

CAPÍTULO I

INTRODUÇÃO

1.1 Justificativas

A humanidade entra no século XXI com seu habitat natural, a superfície terrestre, sofrendo constantes e crescentes alterações causadas pelo desgaste natural ou, principalmente, pela atuação do homem, modificando o ambiente terrestre. Cientistas e ambientalistas estão preocupados com os impactos potencialmente devastadores dessas mudanças e estão estudando, pesquisando e produzindo novas tecnologias para que o homem possa ser capaz de realizar um monitoramento ambiental eficiente, que possa prever os impactos dessas mudanças e, em tempo hábil, evitar ou, ao menos, minimizar os efeitos destrutivos em nossos ecossistemas dessas alterações ambientais (Lunetta & Edvidge, 1998).

Além disso, no Brasil, um país de dimensões continentais, é de fundamental importância se ter uma atualização constante das informações sobre o uso e a cobertura do solo, de modo a estabelecer bases precisas para a tomada de decisão na gestão territorial e para o planejamento do desenvolvimento socioeconômico e ecológico do país.

A tecnologia de Sensoriamento Remoto (SR) tem disponibilizado uma quantidade imensa e de caráter dinâmico de informações sobre a superfície terrestre, permitindo se ter, além de uma base de dados estática – informações obtidas em um período apenas –, também uma atualização constante da informação, formando uma base multitemporal, com a possibilidade de avaliação automática das alterações ocorridas ao longo do tempo.

Os avanços da tecnologia de fabricação de computadores têm incrementado o desenvolvimento de plataformas computacionais, com um constante aumento da capacidade de processamento a um custo decrescente, possibilitando, assim, a execução de programas complexos, em um tempo compatível, que consigam extrair de forma automatizada as informações desejadas dos dados disponibilizados pelos sistemas de sensoriamento remoto.

A partir dessas necessidades prementes de avaliação do uso e cobertura dos solos e do acompanhamento da degradação ambiental, existe uma demanda crescente por metodologias e ferramentas computacionais, cuja análise é objetivo deste trabalho, que, aproveitando as potencialidades advindas dos avanços nas tecnologias de sensoriamento remoto e de fabricação de computadores, sejam capazes de uma forma automatizada e eficiente agilizar os

processos na gestão territorial, no monitoramento ambiental e no planejamento socioeconômico.

1.2 Motivações

Além da atualidade, necessidade e aplicabilidade do tema (“detecção de mudanças na superfície terrestre usando imagens de sensoriamento remoto e técnicas de inteligência computacional”), a interdisciplinaridade dos assuntos envolvidos – sensoriamento remoto, processamento de imagens, inteligência computacional e meio-ambiente – também contribuiu para a escolha do tema. Trabalhar de forma interdisciplinar propicia uma visão abrangente do objeto estudado e abre novas perspectivas e fronteiras para aplicação da tecnologia em prol da preservação ambiental.

O trabalho proposto iniciou-se no projeto ECOAIR¹, que tinha como objetivo final possibilitar a realização periódica de análises e comparações automatizadas do processo de degradação ambiental através da comparação de respostas espectrais de imagens multitemporais, tomadas nos mesmos períodos de cada ano, desenvolvendo uma metodologia e construindo uma ferramenta para disponibilizar, de forma automática, informações sobre mudanças de uso do solo e monitoramento do processo de degradação ambiental a partir de dados obtidos de sensores remotos.

Outro objetivo, também importante, do projeto ECOAIR foi disponibilizar ao pessoal de prefeituras e órgãos do governo, sem formação específica em Processamento de Imagens, uma ferramenta que lhes permitisse fazer um monitoramento periódico das alterações ocorridas ao longo do tempo.

A fim de tornar-se o mais relacionado possível com a questão sócio-ambiental, o projeto utilizou a problemática do Pantanal e das áreas em seu entorno como local de aplicação das técnicas de monitoramento a serem desenvolvidas, surgindo, então, em função de uma demanda ambiental real do Brasil e não meramente como uma fonte de pesquisa teórica.

¹ Instituições participantes do projeto:

- UERJ - Faculdade de Engenharia - Depto de Sistemas e Computação/Geomática.
- Embrapa Solos - Centro Nacional de Pesquisa de Solos.
- PUC-RJ - Depto. de Eng. Elétrica e Depto. de Ciências dos Materiais e Metalurgia.
- UFRJ - Núcleo de Computação Eletrônica.
- INRIA - Institut National de Recherche en Informatique et en Automatique (França).

Assim, o interesse despertado pelo tema e a sua aplicabilidade e relevância demonstradas no escopo do projeto ECOAIR levaram a um estudo mais aprofundado do tema, convergindo nesta dissertação.

1.3 Objetivos

Um dos objetivos desta dissertação foi o de pesquisar e avaliar metodologias de detecção de mudanças, propondo uma metodologia para a detecção de mudanças na superfície terrestre, a partir de imagens multitemporais² e multiespectrais³ de sensoriamento remoto, empregando técnicas de inteligência computacional e identificando os procedimentos necessários para gerar uma imagem com a classificação das áreas de ocorrência de mudanças e das áreas onde não ocorreu mudança na superfície da Terra.

O segundo objetivo, que demandou mais tempo e esforço, foi o de pesquisar, criar ou refinar e avaliar algoritmos computacionais capazes de implementar os procedimentos propostos nas metodologias de detecção de mudanças na cobertura terrestre a partir de imagens multitemporais e multiespectrais de sensoriamento remoto. Esses procedimentos deveriam ter como característica a utilização apenas das imagens de sensoriamento remoto, procurando minimizar a necessidade da intervenção de especialistas em geoprocessamento ou da utilização de dados obtidos de outras fontes (trabalho de campo, fotos aéreas, mapas, ou relatórios técnicos).

1.4 Descrição do Trabalho

Podem-se dividir os métodos de detecção de mudanças em duas abordagens principais: a detecção de mudanças com pré-classificação espectral e abordagem de detecção de mudanças pós-classificação, ilustradas pelos diagramas da Figura 1.1.

Na abordagem com pré-classificação espectral é gerada uma imagem representando a diferença das imagens, implementada aqui neste trabalho por uma técnica denominada Análise do Vetor Mudança (CVA, *Change Vector Analysis*). Finalmente a essa imagem é aplicado um processo de classificação, resultando a imagem binária mudança / não-mudança.

Já na abordagem pós-classificação, é realizada uma classificação temática independente para cada imagem. O procedimento final é uma interpretação direta

² Imagens de datas distintas.

³ Imagens de várias bandas de comprimentos de onda.

automatizada, isto é, uma comparação *pixel*⁴ a *pixel* nas duas imagens, identificando os *pixels* com mesma classificação temática nas duas imagens e os *pixels* com classificação diferente, gerando a imagem mudança / não-mudança.

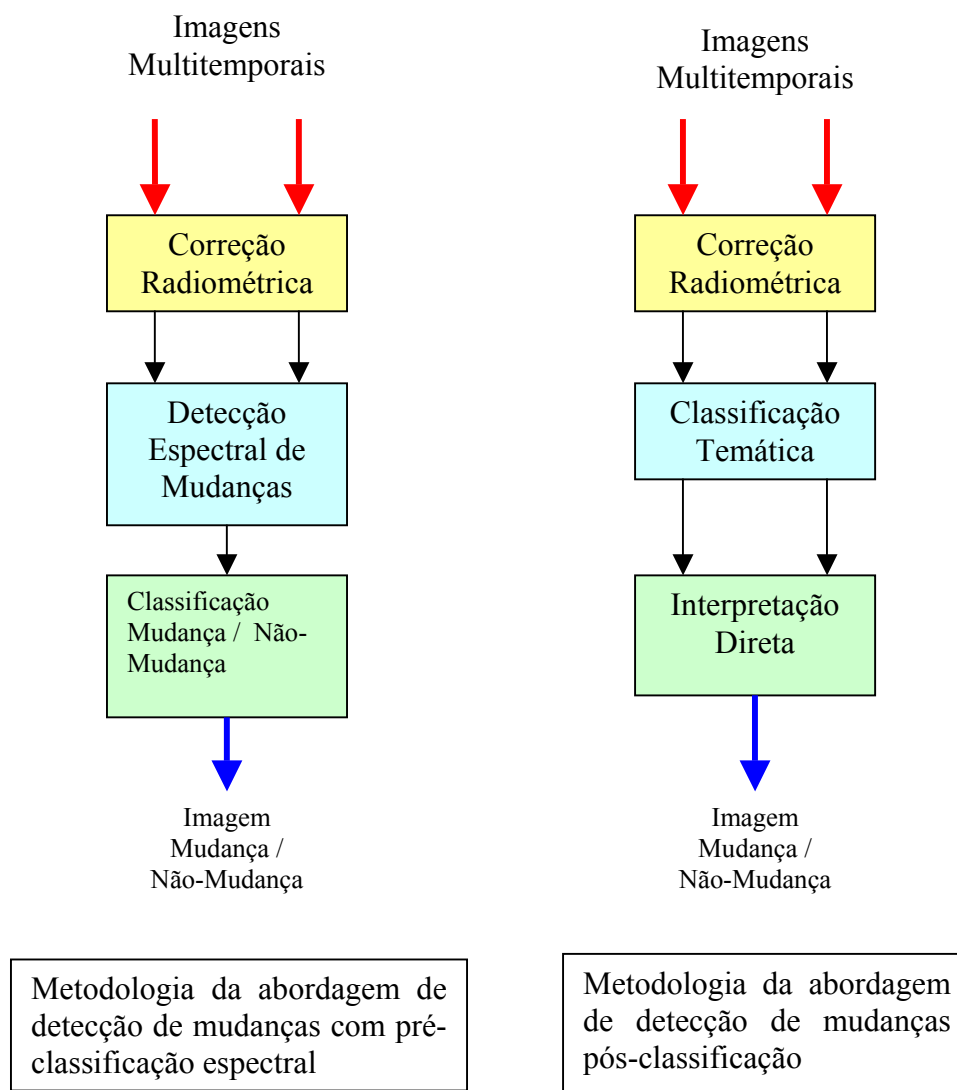


Figura 1.1 – Metodologias.

Uma possível vantagem do método de detecção de mudanças pós-classificação, citada na literatura, é um relaxamento da exigência de uma boa correção radiométrica; já na abordagem de pré-classificação há uma grande dependência do resultado da qualidade da correção radiométrica realizada mas, ao contrário da pós-classificação, só existe uma fonte de erros de classificação.

Contudo, o que foi observado é que, nas duas propostas, o procedimento de correção radiométrica das duas imagens brutas afeta bastante o resultado. Na correção radiométrica são

⁴ *Pixel* (do inglês “picture element”) : célula elementar de uma imagem

realizadas transformações desenhadas para normalizar ou contornar diferenças radiométricas provenientes de efeitos atmosféricos ou erros instrumentais, melhorando o desempenho das etapas seguintes. A abordagem proposta é a da correção radiométrica relativa e realizada por uma regressão não paramétrica.

A metodologia proposta baseia-se na abordagem de pré-classificação espectral, que se mostrou mais eficaz, com a classificação final utilizando um algoritmo neural não supervisionado, denominado Rede Neural por Centróide (CNN, Centroid Neural Network), derivado das redes neurais de aprendizado competitivo.

1.5 Organização da Dissertação

Esta dissertação desdobra-se em sete capítulos. Neste capítulo I são apresentadas as justificativas, motivações, objetivos e descrição do trabalho. Nos capítulos II e III é, de forma objetiva, apresentada a fundamentação teórica das duas principais áreas do conhecimento envolvidas no trabalho: no capítulo II a introdução teórica do processamento digital de imagens de sensoriamento remoto e no capítulo III a introdução teórica das redes neurais artificiais. No capítulo IV é fundamentada a necessidade da correção radiométrica e são apresentados os métodos para realizá-la. O capítulo V é uma descrição das duas principais abordagens para a detecção de mudanças: a abordagem da detecção de mudanças com pré-classificação espectral e a abordagem da detecção de mudanças pós-classificação, com apresentação dos métodos para implementá-las. O capítulo VI inicia conceituando classificação supervisionada e classificação não supervisionada e a seguir apresenta os principais métodos de classificação. No capítulo VII são apresentados os testes e experimentos realizados, com os resultados obtidos. Ao final, no capítulo VIII, são apresentadas as conclusões sobre o trabalho.

CAPÍTULO II

PROCESSAMENTO DIGITAL DE IMAGENS DE SENSORIAMENTO REMOTO

Neste capítulo procura-se, de forma objetiva, conceituar o processamento digital de imagens de sensoriamento remoto, para termos o embasamento necessário ao entendimento da fundamentação teórica e do trabalho desenvolvido nesta dissertação, apresentando a definição e características do Sensoriamento Remoto (SR), as características das imagens de SR e os objetivos do processamento digital de imagens.

2.1 Sensoriamento Remoto

Pode-se iniciar definindo sensoriamento remoto, segundo Novo (1998:2), “como sendo a utilização conjunta de modernos sensores, equipamentos de processamento de dados, equipamentos de transmissão de dados, aeronaves, satélites orbitais etc., com o objetivo de estudar o ambiente terrestre através do registro e da análise das interações entre a radiação eletromagnética e as substâncias componentes do planeta Terra em suas mais diversas manifestações”.

Pode-se observar que a transferência de dados do objeto para o sensor é feita através de energia e, mais especificamente, da energia eletromagnética, portanto, para a aquisição e processamento desses dados, um sistema de sensoriamento remoto é baseado na existência ou execução de algumas condições (Novo, 1998; Moreira, 2001):

- Existência de uma fonte de radiação (A);
- Propagação de radiação pela atmosfera (B);
- Incidência da radiação sobre a superfície terrestre e ocorrência de interações entre a radiação e os objetos da superfície (C);
- Aquisição, através de sensores, e registro da radiação que retorna da superfície da Terra (D);
- Transmissão, recepção e processamento (E);
- Interpretação e análise (F);
- Aplicação (G).

A figura 2.1 ilustra o procedimento para a coleta, análise e utilização de dados sobre a superfície terrestre em um sistema de sensoriamento remoto.




Figura 2.1 - Sistema de sensoriamento remoto.

Fonte: *Natural Resources Canada*.

Pode-se considerar que o sol é a principal fonte de energia eletromagnética disponível para o sensoriamento remoto da superfície terrestre. A atmosfera terrestre permite a propagação de um feixe de radiação eletromagnética da fonte de energia até incidir sobre os objetos da superfície terrestre. Esta radiação, ao atravessar um meio, sofre dois tipos de alterações: espalhamento e absorção, causando uma redução do fluxo radiante, denominada atenuação atmosférica, que é influenciada pelos elementos que compõem a atmosfera. Como a composição físico-química da atmosfera é dinâmica, este efeito da atenuação atmosférica será uma das distorções radiométricas da aquisição dos dados.

Uma vez que a energia faça seu caminho para incidir sobre os objetos da superfície terrestre através da atmosfera, ela vai interagir com esses objetos dependendo das propriedades de ambos, objeto e radiação. Essa interação se dá de três formas: absorção, transmissão e reflexão (Novo, 1998).

O sensoriamento remoto tem por objetivo medir e registrar essa radiação refletida dos objetos, conjuntamente com a radiação emitida pelos mesmos, visto que toda matéria a uma temperatura acima de zero grau Kelvin emite energia. A intensidade do sinal emitido ou refletido pelos objetos em diferentes regiões do espectro eletromagnético⁵ permite derivar informações sobre suas propriedades.

⁵ Conjunto de comprimentos de ondas que compõem a radiação eletromagnética.

Essa radiação eletromagnética refletida ou emitida pelos objetos da superfície da terra propaga-se pela atmosfera até atingir uma plataforma de SR, que pode estar em um satélite orbital, em uma aeronave ou em uma torre terrestre, conforme ilustra a Figura 2.2, e que deve conter um sistema sensor capaz de coletar e registrar, geralmente na forma eletrônica, essa energia. Essa energia registrada pelo sensor deve ser transmitida para uma estação de recebimento e processamento, Figura 2.3, onde os dados serão transformados em uma imagem de sensoriamento remoto.




Figura 2.2 - Tecnologias de Sensoriamento Remoto.
Fonte: INPE – DSR



Figura 2.3 - Centro de Controle de Satélite (CCS) em São José dos Campos, SP, BR.
Fonte: SELPER & INPE-DSR.

Essas imagens brutas de SR são armazenadas e transportadas ou transmitidas diretamente para um sistema de processamento digital de imagens, onde poderão ser analisadas e interpretadas, possibilitando a extração de informações do ambiente terrestre. Essas informações extraídas das imagens de sensoriamento remoto são os elementos finais de SR e podem ser utilizadas para gerar novas informações sobre a superfície terrestre, ou como elemento de apoio à tomada de decisões para solucionar um problema ambiental, implantar um projeto agroindustrial, elaborar políticas de zoneamento ecológico-econômico etc.

2.2 Processamento Digital de Imagens

O objetivo do processamento digital de imagens é o de fornecer ferramentas computacionais (equipamentos, algoritmos e programas) para automatizar a identificação e a extração de informações contidas nas imagens brutas de SR. Sistemas dedicados de computação são utilizados no processamento dessas imagens brutas de SR para produzir outras imagens contendo informações específicas e realçadas.

Este processo automatizado de extração de informações é necessário, pois a informação de interesse é caracterizada em função das propriedades dos objetos ou padrões que compõem a imagem. Portanto, essa tarefa requer grande capacidade de cognição por parte de um intérprete humano. O sistema visual humano possui notável capacidade de reconhecer padrões. Contudo, ele dificilmente é capaz de processar o enorme volume de informações

presentes em uma imagem. Vários tipos de degradações e distorções, inerentes aos processos de aquisição, transmissão e visualização de imagens, contribuem para limitar ainda mais a capacidade de interpretação humana dessas imagens brutas de SR.

Pode-se dizer que o processamento digital de imagens é um estágio intermediário no processo de utilização das imagens de SR, mas obrigatório se desejarmos ter velocidade e precisão na utilização dessas imagens.

2.3 Imagens de Sensoriamento Remoto

O processamento digital de imagens vem sendo utilizado no processamento de imagens das mais diversas origens, como, por exemplo, as imagens médicas (raio X, tomografia, ressonância magnética). Portanto, podemos utilizar algumas das técnicas do processamento digital de imagens sobre as imagens de SR, mas devemos considerar as especificidades dessas imagens para podermos utilizar essas técnicas com a maior eficiência. Essas especificidades são caracterizadas pela estrutura e resolução das imagens de sensoriamento remoto.

2.3.1 Estrutura das Imagens de Sensoriamento Remoto

A estrutura de uma imagem digital pode ser vista como um conjunto de elementos organizados na forma de uma malha. O nome dado ao elemento ou célula desta malha é *pixel*, que deriva do inglês *picture element*. A localização de cada *pixel* é definida por um sistema de coordenadas x (linha) e y (coluna) e tendo sua origem no canto superior esquerdo (x=1 e y=1). Cada *pixel* irá representar, nas imagens de SR, áreas de iguais dimensões na superfície terrestre e lhe será atribuído um valor numérico p, denominado por DN, do inglês *digital number*, que indica o nível ou tom de cinza desta célula ou *pixel* e que irá variar do preto ao branco. Esse atributo numérico de cada *pixel* representa a intensidade da energia eletromagnética refletida ou emitida da área associada ao *pixel*, mais precisamente, o atributo p vai corresponder à média das intensidades da energia refletida ou emitida pelos diferentes materiais presentes na área correspondente a esse *pixel*.

