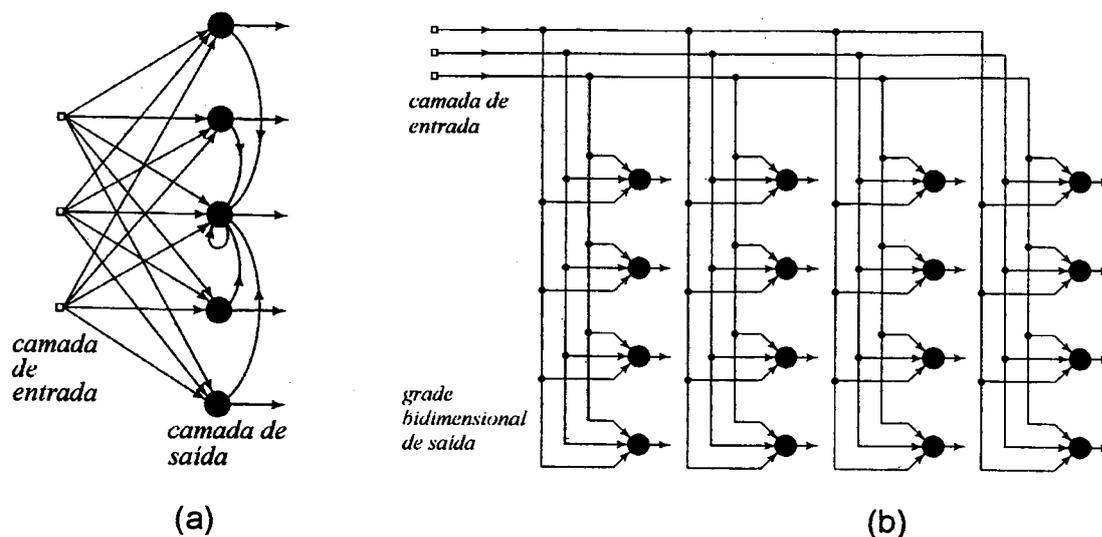


Figura 3.8: (a) Arquitetura de um Mapa Auto-Organizável de Kohonen com topologia linear. (b) Topologia bidimensional. Os neurônios, neste caso, são dispostos em uma “grade” estrutural (HAYKIN, 1994).

As redes de Kohonen, são treinadas de forma não supervisionada. Com base no conceito de vizinhança, a topologia linear de um Mapa Auto-Organizável de Kohonen pode ser compreendida como circular, uma vez que se o neurônio vencedor estiver localizado em uma das pontas da rede ou próximo disto, alguns

dos vizinhos a serem atualizados estarão, provavelmente, na outra ponta, como ilustra a Figura 3.9.

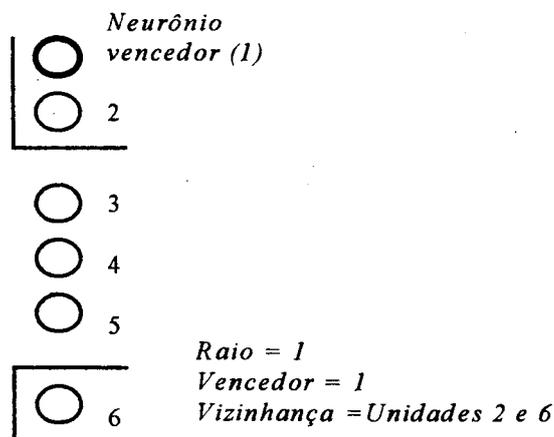


Figura 3.9: Mapa Auto-Organizável de Kohonen com topologia linear. Vizinhaça de raio igual a 1: são atualizados os pesos do neurônio vencedor, de um vizinho anterior (no caso, localizado na outra ponta da rede - o neurônio 6), e de um vizinho posterior (o neurônio 2).

Os Mapas Auto-Organizáveis de Kohonen são utilizados em um número diversificado de aplicações, que vão desde problemas de otimização à problemas de classificação de padrões não linearmente separáveis.

Com o objetivo particular de classificação de dados, uma extensão dos Mapas Auto-Organizáveis de Kohonen, foi desenvolvida: as redes LVQ, ou Learning Vector Quantization (DANDOLINI, 1997). Neste caso, o número de clusters definido é exatamente igual ao número de “categorias” nas quais os dados devem ser classificados. A arquitetura é a mesma de um Mapa Auto-Organizável de Kohonen com “topologia” linear, entretanto, os pesos são ajustados de forma supervisionada.

A arquitetura das redes neurais com função de base radial, que introduzem um conceito inovador quanto à forma de ajuste dos pesos sinápticos e à função de transferência utilizada pelos neurônios da camada escondida, será vista, a seguir, de forma detalhada.

3.6.1. Rede Neural com Função de Base Radial

As Redes Neurais com Função de Base Radial, ou RBFs - de *Radial Basis Function* (BISHOP, 1995; HAYKIN, 1994; HUSH & HORN, 1993; PACHECO, 1996 e TODESCO, 1995), além de possuírem um método de treinamento inovador para RNAs, tem como diferencial, a utilização de uma função de base radial como função de transferência, associada aos neurônios da camada escondida.

Sua arquitetura básica é ilustrada na Figura 3.10 e constitui-se de três camadas, sendo a primeira camada constituída por p entradas (x_i com $i = 1, \dots, p$); a segunda, por M neurônios escondidos associados a M centros, ctr_j com $j = 1, \dots, M$), e a terceira, uma camada constituída por c neurônios de saída (v_k com $k = 1, \dots, c$).

O treinamento dos pesos de uma RBF, normalmente, é híbrido. É comum que a primeira camada de conexões seja ajustada através de algum algoritmo de cluster não supervisionado, como o k-médias (ANDERBERG, 1973 e HARTIGAN, 1975) ou a regra de aprendizado de Kohonen (FAUSETT, 1994). Os M vetores de pesos desta primeira camada, representam os centros que serão utilizados pela função de transferência aplicada pelos M neurônios escondidos.

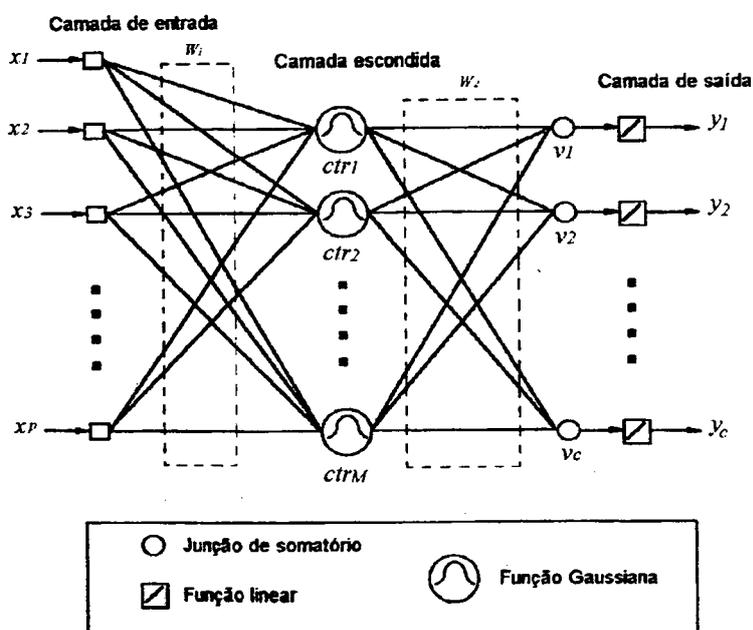


Figura 3.10: Arquitetura da Rede Neural com Função de Base Radial (TODESCO, 1995).

A segunda camada de conexões, é sempre treinada de forma supervisionada e qualquer regra de aprendizado supervisionado pode ser utilizada. O método da Pseudo-inversa (BISHOP, 1995), tem se mostrado bastante rápido e eficiente em aplicações de classificação de dados por RBFs (TODESCO, 1995).

A função de transferência aplicada pelos M neurônios escondidos em uma RBF, é uma função de base radial que permite solucionar de forma aproximada (*smooth*) o problema da interpolação exata (PACHECO, 1996). Este problema diz que cada um dos n vetores de entrada ($x_n=[x_1, x_2, \dots, x_p]$, com $n = 1, \dots, N$) num espaço p -dimensional, deve ser mapeado para um vetor de saída correspondente ($t_n=[t_1, t_2, \dots, t_q]$) em um espaço de saída q -dimensional, sendo o número de funções de base radial utilizadas (M) exatamente igual ao número de padrões de treinamento (N).

Segundo BISHOP (1995), para dados com distúrbios uma função de interpolação exata, como a descrita anteriormente, torna-se altamente oscilatória, e conseqüentemente indesejável para a obtenção de uma boa generalização da rede neural.

Uma solução aproximada, com o número de centros (M) definido de acordo com a complexidade do problema a ser resolvido e significativamente menor do que o número de padrões utilizados (N), pode melhorar o desempenho da RNA, inclusive no que se refere ao tempo gasto com a primeira fase de treinamento.

As funções de base radial aplicadas pelos M centros, ctr_j , são normalmente, funções Gaussianas cujos resultados alimentam a camada de c neurônios de saída.

Como função de transferência, estes neurônios de saída, aplicam uma função tradicional como a sigmoid, a linear ou mesmo a identidade, já que a camada de saída de uma RBF, tem como função primordial apenas reduzir a dimensionalidade existente na camada escondida. Este fato torna-se claro principalmente em aplicações de classificação de dados. Nestes casos, padrões "pré classificados"

como pertencentes à centros “próximos” na camada escondida, são agrupados, pela camada de saída, em uma única classe mais geral.

Na classificação de imagens de satélites, por exemplo, a RBF possibilita que pixels representando classes que apresentam uma resposta espectral aproximada, como ‘Vegetação Sombreada’ e ‘Vegetação Alta’, possam ser agrupadas numa classe única designada de ‘Vegetação’. Neste caso, entretanto, o objetivo para o qual destina-se a imagem classificada, não deve requerer tal nível de detalhamento.

Como visto anteriormente, é comum que a função de base radial Gaussiana (HUSH & HORN, 1993), seja aplicada como função de transferência pelos neurônios da camada escondida em uma RBF.

Segundo BISHOP (1995), a função Gaussiana, não normalizada, calculada para cada uma das n entradas, pode ser obtida por:

$$\varphi(x_{jn}) = \exp\left(-\frac{\|x_{jn} - ctr_j\|^2}{2\sigma_j^2}\right) \quad (3.17)$$

onde: x_{jn} - n -ésimo vetor de entrada p -dimensional que alimenta o neurônio j ,

com $n = 1, \dots, N$;

ctr_j - vetor correspondente ao j -ésimo centro p -dimensional, definido no período de treinamento, com $j = 1, 2, \dots, M$ e

σ_j^2 - variância presente neste j -ésimo centro.