Pode-se então dizer que uma imagem de SR é uma matriz, de dimensões n_l por n_c (linhas x colunas), com cada *pixel* ou elemento dessa matriz sendo um valor numérico p ou um nível de cinza e podemos descrever matematicamente como:

$$I = I_{n_l, n_c} = [p_{xy}] \quad (2.1)$$

onde: I representa a imagem, $I_{nl,nc}$ é uma matriz nl linhas e nc colunas, p é o DN do pixel xy , $x = 1, 2, 3, \dots, nl$, $y = 1, 2, 3, \dots, nc$, nl é o número de linhas e nc é o número de colunas.

A Figura 2.4 nos mostra uma imagem simples, com apenas 3 tons de cinza, um próximo do preto, um próximo do branco e um intermediário.



Figura 2.4 - Imagem simples

A Figura 2.5 nos apresenta a representação matricial da imagem da Figura 2.4, com os valores dos *pixels* iguais a 20, 80 ou 220, representados os três tons de cinza visualizados na Figura 2.4. Finalmente a Figura 2.6 ilustra um recorte de uma imagem real de SR.

20	20	20	20	20	20	20	20	20	20
20	20	20	20	20	20	20	20	20	20
20	20	20	20	20	20	20	20	20	20
20	20	20	20	20	20	20	20	20	20
20	20	20	20	20	20	20	20	20	20
20	20	20	20	20	20	20	20	20	20
20	20	220	220	220	220	220	220	20	20
20	20	220	220	220	220	220	220	20	20
20	20	220	220	220	220	220	220	20	20
20	20	220	220	220	220	220	220	20	20
20	20	220	220	220	220	220	220	20	20
20	20	220	220	220	220	220	220	20	20
80	80	80	80	80	80	80	80	80	80
80	80	80	80	80	80	80	80	80	80
80	80	80	80	80	80	80	80	80	80
80	80	80	80	80	80	80	80	80	80
80	80	80	80	80	80	80	80	80	80
80	80	80	80	80	80	80	80	80	80
80	80	80	80	80	80	80	80	80	80
80	80	80	80	80	80	80	80	80	80

Figura 2.5 - Matriz de *pixels* da imagem da Figura 2.4.



Figura 2.6 - Imagem de Sensoriamento Remoto.

Fonte: *Natural Resources Canada*.

2.3.2 Resolução das Imagens de Sensoriamento Remoto

A resolução de uma imagem de SR pode ser definida por quatro diferentes e independentes parâmetros: a resolução espacial, a resolução espectral, a resolução radiométrica e a resolução temporal (*Natural Resources Canadá*, <<http://www.ccrs.nrcan.gc.ca>>).

2.3.2.1 Resolução Espacial

Pode-se conceitualmente definir a resolução espacial como sendo a capacidade de o sistema sensor “enxergar” objetos, isto é, de permitir distinguir e identificar objetos na superfície terrestre; quanto melhor a resolução espacial, maior o nível de detalhes perceptíveis na imagem. A determinação métrica da resolução espacial do sensor, ou área de “visão” do sensor, é definida pelo campo instantâneo de visada (IFOV- *Instantaneous Field of View*) que representa a área do terreno imageado “vista” pelo instrumento sensor, e depende do diâmetro angular α e da altitude do sensor em um determinado instante, conforme ilustra a Figura 2.7.

A resolução espacial, de uma forma simplificada, irá também representar o tamanho do *pixel*. Por exemplo, se a resolução espacial do sensor for 30 metros por 30 metros, como

nos canais 1,2,3,4,5 e 7 do sensor⁶ TM do *Landsat 5*, cada *pixel* irá representar uma área de 30 m x 30 m.




Figura 2.7 - Resolução Espacial.

2.3.2.2 Resolução Espectral

A maioria das imagens de sensoriamento remoto possuem uma característica peculiar que as distingue de outras imagens digitais: elas são imagens multiespectrais, isto é, são imagens adquiridas em várias partes do espectro eletromagnético, podendo variar da parte visível ao infravermelho termal. A Figura 2.8 ilustra as regiões de espectro eletromagnético utilizadas pelos sensores imageadores.

A imagem multiespectral pode ser representada numericamente por uma matriz:

$$I = I_{nl,nc,bn} = [p_{xyb}] \quad (2.2)$$

⁶ O sensor TM do *Landsat 5* possui 7 canais para coletar a energia eletromagnética em 7 faixas ou bandas distintas, conforme mostrado na Tabela 1.1. O canal 6 tem resolução espacial de 120 m x 120 m.

onde: I representa a imagem multiespectral, $I_{nl,nc,bn}$ é uma matriz $nl \times nc \times nb$, p é o DN do pixel xy da banda espectral b , $x = 1, 2, 3, \dots, nl$, $y = 1, 2, 3, \dots, nc$, $b = 1, 2, 3, \dots, nb$, nl é o número de linhas, nc é o número de colunas e nb é o número de bandas da imagem.




Figura 2.8 - Regiões espectrais das imagens de SR.
Fonte: Swain e Davis,(1978).

A resolução espectral é definida pelo número de bandas ou faixas espectrais de um sistema sensor e pela largura do intervalo de comprimento de onda coberto por cada banda. Quanto maior o número de bandas e menor o intervalo de cada banda, maior a resolução espectral do sensor.

O sensor TM, do satélite *Landsat 5*, por exemplo, possui 7 canais para coletar a energia eletromagnética em 7 faixas ou bandas distintas. A Tabela 1.1 mostra essas 7 faixas ou bandas espectrais e suas aplicações.

Tabela 1.1 - Bandas espectrais do sensor TM do satélite *Landsat 5*.

Fonte: SELPER & INPE-DSR .

BANDAS	FAIXA ESPECTRAL (μm)	APLICAÇÕES
1	0,45-0,52 (azul)	mapeamento de águas costeiras. diferenciação entre solo e vegetação. diferenciação entre vegetação conífera e decídua
2	0,52-0,60 (verde)	mapeamento de vegetação qualidade d'água
3	0,63-0,69 (vermelho)	absorção da clorofila diferenciação de espécies vegetais áreas urbanas, uso do solo agricultura qualidade d'água
4	0,76-0,90 (infravermelho próximo)	delineamento de corpos d'água mapeamento geomorfológico mapeamento geológico áreas de queimadas áreas úmidas agricultura vegetação
5	1,55-1,75 (infravermelho médio)	uso do solo medidas de umidade da vegetação diferenciação entre nuvem e neve agricultura vegetação
6	10,40-12,50 (infravermelho termal)	mapeamento de estresse térmico em plantas correntes marinhas propriedade termal do solo outros mapeamentos térmicos
7	2,08-2,35 (infravermelho médio)	identificação de minerais mapeamento hidrotermal

2.3.2.3 Resolução Radiométrica

A resolução radiométrica de uma imagem de SR é definida pela quantidade de bits⁷ utilizados para representar o atributo numérico do *pixel* ou os níveis (tons) de cinza da imagem e, portanto, quanto maior o número de bits, maior a quantidade de tons de cinza e melhor a resolução radiométrica da imagem. Assim, se o atributo numérico for representado por 1 bit, teremos uma imagem com $2^1 = 2$ níveis digitais ou tons de cinza (preto e branco); se for representado por 6 bits, teremos uma imagem com $2^6 = 64$ níveis digitais; e se for

⁷ BIT (dígito binário) assume apenas 2 valores: 0 e 1.

representado por 8 bits ou 1 byte⁸, a imagem terá $2^8 = 256$ tons de cinza. Portanto uma alta resolução radiométrica irá possibilitar uma maior percepção de detalhes, como ilustra a Figura 2.9 com duas imagens da mesma área; a primeira, uma imagem de 1 bit ou 2 níveis digitais e a segunda, uma imagem de 2 bits ou 4 níveis de cinza.




Figura 2.9 - Imagens de 1 bit e 2 bits
Fonte: Moreira (2001).

Como se pode observar, existe uma diferença no nível de detalhes entre as duas imagens: a imagem de 4 níveis digitais, maior resolução radiométrica, possui um maior nível de discernimento dos detalhes.

2.3.2.4 Resolução Temporal

Pode-se definir resolução temporal como o intervalo de vezes em que o satélite observa uma mesma área do terreno. A resolução temporal refere-se à periodicidade com que o sistema sensor adquire imagens da mesma área da superfície terrestre. Os satélites de sensoriamento remoto orbitam ao redor da Terra em órbita quase polar, ou seja, de um pólo a outro, a uma distância da superfície terrestre em torno de 800 km, conforme é exemplificado na Figura 2.10. Através da combinação sincronizada da velocidade do satélite com a rotação da Terra é possível recobrir todo o planeta após um certo período de tempo. Cada passagem do satélite é chamada de órbita.

⁸ BYTE - conjunto ordenado de 8 bits.




Figura 2.10 - Órbitas de um satélite
 Fonte: INPE – DSR [14].

A frequência dos sistemas espaciais varia de acordo com os objetivos fixados para o sensor. Os satélites meteorológicos são obrigados a fornecer informação em períodos curtos de tempo, pois se dedicam a observar fenômenos muito dinâmicos. Por essa razão, sua resolução temporal é definida em minutos ou horas. Os satélites de recursos naturais oferecem uma periodicidade muito menor, pois coletam informações de fenômenos não tão dinâmicos como os meteorológicos. Assim, a resolução temporal desses satélites é definida em dias, por exemplo, o sensor TM do *Landsat 5* tem uma órbita de imageamento de 185 km e recobre todo o planeta a cada 16 dias, isto é, a cada 16 dias o *Landsat 5* passa sobre um mesmo ponto geográfico da Terra. Portanto, tem uma resolução temporal de 16 dias.

2.4 Pré-processamento de Imagens

No processamento digital de imagens de SR, é necessária a realização de uma primeira etapa, denominada por alguns autores, como Mather (1999), de pré-processamento das imagens, que consiste num conjunto de técnicas que preparam as imagens brutas, corrigindo-as radiometricamente e geometricamente, para que possam ser efetivamente utilizadas nas etapas seguintes dos processamentos digitais das imagens.

As imagens brutas contêm erros geométricos e radiométricos inerentes ao processo de aquisição e registro dos dados. No início da utilização das imagens de SR, essas correções iniciais tinham que ser realizadas pelos próprios usuários dos dados de SR, o que dificultava a sua utilização, pois exigia um alto grau de conhecimento nas áreas de geoprocessamento e

processamento digital de imagens. A tendência atual é a de que os dados fornecidos pelos centros de recepção e distribuição já tenham sofrido essas correções básicas.

2.4.1 Correção Radiométrica

Os erros radiométricos originam-se dos instrumentos sensores utilizados para a coleta e registro dos dados e dos efeitos da atenuação atmosférica (absorção e espalhamento). A interferência da atmosfera e os instrumentos utilizados na aquisição dos dados podem causar dois tipos de erros em uma imagem: primeiro, a distribuição dos níveis digitais dentro de uma imagem não corresponde à distribuição da radiância ou brilho da cena; segundo, a variação relativa dos níveis digitais para um dado *pixel* nas diferentes bandas não corresponde ao comportamento espectral dos objetos da cena. Esses erros precisam ser eliminados pelas correções radiométricas⁹.

Os conceitos fundamentais da correção radiométrica e algumas das principais técnicas para correção desses erros são apresentados no capítulo IV.

2.4.2 Correção Geométrica e Registro de Imagem

O objetivo da correção geométrica é realizar uma reestruturação dos *pixels* de uma imagem relacionando-os a um determinado sistema de projeção cartográfica, para adicionar a uma imagem de SR uma precisão cartográfica quanto ao posicionamento dos objetos, superfícies ou fenômeno representados na imagem.

A falta de precisão das imagens orbitais ocorre em função de uma série de distorções espaciais, sendo que as duas fontes principais dessas distorções são a rotação da Terra e a instabilidade da plataforma.

A relação entre as coordenadas dos dois sistemas mapa¹⁰ e imagem, sendo que em uma imagem as coordenadas são definidas pelos pontos *x* e *y* do *pixel* e em um mapa por suas coordenadas geográficas (latitude e longitude), pode ser calculada através de duas metodologias: transformação baseada no modelo de geometria orbital e transformação baseada em pontos de controle no terreno.

⁹ Para um estudo mais aprofundado consultar Mather, P. N. Computer Processing of Remotely-Sensed Images. Wiley, 1999. capítulo 4.

¹⁰ Segundo Crosta(1992) um mapa pode ser definido como uma representação gráfica, em uma superfície plana, da superfície da Terra, ou parte dela, mostrando suas feições geográficas e superficiais. Estas são posicionadas de acordo com controles geodésicos, grids, projeções e escalas previamente definidos.

2.4.2.1 Transformação Baseada no Modelo de Geometria Orbital

Esta metodologia utiliza conhecimentos das características orbitais do satélite, da rotação da Terra e do fator de amostragem do sensor para realizar a correção geométrica.

O grau de precisão dessa técnica é relativamente baixo e os centros de recepção e distribuição de imagens de SR executam rotineiramente esse tipo de correção em seus produtos para distribuição aos usuários.

2.4.2.2 Transformação Baseada em Pontos de Controle no Terreno

Devido à pouca precisão obtida pela transformação baseada no modelo de geometria orbital, às vezes é preciso refinar a correção geométrica de uma imagem. Para obter essa precisão mais elevada utiliza-se a transformação baseada em pontos de controle no terreno, sendo que essa maior precisão dependerá diretamente da precisão na identificação e posicionamento dos pontos de controle.

Para corrigir a imagem devemos escolher alguns pontos e determinar as diferenças de posicionamento desses pontos na imagem e no mapa. Essas diferenças representarão as distorções existentes na imagem e serão utilizadas para, através de uma transformação adequada, computar a correção geométrica de toda a imagem.¹¹

Esses pontos, denominados pontos de controle no terreno (GCPs, *ground control points*), devem ter feições bem definidas, pois precisam ser facilmente identificados tanto no mapa quanto na imagem. Exemplos típicos de GCPs são: intersecção de estradas, limites de feições agrícolas, pistas de aeroportos e outros. Esses GCPs são identificados e posicionados de maneira interativa na imagem, na forma de coordenadas em linha e coluna. As coordenadas geográficas dos mesmos GCPs são obtidas a partir dos mapas, quando existirem com grau de confiabilidade aceitável e em escala adequada, ou através do uso de GPS¹². Crosta (1992) estima que seja necessário, no mínimo, de 6 a 10 pontos de controle para uma área de 1000 x 1000 *pixels* na imagem.

¹¹ Para um estudo mais detalhado da modelagem matemática utilizada na transformação de uma imagem bruta de SR em uma imagem corrigida geometricamente, podemos consultar Crosta (1992) ou Mather (1999).

¹² GPS ou sistema de posicionamento global é um sistema composto por um conjunto de satélite e um aparelho receptor que permite, através de medidas das distâncias entre os satélites e o usuário (aparelho GPS), determinar por triangulação coordenadas geográficas/topográficas precisas (CIAGRI-USP, <<http://www.gps.ciagri.usp.br>>).

2.4.2.3 Registro de Imagem

Em algumas aplicações de imagens de SR como, por exemplo, na análise de detecção de mudanças de imagens multi-temporais ou na utilização de imagens de diferentes sensores de uma mesma área, é necessário assegurar que o *pixel* de mesma coordenada x e y nas duas imagens represente a mesma área da superfície terrestre, isto é, que ambas as imagens estejam perfeitamente registradas entre si.

Existem duas maneiras de registrar imagens: o modo automático e o modo manual.

No modo automático utilizam-se algoritmos que realizem uma análise de similaridade entre as imagens, de forma a se obter o casamento dos *pixels* entre as duas imagens. Esse método é de alta precisão, mas requer algoritmo complexo e equipamento computacional com grande capacidade de processamento.

O registro manual se baseia na identificação de pontos de controle, semelhante aos GCPs da correção geométrica, nas duas imagens e ao invés de registrar as coordenadas geográficas de um mapa, como na correção geométrica, vão-se registrar duas coordenadas x e y das duas imagens entre si.

CAPÍTULO III

REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) começaram com o trabalho pioneiro de McCulloch e Pitts, em 1943, que sugeria a construção de uma máquina baseada ou inspirada no cérebro humano e evoluiu como um tema interdisciplinar com raízes profundas em neurociência, psicologia, matemática, ciências físicas e engenharias. Além disso, as RNAs apresentam grande potencial de aplicação em diversas áreas do conhecimento humano como, por exemplo, no processamento digital de imagens de sensoriamento remoto, enfoque de nosso trabalho, no qual serão utilizadas RNAs nos procedimentos de classificação de imagens de SR. Assim, apresentaremos neste capítulo uma introdução a essa tecnologia da informação.

Podemos entender uma Rede Neural Artificial (RNA) como um modelo matemático computacional que procura tornar o processamento de um computador semelhante ao funcionamento do cérebro humano, que é um sistema de processamento de informações altamente complexo, não-linear e paralelo, constituído por bilhões de neurônios fortemente conectados, formando uma rede com notável capacidade para realizar funções que envolvam percepção e reconhecimento de padrões (objetivo do nosso trabalho), entre outras, e com isto conseguir um modo de processamento do computador mais eficiente que uma computação digital convencional (Haykin, 2001).

A modelagem de uma RNA pode ser dividida em 3 níveis: o neurônio artificial, a topologia ou arquitetura da rede e o processo ou algoritmo de aprendizado. O neurônio é o elemento de processamento (EP) computacional básico que forma a rede. A topologia define a estrutura das conexões dos neurônios. O algoritmo de aprendizado descreve um método para mudar o comportamento individual dos neurônios com o objetivo de a RNA adquirir um determinado conhecimento¹³ (Haykin, 2001; Galvão *et al*, 1999).

3.1 Definição de uma Rede Neural Artificial

De uma maneira mais formal, Valença e Ludermir (1999:19) definem uma RNA como “um sistema constituído por elementos de processamento interconectados, chamados de

¹³ Conhecimento se refere à informação armazenada em uma RNA, sendo utilizada rede para interpretar, prever e responder apropriadamente a uma excitação externa.

neurônios, os quais estão dispostos em camadas (uma camada de entrada, uma ou várias intermediárias e uma de saída) e são responsáveis pela não-linearidade da rede, através do processamento interno de certas funções matemáticas”.

Uma RNA, segundo Haykin (1999), se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de um conjunto de treinamento, através de um processo de aprendizagem. Esse processo de aprendizagem é realizado por um algoritmo de aprendizagem, cuja função é modificar os pesos sinápticos da rede, de forma ordenada, para adquirir o conhecimento desejado.
2. Os pesos sinápticos ou elos de conexão são utilizados para armazenar o conhecimento adquirido.

As principais características das RNAs (Rumelhart e Clelland, apud Biondi, 2001: 73), são: a) procura paralela e endereçamento pelo conteúdo - semelhante ao cérebro, que não possui endereço de memória nem procura uma informação seqüencialmente; b) aprendizado - as RNAs têm capacidade de aprender certo conhecimento por sucessivas apresentações de padrões (experiência), sem necessidade de projetar os algoritmos para executar um aprendizado específico; c) associação - possibilita que as RNAs possam associar padrões diferentes; d) generalização - habilita as RNAs a lidar com ruído e distorções e a responder corretamente a uma entrada nunca vista, por similaridade com outros padrões já apresentados; e) abstração - as RNAs têm capacidade de abstrair a essência de um conjunto de entradas (conjunto de treinamento); f) robustez - permite, devido ao paralelismo, que, mesmo com a perda de EPs, não haja mau funcionamento da rede.

3.2 Modelo do Neurônio Artificial

O neurônio é a unidade elementar de processamento de uma RNA, também identificado com Elemento Processador (EP). A Figura 3.1 mostra o modelo não-linear de um neurônio, baseado no modelo proposto por McCulloch e Pitts em 1943 (McCulloch & Pitts, 1943).

Três elementos básicos podem ser identificados nesse modelo: os pesos sinápticos, o somador e a função de ativação.

1. Pesos sinápticos ou elos de conexão: é um valor numérico W_{kj} , que pode estar em um intervalo que inclui valores negativos e positivos, multiplicador da entrada x_j da sinapse j do neurônio k .

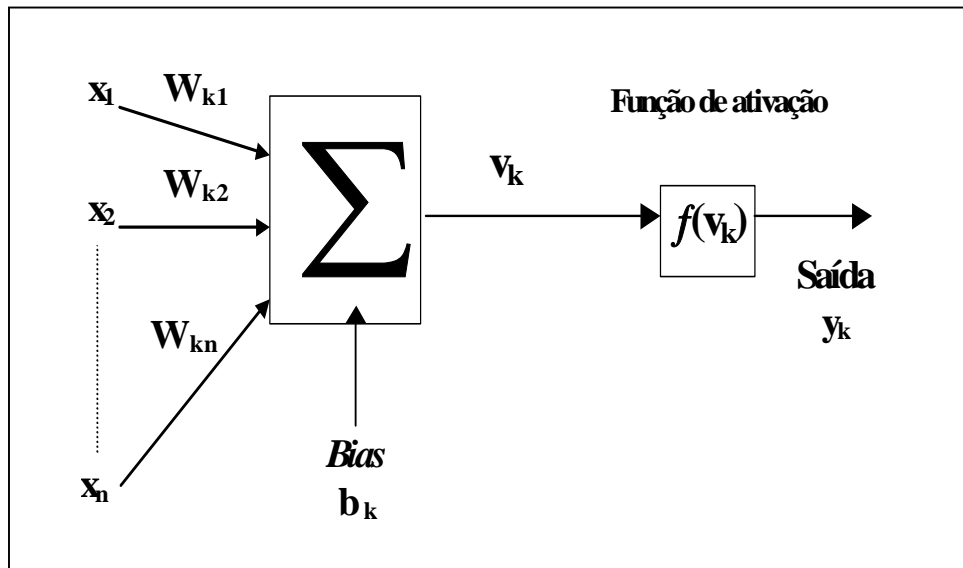


Figura 3.1 - Modelo de um neurônio artificial.

2. Somador: componente que soma as entradas x_j , ponderadas pelos respectivos pesos sinápticos do neurônio k , constituindo um combinador linear.
3. Função de ativação: tem a função de restringir a amplitude da saída de um neurônio, limitando o intervalo permitido da amplitude da saída a um valor finito. Tipicamente, o intervalo normalizado da amplitude da saída de um neurônio é definido como o intervalo fechado $[0,1]$, ou alternativamente $[-1,1]$.

A seguir, são apresentados os três tipos básicos de função de ativação: função degrau, função rampa e função sigmóide.

3.1 Função degrau: para este tipo de função de ativação, mostrada na Figura 3.2, temos:

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




Figura 3.2 - Função degrau.

2.2 Função rampa: para função linear por partes, apresentada na Figura 3.3, temos:

$$f(v) = \begin{cases} 1, & \text{se } v \geq 1 \\ v, & \text{se } |v| < 1 \\ -1, & \text{se } v \leq -1 \end{cases} \quad (3.2)$$




Figura 3.3 - Função rampa.

3.3 Função sigmóide: é a função de ativação mais comum utilizada na construção de RNAs, mostrada na Figura 5.14 e definida por:

$$f(v) = \frac{1}{1 + e^{-v}} \quad (3.3)$$




Figura 3.4 - Função sigmóide.

O modelo do neurônio ou elemento processador da Figura 3.1 inclui também um *bias*, representado por b_k . O *bias* b_k tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo.

O modelo matemático de um neurônio k pode ser descrito pelas equações:

$$u_k = \sum_{i=1}^n w_{ki} \cdot x_i \quad (3.4)$$

$$v_k = u_k + b_k \quad (3.5)$$

$$y_k = f(v_k) \quad (3.6)$$

onde:

- x_1, x_2, \dots, x_n são as entradas do neurônio k ;
- $w_{k1}, w_{k2}, \dots, w_{kn}$ são os pesos do neurônio k ;
- u_k é a saída do somador ou combinador linear;
- b_k é o *bias*;
- $f(v)$ é a função de ativação;
- y_k é a saída do neurônio k .

3.3 Topologias das Redes Neurais Artificiais

As topologias ou arquiteturas das RNAs definem sua estrutura, isto é, a arquitetura das ligações entre seus elementos processadores (neurônios) e estão intimamente ligadas ao algoritmo de aprendizado. Em geral, as RNAs são identificadas como pertencentes a uma das três classes: redes alimentadas adiante com camada única, redes alimentadas diretamente com múltiplas camadas e redes recorrentes (Haykin, 2001).

3.4 Processo de Aprendizado de uma Rede Neural Artificial

A propriedade mais importante das redes neurais é a capacidade de aprender a partir de seu ambiente e com isso melhorar seu desempenho. A aprendizagem é realizada através de um treinamento, que é um processo iterativo de ajustes aplicado a seus pesos. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

As redes neurais se baseiam nos dados para extrair um modelo geral. Portanto, a fase de aprendizado deve ser rigorosa e verdadeira, a fim de se evitarem modelos espúrios. Todo o conhecimento de uma rede neural está armazenado nas sinapses, ou seja, nos pesos atribuídos

às conexões entre os neurônios. Uma porcentagem dos dados, acima de 50%, do total dos dados do conjunto de treinamento deve ser separada para o aprendizado ou treinamento da rede neural, dados estes escolhidos aleatoriamente, a fim de que a rede "aprenda" as regras e não "decore" exemplos. O restante dos dados só é apresentado à rede neural na fase de testes, a fim de que se possa avaliar o desempenho da rede.

3.4.1 Paradigmas de Aprendizagem

Os dois principais paradigmas de aprendizagem das RNAs são: o supervisionado e o não supervisionado. Na aprendizagem supervisionada, o aprendizado da rede é feito com o conhecimento prévio do resultado desejado, ou seja, são fornecidos à rede um conjunto de dados de entrada e as respectivas respostas. A diferença entre a resposta desejada e a atual, fornecida pela rede, é então usada para calcular a correção dos pesos da RNA até essa diferença convergir para um erro estipulado e, portanto, a rede adquirir o conhecimento desejado. Na aprendizagem não supervisionada, a rede aprende com os próprios dados de entrada (somente os estímulos de entrada são mostrados à rede), não requer o conhecimento das saídas. Neste caso, a rede se auto-organiza de forma a adquirir um conhecimento baseado em padrões de semelhança.

3.4.2 Algoritmos de Aprendizagem

Denomina-se algoritmo de aprendizagem a um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado, específicos para determinados modelos de redes neurais. Esses algoritmos diferem entre si principalmente pelo modo como os pesos são modificados, isto é, pelas regras de aprendizagem.

3.5 Redes Neurais de Aprendizado Competitivo

Redes Neurais competitivas podem aprender a detectar regularidades e correlações em suas entradas e adaptar-se para responder a futuras entradas de acordo com esse aprendizado. Os neurônios das redes competitivas aprendem a reconhecer padrões de similaridades nos dados de entrada pela proximidade dos elementos do vetor de entrada.

A arquitetura de uma rede competitiva é apresentada na Figura 3.5.




Figura 3.5 – Rede Competitiva.

O número n das entradas (x_i) será definido pelo número de características existentes no conjunto de dados de entrada. O número m das saídas (y_k) ou neurônios será definido pelo número de classes ou padrões de semelhança estabelecidos.

A cada entrada apresentada, a rede competitiva encontra o neurônio vencedor j , que é o neurônio que apresenta a menor distância entre a entrada e seus pesos, e é definido por:

$$j = \arg \min_k \|x - W_k\| \quad 3.7$$

onde:

$$\|x - W_k\| = \sqrt{\sum_{i=1}^n (x_i - W_{ki})^2} \quad 3.8$$

e W_{ki} é peso da entrada i do neurônio k .

Apenas esse neurônio vencedor tem seus pesos ajustados de forma a convergir para o centróide da classe ou ponto de identificação do padrão, conforme a equação 3.12.

A função de transferência competitiva aceita uma entrada e retorna as saídas dos neurônios em 0 para todos os neurônios, com exceção do neurônio vencedor cuja saída será 1.

Quando não houver mais modificações dos neurônios vencedores de todas as entradas apresentadas à rede, a rede concluiu a identificação.

3.6 Mapas Auto-organizáveis

Uma RNA que utiliza o modelo de mapas auto-organizáveis (SOM, *self-organization map*) foi proposta por Kohonen em 1982, sendo uma rede neural construída em cima de uma grade unidimensional ou bidimensional de neurônios, para extrair ou capturar características (padrões) contidas em um conjunto de dados de entrada.

Os mapas auto-organizáveis utilizam uma topologia de rede com os neurônios ou Eps distribuídos, usualmente, em uma grade bidimensional, conforme apresentamos na Figura 3.6.

Cada neurônio da rede irá representar uma saída da rede e todos estarão amplamente conectados com as entradas, conforme podemos visualizar na Figura 3.6.

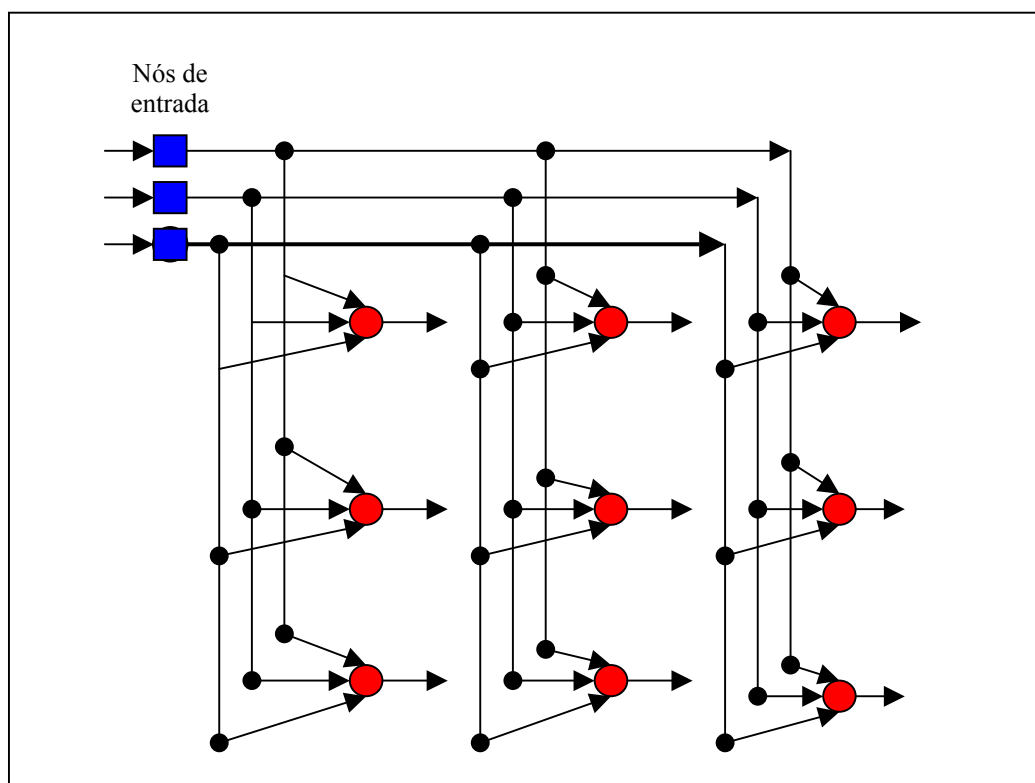


Figura 3.6 – SOM Grade bidimensional.

Se a entrada x é descrita como:

$$x = [x_1, x_2, x_3, \dots, x_n] \quad (3.9)$$

onde n é o número de entradas, a saída de cada neurônio será dada pela distância euclidiana entre as entradas e os pesos do neurônio; portanto, a saída do neurônio k será:

$$y_k = d = \sqrt{\sum_{i=1}^n (x_i - W_{ki})^2} = \|x - W_k\| \quad (3.10)$$

onde:

- y_k , a saída do neurônio k .
- d , distância euclidiana.
- x_i , entrada i da rede
- W_{ki} , peso da entrada i do neurônio k .
- $k = 1, 2, 3, \dots, m$ (identifica o neurônio).
- $i = 1, 2, 3, \dots, n$ (identifica a sinapse).

O treinamento da rede é realizado por um processo não supervisionado de aprendizagem competitiva, obedecendo à regra de Kohonen ou regra do “vencedor leva tudo”.

Na adaptação dos neurônios ou no ajuste dos pesos, considerando a regra do “vencedor leva tudo”, primeiramente deve-se determinar, para a entrada apresentada, o neurônio vencedor, isto é, o neurônio de menor saída (menor distância euclidiana entre as entradas e os pesos do neurônio). A identificação do neurônio vencedor j será:

$$j = \underset{k}{\operatorname{argmin}} \|x - W_k\| \quad (3.11)$$

Então, apenas este neurônio vencedor j terá seus pesos ajustados:

$$W_{ji}(t+1) = W_{ji}(t) + \eta(ep) \cdot [x_i(t) - W_{ji}(t)] \quad (3.12)$$

onde:

- $W_{ji}(t+1)$ são os pesos do neurônio vencedor j ajustados para a próxima iteração.
- $W_{ji}(t)$ são os pesos do neurônio vencedor j na iteração atual.
- $(x_i(t) - W_{ji}(t))$, taxa de erro entre as entradas e os pesos do neurônio vencedor.
- $\eta(ep)$, taxa de aprendizado ou ganho de adaptação na época ep .
- t , iteração ou apresentação de um dado do conjunto de dados de entrada.
- $k = 1, 2, 3, \dots, m$ (identifica o neurônio).
- $i = 1, 2, 3, \dots, n$ (identifica a sinapse).

Deve-se ter um número razoavelmente grande de épocas, sendo uma época definida como a apresentação de todos os dados do conjunto de treinamento. Empiricamente têm-se adotado 500 épocas para cada neurônio. Assim, tendo o mapa 10 neurônios, o treinamento da rede se encerra em 5000 épocas (Kohonen, 1989).

No processo de adaptação ou ajuste dos pesos, o ganho de adaptação ou taxa de aprendizado $\eta(ep)$ é um valor escalar, tal que $0 < \eta(ep) < 1$, e é decrementado com o tempo; se for escolhida uma taxa de aprendizado linear¹⁴, tem-se:

$$\eta(ep) = \eta(0) \cdot (1 - ep/T) \quad (3.13)$$

onde:

- $\eta(ep)$, taxa de aprendizado na época e .
- $\eta(0)$, taxa de aprendizado inicial.
- T , total de épocas.
- ep , época corrente.

A característica topológica, grade de Eps, das redes SOM possibilita a definição de vizinhos de um neurônio, possibilitando estender o ajuste dos pesos aos vizinhos do neurônio vencedor. Assim, apenas os neurônios fora do subconjunto de vizinhos do neurônio vencedor não serão alterados. O ajuste da vizinhança é uma espécie de estímulo aos neurônios que ficam ao redor do vencedor, para que possam vir a ter as mesmas condições de disputa com o neurônio vencedor nas próximas iterações (Kohonen, 1989).

O conjunto inicial de vizinhos deve começar extenso, para um ordenamento mais global da rede, e monotonicamente diminuído com o tempo de treinamento, tendendo o subconjunto de vizinhos ao próprio neurônio vencedor.

Terminado o treinamento, ficam definidos os neurônios vencedores, e cada neurônio vencedor indicará uma classe ou padrão existente no conjunto de dados. Assim a rede se encontra pronta para realizar a classificação de um dado qualquer, bastando apresentá-lo às entradas da rede e avaliar o neurônio vencedor. Assim sendo, o dado apresentado deve ser classificado como pertencente à classe associada ao neurônio vencedor.

3.7 Desenvolvimento de Aplicações

Esta seção procura apresentar os passos necessários ao desenvolvimento de uma aplicação utilizando redes neurais artificiais (Tatibana & Kaetsu, <<http://www.din.uem.br/io/neurais/>>), sendo esses os passos: a coleta e a preparação dos conjuntos de dados, a definição da configuração da rede, o treinamento da rede, o teste de verificação da rede e a integração ou utilização da rede.

¹⁴ Pode-se, também, escolher a taxa exponencial ou proporcional.

3.7.1 Coleta de Dados e Preparação do Conjunto de Dados de Treinamento

O primeiro passo do processo de desenvolvimento de redes neurais artificiais é a coleta de dados relativos ao problema e a sua separação em um conjunto de treinamento e um conjunto de testes. Esta tarefa requer uma análise cuidadosa sobre o problema para minimizar ambigüidades e erros nos dados. Além disso, os dados coletados devem ser significativos e cobrir amplamente o domínio do problema; não devem cobrir apenas as operações normais ou rotineiras, mas também as exceções e as condições nos limites do domínio do problema.

Normalmente, os dados coletados são separados em duas categorias: dados de treinamento, que serão utilizados para o treinamento da rede, e dados de teste, que serão utilizados para verificar sua performance sob condições reais de utilização. Além dessa divisão, pode-se usar também uma subdivisão do conjunto de treinamento, criando um conjunto de validação, utilizado para verificar a eficiência da rede quanto à sua capacidade de generalização durante o treinamento, e podendo ser empregado como critério de parada do treinamento.

Depois de determinados esses conjuntos, eles são geralmente colocados em ordem aleatória para prevenção de tendências associadas à ordem de apresentação dos dados. Além disso, pode ser necessário pré-processar esses dados, através de normalizações, escalonamentos e conversões de formato para torná-los mais apropriados à sua utilização na rede.

3.7.2 Configuração da rede

O segundo passo é a definição da configuração da rede, que pode ser dividido em três etapas:

1. Seleção do paradigma neural apropriado à aplicação;
2. Determinação da topologia da rede a ser utilizada: o número de camadas, o número de unidades em cada camada etc.;

3. Determinação de parâmetros do algoritmo de treinamento e funções de ativação. Esse passo tem um grande impacto na performance do sistema resultante. Existem metodologias, "dicas" e "truques" na condução dessas tarefas. Normalmente essas escolhas são feitas de forma empírica. A definição da configuração de redes neurais é ainda considerada uma arte que requer grande experiência dos projetistas.

3.7.3 Treinamento

O terceiro passo é o treinamento da rede. Nessa fase, seguindo o algoritmo de treinamento escolhido, serão ajustados os pesos das conexões. É importante considerar, nessa fase, alguns aspectos tais como a inicialização da rede e o tempo de treinamento.

Uma boa escolha dos valores iniciais dos pesos da rede pode diminuir o tempo necessário para o treinamento. Normalmente, os valores iniciais dos pesos da rede são números aleatórios uniformemente distribuídos em um intervalo definido. A escolha errada desses pesos pode levar a uma saturação prematura.