Segundo a equação (3.17), além da distância entre os vetores de entrada e o j -ésimo centro, a função Gaussiana no neurônio j utiliza como argumento a variância dentro deste centro. A raiz quadrada desta variância, ou desvio padrão

(σ_j) , define o tamanho e a forma do “campo receptivo” de cada neurônio, representado pela base da função (WASSERMAN, 1993) (Figura 3.11).

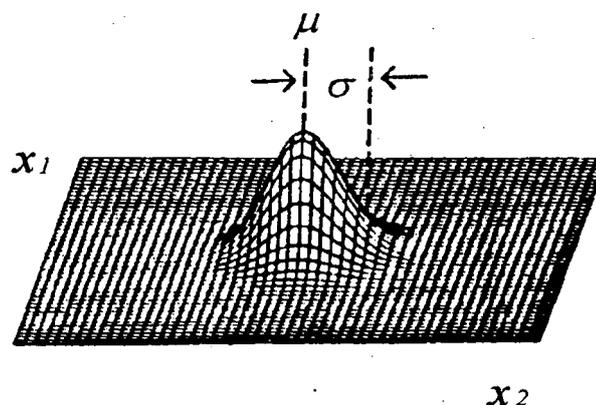


Figura 3.11: A base da função radial, representa a forma do campo receptivo do neurônio, cuja dimensão é definida pela dispersão σ (WASSERMAN, 1993).

Um dos objetivos no projeto de uma RBF é cobrir o espaço de entrada com campos receptivos aproximadamente uniformes. A utilização do algoritmo do vizinho mais próximo, ou *P-nearest neighbour*, adaptado a este tipo de problema, apresenta bons resultados ajustando, o quanto possível, tais valores (TODESCO, 1995).

No contexto de campos receptivos, pode-se dizer que a Gaussiana só apresentará resultados com valores significativos, para entradas que estejam inclusas nos campos receptivos dos neurônios, e quanto mais similar for a n -ésima entrada de determinado centro j , maior será o resultado da Gaussiana aplicada pelo neurônio associado, j .

A equação anterior, $\varphi(x_{jn})$, que descreve a função Gaussiana aplicada pelos neurônios escondidos de uma RBF, pode também ser escrita de forma generalizada, objetivando melhorar a performance da rede (HUSH & HORN, 1993). Neste caso, utiliza-se como argumento para a exponencial da função, a distância de Mahalanobis (PAO, 1989), entre a entrada x_{jn} e o centro j :

$$\varphi(x_{jn}) = \exp\left\{-\frac{1}{2}(x_{jn} - ctr_j)^T \Sigma^{-1}(x_{jn} - ctr_j)\right\} \quad (3.18)$$

onde: Σ^{-1} é a inversa da matriz de covariância da entrada x_{jn} associada ao centro ctr_j .

3.7. CLASSIFICADOR NEURAL X CLASSIFICADOR ESTATÍSTICO

Normalmente, classificadores tradicionais, exigem *a priori*, o conhecimento da forma da distribuição de probabilidade dos dados de entrada; além da estimativa dos parâmetros desta distribuição, feita a partir do acesso às características de todos os dados de treinamento simultaneamente (LIPPMANN, 1989).

As Redes Neurais Artificiais, utilizadas como classificadores de dados, destacam-se sobre os classificadores baseados em conceitos estatísticos, devido a possibilidade de manusear dados de entrada com distribuições de probabilidades desconhecidas *a priori*. Neste caso, apenas o resultado final da rede é avaliado.

Apesar de possuir esta capacidade de adaptação a novos ambientes superior à dos classificadores estatísticos, as RNAs podem consumir um tempo considerável de treinamento, quando o algoritmo utilizado executa cálculos matemáticos muito complexos e o conjunto de treinamento é significativo. O Backpropagation, é geralmente referenciado como um algoritmo lento para grandes quantidades de dados.

Entretanto, novas arquiteturas de redes, como a da RBF, possibilitam uma fase de treinamento mais rápida, onde o processo de ajuste dos pesos baseado na minimização do erro é substituído por uma única iteração.

Estudando as performances de classificação entre os sistemas baseados em conceitos estatísticos e os sistemas neurais, BENEDIKTSSON, SWAIN & ERSOY (1990), afirmam que além da capacidade de classificar dados sem o conhecimento *a*

priori de suas distribuições estatísticas e dos avanços com relação à velocidade de treinamento, as RNAs são mais suscetíveis à amostras de treinamento representativas. Ou seja, quanto mais uniformemente distribuídos estiverem os padrões de treinamento no espaço multidimensional, a melhora na performance da RNA será mais evidente do que a melhora na performance de um classificador estatístico.

LIPPMANN (1989); BENEDIKTSSON, SWAIN & ERSOY (1990); FIERENS *et all*, (1994) e HOLMSTRÖM *et all* (1997) fazem estudos comparativos entre classificadores neurais e classificadores baseados em conceitos estatísticos.

3.8. REDES NEURAS ARTIFICIAIS PARA A CLASSIFICAÇÃO DE IMAGENS MULTIESPECTRAIS

Muitos experimentos utilizando redes neurais artificiais para a classificação de imagens de satélites vem sendo desenvolvidos, de forma bastante significativa, desde o início da década de 90. Um dos trabalhos pioneiros neste estudo, é o de BENEDIKTSSON, SWAIN & ERSOY (1990), que compara a performance de métodos estatísticos de classificação de dados multiespectrais, com o desempenho de classificadores que utilizam a abordagem conexionista das RNAs.

Na mesma linha, HEPNER *et all* (1990) provam que as redes neurais artificiais, utilizando um conjunto de treinamento mínimo, também, fornecem resultados superiores aos obtidos por classificadores supervisionados tradicionais.

YOSHIDA & OMATU (1994), propõem um sistema de classificação de imagens de satélites, composto por duas redes neurais artificiais, no qual um Mapa Auto-Organizável de Kohonen, com topologia bidimensional, auxilia na extração do conjunto de treinamento utilizado por um Perceptron de três camadas, treinado com o algoritmo Back-Propagation.

KUSHADORNO *et al* (1994), também propõem uma rede neural artificial *feedforward*, de três camadas, treinada com o Backpropagation, entretanto, apresentam como entrada para a rede, as matrizes de co-ocorrência de cada banda utilizada. TZENG *et al* (1994), não variam na escolha da arquitetura de rede para a classificação de imagens de satélite. Mas o algoritmo de treinamento, baseado na técnica de filtragem de Kalman, diferencia este estudo dos anteriores.

Outro Perceptron de três camadas, treinado com o Backpropagation, é a proposta de BINAGHI & RAMPINI (1993). Neste caso a rede neural implementa conceitos da lógica difusa (KLIR & YUAN, 1995) na classificação dos dados multiespectrais. As entradas apresentadas, são os tradicionalmente utilizados, níveis de cinza dos pixels nas bandas disponíveis; entretanto, as saídas da rede, são os graus de pertinência destes pixels nas diferentes classes pré determinadas. KIM & KIM (1994) também propõem abordagens difusas para melhorar a performance da classificação de dados de sensoriamento remoto.

Destacando-se da maioria dos experimentos, que propõem o Perceptron Multicamadas ou variações desta arquitetura para a classificação de imagens provenientes de sensoriamento remoto, MILLER, KAMINSKY & RANA (1995), utilizam, com o mesmo fim, uma arquitetura de rede hierárquica, que proporciona uma classificação continuamente refinada dos dados apresentados. Neste caso, tais dados são classificados em dois grupos principais, sendo cada grupo reclassificado, até que todas as classes pré determinadas sejam identificadas.

Informações adicionais a respeito de redes neurais artificiais utilizadas para a classificação de imagens provenientes de sensoriamento remoto, podem ser encontradas em SALU & TILTON (1993); CHEN *et al* (1995); CHONG, JIA & MITAL (1994); CHONG & JIA (1994); FIERENS *et al* (1994); KIM *et al* (1995); SCHLÜZEN *et al* (1993); MACHADO *et al* (1993); CHAKRABARTI, BINDAL & THEAGHARAJAN (1995); HARA *et al* (1994); FOODY, MCCULLOCH & YATES (1995); entre outros.

3.9. CONCLUSÃO:

Neste capítulo, foram abordadas as Redes Neurais Artificiais ou RNAs.

Atributo essencial ao estabelecimento de uma RNA como técnica eficiente na execução de determinadas tarefas, sua capacidade de aprender e memorizar informações através de um processo de treinamento, permite à rede "generalizar". Esta característica faz com que dados que nunca tenham sido apresentados à rede durante a fase de treino possam ser classificados corretamente.

Um bom treinamento da RNA, resulta em uma boa generalização na fase de teste. Portanto, é essencial que a regra de aprendizado escolhida seja adequada à rede utilizada. Como métodos de aprendizado supervisionado tem-se: a regra de Hebb, a regra do Perceptron, o método da Pseudo-inversa, a regra Delta, também conhecida como *Least Mean Squares* ou regra de Widrow e Hoff, e o algoritmo resumido do Backpropagation, que aplica uma extensão da regra Delta para redes com mais de uma camada.

Como aprendizado não supervisionado, foi apresentado o treinamento no qual os pesos vão sendo ajustados a medida em que os padrões de entrada vão sendo apresentados à rede. Neste caso, não há a disponibilidade de um conjunto de entradas pré classificadas, como ocorre em processos de aprendizado supervisionado.

A RBF é treinada de maneira híbrida e, portanto, utiliza de forma conjunta, as duas técnicas de aprendizado descritas inicialmente, a supervisionada e a não supervisionada.

Os pesos da primeira camada de conexões em uma RBF, correspondentes aos centros, são treinados, normalmente, de forma não supervisionada, utilizando algoritmos como o K-médias ou o aprendizado de Kohonen. Já a segunda camada de conexões, é sempre treinada de forma supervisionada, sendo que o método da Pseudo-inversa é bastante utilizado.

Com a utilização do modelo de neurônio artificial criado por McCulloch e Pitts, algumas arquiteturas de redes foram desenvolvidas objetivando solucionar problemas variados, que vão desde a otimização até a classificação de dados.

Várias arquiteturas de RNAs, voltadas para o problema da classificação, foram descritas neste capítulo, entre elas temos: o Perceptron, o Perceptron Multicamadas, os Mapas Auto-Organizáveis de Kohonen, a LVQ e a RBF. A RBF inova quando usa como função de transferência na camada escondida, uma função de base radial. Normalmente, a função Gaussiana, que utiliza como argumento a distância entre os centros e as entradas, bem como a variância dentro de cada centro, é utilizada pela RBF.

A função de transferência aplicada aos neurônios da camada de saída, é normalmente uma função linear. Como o objetivo primordial desta segunda camada de neurônios é, essencialmente, o de reduzir a dimensionalidade da camada escondida, utiliza-se, comumente, como função de transferência a função identidade.

As RNAs, têm-se mostrado classificadores de padrões bastante eficientes. Sua facilidade de implementação é significativa, já que informações estatísticas sobre os dados, não são necessárias, *a priori*, para seu desenvolvimento. Outra característica das redes neurais artificiais, é sua adaptabilidade a ambientes diversos. O que a torna uma excelente opção para aplicações como a classificação de imagens de satélites, conforme apresentado no próximo capítulo.