Quanto ao tempo de treinamento, vários fatores podem influenciar a sua duração, porém sempre será necessário utilizar algum critério de parada, e geralmente é utilizado um número máximo de ciclos. Mas devem ser consideradas a taxa de erro médio por ciclo e a capacidade de generalização da rede. Pode ocorrer que, em um determinado instante do treinamento, a generalização comece a degenerar, causando o problema de supertreinamento (*over-training*), ou seja, a rede se especializa no conjunto de dados do treinamento e perde a capacidade de generalização.

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

3.7.4 Verificação da Rede

O quarto passo é um teste de verificação do funcionamento da rede. Durante essa fase, o conjunto de testes é utilizado para determinar a performance da rede com dados que não

foram previamente utilizados. A performance da rede, medida nesta fase, é uma boa indicação de sua performance real.

Devem ser considerados ainda outros testes, como análise do comportamento da rede, utilizando entradas especiais, e análise dos pesos atuais da rede, pois se existirem valores muito pequenos, as conexões associadas podem ser consideradas insignificantes e assim serem eliminadas. De modo inverso, valores substantivamente maiores que os outros poderiam indicar que houve supertreinamento da rede.

3.7.5 Integração ou Utilização da Rede

Finalmente, com a rede treinada e avaliada, ela pode ser integrada em um sistema do ambiente operacional da aplicação. Para maior eficiência da solução, este sistema deverá conter facilidades de utilização, como interface conveniente e facilidades de aquisição de dados através de planilhas eletrônicas, interfaces com unidades de processamento de sinais, ou arquivos padronizados. Uma boa documentação do sistema e o treinamento de usuários são necessários para o sucesso da aplicação da rede.

Além disso, o sistema deve periodicamente monitorar sua performance e fazer a manutenção da rede quando for necessário, ou indicar aos projetistas a necessidade de retreinamento. Outras melhorias poderão ainda ser sugeridas, quando os usuários forem se tornando mais familiares com o sistema. Essas sugestões poderão ser muito úteis em novas versões ou em novos produtos.

CAPÍTULO IV

CORREÇÃO RADIOMÉTRICA

Na seção 2.4.1 foram apresentadas as causas dos erros radiométricos, seus efeitos em uma imagem de SR e, portanto, a necessidade da correção radiométrica. De acordo com Croce (<http://www.croce.ggf.br>), a correção dos erros radiométricos é importante em três casos específicos: 1) quando o usuário quer recuperar o valor da grandeza radiométrica medida, ou seja, ele deseja conhecer a reflectância, ou a emitância, ou o retroespalhamento do objeto em estudo; 2) quando o usuário precisa utilizar algoritmos que se baseiem em operações aritméticas entre bandas; 3) quando o usuário quer comparar imagens de diferentes datas em termos das propriedades dos objetos na cena.

4.1 Correção dos Efeitos Atmosféricos

Os efeitos da atenuação atmosférica sobre as imagens de SR são a redução do contraste entre os objetos e a redução da capacidade de diferenciar pequenos objetos, ou diferenciar objetos que tenham pequena diferenciação na intensidade da reflectância ou emitância.

A correção precisa ou absoluta dos efeitos atmosféricos necessita de informações que possibilitem determinar o espalhamento e a absorção pela atmosfera nos diferentes comprimentos de ondas. O grande problema é que essas informações dificilmente estão disponíveis. Em função dessa dificuldade, métodos de correção absoluta menos precisos, mas possíveis de serem executados, foram desenvolvidos para eliminar erros mais grosseiros.

Um dos métodos mais simples de correção atmosférica tem como base a suposição de que em toda cena deve existir um objeto de radiância zero, e que, em decorrência da interferência atmosférica, um valor constante foi adicionado a todos os *pixels* da cena. Portanto, para o histograma¹⁵ obtido para toda a cena, o menor valor de radiância será diferente de zero. A análise do histograma de cada banda permite determinar quanto os dados estão desviados da origem, devido ao efeito atmosférico nesta determinada banda; esse valor é então subtraído de todos os *pixels* dessa banda. Realizado esse processo para todas as bandas, obtém-se um conjunto de dados corrigidos dos efeitos aditivos da interferência atmosférica.

¹⁵ Histograma: uma das formas de representar a distribuição dos *pixels* de uma imagem.

4.2 Correção dos Erros Instrumentais

Os métodos de correção dos erros instrumentais procuram minimizar os erros causados pela operação dos sistemas sensores e equipamentos de transmissão.

Dentre os erros existentes, o mais prejudicial à extração de informações está relacionado aos sistemas detectores, que não conseguem manter ao longo do tempo e do espaço a mesma função de transferência. Para correção desses erros, devemos executar procedimentos que transformem a resposta original do detector, não linear, numa resposta linear.

Outro erro radiométrico instrumental inerente ao processo de imageamento é a ausência de linhas da imagem, que pode ser provocada por alterações na órbita do satélite, falhas intermitentes na transmissão do sinal etc. Embora os dados não existam mais, desenvolveram-se métodos para estimá-los a partir da análise de *pixels* adjacentes, de modo que a imagem possa ser utilizada. A correção de linhas não registradas utiliza métodos baseados no pressuposto da autocorrelação espacial, isto é, a correlação entre um dado e seus vizinhos mais próximos. Essa correlação permite que se possam estimar as linhas não registradas a partir das linhas adjacentes.

Essas correções dos erros instrumentais são normalmente realizadas nos centros de recepção e distribuição de imagens de sensoriamento remoto.

4.3 Correção Radiométrica Relativa

Numerosos estudos mostraram tratar-se de uma meta evasiva, se não inacessível, realizar a correção radiométrica precisa e absoluta das imagens de SR. Este tipo de correção requer conjuntos de dados auxiliares como, por exemplo, temperatura atmosférica e umidade relativa, que normalmente são muito exigentes quanto à necessidade de logística e de tempo de mão-de-obra (Yuan & Elvidge, 1996). Procedimentos de correção radiométrica relativa podem ser aplicados para escalonar todas as imagens em uma única referência e ajustar as propriedades radiométricas das imagens corrigidas, a fim de compatibilizá-las com a referência. As imagens transformadas parecem ter sido adquiridas com o sensor de imagem de referência, sob as mesmas condições atmosféricas e de iluminação da cena de referência (HALL *et al*, 1991). Essas transformações desenhadas para normalizar ou contornar diferenças radiométricas entre as imagens brutas normalmente melhoram bastante os resultados de detecção de mudanças (Velloso & Souza, 2002 e Lunetta *et al*, 1998).

Uma extensa gama de algoritmos foi desenvolvida para ajustar modelos lineares, realizando uma transformação ou regressão linear; todavia, várias situações reais apresentam comportamento não linear. A Figura 4.1 mostra o gráfico *quantile-quantile* (qq-plot) das bandas 3, 4 e 5 de imagens multiespectrais, de datas diferentes, adquiridas pelo sensor *Thematic Mapper* do satélite *Landsat 7*. O objetivo do gráfico *quantile-quantile* (qq-plot) é determinar se as amostras em dois conjuntos de dados vêm de um mesmo tipo de distribuição. Se as amostras vêm de uma mesma distribuição (mesma forma), mesmo que uma distribuição seja deslocada e reescalonada a partir da outra (local e parâmetros de escala diferentes), a plotagem será linear. A plotagem da Figura 4.1 mostra forte comportamento não linear nas três bandas.




Figura 4.1 - qq-plot das bandas 3,4 e 5 de imagens multiespectrais, de datas diferentes, adquiridas pelo sensor *TM* do satélite *Landsat 7*.

A tarefa de aproximação da função de regressão pode ser realizada essencialmente de dois modos. A abordagem paramétrica, muito freqüentemente usada, é considerar que a curva de regressão de aproximação possui alguma forma funcional pré-especificada. Como

alternativa, a abordagem de normalização não paramétrica tenta estimar a curva de regressão não parametricamente, sem referência a uma forma específica. A abordagem de normalização não paramétrica, uma aproximação não linear para as funções de regressão, seria mais apropriada, tendo em vista o comportamento não linear apresentado nas três bandas de uma imagem de SR.

A maioria dos modelos relativos de transformação de imagem requerem que a porcentagem de *pixels* modificados na imagem seja relativamente pequena em relação à imagem inteira. Um assunto pendente é como identificar automaticamente o conjunto de *pixels* não variáveis.

4.3.1 Extração Automatizada do Conjunto de Treinamento

Como conjunto de *pixels* não variáveis, Hall (1991) propõe um subconjunto baseado em *pixels* de reflectância estável, derivados dos extremos do diagrama de dispersão (*scattergram*). Outros métodos têm usado *pixels* de reflectância estável, ou as chamadas características pseudo-invariáveis. Os valores desses *pixels* estáveis são usados para encontrar coeficientes lineares a fim de escalonar cada imagem para a referência. Contudo, tais *pixels* estáveis podem não estar disponíveis em algumas áreas, ou podem ser obscurecidos por nuvens ou podem estar ausentes em algumas datas. Algumas abordagens selecionam aleatoriamente os *pixels* e adotam a estratégia de eliminar ou atenuar os *pixels* identificados como *outliers*. Não obstante, tal abordagem só pode ser utilizada se a quantidade de *pixels*, cujos números digitais (DNs) foram modificados na imagem, for relativamente pequena em relação à imagem inteira.

Neste trabalho, propõe-se selecionar automaticamente o subconjunto de *pixels* não variáveis e utiliza-se um procedimento de correlação. Recortes ou extratos de imagem de tamanho 21×21 ¹⁶ *pixels* são utilizados no procedimento, que processa as imagens banda a banda. Esse procedimento resulta num mapa de correlação.

Um recorte da imagem de referência é colocado sobre o recorte centralizado nas mesmas coordenadas na outra imagem. Então a correlação bidimensional entre os *pixels* do recorte é calculada e registrada em um mapa bidimensional, com as mesmas dimensões das imagens e nas mesmas posições dos centros dos recortes das imagens. Esta operação é repetida para todas as coordenadas.

¹⁶ Em Mather (1999) é sugerido a utilização de recortes de 19×19 , experimentou-se tamanhos de 17×17 , 19×19 , 21×21 e 23×23 e concluiu-se empiricamente que o melhor tamanho foi 21×21 .

Assim, é atribuído um coeficiente de correlação para cada *pixel*, para todas as bandas, obtido nos recortes centralizados nesse *pixel*.

A Figura 4.2 mostra uma plotagem do mapa de correlação da banda 3 de duas imagens multiespectrais adquiridas em datas diferentes pelo sensor Thematic Mapper do satélite Landsat 7. Esta plotagem foi dividida em três regiões para melhor visualização: coeficientes iguais ou menores que zero em preto, coeficientes entre zero e 0.5 em cinza, e coeficientes maiores que 0.5 em branco. A Figura 4.3 mostra a imagem de referência.




Figura 4.2 – Mapa de correlação entre duas imagens banda 3.



Figura 4.3 – Imagem referência.

Este procedimento é aplicado para todas as bandas. Em seguida, aplica-se algum critério limiar (*threshold*) banda a banda, baseado na correlação global da banda, para selecionar *pixels* não variáveis que pertenceriam ao conjunto de treinamento, a fim de ajustar a normalização radiométrica. Um *pixel* é considerado como pertencente ao conjunto de treinamento se tiver coeficientes de correlação em todas as bandas maiores do que os limiares respectivos.

4.3.2 Regressão Paramétrica e não Paramétrica

Uma curva de regressão descreve uma relação geral entre uma variável referência X e uma variável de resposta Y. Se n pontos de dados forem coletados, a relação de regressão pode ser modelada como:

$$Y_i = m(X_i) + \varepsilon_i, \quad i = 1, \dots, n \quad (4.1)$$

com a função de regressão desconhecida m e erros de observação ε_i . Uma observação visual do gráfico de dispersão X_i versus Y_i nem sempre basta para estabelecer uma relação de regressão interpretável. Um exemplo é dado na Figura 4.4, que mostra um gráfico de dispersão onde X_i e Y_i são DN's da banda 5 de duas imagens multiespectrais adquiridas em datas diferentes pelo sensor Thematic Mapper do satélite Landsat 7.




Figura 4.5 - Gráfico de dispersão.

A meta de uma análise de regressão é produzir uma aproximação razoável à função de resposta desconhecida m . Reduzindo-se os erros observacionais, permite-se que a interpretação se concentre nos detalhes importantes da dependência média de Y sobre X . Esse procedimento de aproximação geralmente é chamado de "normalização". Esta tarefa de aproximação da função média pode ser realizada essencialmente de dois modos: abordagem paramétrica e abordagem não paramétrica.

A abordagem paramétrica, muito frequentemente usada, considera que a curva média m possui alguma forma funcional pré-especificada, por exemplo, uma linha. O modelo de regressão linear e sua variante robusta são usados neste trabalho para fins de comparação. Como alternativa, pode-se tentar estimar m não parametricamente sem referência a uma forma específica. A abordagem de normalização não paramétrica oferece uma ferramenta flexível na análise das relações de regressão desconhecidas.

4.3.3 Regressão Linear e Regressão Linear Robusta

Uma gama extensa de algoritmos foi desenvolvida para normalização radiométrica baseada em suposições lineares. Uma forma comum para retificação radiométrica linear é:

$$Y_k = a_k \cdot X_k + b_k \quad (4.2)$$

onde: X_k é o valor original do DN da banda k na imagem X e Y_k é o DN normalizado da mesma banda em outra data. A derivação dos coeficientes de normalização, a_k e b_k , varia de acordo com a modelagem selecionada. Normalização de regressão simples (Yuan & Elvidge, 1996), por exemplo, aplica-se à equação de regressão de quadrados mínimos para derivar coeficientes de normalização.

A regressão e a análise de procedimentos de variância dependem de certas suposições, tais como uma distribuição normal para o termo de erro. Às vezes tal suposição não é garantida, por exemplo, se a distribuição dos erros for assimétrica ou propensa a *outliers* extremos, isto é, uma violação da suposição de erros normais. A função de regressão robusta é útil quando existir *outliers*. Os métodos robustos são desenhados para serem relativamente insensíveis a grandes mudanças em uma parte pequena dos dados.

A regressão robusta usada neste trabalho usa um algoritmo de mínimos quadrados iterativamente reponderados, com os pesos em cada iteração calculados pela aplicação da função biquadrada aos resíduos da iteração anterior. Este algoritmo dá peso menor aos pontos que não se ajustam bem (Image Processing Toolbox User's Guide, <http://>

www.mathworks.com). Os resultados são menos sensíveis a *outliers* nos dados em comparação com regressão de quadrados mínimos ordinária.

4.3.4 Regressão não Paramétrica

A abordagem não paramétrica para o cálculo oferece um método versátil de explorar uma relação geral entre duas variáveis e fornece previsões de observações ainda não realizadas, sem referência a um modelo paramétrico fixo, constituindo, ainda, um método flexível de substituição para valores ausentes ou de interpolação entre valores de X adjacentes.

A idéia básica da normalização não paramétrica é um procedimento local para cálculo da média para estimar m na fórmula (4.1). Mais formalmente, este procedimento pode ser definido como:

$$\hat{m}(x) = n^{-1} \sum_{i=1}^n W_{ni}(x) Y_i \quad (4.3)$$

onde $\{W_{ni}(x)\}_{i=1}^n$ denota uma seqüência de pesos que dependem do vetor como um todo $\{X_i\}_{i=1}^n$.

A maioria dos métodos de normalização são, pelo menos assintoticamente, da forma (4.3).

Uma aproximação conceitualmente simples para uma representação da função de peso $\{W_{ni}(x)\}_{i=1}^n$ consiste em descrever a forma da função de peso por uma função de densidade com um parâmetro de escala que ajuste o tamanho e a forma dos pesos próximos a x . É muito comum referir-se a esta função de forma como um núcleo K . O núcleo é uma função K real contínua, delimitada e simétrica com integral igual a um, $\int K(u)du = 1$.

A sucessão de pesos para os normalizadores de núcleo (para x unidimensional) é definida por:

$$W_{ni}(x) = \frac{K_{hn}(x - X_i)}{\hat{f}_{hn}(x)} \quad (4.4)$$

onde:

$$\hat{f}_{hn}(x) = n^{-1} \sum K_{hn}(x - X_i) \quad (4.5)$$

e, ainda, onde:

$$K_{hn}(u) = hn^{-1} K\left(\frac{u}{hn}\right) \quad (4.6)$$

é o núcleo com fator de escala h_n . Suprimindo-se a dependência de $h=h_n$ no tamanho da amostra n , a sucessão de núcleo (4.4) é convenientemente abreviada como $\{W_{hi}(x)\}_{i=1}^n$.

A função $\hat{f}_h(\cdot)$ é o estimador de densidade do núcleo de Rosenblatt-Parzen da densidade (marginal) de X . A fórmula (4.4) de pesos de núcleo $\{W_{hi}(x)\}_{i=1}^n$ foi proposta por Nadaraya e Watson (apud Velloso & Souza, 2002:4) e a fórmula:

$$\hat{m}_h(x) = \frac{n^{-1} \sum_{i=1}^n K_h(x - X_i) Y_i}{n^{-1} \sum_{i=1}^n K_h(x - X_i)} \quad (4.7)$$

é chamada com frequência de estimador Nadaraya-Watson. K determina a forma dos pesos de núcleo, enquanto que o tamanho dos pesos é parametrizado por h , que é chamado a largura da banda.

A estimativa de construção do vizinho mais próximo difere das estimativas de núcleo. A estimativa de núcleo foi definida como uma média ponderada das variáveis de resposta em uma vizinhança fixa ao redor de x . A estimativa do k -vizinho mais próximo (k -NN, *k-Nearest Neighbor*) é uma média ponderada em uma vizinhança variada. Esta vizinhança é definida por aquelas X -variáveis, as quais se encontram entre os k -vizinhos mais próximos de x na distância euclidiana. O normalizador k -NN mais simples é definido como:

$$\hat{m}_k(x) = n^{-1} \sum_{i=1}^n W_{ki}(x) Y_i \quad (4.8)$$

onde:

$$W_{ki}(x) = \begin{cases} n/k, & \text{if } i \in J_x \\ 0 & \text{otherwise} \end{cases}$$

e $J_x = \{i : X_i \text{ é uma das observações } k \text{ mais próximas de } x\}$.

Ao invés de usar pesos uniformes, usam-se pesos triangulares k -NN (Hardle, 1989) e os vizinhos mais distante de x foram ponderados de forma mais fraca. Em geral, os pesos podem ser interpretados como sendo gerados por uma função de núcleo K ,

$$W_{Ri}(x) = \frac{K_R(x - X_i)}{\hat{f}_R(x)} \quad (4.9)$$

onde

$$\hat{f}_R(x) = n^{-1} \sum K_R(x - X_i) \quad (4.10)$$

é uma estimativa de densidade de núcleo de $f(x)$ com sequência de núcleo:

$$K_R(u) = R^{-1} K(u/R) \quad (4.11)$$

e $R=R_n$ é a distância entre x e seu vizinho k ésimo mais próximo. K é:

$$K(u) = (1 - |u|) I(|u| \leq 1) \quad (4.12)$$

onde $I(\cdot)$ é a função indicador, ou delta Dirac,

$$I(u) = \begin{cases} 1 & u = 0 \\ 0 & \text{otherwise} \end{cases}.$$

Aplicamos o normalizador triangular k-NN para cada banda e geramos tabelas, com base nos conjuntos de treinamento, para corrigir radiometricamente a outra imagem.