Capítulo 4

UTILIZAÇÃO DE UMA RBF PARA CLASSIFICAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO

4.1. INTRODUÇÃO

No método da Máxima Verossimilhança admite-se que as classes de uso do solo, seguem uma distribuição normal multivariada. A designação de um padrão a uma classe, baseia-se na distribuição das amostras de treinamento e de um limiar estabelecido.

A utilização de uma RBF favorece o processo de classificação uma vez que nenhuma forma de distribuição de probabilidade é assumida para o conjunto de dados e a designação de um pixel a uma classe é realizada através da consideração, simultânea, dos efeitos de todas as bases radiais que identificam as classes sob estudo.

4.2. ARQUITETURA DE RNA PROPOSTA

A arquitetura proposta é apresentada esquematicamente na Figura 4.1.

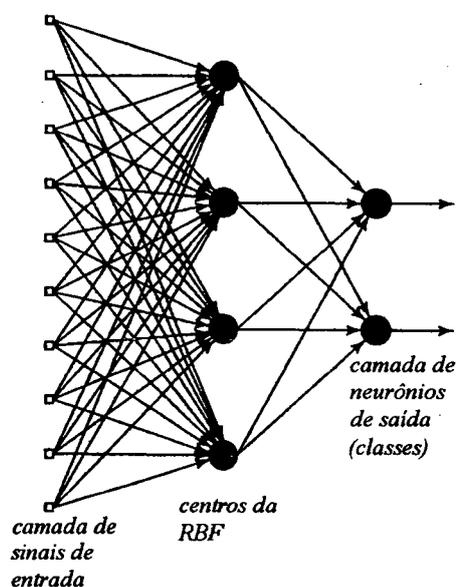


Figura 4.1: Arquitetura de RNA proposta.

A camada de entrada é definida pelo número de bandas disponíveis. O conjunto de dados de entrada é representado por uma matriz de dimensões:

$$P = N_b \times N_P$$

onde: N_b - número de bandas da imagem e
 N_P - número de padrões a serem classificados.

A camada intermediária é definida a partir de um processo de tentativa e erro. O número de neurônios desta camada deve sempre ser maior do que o número de neurônios da camada de saída. Um critério a ser utilizado para a determinação do número de neurônios desta camada consiste na observação do desempenho apresentado, em termos de classificação correta, obtido durante a fase de teste.

A camada de saída é definida de acordo com a imagem a ser classificada. Cada neurônio representa uma classe de uso do solo. Assim, a saída da rede apresenta as seguintes dimensões:

$$S = N_P \times N_{ci}$$

onde N_P - número de padrões a serem classificados e
 N_{ci} - número de classes identificadas

A determinação dos pesos, durante a fase de treinamento, é realizada em duas etapas. Na primeira etapa, referente aos pesos entre a entrada e a camada intermediária, utiliza-se o método das K-médias ou uma arquitetura de Kohonen. Os testes realizados conduziram a observação empírica de que para grandes conjuntos de treinamento a arquitetura de Kohonen apresenta tempo de processamento menor se comparado ao método das K-médias.

Na segunda etapa, que estabelece os pesos entre a camada intermediária e a camada de saída, o Método dos Mínimos Quadrados, com resolução do sistema através do algoritmo da Pseudo-inversa é utilizado.

A inicialização dos pesos consiste em adotar os primeiros elementos de cada classe, presentes no conjunto de treinamento, como centros iniciais da rede (tanto no procedimento K-médias quanto na utilização da arquitetura de Kohonen).

Na Figura 4.2, está sumarizado o esquema de funcionamento da RBF proposta.

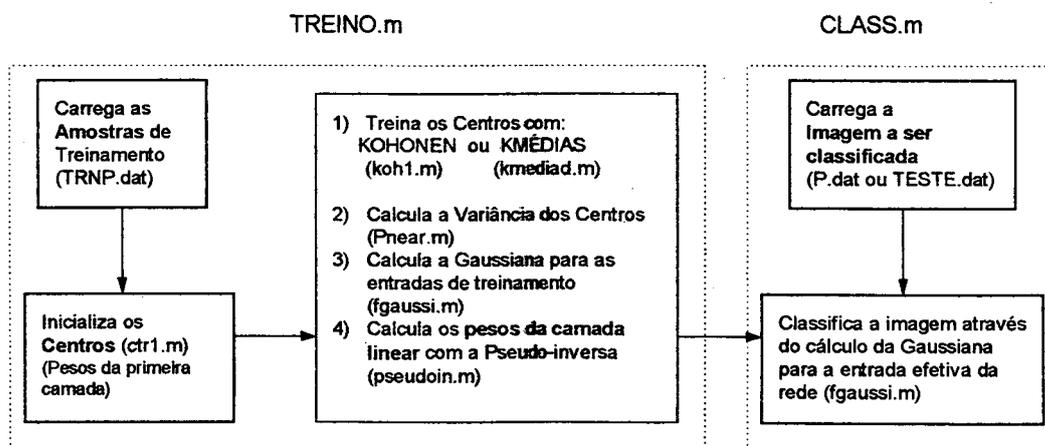


Figura 4.2: Esquema de funcionamento da RBF proposta.

4.3. APLICAÇÃO PRÁTICA DA ARQUITETURA PROPOSTA

Foram analisadas duas imagens digitais LANDSAT 5 TM.

A primeira imagem, refere-se a uma região de Florianópolis, no estado de Santa Catarina (órbita/ponto 220/079, quadrante E), datada de 18 de maio de 1995. Foram utilizadas as três primeiras bandas do espectro eletromagnético.

A segunda imagem, referente à região de São Francisco do Sul (órbita/ponto 220/078, quadrante D), também no Estado de Santa Catarina, da qual foram adquiridas as bandas 4, 5 e 7.

4.3.1. Preparação dos Dados Utilizados

Para a utilização das imagens foi necessária uma preparação dos dados adquiridos. Inicialmente, porções menores das imagens, denominadas de *cortes*, foram extraídas. A Figura 4.3, ilustra o procedimento efetuado neste caso.

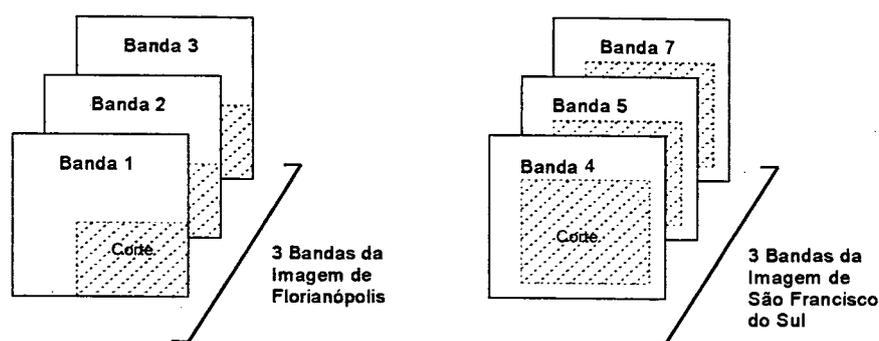


Figura 4.3: Exemplos de cortes extraídos das imagens. Três bandas disponíveis, três arquivos de imagens resultantes.

Para efetuar estes cortes, bem como para a extrair as amostras presentes nos conjuntos de treinamento e teste da RNA, foi utilizado o software Idrisi for Windows, versão 1.0.

Objetivando melhorar a qualidade visual da imagem e assim facilitar a seleção das áreas a serem classificadas, uma composição colorida utilizando imagens realçadas linearmente, com saturação 2,5, foi efetuada.

As amostras dos conjuntos de treinamento e teste foram extraídas tomando-se como base a mesma imagem realçada usada na extração dos cortes. Cuidados foram tomados para que não se repetissem pixels do conjunto de treinamento no conjunto de teste.

Polígonos envolvendo os pixels representativos de cada classe especificamente, foram desenhados sobre as áreas de classificação conhecida e

posteriormente, os níveis de cinza das bandas utilizadas na classificação foram extraídos nas posições determinadas pelos polígonos. A Figura 4.4 ilustra o corte realizado da imagem de Florianópolis com os polígonos constituintes do conjunto de treinamento.

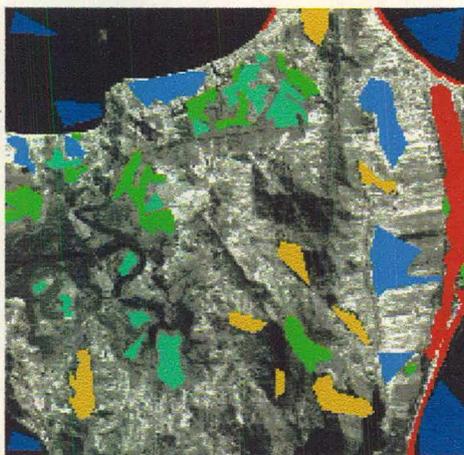


Figura 4.4: Corte da região Norte de Florianópolis, Santa Catarina, com a sobreposição dos polígonos de amostras extraídas para a construção do conjunto de treinamento. Cada cor representa uma classe.

O processo de manipulação dos arquivos de imagens executado é descrito de forma resumida no esquema ilustrado na Figura 4.5, a seguir:

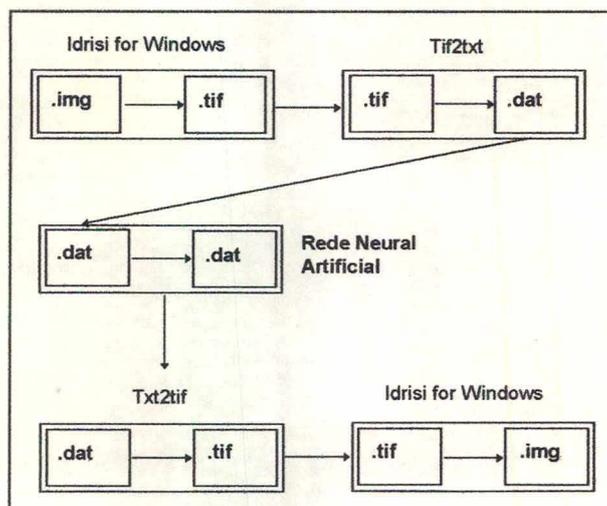


Figura 4.5: Esquema do processo de manipulação dos arquivos de imagens. Após a execução da RNA, os resultados são analisados no software Idrisi for Windows, versão 1.0.

4.4. RESULTADOS OBTIDOS DA CLASSIFICAÇÃO

A Rede Neural com Função de Base Radial proposta foi treinada de forma híbrida e dois algoritmos de treinamento não supervisionado para a primeira camada de conexões foram testados: o algoritmo das K-médias e o algoritmo de Kohonen, baseado em competição.