A Figura 4.5 mostra a curva obtida da regressão não paramétrica em duas imagens multiespectrais adquiridas, em datas diferentes, pelo sensor Thematic Mapper do satélite Landsat 7.




Figura 4.5 – Curva obtida da regressão não paramétrica.

CAPÍTULO V

MÉTODOS DE ANÁLISE DE MUDANÇAS NA SUPERFÍCIE TERRESTRE

As técnicas de detecção de mudanças têm por objetivo realizar uma identificação de mudanças na superfície terrestre. Essa identificação consiste no uso de imagens multiespectrais de sensoriamento remoto por satélite - imagens de várias bandas de comprimentos de onda, e imagens multitemporais - imagens de datas distintas, para, através de algoritmos matemáticos de análise espectral, gerar um mapa de mudanças, identificando as áreas de mudanças na cobertura terrestre após um período de tempo.

Lunetta e Elvidge (1998) realizaram uma compilação dos métodos multiespectrais para análise de mudanças na cobertura terrestre. Com base nessa compilação, serão apresentados os métodos de detecção de mudanças mais importantes das duas principais abordagens: detecção de mudanças pós-classificação e detecção de mudanças com pré-classificação espectral.

5.1 Detecção de Mudanças com Pré-Classificação Espectral

Nesta abordagem, categorizada como detecção de mudanças com pré-classificação espectral, os métodos de identificação de mudanças são aplicados às imagens multitemporais a priori do processo analítico de classificação da produção da rotulação das regiões de mudança e das regiões de não-mudança.

Nesta seção apresentaremos uma visão geral dos vários métodos computacionais de detecção de mudanças com pré-classificação espectral, utilizando imagens digitais de sensoriamento remoto, divididos em operações no *pixel* e operações na cena.

5.1.1 Métodos de Identificação Espectral de Mudanças com Operações no *Pixel*

Nestes métodos as operações realizadas para identificar mudanças são processadas considerando apenas a informação do *pixel*. A seguir, apresentaremos alguns dos métodos de identificação espectral de mudanças com operações no *pixel*.

5.1.1.1 Diferença de Imagens

Este método consiste em subtrair, *pixel* por *pixel*, uma imagem da outra, gerando uma nova imagem que representa a mudança ocorrida entre duas imagens registradas em datas diferentes. Esta imagem resultante mantém o mesmo número de bandas das duas imagens analisadas.

Sejam as imagens I1 e I2 da mesma área em duas datas distintas:

$$I1 = I1_{nl,nc,bn} = [p1_{xyb}] = [p1_{xy1}, p1_{xy2}, \dots, p1_{xynb}] \quad (5.1)$$

$$I2 = [p2_{xy1}, p2_{xy2}, \dots, p2_{xynb}] \quad (5.2)$$

onde: I1 e I2 representam as imagens multiespectrais, $I1_{nl,nc,bn}$ e $I2_{nl,nc,bn}$ são matrizes $nl \times nc \times nb$, p é o DN do *pixel* xy da banda espectral b , $x = 1, 2, 3, \dots, nl$, $y = 1, 2, 3, \dots, nc$, $b = 1, 2, 3, \dots, nb$, nl é o número de linhas, nc é o número de colunas e nb é o número de bandas da imagem. A imagem diferença D será:

$$D = [|p1_{xy1} - p2_{xy1}|, |p1_{xy2} - p2_{xy2}|, \dots, |p1_{xynb} - p2_{xynb}|] \quad (5.3)$$

Este método é de fácil implementação computacional, mas peca por não conseguir caracterizar os tipos das mudanças que ocorreram na cobertura terrestre de uma imagem para outra e necessita de procedimentos para otimização do limiar (*threshold*) de mudança/não-mudança. Também peca por ser sensível a registros errôneos das imagens, à existência de *pixels* misturados e a diferenças radiométricas entre as imagens de entrada (Johnson & Kasischke, 1998).

5.1.1.2 Análise do Vetor Mudança

O vetor mudança de um *pixel* é definido como o vetor diferença entre os vetores multibandas do *pixel* em duas datas diferentes. O vetor descrevendo a direção e a magnitude da mudança da primeira para a segunda data é um vetor mudança espectral.

Neste método - Análise do Vetor Mudança (CVA, *Change Vector Analysis*) - duas imagens associadas são calculadas. A primeira contém a magnitude e a segunda a direção dos vetores mudança de cada *pixel*. A decisão sobre a ocorrência de uma mudança é determinada se a magnitude do vetor mudança ultrapassou um determinado limiar de decisão. O *pixel* identificado como havendo mudança espectral deverá ser examinado na imagem direção para determinar o tipo de mudança.

Similar ao método anterior, este método é sensível a registros errôneos das imagens, à existência de *pixels* misturados e a diferenças radiométricas entre as imagens de entrada e,

ainda, apresenta dificuldades na precisão da interpretação da direção da mudança (Johnson & Kasischke, 1998).

Como a proposta deste trabalho é apenas identificar áreas de alterações na cobertura terrestre, não determinando o tipo da mudança, utiliza-se esse método CVA para detecção espectral de mudança, mas usando-se apenas a imagem de magnitude. Esta imagem de magnitude IM de uma única banda, será:

$$IM = IM_{nl,nc} = [d_{xy}] \quad (5.4)$$

onde:

$$d_{xy} = \sqrt{(p1_{xy1} - p2_{xy1})^2 + (p1_{xy2} - p2_{xy2})^2 + + (p1_{xybn} - p2_{xybn})^2} \quad (5.5)$$

5.1.2 Métodos de Identificação Espectral de Mudanças com Operações na Cena

Como apresentado nos método de detecção de mudança em que apenas as informações dos *pixels* são processadas, as condições radiométricas diferentes entre duas imagens multitemporais são fatores causadores de falsas indicações de mudanças. Assim, métodos baseados em normalização ou correções radiométricas processando todo o cenário das imagens têm sido desenvolvidos. No capítulo anterior avaliamos três métodos de correção radiométrica relativa das imagens de SR, que realizam um processamento a priori de todo o cenário, normalizando as imagens. Somente após essa normalização é que se aplica o processo de identificação de mudanças operando apenas nos *pixels*.

5.2 Método de Detecção de Mudanças Pós-classificação

Neste método, duas imagens registradas em datas diferentes sofrem um processo de classificação e identificação dos tipos de cobertura da superfície terrestre existentes na área imageada, gerando, de forma independente, dois mapas temáticos. A seguir, através de uma interpretação visual ou automática, ou ambas, são realizadas a identificação e a classificação das áreas onde ocorreram mudanças.

Este método tem a vantagem de não necessitar de normalização dos dados, visto que as duas imagens são classificadas separadamente. Entretanto, possui alguns fatores limitantes: custo, consistência e propagação de erros. O custo final desta abordagem sofre o impacto do alto custo da interpretação visual; a consistência dos resultados é fortemente dependente da precisão do classificador, que pode ter limitações e é muito susceptível a erros; um erro na classificação pode ser propagado, gerando uma falsa avaliação de mudanças.

CAPÍTULO VI

CLASSIFICAÇÃO

Este Capítulo inicia conceituando classificação supervisionada e classificação não supervisionada e a seguir apresenta os principais classificadores em cada abordagem. Na classificação supervisionada: classificadores estatísticos e classificadores neurais, e na classificação não supervisionada: classificadores por centróide, classificadores neurais e o classificador CNN.

O processo de classificação de imagens de sensoriamento remoto tem por objetivo realizar a demarcação e a identificação em uma imagem, obtida por sensoriamento remoto, dos vários tipos de cobertura da superfície terrestre ou objetos do mundo real como, por exemplo, corpos de água, florestas, áreas urbanas etc.

No processo de classificação temos dois estágios: o primeiro é o reconhecimento das categorias dos objetos do mundo real, que dependem da escala geográfica e da natureza do estudo; o segundo é a rotulagem dos elementos representativos dos objetos do mundo real na imagem. Em uma imagem digital estes elementos são os *pixels* da imagem, portanto deve-se para cada *pixel* reconhecer a que classe de objetos do mundo real esse *pixel* pertence e atribuir-lhe um rótulo, que pode ser um valor numérico, correspondente à sua classe: por exemplo, rótulo 1 para a classe corpo de água, rótulo 2 para florestas e assim por diante.

Nesse processo de classificação podemos ter duas abordagens, a classificação supervisionada e classificação não supervisionada.

Na classificação supervisionada, é requerida a execução dos seguintes procedimentos: determinar a priori o número e a natureza dos tipos de cobertura da superfície terrestre, sendo, portanto, necessária a atuação de um especialista com conhecimento para determinar o número de classes e a descrição da natureza de cada classe e, a seguir, rotular cada *pixel* associando-o a cada uma das classes ou categorias da cobertura terrestre, utilizando um algoritmo computacional que execute as regras de decisão e classificação definidas no passo anterior.

Em contraste, na abordagem não supervisionada, não é necessária a definição do conjunto de categorias que descrevem a superfície terrestre. No processo não supervisionado, inicialmente é executado um procedimento de agrupamento dos *pixels*, que é um procedimento exploratório visando determinar o número de categorias distintas da superfície terrestre presentes na imagem. Esse processo faz um agrupamento dos *pixels* com características

semelhantes e, em seguida, se realiza a rotularização dos *pixels* ou a associação dos agrupamentos aos tipos de cobertura da superfície terrestre.

Numa primeira avaliação, um *pixel* é caracterizado por um vetor cujos elementos são seus atributos numéricos DN (tons de cinza) em cada banda espectral; portanto, este vetor representa as propriedades espectrais do *pixel*, ou a sua assinatura espectral. Este conjunto de valores na escala de cinza para um certo número de bandas espectrais como por exemplo, as 7 bandas do sensor TM do satélite *Landsat 5*, irá definir um padrão de identificação dos *pixels*.

O modo mais fácil para perceber a distribuição dos valores medidos de duas características é um gráfico de uma característica contra a outra. A Figura 6.1 mostra um gráfico de uma característica X qualquer contra uma característica Y qualquer, para um objeto hipotético. No caso de imagens de SR, as características de um objeto ou de uma superfície terrestre serão representadas pelos atributos numéricos DN em cada banda espectral dos *pixels* que compõem o objeto ou a superfície terrestre.




Figura 6.1 - Gráfico da característica X contra a característica Y.

Pela análise visual, percebe-se que existem dois tipos básicos de classificação dos objetos relacionados às características X e Y. O primeiro tipo tem valor pequeno das características X e Y e o segundo tipo tem valores maiores para as características X e Y.

Às características espectrais podemos adicionar outras propriedades do *pixel*, derivadas principalmente de sua vizinhança, tais como contexto¹⁷ e textura¹⁸, aumentando o número das

¹⁷ Contexto é a relação de um objeto com a sua vizinhança.

¹⁸ Textura é a característica de rugosidade ou suavidade de um alvo em uma imagem de SR e pode ser entendida como sendo o padrão do arranjo espacial dos elementos texturais. Elemento textural é a menor feição contínua e homogênea distinguível em uma imagem.

características do *pixel* para definir os padrões de identificação e classificação do *pixel*, tornando mais precisa essa classificação.

O aumento do número de bandas espectrais ou a inclusão de outras características no processo de classificação incrementa o tempo de computação e pode tornar inviável este processo de classificação automática. Devemos, portanto, realizar uma avaliação do custo/benefício de aumentar o número de bandas e/ou o número de características, para aumentar a precisão da classificação e o tempo de processamento computacional.

Pode-se resumir que os métodos de classificação ou de reconhecimento de padrões executam genericamente os seguintes passos: seleção de um conjunto de características que melhor descrevem o padrão ou modelo dos objetos do mundo real e escolha de um método apropriado para identificar e classificar um objeto do mundo real como um dos diversos tipos possíveis de cobertura terrestre. Pode-se, ainda, incluir um terceiro estágio, que seria uma avaliação do grau de precisão do processo de classificação.

6.1 Classificação Supervisionada

Métodos de classificação supervisionada são baseados na existência prévia de conhecimentos sobre a área a ser classificada de uma imagem, isto é, requer como dados de entrada, além da imagem, informações derivadas de trabalhos de campo, análise de fotos aéreas, relatórios técnicos ou estudos de mapas. A extração dessas informações relevantes sobre a área em classificação da imagem exige o trabalho de pessoas especialistas nesta tarefa. Em alguns casos não se tem disponíveis essas informações em quantidade e diversidade suficiente. Estes dois fatores, trabalho especializado e indisponibilidade de informações, podem inviabilizar a realização da classificação por métodos supervisionados.

A seguir ilustram-se duas possibilidades de implementar uma classificação supervisionada: utilizando algoritmos estatísticos ou utilizando algoritmos neurais. Algoritmos estatísticos usam parâmetros derivados das amostras de dados, de modo a estabelecer e identificar as classes no processo de classificação. Parâmetros, tais como valores mínimos e máximos, ou valores médios, ou desvios padrões, são utilizados como elementos para definir as classes existentes em uma imagem. Os algoritmos neurais utilizam diretamente as amostras de dados como conjunto de dados de treinamento de sua rede neural, possibilitando a identificação das classes por padrões de reconhecimento. Assim, os métodos estatísticos são chamados paramétricos, pois não utilizam diretamente o conjunto de dados de entrada, mas parâmetros estatísticos derivados desse conjunto de informações. Em contraposição, os

métodos neurais são chamados não paramétricos, o que permite mais facilmente a incorporação de dados não obtidos por sensoriamento remoto, como declividade do terreno ou tipos de solo, no procedimento de classificação.

6.1.1 Classificadores Estatísticos

Nos classificadores estatísticos, o conjunto de dados de treinamento, devidamente avaliado e classificado por especialistas e representando as verdades terrestres, é utilizado para se extraírem os parâmetros estatísticos que irão definir as classes e as regras de identificação dos *pixels* desconhecidos do conjunto de dados em classificação.

Para que estes algoritmos de classificação sejam eficientes, é necessária uma quantidade muito grande de dados para formar o conjunto de treinamento com uma boa diversidade, pois os classificadores estatísticos não possuem um grande poder de generalização, o que acarreta muitos *pixels* não classificados ou classificados erroneamente.

Os classificadores estatísticos supervisionados mais comuns utilizam os métodos do paralelepípedo, da distância mínima e da máxima verossimilhança.

6.1.1.1 Método do Paralelepípedo

Neste método, após a avaliação e classificação, com a definição das classes, do conjunto de dados de treinamento, realizadas pelo especialista em sensoriamento remoto ou geoprocessamento, são extraídos os limites mínimo e máximo do valor DN de cada banda, que caracterizam cada classe e que vão constituir as regras de decisão, ou os limites de decisão, no processo de identificação e rotularização dos *pixels* desconhecidos do conjunto de dados em classificação. Na Figura 6.2 temos um exemplo para visualizar o entendimento do método para classificação dos *pixels* de uma imagem de duas bandas, onde já foram obtidos do conjunto de treinamento a determinação de duas classe A e B e os parâmetros de mínimo e máximo de definição das classes.

Os *pixels* que estiverem dentro da área verde, definida pelos seus limites de máximo e mínimo, serão classificados como pertencentes à classe A e os *pixels* que estiverem dentro da área azul serão classificados como pertencentes à classe B. Os *pixels* vermelhos serão *pixels* não classificados.

Uma característica dos classificadores que usam o método do paralelepípedo é que, numa imagem de SR onde existem milhares de *pixels*, uma grande quantidade de *pixels* vai

estar fora dos limites de definição de qualquer classe, por mais classes que se definam. Outra característica desse método é a existência de áreas de recobrimento, como exemplifica a Figura 6.3. O aumento do número de classes ou a ampliação dos limites das classes para resolver o problema dos *pixels* não classificados irá elevar a probabilidade da existência de áreas de recobrimento.




Figura 6.2 - Método do paralelepípedo.




Figura 6.3 - Área de recobrimento.

6.1.1.2 Método da Distância Mínima

Neste método, após o processo de avaliação e classificação do conjunto de dados de treinamento, é realizado o procedimento de identificação das classes que, nesse caso, consiste em encontrar o centro de cada classe pela média dos pontos (*pixels*) pertencentes à classe. A regra de decisão nesse método é a da distância mínima, isto é, um *pixel* desconhecido será classificado como pertencente à classe cujo centro é mais próximo a ele.

Este método resolve o problema da grande quantidade de *pixels* não classificados do método anterior, porém pode apresentar uma grande quantidade de *pixels* classificados erroneamente. Conforme ilustra a Figura 6.4, o *pixel* 1 está mais próximo do centróide da classe B, sendo então classificado como pertencente à classe B. Porém, observando os limites da classe A, notamos que ela ocupa uma região maior no espaço de atributos do que a classe B e que, na verdade, o *pixel* 1 tem maior afinidade com a classe A e, portanto, foi classificado erroneamente como *pixel* da classe B. Essa questão só pode ser resolvida com a utilização de parâmetros estatísticos mais complexos, para ponderar o peso de cada classe, nas regras de decisão para atribuir os *pixels* às suas classes.




Figura 6.4 - Pixel classificado erroneamente.

6.1.1.3 Método da Máxima Verossimilhança

O método de Máxima Verossimilhança realiza uma ponderação das distâncias dos pontos representativos dos *pixels* aos centróides das classes. Essa ponderação é determinada por isolinhas ou curvas de contorno no espaço de atributos, representando a densidade dos *pixels* do conjunto de treinamento para cada classe, conforme mostrado na Figura 6.5.




Figura 6.5 - Isolinhas ou curvas de probabilidades.

Os contornos da Figura 6.5. representam um ajuste estatístico baseado na distribuição Normal ou Gaussiana dos *pixels* de treinamento, pois os contornos reais são irregulares, o que dificultaria seu processamento.

Podem-se entender os contornos ao redor de cada classe como sendo a probabilidade de existir um *pixel* pertencente àquela classe no conjunto de treinamento. Assim, se o conjunto de treinamento for representativo, podemos estender essa probabilidade a um conjunto de *pixels* desconhecidos.

Para que a classificação por Máxima Verossimilhança tenha um grau de precisão razoável, é necessário que o conjunto de treinamento tenha um número de *pixels* suficiente para torná-lo representativo.

Essas probabilidades representam um parâmetro estatístico poderoso e flexível para realizarmos a classificação dos *pixels* e assim minimizarmos o problema da classificação errônea de alguns *pixels* usando apenas o parâmetro da menor distância, como ilustra a Figura 6.6.

O *pixel* do ponto P, considerando apenas o parâmetro da menor distância, seria classificado como pertencente à classe B, visto que a distância do ponto P ao centróide da classe B (ponto CB) é menor que a distância do ponto P ao centróide da classe A (ponto CA). Porém, observando as isolinhas, vemos que o *pixel* do ponto P tem uma probabilidade maior de pertencer à classe A (20%) do que pertencer à classe B (1%), portanto, deve ser classificado como pertencente à classe A.




Figura 6.6 - Classificação por Máxima Verossimilhança.

6.1.2 Classificadores Neurais

Os classificadores estatísticos têm como base para classificação dos *pixels* desconhecidos os parâmetros estatísticos obtidos das áreas de treinamento. Se o usuário não conseguir definir esses parâmetros precisamente, devido às dificuldades de perceber visualmente diferenças sutis nas propriedades espectrais dos *pixels* das áreas de treinamento, podemos ter uma classificação com erros na identificação dos *pixels*.