A seguir, serão descritos alguns resultados obtidos a partir de classificações das imagens multiespectrais pela RNA desenvolvida e pelo classificador de Máxima Verossimilhança, implementado no software Idrisi for Windows.

Os resultados obtidos com a utilização do treinamento de Kohonen e do algoritmo das K-médias pela RBF serão apresentados separadamente, em tópicos distintos.

4.4.1. Resultados Obtidos para a Imagem de Florianópolis

Os cortes utilizados geraram imagens de 160.801 pixels, estruturados em matrizes de 401 linhas por 401 colunas. Sendo assim, 160.801 vetores de entrada são apresentados à rede para classificação.

A Figura 4.6 ilustra a área selecionada para o primeiro processo classificatório. Esta região refere-se ao Norte da Ilha de Florianópolis, nas proximidades do Bairro do Rio Vermelho e das praias de Canasvieiras e Ingleses.



Figura 4.6: Área selecionada para classificação na imagem de Florianópolis (401x401 pixels). Região Norte da Ilha.

O conjunto de treinamento utilizado no ajuste dos pesos da rede constitui-se de 23.900 pixels. Sua dimensão representa aproximadamente 15% do tamanho total da imagem a ser classificada. Esse conjunto foi formado a partir do conhecimento prévio da região apoiado em fotografias aéreas na escala de 1:25000 e 1:8000, datadas de 1994.

O conjunto de testes, utilizado para avaliar o percentual de erro da rede, constitui-se de 3.135 pixels representando cerca de 13% do tamanho do conjunto de treinamento.

De forma esquemática, os dados utilizados na execução da rede para a classificação da imagem de Florianópolis, foram portanto:

- ENTRADA (P) - 160.801 vetores de entrada constituídos por três valores de cinza, referentes às três bandas da imagem utilizadas (3 x 160.801);
- CONJUNTO DE TREINAMENTO (TRNP) - 23.900 vetores de treinamento (4 x 23.900) e
- CONJUNTO DE TESTE (TESTE) - 3.135 vetores utilizados para testar a rede (4 x 3.135).

Foram identificadas, 6 classes dominantes na região selecionada:

| | |
|---------------------------------|--------------------|
| Classe: 1 - Vegetação Rasteira; | 4 - Areia; |
| 2 - Ocupação Urbana; | 5 - Água e |
| 3 - Vegetação Alta com Sombra; | 6 - Vegetação Alta |

a) RBF - KOHONEN/PSEUDO-INVERSA

Utilizando-se como classificador a RBF treinada com o aprendizado de Kohonen e o algoritmo da Pseudo-inversa, foram realizados testes a partir dos quais determinou-se a quantidade de centros na camada escondida (22 para esta aplicação).

A sobreposição das imagens de Alvo e obtida pela classificação do conjunto de Teste foi efetuada utilizando-se o software Idrisi for Windows. Os resultados obtidos estão apresentados na Tabela 4.1.

Tabela 4.1: Tabulação Cruzada - Imagem Alvo e Conjunto TESTE

| | 1 | 2 | 3 | 4 | 5 | 6 | Total |
|-------|-----|-----|-----|-----|-----|-----|-------|
| 1 | 457 | 11 | 1 | 0 | 0 | 51 | 520 |
| 2 | 10 | 498 | 0 | 46 | 1 | 0 | 555 |
| 3 | 11 | 1 | 306 | 0 | 66 | 50 | 434 |
| 4 | 0 | 14 | 0 | 158 | 0 | 0 | 172 |
| 5 | 0 | 0 | 0 | 0 | 774 | 0 | 774 |
| 6 | 29 | 2 | 38 | 2 | 0 | 609 | 680 |
| Total | 507 | 526 | 345 | 206 | 841 | 710 | 3135 |

Índice Kappa Total = 0.8687

A partir da análise da matriz confusão tem-se que: de 520 pixels pertencentes à classe 1, a RBF classifica 507. Os erros de omissão ocorrem mais freqüentemente nas 3 primeiras classes identificadas, enquanto que para as classes 4, 5 e 6, a rede comete erros de inclusão mais significativos.

Verifica-se que os maiores erros de classificação ocorreram entre as classes 1 (Vegetação Rasteira) e 6 (Vegetação Alta); 5 (Água) e 6 com a classe 3 (Vegetação Alta com Sombra), e entre as classes 4 (Areia) e 2 (Ocupação Urbana). Erros explicados devido a semelhança espectral entre essas classes.

O percentual de acerto foi de 89.40%, e o índice Kappa de precisão da classificação total de 0.8687 (quanto mais próximo de 1, este índice estiver, melhor deve ser considerada a classificação). Desta forma, tomando-se os resultados da porcentagem de pixels classificados corretamente e do índice Kappa resultante, além da porcentagem de erro admissível em classificações de imagens de satélite, a performance da RBF proposta, pode ser considerada satisfatória (KIM *et al*, 1995; HEPNER *et al*, 1990; entre outros).

As performances dos classificadores de máxima verossimilhança e neural, foram comparadas utilizando-se o índice de precisão da classificação total Kappa,

como um índice de concordância entre as duas imagens classificadas. Sendo assim, a tabulação cruzada entre a classificação obtida pela RBF, tomada como imagem de referência, e a obtida pelo classificador de Máxima Verossimilhança, resulta em uma matriz confusão e um índice de concordância descritos na Tabela 4.2.

Tabela 4.2: Tabulação Cruzada - RBF e Máxima Verossimilhança

| | 1 | 2 | 3 | 4 | 5 | 6 | Total |
|-------|-------|-------|-------|------|-------|-------|--------|
| 1 | 30447 | 3839 | 0 | 293 | 0 | 1400 | 35979 |
| 2 | 4324 | 27711 | 0 | 867 | 0 | 451 | 33353 |
| 3 | 18 | 0 | 13241 | 250 | 46 | 3954 | 17509 |
| 4 | 0 | 431 | 0 | 5183 | 0 | 5 | 5619 |
| 5 | 1 | 0 | 247 | 508 | 25466 | 141 | 26363 |
| 6 | 1525 | 503 | 4006 | 229 | 0 | 35715 | 41978 |
| Total | 36315 | 32484 | 17494 | 7330 | 25512 | 41666 | 160801 |

Índice Kappa de Concordância = 0.8210

Ambos os classificadores coincidem 85.63% de pixels classificados na mesma categoria, e têm um índice Kappa de concordância de 0.8210.

A Figura 4.7, ilustra as classificações resultantes da utilização da RBF (a), e do classificador de Máxima Verossimilhança (b), utilizando o mesmo conjunto de treinamento.

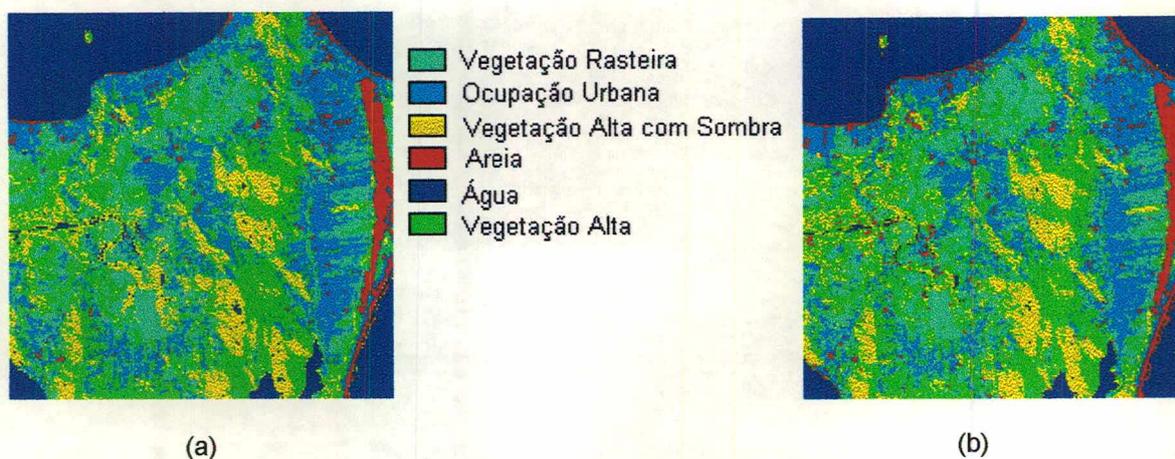


Figura 4.7: (a) Imagem classificada com a RBF. 22 centros, treinados com aprendizado de Kohonen em 130 iterações. Ao centro, a legenda das classes identificadas na região. (b) Imagem resultante da classificação pela máxima verossimilhança.

b) RBF - K-MÉDIAS/PSEUDO-INVERSA

Dos resultados obtidos a partir de testes utilizando a RBF treinada com o algoritmo das K-médias em conjunto ao algoritmo da Pseudo-inversa, a quantidade de 10 centros foi considerada suficiente para uma boa performance de generalização da rede.

Para esta arquitetura, o percentual de erro mais baixo encontrado na fase de testes foi de 13.49%. Sendo o índice Kappa de precisão da classificação total entre o resultado obtido pela rede, para 10 centros, e o Alvo, igual a 0.8332.

Mesmo com performance inferior à da classificação com o aprendizado de Kohonen, o percentual de erro para a RBF utilizando o algoritmo das K-médias é admissível, já que a rede tem um percentual de acerto de cerca de 86.50% (KIM *et al*, 1995; HEPNER *et al*, 1990; entre outros).

Tabela 4.3: Tabulação Cruzada - Alvo e Conjunto TESTE

| | 1 | 2 | 3 | 4 | 5 | 6 | Total |
|-------|-----|-----|-----|-----|-----|-----|-------|
| 1 | 423 | 6 | 1 | 0 | 0 | 90 | 520 |
| 2 | 25 | 507 | 1 | 21 | 0 | 1 | 555 |
| 3 | 11 | 1 | 308 | 0 | 82 | 32 | 434 |
| 4 | 0 | 22 | 0 | 150 | 0 | 0 | 172 |
| 5 | 0 | 0 | 0 | 0 | 774 | 0 | 774 |
| 6 | 33 | 0 | 94 | 3 | 0 | 550 | 680 |
| Total | 492 | 536 | 404 | 174 | 856 | 673 | 3135 |

Índice Kappa Total = 0.8332

A concordância entre a classificação pela RBF - K-médias/Pseudo-inversa, tomada como referência, e o classificador de Máxima Verosimilhança também foi calculado e resultou num índice Kappa de 0.7769.

Vale ressaltar, que com a utilização do algoritmo das K-médias no treinamento da primeira camada de conexões, os percentuais de erro foram maiores que os obtidos com a utilização do aprendizado de Kohonen.