Os classificadores neurais utilizam uma abordagem alternativa no processo de classificação. Utilizam uma Rede Neural Artificial (RNA)¹⁹ na sua aplicação clássica de reconhecimento de padrões, na qual as regras de decisões são extraídas diretamente das características espectrais dos dados do conjunto de treinamento, procurando substituir os olhos e o cérebro do usuário por um algoritmo computacional, no processo de identificação das classes no conjunto de treinamento.

Para se utilizar uma RNA como classificador de imagens de sensoriamento remoto, o primeiro procedimento é coletar e preparar um conjunto de treinamento. Este conjunto de treinamento deve ser um subconjunto representativo das características que serão classificadas, no qual, através de um especialista e de dados de fontes adicionais às imagens de SR, seja relacionado para cada dado de entrada (vetor dos valores DN do pixel em cada banda) a sua saída (classe a que pertence). O conjunto de treinamento deve ser dividido em dois subconjuntos, um para o treinamento da rede e outro para a avaliação ou teste da rede.

A seguir, deve-se determinar a configuração da rede: modelo do neurônio (função de ativação signóide), topologia da rede (rede MLP), algoritmo de aprendizagem (algoritmo de retropropagação (BP, Back-propagation), número de entradas (número de bandas da imagem) e número de saídas (número de classe determinada pelo especialista).

Com a configuração da rede e do conjunto de treinamento pode-se iniciar o treinamento da rede, que é um processo empírico e experimental de ajustes de parâmetros da rede (valor inicial dos pesos, taxa de aprendizagem, taxa de erro, número de iteração, número de camadas intermediárias, número de neurônio das camadas intermediárias etc.) e avaliação do aprendizado da rede, até finalizar o treinamento da rede. Este ocorre quando se concluir que a rede terminou seu aprendizado (por exemplo, quando o erro atingir um limiar estabelecido), ou seja, adquiriu o conhecimento desejado.

¹⁹ Um estudo mais detalhado das RNAs em sua aplicação clássica de reconhecimento de padrões utilizando o algoritmo de Retropropagação pode ser encontrada em Haykin (2001) e Galvão *et al* (1999).

Treinada a rede, deve-se, com o subconjunto de teste do conjunto de treinamento, determinar a performance da rede.

Com a conclusão de um bom funcionamento da rede, esta pode agora ser utilizada para a classificação de outras áreas, bastando apresentar à rede as entradas (vetor dos valores DN do pixel em cada banda) extraídas da imagem que se deseja classificar e a rede realizará o processo de classificação, indicando através de suas saídas a classificação de cada *pixel* da imagem, gerando um mapa temático.

6.2 Classificação Não Supervisionada

Quando se têm apenas as imagens de SR para realizar o processo de classificação, isto é, não se conseguem informações derivadas de trabalhos de campo, análise de fotos aéreas, relatórios técnicos ou estudos de mapas ou, ainda, não se tem um especialista para analisar e extrair as informações deste conjunto de treinamento, torna-se impossível a realização da classificação por métodos supervisionados.

Em contraste, na abordagem não supervisionada não é necessária, a priori, a definição do conjunto de categorias que descrevem a superfície terrestre. No processo não supervisionado, inicialmente é executado um procedimento de agrupamento dos *pixels*, que é um procedimento exploratório visando determinar o número de categorias distintas da superfície terrestre presentes na imagem. Esse processo faz um agrupamento dos *pixels* com características semelhantes e, em seguida, se realiza a rotularização dos *pixels* ou a associação dos agrupamentos aos tipos de cobertura da superfície terrestre. Assim, a classificação não supervisionada baseia-se no princípio de que o computador, através de um algoritmo adequado, é capaz de identificar, por si só, as classes dentro de uma imagem de SR.

Nas seções a seguir apresentaremos três classificadores não supervisionados: classificador estatístico, classificador neural de aprendizado competitivo e o classificador CNN (Rede Neural por Centróide, *Centroid Neural Network*).

6.2.1 Classificadores Estatísticos

Os classificadores estatísticos, não supervisionados, baseiam-se no parâmetro estatístico da média dos pontos para determinar o ponto central do agrupamento, que será o parâmetro identificador da classe, e na distância euclidiana como regra de classificação dos pontos. Nas seções seguintes são apresentadas as bases geométricas desta classificação, o

algoritmo *K-means* e o algoritmo *Isodata* (*Iterative Self-Organising Data Analysis Technique*).

6.2.1.1 Bases Geométricas da Classificação

O exemplo apresentado na Figura 6.1, no início do capítulo, pode demonstrar duas idéias fundamentais: a primeira é a representação das características de um objeto de estudo por eixos do espaço euclidiano; a segunda é o uso de medidas de semelhança ou proximidade dos pontos como as bases para classificar os objetos quanto às características X e Y. No sistema de coordenadas cartesianas, os eixos x e y são ortogonais e definem um espaço euclidiano de duas dimensões. A posição de um ponto neste espaço de duas dimensões está relacionado com o valor da magnitude das duas características para um dado objeto, que será representado por este ponto (Matter, 1999).

Os olhos e o cérebro combinados possibilitam uma interpretação visual de um padrão dos pontos, quando olhamos e analisamos a Figura 6.1. O reconhecimento de dois agrupamentos de pontos é determinado pela existência de duas regiões de características espaciais com densidade de distribuição dos pontos semelhantes e uma região entre eles mais ou menos vazia. Um ponto P é visto como pertencente ao grupo ou agrupamento 2, se ele está mais perto do centro do grupo 2 que do centro do agrupamento 1, conforme mostra a Figura 6.7. A distância entre um ponto e o centro do agrupamento pode ser usada como medida de semelhança, para classificarmos e rotularmos o objeto representado por este ponto como sendo do mesmo tipo dos objetos representados por pontos dentro do agrupamento 2. Portanto, podemos utilizar esta distância para generalizar e desenhar a linha das fronteiras dos agrupamentos. Esta linha é denominada fronteira de decisão. Mas devemos ter cuidado com a escala na qual os valores numéricos são expressos, pois podemos notar que, se os valores de x ou y dos pontos na Figura 6.7 forem multiplicados ou divididos por um fator escalar, nossa




Figura 6.7 - Agrupamento dos pontos.

interpretação visual da relação entre pontos poderá ser alterada ou distorcida.

Os mesmos conceitos de associação de uma característica de um objeto com um eixo do espaço euclidiano e o uso da distância entre pontos como as bases das regras de decisões, podem ser facilmente estendidos para 3, 4, ou N dimensões ou características (Matter, 1999).

Para mais de três características fica difícil a visualização do espaço euclidiano, mas esta visualização não é necessária, pois podemos medir a distância entre dois pontos pela sua distância euclidiana, que é a aplicação simples do teorema de Pitágoras, Figura 6.8.




Figura 6.8 - Teorema de Pitágoras.

Pelo teorema de Pitágoras:

$$a^2 = b^2 + c^2 \quad (6.1)$$

Portanto a distância entre os pontos 1 e 2 será:

$$d_{12} = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (6.2)$$

Para 3 dimensões:

$$d_{12} = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2 + (z_1 - z_2)^2} \quad (6.3)$$

Generalizando para n dimensões, ou eixos, ou características:

$$d_{12} = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2 + \dots + (n_1 - n_2)^2} \quad (6.4)$$

Transportando esses conceitos para uma aplicação em sensoriamento remoto, utilizaremos um exemplo de classificação apresentado por Matter (1999), de dois materiais ou objetos da superfície terrestre. O primeiro é um corpo de água que tem uma pequena reflectância na faixa de onda do infravermelho próximo e relativamente baixa na faixa de onda do vermelho da luz visível. Vegetações densas refletem fortemente na faixa de onda do infravermelho próximo e têm uma reflectância intermediária no vermelho da luz visível.

As bandas ou faixas de onda vermelho da luz visível e infravermelho próximo podem ser selecionadas como características das imagens de satélite obtidas por sensoriamento remoto, para classificar a cobertura terrestre. Os valores DN dos *pixels*, em cada banda espectral, de uma área amostra da imagem, podem ser utilizados para identificar e rotular como água ou vegetação densa, construindo-se um sistema de coordenadas cartesianas no qual o eixo x representa os valores DN do *pixel*, da escala de cinza da imagem e, portanto, a reflectância daquele ponto na banda de onda do infravermelho próximo, e o eixo y os valores DN do *pixel* na banda de onda vermelho da luz visível.

Os pontos a, b, c e d na Figura 6.9 representam *pixels* não classificados da área da imagem tomada como amostra, para um processo de classificação automática.

Com os conhecimentos adquiridos de um especialista sobre a reflectância de corpos de água e vegetação densa, visualmente podemos classificar os *pixels* dos pontos a e b como área de um corpo de água e os *pixels* dos pontos c e d como área de vegetação densa.

Para uma classificação automática de um *pixel* devemos encontrar os pontos A e VD que são, respectivamente, o ponto médio dos *pixels* classificados como água e o ponto médio dos *pixels* classificados como vegetação densa. Esses pontos são os pontos centrais ou centróides de cada classe.. A seguir, devemos escolher regras de decisões baseadas na distância euclidiana do ponto em classificação aos pontos A e VD, para rotular o *pixel* representado por esse ponto.




Figura 6.9 - Exemplo de classificação de *pixel*.

Repetindo este procedimento para todos os *pixels* da área amostra, podemos criar uma nova imagem associada a essa área amostra, na qual o *pixel* da nova imagem será de cor azul, se o *pixel* correspondente na imagem original for classificado como corpo de água, e de cor verde se for classificado como vegetação densa. A essa nova imagem, que nos apresenta os

tipos de cobertura da superfície terrestre existentes na área amostra e sua localização, denominamos mapa temático.

6.2.1.2 O Algoritmo K-Means

O algoritmo k-means é um procedimento exploratório de classificação que busca, a partir de conhecido o número de classes (M), agrupar e rotular os pontos como pertencentes a uma dessas classes (Hartigan, 1975).

Inicia-se o procedimento definindo-se aleatoriamente os centróides, pontos centrais dos agrupamentos, que também são os identificadores de cada classe, pontos $C1_0$, $C2_0$, $C3_0$, CM_0 , conforme ilustra a Figura 6.10 para um exemplo de duas classes ($C1_0$, e $C2_0$).




Figura 6.10 - Agrupamento pelo algoritmo K-means..

Utilizando a menor distância ao centro como regra de decisão, cada ponto representativo de um *pixel* é classificado como pertencente a uma classe ou agrupamento. No exemplo da Figura 6.10, os pontos são rotulados como pertencentes à classe 1 ou à classe 2. Após esta rotulação, um novo centróide $C1_1$ é calculado para a classe 1, através da média dos pontos rotulados para a classe 1; esse procedimento é realizado para calcular o novo centróide

$C2_1$ da classe 2, para o exemplo de duas classes da Figura 6.10. Para M classes serão calculados os novos centróides para todas as M classes.

Esse procedimento de rotular os pontos e calcular um novo centróide é repetido até que, por um critério de convergência, seja estabelecido o fim do processo de agrupamento, no qual os pontos estarão classificados e rotulados como pertencentes a uma das classes.

Podemos adotar como critério de convergência o número de iterações ou, ainda, a quantidade de pontos que mudam de classe a cada repetição do procedimento de rotular os pontos a partir dos novos centróides.

O algoritmo *K-means* é simples e rápido, podendo ser usado em muitas aplicações, embora apresente alguns problemas inevitáveis (Darken & Moody, 1990). Um dos problemas é o da escolha dos valores iniciais dos centróides que podem levar a um tempo de execução excessivo, mas o problema mais sério é que o algoritmo pode não convergir para uma solução ótima (Darken & Moody, 1990).

6.2.1.3 O Algoritmo *Isodata*

O algoritmo *Isodata* é uma evolução do algoritmo *K-means* (que considera o número de agrupamentos ou classes como um dado conhecido) para realizar a classificação, quando não se tem conhecimento do número de classes (Mather, 1999).

Partindo de uma classificação pelo procedimento de *K-means* para um número estimado de classes, o algoritmo *Isodata* realiza um procedimento de avaliar os agrupamentos e realizar fusões ou desdobramentos dos grupos ou classes.

Para realizar o procedimento de fusão de grupos, são calculadas as distâncias entre o centróide 1 e todos os demais; caso existam distâncias inferiores a um valor limite para a distância entre centróides (limiar de proximidade), estabelecido pelo usuário, os agrupamentos correspondentes a esses centróides são fundidos em um único agrupamento. Este procedimento é repetido para todos os demais centróides. Exemplificando na Figura 6.11, se a distância entre os centróides dos agrupamentos 1 e 3 ($d_{1,3}$) é menor que o limiar de proximidade, então os pontos pertencentes aos dois agrupamentos são fundidos em um único agrupamento.

Para realizar o desdobramento de grupos, são calculados separadamente os desvios padrões (medida da compactação dos agrupamentos) de cada uma das características ou eixos, para todos os agrupamentos. Se existirem desvios padrões com um valor superior ao valor limite do desvio padrão (limiar de alongamento), especificado pelo usuário, então esses agrupamentos, no qual um ou mais desvios padrões excederem ao valor limite, serão

desdobrados. Os desdobramentos ocorrem nos eixos em que o desvio padrão ultrapassa o limiar de alongamento.

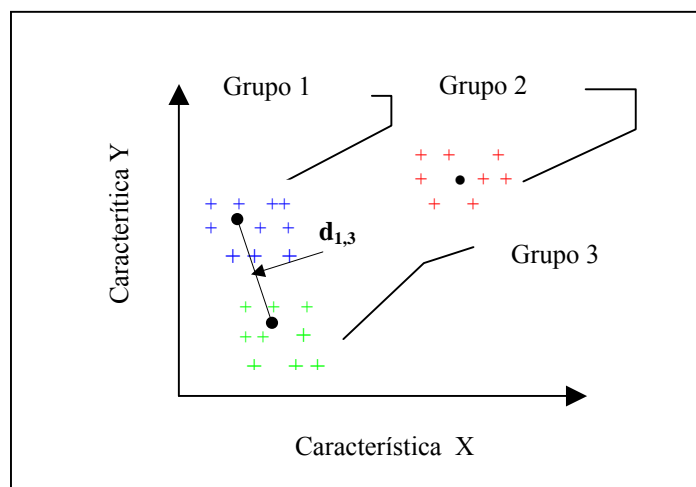


Figura 6.11 – Fusão de agrupamentos.

A Figura 6.12 exemplifica o desdobramento do grupo 1, que é separado ao meio por uma reta perpendicular ao eixo, cujo desvio padrão foi maior que o limiar estabelecido pelo usuário. Os pontos à esquerda desta reta formarão um novo agrupamento e os pontos à direita, um segundo novo agrupamento.




Figura 6.12 – Desdobramento de um agrupamento.

O procedimento de avaliar os agrupamentos e realizar fusão ou desdobramento é repetido até que não seja mais realizado nenhum procedimento de fusão ou separação em uma iteração.

O tempo computacional no algoritmo *Isodata* é fortemente influenciado pelas escolhas do número de centróides, dos valores iniciais destes centróides, do limiar de alongamento e do limiar de proximidade. Pode ainda, no procedimento de fusão/desdobramento, apresentar problema de convergência, com agrupamentos fundidos em uma iteração e separados na iteração seguinte, e assim indefinidamente (Mather, 1999).

6.2.2 Classificador Neural de Aprendizado Competitivo

Pode-se utilizar uma RNA de aprendizado não supervisionado e competitivo para extrair de um conjunto de dados – neste trabalho imagens de SR multiespectral – uma classificação temática por semelhança de padrões.

O uso de uma RNA traz como vantagens em relação aos classificadores estatísticos (algoritmos *K-means* e *Isodata*) a capacidade de generalização das RNAs, isto é, responder corretamente a uma entrada nunca vista por similaridade com os outros padrões já apresentados e, também, a possibilidade de adaptação, capacidade inata das RNAs de adaptar seus pesos sinápticos a modificações nos dados de entrada, podendo ser facilmente retreinada para classificar novas imagens, que contenham padrões até então desconhecidos.

Pode-se empregar uma rede SOM²⁰ (mapas auto-organizáveis) com uma topologia em grade bidimensional e com o número de entradas igual ao número de bandas da imagem multiespectral.

O número de neurônios vencedores indicará quantas classes ou padrões distintos existem na imagem e cada neurônio vencedor indicará um tipo de classe.

Esta capacidade de extrair dos próprios dados o número de classes é uma qualidade da rede ou algoritmo SOM, pois não se tem a necessidade de determinar a priori o número de classes.

6.2.3 Classificador CNN

O algoritmo denominado Rede Neural por Centróide (CNN, *Centroid Neural Network*) é um algoritmo de aprendizagem competitiva não supervisionada, baseado no algoritmo

²⁰ As redes SOM foram apresentadas na seção 3.6.

clássico de agrupamento *K-means* com estrutura de uma rede neural competitiva, podendo ser utilizado para processar um conjunto de entradas com o objetivo de realizar tarefas complicadas de classificação, com uma qualidade compatível com outros classificadores, mas com um tempo de convergência muito mais rápido (Park, 2000).

A idéia por trás do algoritmo CNN está baseada na observação de que os vetores dos pesos sinápticos, nos algoritmos neurais de aprendizagem competitiva como o SOM e o DCL (Aprendizagem Competitiva Diferencial, *Differential Competitive Learning*) (Kong & Kosko, 1991), convergem para os centróides dos agrupamentos. Portanto o CNN, para que também seus pesos sinápticos converjam para os centróides das classes, utiliza uma regra de aprendizagem competitiva semelhante à utilizada pelos algoritmos SOM e DCL.

No SOM a regra determina que apenas o neurônio vencedor e seus vizinhos tenham os pesos reajustados a cada iteração (apresentação de um dado). Já no DCL a regra é baseada no conceito de recompensa para o vencedor e castigo para o perdedor.

O CNN utiliza uma regra baseada no conceito de recompensa e castigo semelhante ao DCL, contudo o CNN encontra os vetores de pesos sinápticos ótimo localmente, isto é, a cada apresentação do conjunto de dados (a cada época) e, por conseguinte, convergem para os centróides dos agrupamentos muito mais rapidamente do que em outros algoritmos de classificação ou de agrupamentos.

6.2.3.1 Configuração da Rede CNN

A topologia da rede CNN é apresentada na Figura 6.13, onde:

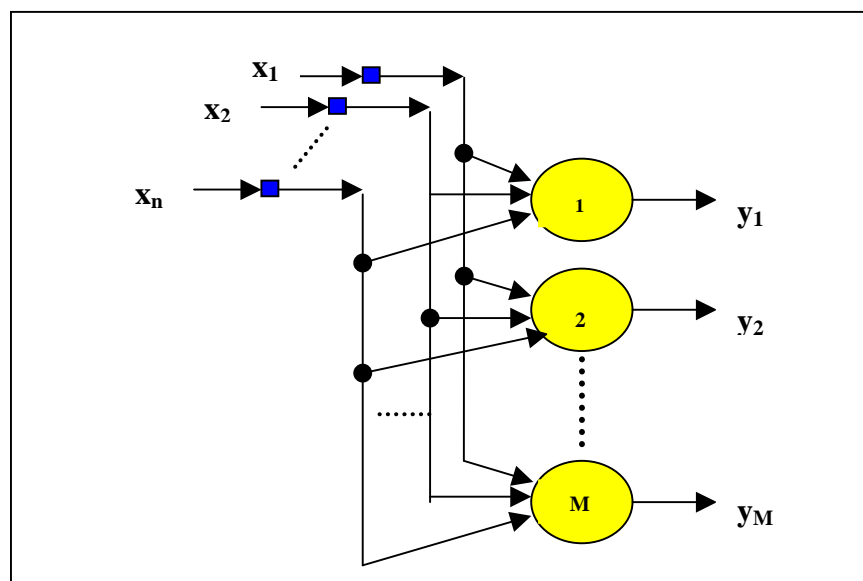


Figura 6.13 – Rede CNN

- x são as entradas e y são as saídas.
- n é o número de entradas.
- M é o número de neurônios, que deve ser igual ao número de agrupamentos ou classes.