Tabela 4.4: Tabulação Cruzada - RBF e Máxima Verossimilhança

| | 1 | 2 | 3 | 4 | 5 | 6 | Total |
|-------|-------|-------|-------|------|-------|-------|--------|
| 1 | 28133 | 4140 | 0 | 307 | 0 | 753 | 33333 |
| 2 | 3704 | 27574 | 0 | 1222 | 0 | 341 | 32841 |
| 3 | 466 | 110 | 13740 | 633 | 14 | 8131 | 23094 |
| 4 | 0 | 33 | 0 | 4657 | 0 | 0 | 4690 |
| 5 | 0 | 0 | 1097 | 400 | 25498 | 90 | 27085 |
| 6 | 4012 | 627 | 2657 | 111 | 0 | 32351 | 39758 |
| Total | 36315 | 32484 | 17494 | 7330 | 25512 | 41666 | 160801 |

Índice Kappa de Concordância = 0.7769

A seguir são ilustradas as imagens classificadas pela RBF-K-médias/Pseudo-inversa (a) e o classificador de Máxima Verossimilhança (b).



Figura 4.8: (a) Imagem classificada com a RBF. 10 centros, treinados com algoritmo da K-médias. Ao centro, a legenda das classes identificadas na região. (b) Imagem resultante da classificação pela máxima verossimilhança.

4.4.2. Resultados para a Imagem de São Francisco do Sul

A área selecionada para a classificação neste caso, refere-se à região central da Ilha de São Francisco do Sul e é ilustrada na Figura 4.9.

Os cortes extraídos das imagens de São Francisco do Sul referem-se à matrizes de níveis de cinza constituídas por 391 linhas e 441 colunas. Sendo assim, 172.431 vetores de entrada são apresentados à rede.



Figura 4.9: Área selecionada para classificação na imagem de São Francisco do Sul.

Como conjunto de treinamento, 21.519 vetores de níveis de cinza foram extraídos a partir de uma composição colorida RGB da imagem original. O conjunto de testes, composto de 3.720 pixels extraídos sob a mesma composição colorida, representa cerca de 17.3% da dimensão do conjunto de treinamento.

Esquematicamente:

- P - 172.431 vetores a serem classificados (3 x 172.431);
- TRNP - 21.519 vetores destinados a treinar a rede (4 x 21.519) e
- TESTE - 3.720 vetores extraídos para testar a performance da rede (4 x 3.720).

Informações geográficas prévias a respeito da área a ser classificada foram decisivas na identificação das nove classes descritas abaixo:

- Classe: 1 - Vegetação Rasteira;
2 - Mangue;;
3 - Solo Úmido;
4 - Vegetação com Sombra;
5 - Água;
6 - Vegetação Alta;
7 - Rocha
8 - Areia e
9 - Urbana.

a) RBF - KOHONEN/PSEUDO-INVERSA

Utilizando-se o treinamento híbrido a partir do aprendizado não supervisionado de kohonen na primeira camada de conexões e o algoritmo da Pseudo-inversa na segunda camada, a RBF proposta para a classificação da imagem multiespectral de São Francisco do Sul obteve o percentual de erro de 16.39%. A configuração utilizada neste caso, constitui-se de 43 centros na camada escondida e 9 classes de saída.

A tabulação cruzada entre a imagem utilizada como referência (imagem Alvo) e a classificação do conjunto de teste pela RBF é apresentada a seguir (Tabela 4.5).

Tabela 4.5: Tabulação Cruzada - Alvo e o Conjunto TESTE

| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | Total |
|-------|-----|----|-----|-----|-----|-----|-----|-----|-----|-------|
| 1 | 671 | 0 | 1 | 0 | 0 | 27 | 20 | 0 | 0 | 719 |
| 2 | 1 | 61 | 16 | 8 | 0 | 206 | 0 | 0 | 0 | 292 |
| 3 | 23 | 0 | 165 | 0 | 0 | 4 | 6 | 0 | 22 | 220 |
| 4 | 1 | 4 | 1 | 184 | 0 | 28 | 0 | 0 | 0 | 218 |
| 5 | 0 | 0 | 0 | 0 | 507 | 0 | 0 | 0 | 0 | 507 |
| 6 | 15 | 10 | 3 | 0 | 0 | 318 | 0 | 0 | 0 | 346 |
| 7 | 47 | 0 | 0 | 0 | 0 | 2 | 243 | 0 | 0 | 292 |
| 8 | 0 | 0 | 4 | 3 | 0 | 6 | 3 | 192 | 40 | 248 |
| 9 | 1 | 0 | 43 | 0 | 0 | 0 | 6 | 59 | 769 | 878 |
| Total | 759 | 75 | 233 | 195 | 507 | 591 | 278 | 251 | 831 | 3720 |

Índice Kappa Total = 0.8084

Com um índice de precisão da classificação total igual a 0.8084, a performance do classificador neural pode ser considerada ainda satisfatória (KIM *et al*, 1995; HEPNER *et al*, 1990; entre outros). Seu valor mostra-se inferior à performance da rede usada para a classificação da imagem de Florianópolis, principalmente, devido à identificação de um número de classes maior na região estudada.

A concordância entre a classificação da imagem de São Francisco do Sul, pela RBF-Kohonen/Pseudo-inversa e a classificação pela Máxima Verossimilhança, utilizando o mesmo conjunto de treinamento é, de acordo com a tabulação cruzada apresentada a seguir, de 0.7446 (Tabela 4.6).

Tabela 4.6: Tabulação Cruzada - RBF e Máxima Verossimilhança

| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | Total |
|-------|-------|------|-------|------|-------|-------|-------|------|-------|-------|
| 1 | 50759 | 0 | 2697 | 0 | 0 | 827 | 1369 | 5 | 90 | 55747 |
| 2 | 0 | 1918 | 16 | 0 | 0 | 0 | 0 | 1 | 3 | 1938 |
| 3 | 3 | 272 | 11233 | 12 | 0 | 0 | 0 | 194 | 427 | 12141 |
| 4 | 0 | 47 | 24 | 4035 | 43 | 0 | 0 | 5 | 9 | 4163 |
| 5 | 0 | 0 | 0 | 726 | 27149 | 0 | 0 | 0 | 0 | 27875 |
| 6 | 4337 | 6768 | 1964 | 533 | 0 | 23017 | 95 | 60 | 223 | 36997 |
| 7 | 202 | 0 | 5428 | 0 | 0 | 0 | 9347 | 2761 | 3636 | 21374 |
| 9 | 0 | 0 | 1321 | 0 | 0 | 0 | 0 | 1891 | 8984 | 2196 |
| Total | 55301 | 9005 | 22683 | 5306 | 27192 | 23844 | 10811 | 4917 | 13372 | 72431 |

Índice Kappa de Concordância = 0.7446

Este índice de concordância apresenta-se relativamente baixo levando-se em consideração que o índice de precisão da classificação total obtido, foi de 0.8084.

A seguir, as imagens resultantes da classificação pela RBF proposta (a) e pelo classificador de Máxima Verossimilhança (b) são ilustradas na Figura 4.10.



Figura 4.10: (a) Imagem classificada com a RBF. 43 centros treinados com aprendizado de kohonen em 130 iterações. Ao centro, a legenda das classes identificadas na região. (b) Imagem resultante da classificação pela Máxima Verossimilhança.

b) RBF - K-MÉDIAS/PSEUDO-INVERSA

Utilizando como treinamento não supervisionado o algoritmo das K-médias, a RBF proposta obteve o menor percentual de erro na classificação, para uma configuração de 36 centros, 17.42%.

Com a utilização do algoritmo das K-médias, variações na performance da rede para mesmas quantidades de centros não foram constatadas.

A tabulação cruzada entre a classificação do conjunto de teste e a imagem Alvo, usada como referência, resulta em um índice de precisão da classificação total igual a 0.7962. Este valor ainda pode ser considerado satisfatório em processos de classificação de imagens multiespectrais (KIM *et al*, 1995; HEPNER *et al*, 1990; entre outros).

Tabela 4.7: Tabulação Cruzada - Alvo e TESTE

| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | Total |
|-------|-----|----|-----|-----|-----|-----|-----|-----|-----|-------|
| 1 | 670 | 0 | 0 | 0 | 0 | 30 | 19 | 0 | 0 | 719 |
| 2 | 2 | 54 | 13 | 8 | 0 | 215 | 0 | 0 | 0 | 292 |
| 3 | 42 | 0 | 140 | 0 | 0 | 4 | 0 | 0 | 34 | 220 |
| 4 | 1 | 4 | 1 | 186 | 0 | 26 | 0 | 0 | 0 | 218 |
| 5 | 0 | 0 | 0 | 0 | 507 | 0 | 0 | 0 | 0 | 507 |
| 6 | 18 | 9 | 2 | 1 | 0 | 316 | 0 | 0 | 0 | 346 |
| 7 | 56 | 0 | 0 | 0 | 0 | 1 | 235 | 0 | 0 | 292 |
| 8 | 2 | 1 | 3 | 2 | 0 | 6 | 7 | 198 | 29 | 248 |
| 9 | 1 | 0 | 56 | 0 | 0 | 0 | 9 | 46 | 766 | 878 |
| Total | 792 | 68 | 215 | 197 | 507 | 598 | 270 | 244 | 829 | 3720 |

Índice Kappa Total = 0.7962

O índice de concordância entre os dois classificadores utilizados é obtido através da tabulação cruzada entre a classificação pela rede neural proposta, usada como imagem de referência, e a classificação pela Máxima Verossimilhança. A matriz confusão resultante e o índice de concordância entre os classificadores, é descrito a seguir.

Tabela 4.8: Tabulação Cruzada - RBF e Máxima Verossimilhança

| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | Total |
|-------|-------|------|-------|------|-------|-------|-------|------|-------|--------|
| 1 | 50579 | 0 | 4579 | 0 | 0 | 953 | 2106 | 229 | 261 | 58707 |
| 2 | 0 | 1924 | 243 | 53 | 0 | 0 | 0 | 17 | 25 | 2262 |
| 3 | 0 | 110 | 14489 | 0 | 0 | 0 | 52 | 154 | 551 | 15356 |
| 4 | 0 | 37 | 227 | 4114 | 120 | 0 | 0 | 20 | 88 | 4606 |
| 5 | 0 | 0 | 0 | 727 | 27072 | 0 | 0 | 0 | 0 | 27799 |
| 6 | 455 | 6934 | 1458 | 412 | 0 | 22891 | 4 | 17 | 63 | 36337 |
| 7 | 164 | 0 | 10 | 0 | 0 | 0 | 8649 | 568 | 133 | 9524 |
| 8 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1521 | 195 | 1716 |
| 9 | 0 | 0 | 1677 | 0 | 0 | 0 | 0 | 2391 | 12056 | 16124 |
| Total | 55301 | 9005 | 22683 | 5306 | 27192 | 23844 | 10811 | 4917 | 13372 | 172431 |

Índice de Kappa Concordância = 0.7919



Figura 4.11: (a) Imagem classificada com a RBF. 36 centros treinados com o algoritmo das K-médias. Ao centro, a legenda das classes identificadas na região. (b) Imagem resultante da classificação pela Máxima Verossimilhança.