O modelo de neurônio ou elemento processador (EP) é apresentado na Figura 6.14, onde: $i = 1, 2, 3, \dots, n$ e $k = 1, 2, 3, \dots, M$.




Figura 6.14 – Modelo do EP do algoritmo CNN.

6.2.3.2 O Algoritmo CNN

O algoritmo CNN inicia-se com a definição do número de classes ou agrupamentos M , do número de entradas n (no caso de imagens de SR será o número de bandas espectrais da imagem), da quantidade de elementos N (no caso de imagens SR o número de *pixels* da imagem) presentes no conjunto ou vetor de entradas; em seguida, atribui-se o valor inicial dos pesos sinápticos, que representarão os valores iniciais dos centróides. Para evitar que o algoritmo fique preso a um mínimo local indesejado, começa-se com apenas duas classes ou apenas dois vetores de peso W_1 e W_2 , aumentando até atingir o número M predeterminado de grupos ou classes. Iniciam-se esses dois vetores de peso aleatoriamente, ou equidistantes, ou através da fórmula:

$$W_1 = C + \varepsilon \quad (6.5)$$

$$W_2 = C - \varepsilon \quad (6.6)$$

onde:

- C é o centróide de todo o conjunto de dados de entrada.
- ε é uma pequena variação aplicada ao centróide e definida empiricamente em função dos dados de entrada.

Considerar cada iteração t como a apresentação à rede de um elemento do vetor de entradas, portanto, $t = 1, 2, 3, \dots, N$.

Considerar cada época ep como a apresentação à rede de todos os elementos do vetor de entradas.

Para cada iteração é determinado o neurônio vencedor j , pela condição de menor saída ou menor distância entre a entrada e os pesos sinápticos (ou centróide do agrupamento). Assim o neurônio vencedor será:

$$j = \arg \min_k \|x - W_k\| \quad (6.7)$$

Este neurônio terá seus pesos ajustados se, e somente se, na apresentação desta entrada na época anterior, este neurônio não foi o vencedor. Isto acontecendo, o neurônio vencedor na época anterior será considerado o neurônio perdedor p e o ajuste dos pesos dos neurônios vencedor e perdedor para a próxima iteração será determinado pelas equações:

$$W_j(t+1) = W_j(t) + \frac{1}{N_j + 1} [x(t) - W_j(t)] \quad (6.8)$$

$$W_p(t+1) = W_p(t) + \frac{1}{N_p - 1} [x(t) - W_p(t)] \quad (6.9)$$

onde:

- N_j é o número de entradas classificadas como classe j na época anterior.
- N_p é o número de entradas classificadas como classe p na época anterior.

Quando em uma época não ocorrer nenhum ajuste nos pesos, isto é, os neurônios vencedores na época corrente são os mesmos vencedores da época anterior, o número de classes é incrementado e o processo é repetido com o acréscimo de mais um centróide. Este novo centróide ou vetor de pesos é inicializado com o valor dos pesos do neurônio que apresentar maior saída – maior distância entre entradas e pesos sinápticos – adicionado de um pequeno ε .

O algoritmo é encerrado quando o número de classe chegar a M (total de classes) e não ocorrerem mais alterações dos neurônios vencedores em uma época.

No apêndice A o procedimento CNN é apresentado em uma linguagem algorítmica.

O algoritmo CNN não oferece nenhuma garantia de convergência para uma solução ótima global como os algoritmos SOM e DCL, mas oferece uma garantia de convergência para um mínimo local (Park, 2000).

6.2.3.3 Características Vantajosas do CNN

A principal vantagem do algoritmo CNN em relação aos outros algoritmos de agrupamento é o fato de que o CNN converge muito mais rapidamente (Park, 2000).

O CNN em relação aos algoritmos *K-means* e *Isodata* não apresenta o inevitável problema da possibilidade de uma não-convergência presente nesses algoritmos.

Em relação aos algoritmos SOM e DCL, o CNN tem as vantagens de não requerer uma programação para a taxa ou coeficiente de aprendizado – o CNN encontra, em cada época, seu coeficiente de aprendizado ótimo – e, também, de não requerer a definição inicialmente do número total de épocas. A escolha no SOM e no DCL do valor inicial do coeficiente de aprendizado e do número total de épocas deve ser realizada cuidadosamente, em função de uma análise do conjunto de dados, para evitar resultados instáveis.

CAPÍTULO VII

TESTES E EXPERIMENTOS

Este capítulo apresenta alguns resultados que mostram o desempenho das técnicas propostas. Foram utilizadas imagens multiespectrais retiradas de três cenas obtidas pelo satélite Landsat 7, bandas espectrais 3, 4 e 5, registradas respectivamente pelos canais 3, 4 e 5 do sensor TM, nos anos de 1996, 1998 e 1999. Essas imagens são da região do alto Taquari-MS, no Centro-Oeste brasileiro, em acelerado processo de degradação ambiental causado pela intensa ocupação agrícola do solo ocorrida nos últimos anos e, portanto, demandando monitoração constante das condições ambientais.

Como as duas técnicas investigadas neste trabalho – correção radiométrica não paramétrica e classificador CNN – podem ser utilizadas de maneira independente, conjugadas com outras técnicas, os experimentos foram realizados separadamente para cada técnica e serão apresentados em duas seções separadas.

A seção 7.1 apresenta experimentos que comparam, através dos resultados obtidos por uma classificação, a influência do método de correção relativa radiométrica não paramétrica na detecção de mudanças. O método proposto é comparado com a regressão linear e com regressão robusta.

A seção 7.2 apresenta o método de classificação espectral não supervisionada CNN utilizado para detecção de mudanças de cobertura terrestre nas duas abordagens: pré e pós-classificação. Foram realizados testes em dois tipos de conjuntos de dados. O primeiro tipo é composto de duas imagens reais, multiespectrais e multitemporais, e o segundo tipo é um conjunto de dados sintéticos, obtidos a partir da mesma região, utilizado para testar a robustez do algoritmo com diferentes níveis de ruído.

Todos os procedimentos necessários para realizar os testes e experimentos para avaliar as duas metodologias foram programados utilizando o software Matlab. No capítulo I foram apresentados, na Figura 1.1, os diagramas que ilustram as duas metodologias.

7.1 Testes e Experimentos do Procedimento de Correção Radiométrica Relativa

Conforme exposto no capítulo IV, a correção radiométrica das imagens brutas normalmente melhora sensivelmente os resultados de detecção de mudanças (Velloso & Souza, 2002 e Lunetta *et al.*, 1998) e em virtude das dificuldades de realizar a correção

radiométrica absoluta e do melhor desempenho da correção relativa para o problema de detecção de mudanças, optou-se por realizar esta última.

A técnica proposta foi comparada experimentalmente com as duas técnicas mais utilizadas em correção relativa: regressão linear e regressão linear robusta.

A fim de avaliar o desempenho dos três procedimentos de correção radiométrica relativa – regressão linear, regressão linear robusta e regressão não paramétrica – foram realizados experimentos de classificação com um conjunto de dados composto de duas imagens multiespectrais adquiridas em 1998 e 1999. Em particular, foi selecionada uma seção (700x700 *pixels*) da mesma cena nas duas imagens.

Montaram-se três conjuntos de imagens, com duas imagens em cada conjunto, todos os três conjuntos com a mesma imagem de referência, com as características radiométricas originais, porém a segunda imagem foi modificada artificialmente introduzindo-se modificações conhecidas a priori, de tal forma que, através de uma interpretação visual, foi verificada a inexistência de mudanças reais, isto é, entre as duas imagens só existiam as mudanças previamente estabelecidas e conhecidas. Em seguida, essa imagem modificada foi radiometricamente corrigida pelos três métodos diferentes: regressão linear simples, regressão robusta e regressão não paramétrica.

A Figura 7.1 mostra o recorte na imagem original de 1998, considerada imagem referência, e a Figura 7.2 mostra o recorte na imagem original de 1999, imagem que sofrerá o processo de correção.



Figura 7.1 – Recorte da imagem original de 1998.




Figura 7.2 – Recorte da imagem original de 1999.

A Figura 7.3 ilustra o recorte da imagem de 1999, modificada artificialmente e corrigida radiometricamente pelo método da regressão não paramétrica, e a Figura 7.4 ilustra o recorte da imagem de 1999, modificada artificialmente e corrigida radiometricamente pelo método da regressão linear.

Usa-se a imagem diferença para realizar a detecção de mudança. Assim, a classificação é binária e tem duas classes: *pixels* alterados e não alterados. A operação de subtração é realizada no par de imagens - imagem referência e imagem modificada/corrigida. A imagem diferença é realizada *pixel* por *pixel*. O método de classificação foi o mesmo para os três conjuntos de dados, um classificador de limiar simples. Os mesmos limiares para cada banda foram usados em todos os três casos. Então aplicamos uma regra de lógica:

- **se** [(*pixel* não alterado na banda 1) **e** (*pixel* não alterado na banda 2) **e**...(*pixel* não alterado na banda nb)] **então** (*pixel* não alterado).




Figura 7.3 – Recorte da imagem de 1999, modificada artificialmente e corrigida radiometricamente por regressão não paramétrica.

Para interpretar a precisão nas classificações, usamos duas medidas distintas: a precisão global e o coeficiente de Kappa (Velloso *et al*, 2002). A precisão global é computada dividindo-se o número total de *pixels* corretamente classificados pelo número total de *pixels* de referência. O coeficiente de concordância de Kappa é uma medida de precisão para classificação temática e vai de 0 até 1. É uma medida da diferença entre o total de acertos de um classificador automatizado e o total de acertos de um classificador aleatório. Para um acerto total do classificador automático, o coeficiente de Kappa equivale a 1, e para um acerto do classificador automático igual ao acerto de um classificador aleatório, Kappa equivale a 0. Um coeficiente de Kappa de 0 sugere que uma determinada classificação não é melhor do que uma atribuição aleatória de *pixels* (Lillesand & Kieffer, 2000).



Figura 7.4 – Recorte da imagem de 1999, modificada artificialmente e corrigida radiometricamente por regressão linear.

As Tabelas 7.1, 7.2 e 7.3 mostram a matriz de confusão para os três conjuntos de dados, com imagens corrigidas radiometricamente por regressão linear, regressão robusta e regressão não paramétrica, respectivamente, onde o elemento (1,1) da matriz indica o número de *pixels* que o classificador indicou não-mudança e na realidade é um *pixel* não-mudança; elemento (1,2) da matriz indica o número de *pixels* que o classificador indicou mudança e na realidade é um *pixel* não-mudança; elemento (2,1) da matriz indica o número de *pixels* que o classificador indicou não-mudança e na realidade é um *pixel* mudança; e elemento (2,2) da matriz indica o número de *pixels* que o classificador indicou mudança e na realidade é um *pixel* mudança. Portanto, os elementos (1,2) e (2,1) são os erros cometidos pelo classificador.

Tabela 7.1 - Matriz de Confusão para o conjunto de dados com imagem corrigida radiometricamente por regressão linear.

		Classificador			
		Não-mudança		Mudança	
Classificação real	Não-mudança	(1,1)	11106	(1,2)	6
	Mudança	(2,1)	1768	(2,2)	14030

Tabela 7.2 – Matriz de Confusão para o conjunto de dados com imagem corrigida radiometricamente por regressão robusta.

		Classificador			
		Não-mudança		Mudança	
Classificação real	Não-mudança	(1,1)	11103	(1,2)	9
	Mudança	(2,1)	1597	(2,2)	14201

Tabela 7.3 – Matriz de Confusão para o conjunto de dados com imagem corrigida radiometricamente por regressão não paramétrica.

		Classificador			
		Não-mudança		Mudança	
Classificação real	Não-mudança	(1,1)	11106	(1,2)	6
	Mudança	(2,1)	1029	(2,2)	14769

A Tabela 7.4 resume os resultados, apresentando a precisão global e o coeficiente de Kappa para os três conjuntos de dados. O pior desempenho foi obtido pelo conjunto de dados com uma imagem corrigida radiometricamente por regressão linear simples, com o

coeficiente de Kappa 0.867, e o melhor desempenho foi pelo conjunto de dados com uma imagem corrigida radiometricamente por regressão não paramétrica, com um coeficiente de Kappa igual a 0.922.

Tabela 7.4 – Resultados para os três conjuntos de dados.

Modelo de correção	Coeficiente de Kappa	Precisão global
Regressão Linear	0.8672	93.4%
Regressão Robusta	0.8798	94.0%
Regressão Não Paramétrica	0.9217	96.2%

7.2 Testes e Experimentos das Metodologias Avaliadas: Pré-classificação Espectral e Pós-classificação

Foram avaliadas duas metodologias de detecção de mudanças: abordagem com pré-classificação espectral e abordagem pós-classificação; nas duas metodologias foi realizado inicialmente um procedimento de correção radiométrica relativa por regressão não paramétrica, pois apresentou melhor desempenho entre os três métodos avaliados.

Na abordagem com pré-classificação espectral é gerada uma imagem representando a diferença espectral das imagens, implementada pela técnica denominada Análise do Vetor Mudança (CVA, *Change Vector Analysis*). Na técnica de CVA, cada pixel da imagem multiespectral é interpretado como um vetor e são gerados dois produtos: o módulo da imagem diferença e o ângulo da imagem diferença. O primeiro produto é utilizado para a detecção de mudanças e o segundo para determinar a direção da mudança. Nesta seção serão apresentados experimentos e resultados somente em relação à detecção de mudanças e, portanto, somente o módulo da imagem diferença é utilizado. Finalmente, a esta imagem diferença é aplicado um processo de classificação, utilizando o algoritmo CNN, resultando a imagem binária mudança / não-mudança, conforme ilustra a Figura 7.5.

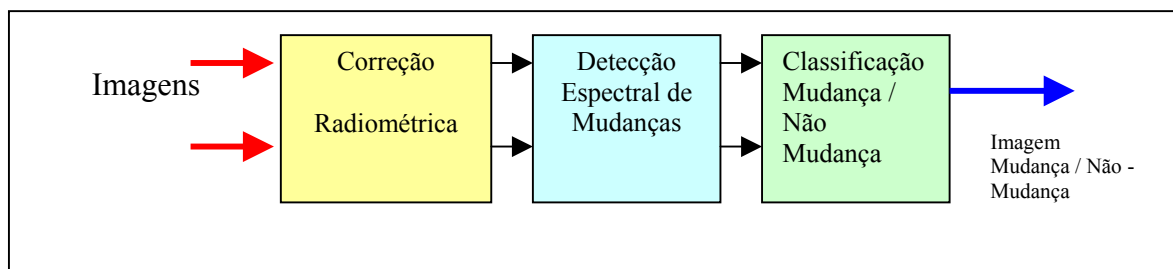


Figura 7.5 - Metodologia da abordagem de detecção de mudanças com pré-classificação espectral

Já na abordagem pós-classificação, é realizada uma classificação temática independente para cada imagem. O procedimento final é uma interpretação direta automatizada, isto é, uma comparação *pixel a pixel* nas duas imagens, identificando os *pixels* com mesma classificação temática nas duas imagens e os *pixels* com classificação diferente, gerando a imagem mudança / não-mudança, conforme ilustra a Figura 7.6. Nessa abordagem não é possível utilizar uma classificação binária para detectar somente se houve ou não mudança na cobertura. O resultado das classificações temáticas, que normalmente contemplam mais de duas classes, já traz a informação sobre direção da mudança, além de onde esta ocorreu.

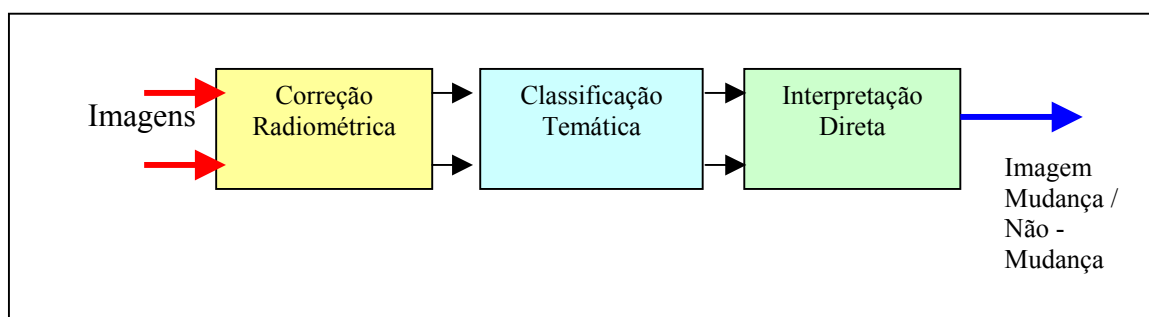


Figura 7.6 - Metodologia da abordagem de detecção de mudanças pós-classificação

Na sequência para avaliar e comparar a eficiência das metodologias testadas, foram realizados experimentos e testes com dois conjuntos de dados diferentes. O primeiro, um conjunto de dados sintéticos gerados a partir de uma imagem referência. O segundo, um conjunto de dados reais multitemporais formado por duas imagens multiespectrais.

O conjunto de dados sintético é composto de duas imagens. A primeira é a imagem referência, um recorte de 700x700 *pixels*, da imagem de 1996 do conjunto de dados de imagens de SR disponível; a segunda é uma imagem sintética gerada artificialmente a partir

da imagem referência, sendo construída com a inserção de algumas mudanças na imagem referência para simular variações na cobertura terrestre. A seguir, o histograma desta imagem com mudanças, conhecidas a priori, foi deslocado levemente para simular condições diferentes de luminosidade nas duas imagens. Finalmente, foi adicionado um ruído Gaussiano de média zero e de proporção sinal ruído $SNR = 10$ db (SNR , *Signal Noise Ratio*) à imagem para transformar as mudanças discretas introduzidas na imagem, simulando mudanças mais semelhantes às mudanças reais que ocorrem na natureza. A Figura 7.7 mostra estas duas imagens, sendo a imagem referência a da Figura 7.7.a e a imagem modificada a da Figura 7.7.b.

O conjunto de dados reais é mostrado na Figura 7.8, onde na Figura 7.8.a é mostrada uma imagem de 1998 e na Figura 7.8.b a mesma região em 1999.



Figura 7.7.a – Imagem referência.



Figura 7.7.b – Imagem modificada.

Figura 7.7 – Imagens sintéticas de teste.