4.4.3. Classificações Utilizando Conjuntos de Treinamento Mínimos

A extração das amostras de treinamento, em qualquer processo de classificação supervisionada, é considerada essencial para os resultados da classificação. A utilização de amostras menores facilita o trabalho do analista e reduz possíveis erros de amostragem.

A fim de verificar a performance da RBF utilizando conjuntos de treinamento mínimos, foram efetuadas classificações nas imagens descritas anteriormente com o aprendizado de Kohonen.

Para classificar a imagem referente à região de Florianópolis foi utilizado um conjunto de treinamento mínimo constituído por 3.135 pixels representando cerca de 1,95% do tamanho total da imagem a ser classificada.

A Figura 4.12 apresenta os resultados da classificação obtidos pela RBF e pela Máxima Verossimilhança.



Figura 4.12: (a) Classificação pela RBF-KOHONEN/Pseudo-inversa. 22 centros treinados por Kohonen em 130 iterações, utilizando um conjunto de treinamento mínimo. (b) Classificação pela Máxima Verossimilhança, utilizando um conjunto de treinamento.

Analisando a Figura 4.12, verifica-se um melhor desempenho da RBF em relação ao classificador de Máxima Verossimilhança utilizando um conjunto de treinamento mínimo. Esta superioridade pode ser observada nas classes Areia e Água.

O mesmo processo utilizado na classificação da imagem de Florianópolis, foi utilizado para a classificação da imagem de São Francisco do Sul. O conjunto de treinamento utilizado nas classificações pela RBF e pela Máxima Verossimilhança constitui-se de 3.720 pixels, ou seja, cerca de 2,15% do tamanho da imagem a ser classificada.

Os resultados obtidos das classificações são apresentados a seguir.



Figura 4.13: (a) Classificação pela RBF-KOHONEN/Pseudo-inversa, com 43 centros treinados em 130 iterações utilizando um conjunto de treinamento mínimo. (b) Classificação pela Máxima Verossimilhança utilizando o mesmo conjunto de treinamento.

Neste caso também fica claro o melhor desempenho da RBF sobre o do classificador de Máxima Verossimilhança. Nesta classificação (Figura 4.13 (b)), observa-se uma confusão entre as classes Água e Vegetação com Sombra e as classes Areia e Ocupação Urbana.

4.5. DISCUSSÃO DOS RESULTADOS

Duas formas de aprendizado não supervisionado para a primeira camada de conexões da RBF proposta foram testadas: o aprendizado de kohonen e o algoritmo das K-médias. Entretanto, a segunda camada da rede, uma camada linear, foi treinada com o algoritmo da Pseudo-inversa. Tradicionalmente, a arquitetura de RBF utiliza o algoritmo das K-médias na primeira fase de treinamento. A introdução da arquitetura de Kohonen mostrou-se vantajosa tanto em termos de taxa de acerto quanto em termos de tempo computacional requerido para o processo de classificação.

Duas imagens digitais LANDSAT 5 TM foram utilizadas nos processos de classificação: uma referente à região de Florianópolis, constituída pelas bandas espectrais 1, 2 e 3 e da qual foram extraídos cortes contendo 401 linhas e 401 colunas. E outra imagem cobrindo a região de São Francisco do Sul, também no

Para a imagem de São Francisco do Sul, os mais altos percentuais de acerto da rede na fase de testes foram:

- 84.71% e índice Kappa de 0.8084 para a RBF-Kohonen/Pseudo-inversa, com uma configuração de 43 centros treinados em 130 iterações e
- 82.58% de acerto com índice Kappa de 0.7962, para a RBF-K-médias/Pseudo-inversa, sendo a melhor configuração de 36 centros na camada escondida.

A concordância de pixels classificados igualmente entre a RBF-Kohonen/Pseudo-inversa e o classificador de Máxima Verossimilhança foi de 0.7446 para a imagem de São Francisco do Sul, sendo de 0.7919 para a tabulação cruzada efetuada entre a RBF-K-médias/Pseudoinversa e o classificador de Máxima Verossimilhança.

Utilizando conjuntos de treinamento mínimos, a RNA apresentou resultados superiores aos obtidos pelo classificador de Máxima Verossimilhança. A possibilidade de extração de amostras de tamanhos aproximadamente iguais para cada uma das classes favorece o desempenho da rede em relação à conjuntos de treinamento maiores.

Considerando o fato de que a extração de amostras é uma fase desgastante em processos de classificação de imagens, a possibilidade de extrair um conjunto de treinamento mínimo (menos de 3% do tamanho da imagem total) e obter resultados satisfatórios, constitui-se num fato relevante.

Capítulo 5

CONCLUSÕES E RECOMENDAÇÕES

5.1. CONCLUSÕES

A obtenção de informações sobre a superfície terrestre, a partir de dados provenientes de sensoriamento remoto a nível orbital, tem demonstrado importância significativa em processos tais como o de monitoramento de recursos terrestres ou o de mapeamento de uso do solo.

Com o desenvolvimento tecnológico impulsionando a modernização dos equipamentos envolvidos na coleta dos dados, informações mais detalhadas e seguras podem ser obtidas.

Os satélites atualmente em operação são capazes de capturar imagens em um número de bandas do espectro eletromagnético há algum tempo impensado.

O processamento digital de imagens pode ser considerado como um conjunto de técnicas para a extração de informações detalhadas a respeito dos dados de imagem coletados remotamente.

Normalmente, encontram-se implementados em sistemas computacionais, classificadores de imagens multiespectrais baseados em conceitos estatísticos. Neste caso, informações *a priori* sobre as estatísticas dos dados são indispensáveis. Esse fato torna-se uma limitação quando tais informações não existem ou são insuficientes.

Neste trabalho foi proposta a implementação de um classificador de imagens multiespectrais, baseado na tecnologia das Redes Neurais.

Redes Neurais Artificiais, voltadas para problemas de classificação de padrões, dispensam qualquer informação estatística prévia a respeito dos dados a

serem processados. Portanto, mostram-se como uma excelente alternativa aos classificadores estatísticos.

Considerando sua simplicidade estrutural e facilidade de implementação, performances de classificação obtidas pela RNA, superiores ou equivalentes às de classificadores baseados em estatística, podem ser consideradas satisfatórias.

Em diversas publicações comparando classificadores neurais e estatísticos, são descritas as vantagens e desvantagens de ambas as técnicas. Entretanto, a designação do mérito de “melhor classificador de dados” para qualquer uma delas, ainda está muito distante de ocorrer ou, provavelmente, nunca ocorrerá. O que temos são classificadores mais aptos a determinados problemas.

A arquitetura de rede implementada neste trabalho, a Rede Neural com Função de Base Radial Gaussiana, apresenta características fundamentais a um bom classificador de dados. A RBF soluciona de forma aproximada o problema da interpolação exata; utiliza uma forma de aprendizado híbrida, considerada mais eficiente; e implementa o conceito de campos receptivos dos neurônios, representados pelas bases radiais das funções, considerando a dispersão dos dados agrupados em cada centro.

De acordo com os resultados obtidos de testes efetuados durante o desenvolvimento da RBF, implementada no software Matlab, versão 4.2c, as performances de classificação da rede neural e do classificador de Máxima Verossimilhança, implementado no software Idrisi for Windows, versão 1.0, mostraram-se equilibradas, e em alguns casos, sobressaindo-se o desempenho da rede neural sobre o do classificador estatístico.

Quando utilizados conjuntos de treinamento mínimos, a RBF demonstrou performances de classificação superiores às do classificador de Máxima Verossimilhança.

5.2 RECOMENDAÇÕES A TRABALHOS FUTUROS

Estudos sobre a extração de conjuntos de treinamento mínimos mas adequados a uma boa performance de generalização, mostram-se essenciais, já que agilizam a fase mais complexa e trabalhosa dos processos de classificação de imagens supervisionados: a extração de amostras adequadas.

A utilização de técnicas como a dos Algoritmos Genéticos na obtenção de conjuntos de treinamento ótimos, apresenta-se como uma alternativa a ser investigada.

A modelagem dos dados de forma mais realista, proporcionada pela utilização de conceitos como os da Teoria dos Conjuntos Difusos, possibilita que, em aplicações de classificação de imagens multiespectrais, por exemplo, pixels misturados, englobando diversos tipos de classes e retornando uma única resposta espectral, possam ser classificados com base em sua pertinência nas diversas classes identificadas.

A utilização de RNAs difusas para a classificação de imagens multiespectrais pode ser considerada uma excelente alternativa aos classificadores atualmente utilizados e conseqüentemente deve ser investigada.

ANEXO

CLASSIFICA.m

%Treina os pesos com Kohonen
TREINOKOH.m

%ou treina os pesos com K-médias
%TREINOKM.m

%Classifica a imagem
CLASS.m

TREINOKOH.m

%Carrega as amostras de treinamento: TRNP, num. de classes e de centros
load amostras;

%ctr1.m e fdef.m para inicializar os centros
[Centros, prepara, variavel]=ctr1(TRNP, numclas);
[W, M] = fdef(Centros, numctr, numclas, prepara, variavel);
clear Centros;

%koh1.m para treinar os centros com o aprendizado de KOHONEN
ctr = koh1(W,M,TRNP(1:3,:));
clear W M;

%pnear.m para calcular a variância entre os centros
sd = pnear(ctr);
%multiplica a variância por uma constante = 50
var = 50;
sd = sd*var;

%fgaussi.m para calcular o resultado da função Gaussiana com o conjunto de
%treinamento
out = fgaussi(ctr, sd, TRNP);

%pseudoin.m para definir os pesos da segunda camada através do cálculo
%da PSEUDO-INVERSA
Wnovo = pseudoin(out, numclas, numctr, TRNP);
clear numctr out TRNP;

TREINOKM.m

```
%Carrega as amostras de treinamento: TRNP, num. de classes e de centros  
load amostras;
```

```
%ctr1.m e define.m para inicializar os ctrs  
[Centros, prepara, variavel]=ctr1(TRNP, numclas);  
ctr0 = define(Centros, numctr, numclas, prepara, variavel);
```

```
%kmediad.m para treinar os centros com K-MÉDIAS  
ctr = kmediad(TRNP(1:3,:), numctr, ctr0);  
clear variavel;
```

```
%pnear.m para calcular a variância entre os centros  
sd = pnear(ctr);  
%multiplica a variância por uma constante = 50  
var=50;  
sd = sd*var;
```

```
%fgaussi.m para calcular o resultado da função Gaussiana com o Conjunto  
%de treinamento  
out = fgaussi(ctr, sd, TRNP);
```

```
%pseudoin.m para definir os pesos da segunda camada através do cálculo  
%da PSEUDO-INVERSA  
Wnovo = pseudoin(out, numclas, numctr, TRNP);  
clear numctr out TRNP;
```

CLASS.m

```
%carrega a imagem a ser classificada  
load P.dat;
```

```
%fgaussi.m para calcular o resultado da função Gaussiana com o conjunto  
%de entrada efetiva  
FINAL=fgaussi(ctr, sd, P);  
clear ctr sd P variavel var prepara;
```

```
%Novasaid.m para classificar os pixels  
IMGCLASS = Novasaid (numentr, linhas, colunas, FINAL, Wnovo);  
clear FINAL Wnovo;
```

```
%salva a imagem classificada em um arquivo textual ".dat"  
save IMGCLASS.dat IMGCLASS -ascii;  
clear numentr numclas linhas colunas;
```

FUNÇÕES:**ctr1.m**

```
function [Centros, prepara, variavel] = ctr1(CTREINO, numclas)
```

```
%Constrói Centros, um conjunto com até 50 centros para cada classe
```

```
[bandas,numtrn]=size(CTREINO);
```

```
cont = 1;  
cont1 = 1;  
clas=1;  
classe=1;
```

```
variavel=50;  
prepara =numclas*variavel;
```

```
while classe <= numclas,  
for i = 1:numtrn  
if cont1 <= prepara & classe == clas,  
if CTREINO(4,i) == clas,  
Centros(1:3,cont1) = CTREINO(1:3,i);  
cont1 = cont1 + 1;  
if cont1 == cont+variavel,  
cont = cont1;  
clas = clas+1;  
end  
end  
end  
end  
classe = clas;  
end
```

fdef.m

```
function [W,M] = fdef(Centros, numctr, numclas, prepara,variavel)
```

```
%Define a matriz W com os centros iniciais referentes aos primeiros elementos de  
%cada classe, disponíveis no conjunto de treinamento
```

```
i = 1;  
cont=1;  
c=1;  
conta=1;
```

```
while conta <= numctr  
    if i <= prepara & conta <= numctr,  
        s(:,conta) = Centros(:,i);  
        i = i+variavel;  
    end  
    if i > prepara & conta <= numctr,  
        i = c+1;  
        c = i;  
    end  
    conta = conta+1;  
end
```

```
W = s(:,1:numctr);
```

```
%Cria a matriz de vizinhanca usada no treinamento de Kohonen  
M = nbman(numctr);
```

define.m

```
function ctr0 = define(Centros, numctr, numclas, prepara, variavel)
```

```
%Define ctr0, com os centros iniciais referentes aos primeiros elementos de cada
%classe, disponíveis no conjunto de treinamento
```

```
i = 1;
cont=1;
c=1;
conta=1;

while conta <= numctr
    if i <= prepara & conta <= numctr,
        s(:, conta) = Centros(:, i);
        i = i+variavel;
    end
    if i > prepara & conta <= numctr,
        i = c+1;
        c = i;
    end
    conta = conta+1;
end

ctr0 = s(:, 1:numctr);
```

koh1.m

```
function ctr = koh1(W, M, CTREINO)
```

```
%Treina os centros inicializados em ctr1.m com o aprendizado de KOHONEN
```

```
tp = [13 130 1];
W = W';
W = trainsm(W, M, CTREINO, tp);
close(gcf);
ctr = W;
```

kmediad.m

```
function ctr = kmediad(TRNP, nc, ctr)
```

```
%Treina os centros inicializados em ctr1.m com K-MÉDIAS
```

```
ctr=ctr';
TRNP = TRNP';
[numtrn,elem]=size(TRNP);

TEMPO = zeros(numtrn,nc);
VAR = 1;
np=zeros(1,numtrn);
cont=0;
while VAR == 1,
    cp = zeros(nc,elem);
    csize=zeros(nc,1);
    for i=1:nc,
        TEMPO(:,i)= ((TRNP-ones(numtrn,1)*ctr(i,:)).^2)*ones(elem,1);
    end;
    [ymin,cnumber]=min(TEMPO');
    for i=1:numtrn,
        k=cnumber(i);
        cp(k,:)=cp(k,:)+TRNP(i,:);
        csize(k) = csize(k)+1;
    end;
    for i=1:nc,
        ctr(i,:)=cp(i,:)/(csize(i)+eps);
    end;
    if cnumber == np,
        [nm,i]=min(csize);
        nm, %pause;
        if nm==0,
            ctr(i,:)=2*rand(1,elem)-1;
        else,
            VAR = 0;
        end;
    else,
        np=cnumber;
    end;
    cont=cont+1;
end;
```

pnear.m

```

function sd = pnear(ctr)

%Calcula a variância através do algoritmo do vizinho mais próximo

%Número de vizinhos mais próximos
p=1;
[M,Q]=size(ctr);
tmp=zeros(M,M);
for i=1:M
    tmp(:,i)=(sum(((ctr-ones(M,1)*ctr(i,:)).^2)))';
    tmp(i,i)=1000;
end

tmp1=[];
sd=zeros(M,1);
for j=1:p
    [Y,l]=min(tmp');
    tmp1=[tmp1 l'];
    for k=1:M
        tmp(k,l(k))=1000;
        sd(k)=sd(k)+(ctr(k,:)-ctr(l(k,:)))*(ctr(k,:)-ctr(l(k,:)))';
    end
end
sd=sqrt(sd)./p;

%Para variâncias iguais a zero, acrescenta 40% da variância do vizinho anterior ou
%posterior
conta=0;
while conta <= 0,
if sd(1) == 0,
    sd(1) = sd(M)*0.40;
    sd(M) = sd(M)-sd(M)*0.40;
end
for i = 2:M-1,
    if sd(i) == 0,
        sd(i) = sd(i-1)*0.40;
        sd(i-1) = sd(i-1)-sd(i-1)*0.40;
    end
end
if sd(M) == 0,
    sd(M) = sd(M-1)*0.40;
    sd(M-1) =sd(M-1)-sd(M-1)*0.40;
end
for i = 1:M,
    if sd(i) < 0,
        sd(i) = sd(i)*(-1);
    end
end
conta=min(sd);
end

```

fgaussi.m

```
function SAIDA = fgaussi(ctr,sd, C)

%Calcula o resultado da função Gaussiana

C = C';
C = C(:,1:3);
[nc,p]=size(ctr);
[N,p]=size(C);

SAIDA = zeros(N,nc);
for i=1:nc
    SAIDA(:,i)=(exp(-0.5*(((C-ones(N,1))*ctr(i,:)).^2))*ones(p,1)/sd(i));
end
```

pseudoin.m

```
function Wnovo = pseudoin(out, numclas, numctr, CTREINO)

%Treina os pesos da primeira camada usando o algoritmo da Pseudo-inversa

[x,l]=size(out);
Wnovo = zeros(numctr,numclas);
novo = zeros(numctr, x);

A = Resp(CTREINO, numclas);

novo=inv(out'*out)*out';

Wnovo=novo*A';
```

novasaid.m

```
function lmax = Novasaid(numentr, linhas, colunas, FINAL, Wnovo)

%Designa os pixels às classes

[IF,cF]=size(FINAL);
[IW,cW]=size(Wnovo);
H = zeros(IF,cW);
H = FINAL*Wnovo;
[Hmax,lmax]=max(H');

lmax = reshape(lmax, linhas, colunas);
```

REFERÊNCIAS BIBLIOGRÁFICAS

ANDERBERG, Michael R. ***Cluster Analysis For Applications***. Em Probability and Mathematical Statistics, vol 19, Academic Press, Inc., USA, NY - New York, 1973.

BASTOS, L. C.; LAPOLLI, E. M.; BASTOS, R. C. e BARCIA, R. M. ***Sensoriamento Remoto: Uma Técnica em Expansão***. Anais do XVI Congresso Brasileiro de Cartografia, vol 2, Rio de Janeiro, outubro de 1993.

BENEDIKTSON, J. A.; SWAIN, P. H.; & ERSOY, O K. ***Neural Network Approaches versus Stastical Methods in Classification of Multisource Remote Sensing Data***. IEEE Transactions on Geoscience and Remote Sensing, Vol. 28, No. 4, julho de 1990, p. 540-552.

BINAGHI, E. & RAMPINNI, A. ***Fuzzy Decision Making in the Classification of Multisource Remote Sensing Data***. Optical Engineering, Vol.32, No.6, 1993,

BISHOP, Christopher M. ***Neural Networks for Pattern Recognition***. Oxford University Press Inc., USA, NY - New York, 1995.

CHAKRABARTI, S.; BINDAL, N. & THEAGHARAJAN, K. ***Robust Radar Target Classifier Using Artificial Neural Networks***. IEEE Transactions on Neural Networks, Vol. 6, No. 3, maio de 1995, p. 760-767.

CHEN, K. S.; TZENG, Y. C.; CHEN, C. F. & Kao, W. L. ***Land-Cover Classification of Multispectral Imagery Using a Dynamic Learning Neural Network***. Photogrammetric Engineering 7 Remote sensing, vol 61, No. 4, abril de 1995, p. 406-408.

- CHONG, C. C. & JIA J. C. **Assessment of Neural Network Output Codings for Classification of Multispectral Images Using Hamming Distance Measure.** Proceedings of 12th IAPR - International Conference on Pattern Recognition, Vol. 2, 1994, IEEE, Piscataway, NJ, USA, p. 526-528.
- CHONG, C. C.; JIA, J. C. & MITAL, D. P. **Classification of Multispectral Images Using BP-Neural Network Classifier - Input Codings Assessment.** Frontiers of Computer Technology IEEE Region 10's Annual International Conference (TENCON'94), Proceedings, Vol. 2, 1995, IEEE, Piscataway, NJ, USA, p. 867-871.
- CRÓSTA, Alvaro P. **Processamento Digital de Imagens de Sensoriamento Remoto.** Gráfica da UNICAMP, Campinas - SP, 1992.
- CRÓSTA, Alvaro P & FILHO, Roberto de Souza. **Sensoriamento Remoto.** Anuário Fator GIS 97: O Guia de Referência do Geoprocessamento, Ano 1, No. 1, Curitiba - PR, 1997, p. c.10-c.21.
- DANDOLINI, Gertrudes A. **Um Procedimento para Avaliação da Saúde Financeira de Pequenas Empresas: Estudo de um Caso usando Redes Neurais Artificiais.** Dissertação de Mestrado, Universidade Federal de Santa Catarina - UFSC, Programa de Pós-Graduação em Engenharia de Produção, Florianópolis - SC, novembro de 1997.
- EASTMAN, J.R. **Idrisi for Windows - User's Guide - version 1.0.** Clark Labs for Cartographic and Geographic Analysis, USA, MA - Worcester, 1995.
- EDEN, M. J. & PARRY, J. T. **Remote Sensing and Tropical Land Management.** John Wiley & Sons, Great Britain, 1986.
- FAUSETT, Laurene V. **Fundamentals of Neural Networks - Architectures, Algorithms, and Applications.** Prentice Hall International Editions. USA, New Jersey, 1994.