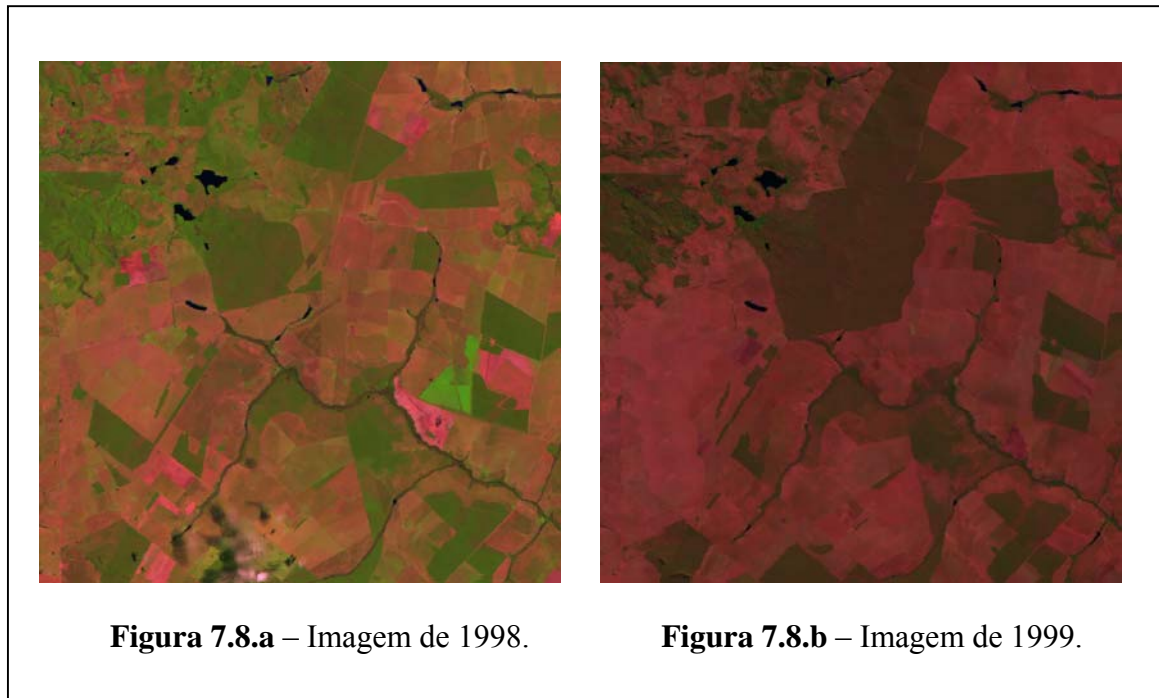


Figura 7.8 – Imagens reais de teste.

7.2.1 Testes e Experimentos para Abordagem Pós-Classificação

Na metodologia da abordagem de detecção de mudanças pós-classificação, foi realizada a classificação temática de cada imagem independentemente, através do algoritmo CNN, que convergiu em 4 classes nos dois casos. A convergência nos dois conjuntos no mesmo número de classes era de se esperar, já que todos os conjuntos de imagens foram extraídos da mesma região.

A Figura 7.9 mostra os resultados da classificação das duas imagens pertencentes ao conjunto sintético de dados, baseado em uma imagem de 1996.

O procedimento final é uma interpretação direta automatizada, isto é, uma comparação *pixel a pixel* nas duas imagens, identificando os *pixels* com mesma classificação temática nas duas imagens e os *pixels* com classificação diferente.




Figura 7.9.a – Classificação temática da imagem referência.




Figura 7.9.b – Classificação temática da imagem modificada.

Figura 7.9 – Classificação temática das imagens de teste.

Nos testes e experimentos com dados reais utilizou-se o recorte da imagem original de 1998 e o recorte da imagem original de 1999, Figura 7.8. Ao recorte da imagem original de 1999 aplicou-se uma correção radiométrica relativa por regressão não paramétrica, método de melhor desempenho.

Para se ter uma referência das mudanças / não-mudanças e assim realizar-se a comparação com os resultados do experimento realizado, foi feita uma classificação de mudanças e não-mudanças por uma interpretação visual, gerando uma imagem como máscara de referência, ilustrada na Figura 7.10.




Figura 7.10 – Máscara da diferença entre as imagens de 1998 e 1999.

Para interpretar a precisão dos dois conjuntos de dados, duas medidas distintas foram usadas: a precisão global e o coeficiente de Kappa. A Tabela 7.5 expressa o desempenho da pós-classificação nos dois conjuntos de dados.

Tabela 7.5 – Resultados do desempenho para pós-classificação

Dados	Coeficiente de Kappa	Precisão global
Dados sintéticos	0,51	96,5 %
Dados reais	0,32	75,1 %

7.2.2 Testes e Experimentos para Abordagem com Pré-Classificação Espectral

Na abordagem com pré-classificação espectral é calculada uma imagem representando a diferença das imagens, implementada por uma técnica denominada Análise do Vetor Mudança (CVA, *Change Vector Analysis*). Como a proposta deste trabalho é apenas identificar áreas de alterações na cobertura terrestre, não determinando o tipo da mudança, utiliza-se apenas a imagem de magnitude.

A Figura 7.11 mostra a imagem do módulo da diferença entre as duas imagens dos dados sintéticos referentes ao ano de 1996.

Nessa abordagem, a classificação será binária, ou seja, o número de classes máximo para o CNN será sempre dois.




Figura 7.11 – Imagem do módulo da diferença do conjunto sintético de imagens,

A Tabela 7.6 expressa os resultados dos testes realizados com os dois conjuntos de dados: sintético (Figura 7.7) e real (Figura 7.8).

Tabela 7.6 – Resultados do desempenho da pré-classificação.

Dados	Coeficiente de Kappa	Precisão global
Dados sintéticos	0,88	96,3%
Dados reais	0,83	99,4%

CAPÍTULO VIII

CONCLUSÃO

O objetivo principal deste trabalho foi avaliar duas metodologias de detecção de mudanças na cobertura terrestre – abordagem com pré-classificação espectral e abordagem pós-classificação – usando imagens multiespectrais e multitemporais de sensoriamento remoto. Para as duas metodologias, concluiu-se pela necessidade inicial de realizar uma correção radiométrica relativa das imagens.

Entre os métodos de correção radiométrica relativa avaliados, a técnica de regressão não paramétrica foi a que mais adicionou ganhos ao desempenho do método de detecção de mudanças mais simples, baseado na imagem diferença. A técnica também permitiu a seleção automática do conjunto de treinamento. Apesar da simplicidade adotada, os resultados experimentais confirmam a eficácia da técnica de correção radiométrica relativa por regressão não paramétrica. Como aperfeiçoamento futuro, poderiam ser testados critérios para especificar o limiar adequado para o mapa de correlação empregado nessa técnica.

Após os testes e experimentos realizados, tanto com os dados sintéticos quanto com os dados reais, verificou-se que a metodologia da abordagem com pré-classificação espectral foi mais eficiente no procedimento de classificação das mudanças e não-mudanças do que a abordagem de pós-classificação. Desta forma, a metodologia mais indicada para a identificação das áreas de mudança e áreas de não-mudança em imagens multiespectrais e multitemporais de sensoriamento remoto é a de pré-classificação espectral.

Nas duas metodologias optou-se por empregar o algoritmo CNN como classificador, por apresentar, como principal vantagem em relação aos outros algoritmos de agrupamento, o fato de que o CNN converge muito mais rapidamente.

Além disso, o CNN em relação aos algoritmos estatísticos como, por exemplo, o *K-means* e o *Isodata*, não apresenta o inevitável problema da não-convergência desses algoritmos.

Em relação aos algoritmos neurais de aprendizado competitivo como, por exemplo, o SOM e o DCL, o CNN tem a vantagem de não depender da escolha do valor inicial do coeficiente de aprendizado e do número total de épocas. Essa escolha deve ser realizada cuidadosamente, em função de uma análise do conjunto de dados, para evitar resultados instáveis.

Como trabalho futuro, seria importante desenvolver uma complementação ao algoritmo CNN, para que esse não dependesse da estimativa do número de classes e sim o próprio algoritmo encontrasse o número de classes existentes no conjunto de dados de entrada. Na metodologia proposta, pré-classificação espectral, essa característica do CNN não tem importância, visto que as classes já estão definidas em duas (mudança e não-mudança), mas pode-se, também, avaliar como trabalho futuro o desempenho do CNN como um classificador temático, e neste caso a definição precisa do número de classes é bastante influente no resultado da classificação.

Nossos dados de entrada são imagens da região do alto Taquari-MS, no Centro-Oeste brasileiro, em acelerado processo de degradação ambiental, causado pela intensa ocupação agrícola do solo ocorrida nos últimos anos. Essa região é limítrofe do Pantanal, e seu processo de degradação ambiental tem afetado a região Pantaneira pelo carreamento de sedimentos do solo e tem causado o assoreamento dos rios do Pantanal, provocando sérios danos ambientais a esse paraíso ecológico. Assim, metodologias e ferramentas computacionais que ajudem no monitoramento ambiental, na prevenção e na correção de danos ambientais são de suma importância e acreditamos que nosso trabalho possa contribuir na especificação e construção dessas metodologias e ferramentas computacionais.

Também na gestão territorial, a extração automatizada de informações é uma necessidade premente, como podemos constatar em matéria publicada no Jornal Folha de São Paulo, do dia 22/08/2004, página 4B, com o título “Governo quer ver safra via satélite”, da qual ressaltamos o trecho: “O ministro da Agricultura, Roberto Rodrigues, quer conhecer o tamanho da safra brasileira antes dos norte-americanos. Para alcançar o objetivo, Rodrigues iniciou um projeto de R\$ 13,7 milhões para passar a estimar a colheita do país por meio de satélites...”. Nesse contexto, acreditamos que este trabalho possa subsidiar projetos como o acima citado.

BIBLIOGRAFIA

CIAGRI-USP. Sistema de Posicionamento Global (GPS, Global Positioning System). Disponível em; <http://www.gps.ciagri.usp.br>.

CROCE, Ricardo. Sensoriamento Remoto. Disponível em: <http://www.croce.ggf.br>.

CRÓSTA, Álvaro Penteado. Processamento Digital de Imagens de Sensoriamento Remoto. Campinas: IG/UNICAMP, 1993.

DARKEN, C. & MOODY, J. Fast adaptive k-means Clustering: Some Empirical Result. In: Int. Joint Conf. Neural Networks, vol. 2, p. 233-238, 1990.

DEER, Peter. Digital Change Detection in Remotely Sensed Imagery Using Fuzzy Set Theory. Adelaide: University of Adelaide, Department of Geography and Department of Computer Science, 1998.

DONG, Chul Park & YOUNG, June Woo. Weighted Centroid Neural Network for Edge Preserving Image Compression. In: IEEE Trans. on Neural Networks, Vol. 12, nº. 5, p. 1134-1146, set/2001.

ELVIDGE, C. D., YUAN, D., WERACKOON, R. D. e LUNETTA, R. S. Relative Radiometric Normalization of Landsat Multispectral Scanner (MSS) Data Using an Automated Scattergram Controlled Regression. In: Photogrammetric Engineering and Remote Sensing, Vol. 61, p. 1255-1260, 1995.

FONSECA, Jairo Simon da. & MARTINS, Gilberto de Andrade. Curso de Estatística. São Paulo: Ed. Atlas S.A., 1996.

GALVÃO, C. de Oliveira & VALENÇA, M. J. Silva. Sistemas Inteligentes-Aplicações a Recursos Hídricos e Ciências Ambientais. Porto Alegre: Ed. Universidade/UFRG/ABRH, 1999.

GONZALES, Rafael C. & WOODS, Richard E. Processamento de Imagens Digitais. São Paulo: Edgard Blucher Ltda, 2000.

HALL, F. G., STREBEL, D. E., NICKESON, J. E. e GOETZ, S. J. Radiometric Rectification: Toward a common Radiometric Response Among Multidate, Multisensor Images. Remote Sensing of Environment, vol. 35, p. 11-27, 1991.

HARDLE, W. Nappied Nonparametric Regression. Cambridge: Cambridge University Press, 1989.

HARTIGAN, J. Clustering Algorithms. Nova York: Wiley, 1975.

HAYKIN, Simon. Redes Neurais-Princípios e Práticas. Porto Alegre: Bookman, 2001.

INPE-DSR. Projeto EDUCA SeRe III. Disponível em: <http://www.dsr.inpe.br>.

JOHNSON, R. D. & KASISCHKE, E. S. Change Vector Analysis: a Technique for the Multispectral Monitoring of Land Cover and Condition. In: International Journal of Remote Sensing, n^o. 19, p. 411-426, 1998.

Jornal Folha de São Paulo. Governo quer ver safra via satélite. São Paulo, 22/08/2004, p. B4.

KOHONEN, T. Self-Organization and Associative Memory. Berlin: Springer-Verlag, 1989.

KONG, S. & KOSKO, B. Differential Competitive Learning for Centroid Estimation and Phoneme Recognition. In: IEEE-Trans. on Neural Networks, vol. 2, 118-124, jan/1991.

LILLESAND & KIEFFER. Remote Sensing and Image Interpretation. 4th Edition, John Wiley & Sons, Inc., 2000.

LUNETTA, Ross S. & ELVIDGE, Christopher D. Remote Sensing Change Detection. Michigan: Ann Arbor Press, 1998.

MALILA, W. A. Change Vector Analysis: An Approach for Detecting Forest Changes with Landsat. In: Proceedings of the Machine Processing of Remotely Sensed Data Symposium, Ann Arbor, ERIM, p. 326-335, 1980,.

MATHER, Paul M. Computer Processing of Remotely-Sensed Images. Nova York: John Wiley & Sons, 1999.

MATSUMOTO, Élia Yathie. Matlab 6.5 – Fundamentos de Programação. São Paulo: Érica, 2002.

McCULLOCH, W. S. & PITTS, W. A Logical Calculus of the Ideas: Immanent in Nervous Activity. In: Bulletin of Mathematical Biophysics, vol. 5, p. 115-133, 1943.

MOREIRA, Maurício Alves. Fundamentos do Sensoriamento Remoto e Metodologia de Aplicação. INPE: São José dos Campos, 2001.

NATURAL RESOURCES CANADA. Disponível em: <http://www.ccrs.nrcan.gc.ca>.

NETO, Luiz Biondi. Neuro-DEA – Nova Metodologia para Determinação da Eficiência Relativa de Unidades Tomadoras de Decisão. Rio de Janeiro: COPPE-UFRJ, Programa de Engenharia de Produção, 2001.

NOVO, Evelyn M. L. de Moraes. Sensoriamento Remoto - Princípios e Aplicações. São Paulo: Edgard Blucher Ltda, 1998.

PARK, Dong Chul. Centroid Neural Network for Unsupervised Competitive Learning. In: IEEE-Trans. on Neural Network, vol. 11, nº. 2, p. 520-528, 2000.

RUMELHART, D. E. & MC CLELLAND, J. Paralled Distributed Processing: Explorationing in the Microstruture Cognition, vol 1. Cambridge: Bradford Book-Mit Press, 1986.

SELPER & INPE-DSR. Projeto EDUCA SeRe I – Cadernos Didáticos para o Ensino de Sensoriamento Remoto. São José dos Campos: SELPER/Capítulo Brasil & INPE, 1997.

SWAIN, P. H. & DAVIS, S. M. Remote Sensing: The Quantitative Approach. Nova York: Mc Graw-Hill, 1978.

VELLOSO, Maria Luiza Fernandes, SOUZA, Flávio Joaquim de e ALMEIDA, Nival Nunes.de. Relative Radiometric Correction on Remotely Sensed Data for Land Cover Change Detection: An Unsupervised Clustering Approach. In: International Geoscience and Remote Sensing Symposium 2003, Toulouse,. 2003.

VELLOSO, Maria Luiza Fernandes; SIMÕES, Margareth; CARNEIRO, Thales Avila. Competitive Artificial Neural Network for Change-Detection of Land Cover: An Unsupervised Approach. In: International Geoscience and Remote Rensing Symposium 2002, Toronto. Conference Proceedings of International Geoscience and Remote Sensing Symposium 2002. IEEE Press, v. 1, p. 95-97, 2002, .

VELLOSO, Maria Luiza Fernandes; SIMÕES, Margareth; CARNEIRO, Thales Avila. Self-Adaptive Artificial Neural Network for Change-Detection of Land Cover: An Unsupervised Approach. In: 2002 WSES International Conference on Neural Networks and Applications, Interlaken, 2002. Proceedings of 2002 WSES International Conference on Neural Networks and Applications. WSES Press, 2002.

VELLOSO, Maria Luiza Fernandes; SIMÕES, Margareth; CARNEIRO, Thales Avila. Self-Adaptive Artificial Neural Network for Change-Detection of Land Cover: An Unsupervised Approach. In: III International Congress Geomatica 2002, Havana, 2002,.

TATIBANA, C. Y. & KAETSU, D. Y. Homepage de Redes Neurais. Disponível em: <http://www.din.uem.br/ia/neurais>.

THE MATHWORKS, In. Image Processing Toolbox User's Guide. Disponível em: <http://www.mathwoks.com>.

YUAN, D. & ELVIDGE, C. D. Comparison of relative radiometric normalization techniques. In: ISPRS Journal of Photogrammetry and Remote Sensing, vol. 51, n^o. 3, p. 117-126, 1996.

APÊNDICE A

O Algoritmo Redes Neurais por Centróide (CNN)

```

Algoritmo CNN (M,N) [M: número de agrupamentos, N:número de dados do vetor de entrada]
  [Inicialização dos pesos  $W_1$  e  $W_2$ ]
  Encontrar o centróide C de todo o vetor de dados de entrada
  Inicialize  $W_1$  e  $W_2$  em torno de C, com um pequeno desvio  $\varepsilon$ 
   $W_1 = C + \varepsilon$  e  $W_2 = C - \varepsilon$ 
   $N_1 = 0$  e  $N_2 = 0$ 
   $k = 2$  e época = 0
  for (  $k \leq M$  )
    do
      perdedor = 0
      for (  $t \leq N$  )
        Aplica o dado  $x_t$  do vetor de entrada à rede
        Encontra o neurônio vencedor j, nesta época para  $1 \leq j \leq k$ 
        se ( época  $\neq 0$  ), então encontre o neurônio p, vencedor da época anterior
        se (  $j \neq p$  ), então p é o neurônio perdedor
        se ( época == 0 OU  $j \neq p$  )
          Execute atualizar_pesos ( $x_t, W_j, W_p, \text{época}$ )
          perdedor ++
        fim_se
      t++
    fim_for [apresenta todos os dados de entrada]
    época++
  enquanto (perdedor  $\neq 0$ )
    se (  $k \neq M$  )
      [Aumenta o número de grupos]
      Encontra o neurônio m, que apresenta maior distância entre entradas e pesos
       $W_{k+1} = W_m + \varepsilon$ 
    fim_se
     $k++$  e  $N_k = 0$ 
  fim_for
fim_algoritmo

```

```

Função atualizar_pesos ( $x_t, W_j, W_p, \text{época}$ )
  [Atualiza pesos do neurônio vencedor]
  
$$W_j(t+1) = W_j(t) + \frac{1}{N_j + 1} [x(t) - W_j(t)]$$

  se (época  $\neq 0$ ) [neurônio perdedor ocorre somente quando época  $\neq 0$ ]
    [Atualiza pesos do neurônio perdedor]
    
$$W_p(t+1) = W_p(t) + \frac{1}{N_p - 1} [x(t) - W_p(t)]$$

  fim_se
fim_Função

```