- FIERENS, F.; KANELLOPOULOS, I.; WILKINSON, G. G. & MEGIER, J. ***Comparison and Visualization of Feature Space Behaviour of Statistical and Neural Classifiers of Satellite Imagery***. Proceedings of the 1994 IGARSS - International Geoscience and Remote Sensing Symposium, Vol. 4, 1994, IEEE, Piscataway, NJ, USA, p. 1880-1882.
- FOODY, G. M.; MCCULLOCH M. B. & YATES, W. B. ***Classification of Remotely Sensed Data by an Artificial Neural Network: Issues Related to Training Data Characteristics***. Photogrammetric Engineering & Remote Sensing, Vol. 61, No. 4, abril de 1995, p. 391-401.
- FRANZONI, Ana M. ***Aplicação do Sensoriamento Remoto no Monitoramento de Áreas Sujeitas à Degradação Ambiental: O Caso da Bacia Hidrográfica do Sangão - SC***. Dissertação de Mestrado, Universidade Federal de Santa Catarina - UFSC, Curso de Pós-Graduação em Geografia, Florianópolis - SC, 1993.
- GONG, P. & HOWARTH, P. ***Frequency-Based Contextual Classification and Gray-Level Vector Reduction for Land Use Identification***. Photogrammetric Engineering Remote Sensing, Vol. 58, No. 4, 1992, p. 423-437.
- HARA, Y.; ATKINS, R. G.; YUEH, S. H.; SHIN, R. T. & KONG, J. A. ***Application of Neural Networks to Radar Image Classification***. IEEE Transactions on Geoscience and Remote Sensing, Vol. 32, No. 1, janeiro de 1994, p. 100-109.
- HARTIGAN, John A. ***Clustering Algorithms***. John Wiley & Sons, Inc., USA, NY - New York, 1975.
- HAYKIN, S. ***Neural Networks - A Comprehensive Foundation***. Macmillan College Publishing Company, USA, NY - New York, 1994.

- HEPNER, George F.; LOGAN, Thomas; RITTER, Niles & BRYANT, Nevin. ***Artificial Neural Network Classification Using a Minimal Training Set: Comparison to Conventional Supervised Classification.*** Photogrammetric Engineering and Remote Sensing, vol 56, No. 4, abril de 1990, p. 469-473.
- HOLMSTRÖM, L.; KOISTINEN, P.; LAAKSONEN, J. & OJA, E. ***Neural and Statistical Classifiers - Taxonomy and Two Case Studies.*** IEEE Transactions on Neural Networks, Vol. 8, No. 1, janeiro de 1997, p. 5-17.
- HUSH, Don R. & HORNE, Bill G. ***Progress in Supervised Neural Networks - What's New Since Lippmann?*** IEEE Signal Processing Magazine, janeiro de 1993, p. 8-39.
- JENSEN, John R. ***Introductory Digital Image Processing - A Remote Sensing Perspective.*** Prentice-Hall, USA, New Jersey, 1986.
- JOHNSON, Richard A & WICHERN, Dean W. ***Applied Multivariate Statistical Analyse.*** Prentice Hall, Inc., USA, New Jersey, 1982.
- KIM, J. I. & KIM, S. C. ***Fuzzy Approaches for Improving a Classification Accuracy in Remote Sensing Image Data.*** Proceedings of IEEE International Conference on Systems, Man and Cybernetics, Vol. 1, 1994, IEEE, Piscataway, NJ, USA, p. 354-357.
- KIM, K-O.; YANG, Y-K.; LEE, J-H; CHOI, K-HO & KIM, T-K. ***Classification of Multispectral Image Using Neural Network.*** Proceedings of The 1995 IGARSS - International Geoscience and Remote Sensing Symposium, Vol. 1, 1995, p. 446-448.
- KLIR, G. J. & YUAN, B. ***Fuzzy Sets and Fuzzy Logic - Theory and Applications.*** Prentice Hall PTR, USA, 1995.

- KUSHADORNO, D.; FUKUE, K.; SHIMODA, H. & SAKATA, T. ***A Spatial Land Cover Classification with the Aid of Neural Network***. Proceedings of SPIE - The International Society for Optical Engineering, Vol. 2315, 1994, Society of Photo-Optical Instrumentation Engineers, Bellingham, WA, USA, p.702-710.
- LAPOLLI, Édis Mafra. ***Processamento de Imagens Digitais: Uma Abordagem Utilizando Conjuntos Difusos***. Tese de Doutorado, Universidade Federal de Santa Catarina - UFSC, Programa de Pós-Graduação em Engenharia de Produção - PPGE, Florianópolis - SC, 1994.
- LILLESAND, Thomas M. & KIEFER, Ralph W. ***Remote Sensing and Image Interpretation***. John Wiley & Sons, Inc., USA, NY - New York, 1979.
- LIPPMANN, Richard P. ***Pattern Classification Using Neural Networks***. IEEE Communications Magazine, novembro de 1989, p. 47-64.
- MACHADO A. ***Neuroanatomia Funcional***. Livraria Atheneu, 1980
- MACHADO, R. J.; BARBOSA, V. C. & LIPORACE, F. S.. ***Applying Neural Networks for Deforestation Monitoring of the Amazon Region***. Versão revisada do artigo "Monitoring the Deforestation of the Amazon Region with Neural Networks", publicado nos Proceedings of The Interantional Joint Conference on Neural Networks (IJCNN'93), Nagoya-Japan, 1993, p. 1239-1242.
- MASCARENHAS, N. D. A & VELASCO, F. R. D. ***Processamento Digital de Imagens***. Editora Kapelusz, Buenos Aires, 1989.
- MARTINS, Mauro R. ***Estudos da Massa D'Água Superficial das Baías de Paranaguá e Antonina PR, Utilizando Sensoriamento Remoto e Geoprocessamento***. Dissertação de Mestrado, Universidade Estadual Paulista - UNESP, Instituto de Geociências e Ciências Exatas, Rio Claro - SP, 1994.

Matlab - High-Performance Numeric Computation and Visualization Software - User's Guide. The Math Works Inc., USA, 1994.

Matlab - Neural Toolbox User's Guide. The Math Works Inc., USA, 1994.

MILLER, Diane M.; KAMINSKY, Edit J. & RANA, Soraya. **Neural Network Classification of Remote-Sensing Data.** Computers & Geosciences, vol 21, No. 3, 1995, p. 377-386.

NELSON, Marilyn M. & ILLINGWORTH, W. T. **A Practical Guide to Neural Nets.** Addison-Wesley Publishing Company, Inc. USA, 1991.

NOVO, Evelyn M. L. M. **Sensoriamento Remoto - Princípios e Aplicações.** Editora Edgard Blücher Ltda. São Paulo, Brasil, 1992.

PAO, Yoh-Han. **Adaptive Pattern Recognition and Neural Networks.** Addison-Wesley Publishing Company, Inc., USA, 1989.

PACHECO, Roberto C. S. **Hybrid Intelligent System for Prediction and Solving Financial Problems of Small Retail Firms.** Ph.D. Tese de Doutorado, Universidade Federal de Santa Catarina - UFSC. Programa de Pós-Graduação em Engenharia de Produção - PPGE, 1996.

PANDYA, Abhijit S. & MACY, Robert B. **Pattern Recognition with Neural Networks in C++.** CRC Press, Inc. Florida Atlantic University, USA, Boca Raton, Florida, 1996.

RAPOSO, Emerson P. **Desenvolvimento de um Sistema de Reconhecimento de Comandos Verbais para Robôs Baseado na Técnica de Redes Neurais Artificiais.** Dissertação de Mestrado, Universidade Federal de Santa Catarina - UFSC. Programa de Pós Graduação em Engenharia Elétrica - PPGE, 1997.

- ROSA, Roberto. ***Introdução ao Sensoriamento Remoto***. EDUFU, Uberlândia - MG, 1992.
- RICHARD, John A. ***Remote Sensing Digital Image Analysis - An Introduction***. Springer-Verlag Berlin Heidelberg, Alemanha, 1986.
- SALU, Yehuda & TILTON, James. ***Classifications of Multispectral Image Data by Binary Diamond Neural Network and by Nonparametric, Pixel-by-Pixel Methods***. IEEE Transactions on Geoscience and Remote Sensing, vol 31, No. 3, maio de 1993, p. 606-617.
- SCHALKOFF, Robert. ***Pattern Recognition - Statistical, Structural and Neural Approaches***. John Wiley & Sons, Inc. USA, 1992.
- SCHLÜNZEN, E. T. M.; TRINDADE, M. L. B; SHIMABUKURO, M. H; JUNIOR, SCHLÜNZEN Jr., K. & NETO, M. L. A . ***Perspectivas da Aplicação de Redes Neurais na Classificação de Dados Multiespectrais de Sensoriamento Remoto***. Anais do VII SBSR - Simpósio Brasileiro de Sensoriamento Remoto, 1993, p. 438-444.
- SKAPURA, David M. ***Building Neural Networks***. ACM Press Books, USA, NY - New York, 1996.
- SIMONETT, David S. ***The Development and Principles of Remote Sensing***. Capítulo I em Manual of Remote Sensing - Theory, Instruments and Techniques - Second Edition, vol I. American Society of Photogrammetry, USA, Virginia, 1983.
- SOUZA FILHO, C. R. ***Métodos para Supressão de Ruídos Periódicos em Imagens de Sensoriamento Remoto***. Anais do IV Simpósio Brasileiro de Geoprocessamento, São Paulo, novembro de 1997, p 129-140.
- STAR, J. & ESTES, J. ***Geographic Information Systems - An Introduction***. Prentice Hall, Inc., New Jersey - USA, 1990.

- TAFNER, Malcon A; XEREZ, Marcos de & FILHO, Ilson W. R. **Redes Neurais Artificiais - Introdução e Princípios de Neurocomputação**. Editora EKO, Universidade Regional de Blumenau, Blumenau - SC, 1996.
- TODESCO, José L. **Reconhecimento de Padrões Usando Rede Neuronal Artificial com uma Função de Base Radial: Uma aplicação na Classificação de Cromossomos Humanos**. Tese de Doutorado, Universidade Federal de Santa Catarina - UFSC, Programa de Pós-Graduação em Engenharia de Produção - PPGEP, Florianópolis - SC, 1995.
- TZENG, Yu Chang; CHEN, K. S.; KAO, Wen-Liang & FUNG, A K. **A Dynamic Learning Neural Network for Remote Sensing Applications**. IEEE Transactions on Geoscience and Remote Sensing, vol. 32, No. 5, setembro de 1994, p. 1096-1103.
- WASSERMAN, Philip D. **Advanced Methods in Neural Computing**. Van Nostrand Reinhold, USA, NY - New York, 1993.
- WELLS, W. A. **Lowly Glial Cells Strengthen Brain Connections**. <http://www-leland.stanford.edu/dept/news/report/news/september24/glia.html>. Stanford Report [online], 27 de setembro de 1997.
- YOSHIDA, Tomoji & OMATU, Sigeru. **Neural Network Approach to Land Cover Mapping**. IEEE Transactions on Geoscience and Remote Sensing, vol. 32 No. 5, setembro de 1994, p. 1103-1109.