

UNIVERSIDADE ESTADUAL PAULISTA “JULIO DE MESQUITA FILHO”
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CÂMPUS DE BOTUCATU

**CLASSIFICAÇÃO DE COBERTURA DO SOLO UTILIZANDO
ÁRVORES DE DECISÃO E SENSORIAMENTO REMOTO**

TATIANA MONTES CELINSKI

Tese apresentada à Faculdade de Ciências
Agronômicas da Unesp - Câmpus de Botucatu,
para obtenção do título de Doutor em
Agronomia (Energia na Agricultura)

BOTUCATU - SP

Dezembro - 2008

UNIVERSIDADE ESTADUAL PAULISTA “JULIO DE MESQUITA FILHO”
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CÂMPUS DE BOTUCATU

**CLASSIFICAÇÃO DE COBERTURA DO SOLO UTILIZANDO
ÁRVORES DE DECISÃO E SENSORIAMENTO REMOTO**

TATIANA MONTES CELINSKI

Orientadora: Prof^a. Dr^a. Célia Regina Lopes Zimback

Tese apresentada à Faculdade de Ciências
Agronômicas da Unesp - Câmpus de Botucatu,
para obtenção do título de Doutor em
Agronomia (Energia na Agricultura)

BOTUCATU - SP

Dezembro – 2008

FICHA CATALOGRÁFICA ELABORADA PELA SEÇÃO TÉCNICA DE AQUISIÇÃO E TRATAMENTO DA INFORMAÇÃO - SERVIÇO TÉCNICO DE BIBLIOTECA E DOCUMENTAÇÃO - UNESP - FCA - LAGEADO - BOTUCATU (SP)

C392c Celinski, Tatiana Montes, 1963-
Classificação de cobertura do solo utilizando árvores de decisão e sensoriamento remoto / Tatiana Montes Celinski. - Botucatu : [s.n.], 2008.
xii, 112 f. : il. color., gráfs., tabs.

Tese (Doutorado) - Universidade Estadual Paulista, Faculdade de Ciências Agrônômicas, Botucatu, 2008

Orientador: Célia Regina Lopes Zimback

Inclui bibliografia

1. Sensoriamento remoto. 2. Processamento de imagens - Técnicas digitais. 3. Mapeamento da cobertura do solo. 4. Mineração de dados (Computação). I. Zimback, Célia Regina Lopes. II. Universidade Estadual Paulista "Júlio de Mesquita Filho" (Campus de Botucatu). Faculdade de Ciências Agrônômicas. III. Título.

UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"

FACULDADE DE CIÊNCIAS AGRONÔMICAS

CAMPUS DE BOTUCATU

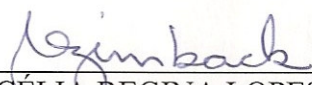
CERTIFICADO DE APROVAÇÃO

TÍTULO: "CLASSIFICAÇÃO DE COBERTURA DO SOLO UTILIZANDO ÁRVORES
DE DECISÃO E SENSORIAMENTO REMOTO"

ALUNA: TATIANA MONTES CELINSKI

ORIENTADOR: PROFA. DRA. CÉLIA REGINA LOPES ZIMBACK

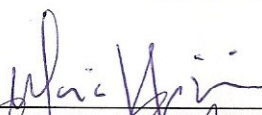
Aprovado pela Comissão Examinadora



PROFA. DRA. CÉLIA REGINA LOPES ZIMBACK



PROF. DR. ZACÁRIAS XAVIER DE BARROS



PROF. DR. MARCO ANTONIO M. BIAGGIONI



PROF. DR. MARCELO GIOVANETI CANTERI



PROF. DR. IVO MARIO MATHIAS

Data da Realização: 02 de dezembro de 2008.

AGRADECIMENTOS

À força divina, fonte de inspiração e esperança em minha vida.

Aos meus preciosos filhos Camila, Giovana e Diogo, e ao meu querido esposo Victor, pela compreensão, estímulo e amor incondicionais dedicados.

Aos meus pais David e Maria Estela, e aos meus sogros Vitoldo e Savina, os pilares e o esteio de minha família, pela ajuda oferecida para a realização deste trabalho.

Aos meus caros irmãos Josué, Tamara e Cassiano, que deram a sua contribuição durante a realização deste trabalho.

À Marisa Martins, pelo apoio e pela dedicação à minha família.

À minha orientadora Prof^a. Dr^a. Célia Regina Lopes Zimback pela confiança, apoio e compreensão dedicados, e pela amizade compartilhada.

Ao Prof. Dr. Ivo Mário Mathias, pelo incentivo e apoio que permitiram a minha participação no Projeto de Qualificação Interinstitucional FCA/UNESP/UEPG.

Ao amigo e colega Marcelo Ferrasa, pela amizade e companheirismo vivenciados durante a realização de nossos trabalhos.

Aos colegas e amigos do Departamento de Informática da Universidade Estadual de Ponta Grossa, em especial a Elaine Margarete Guimarães, Leila Issa Rickli, Ariangelo Hauer Dias e Frederico Guilherme de Paula Ferreira Ielo, pelo incentivo e apoio.

Aos professores da Faculdade de Ciências Agrônomicas de Botucatu que tive a honra de conhecer como aluna, pelo apoio e contribuição para realização deste trabalho.

Aos professores membros da banca examinadora desta tese de doutorado, pelo aceite em participar da mesma e pelas suas contribuições ao trabalho.

Aos funcionários dos departamentos de Recursos Naturais e Ciência do Solo e de Gestão e Tecnologia Agroindustrial, da Faculdade de Ciências Agrônomicas de Botucatu, em especial a Mario Eduardo Bianconi, pela atenção dispensada.

Aos coordenadores do Programa de Qualificação Interinstitucional FCA/UNESP/UEPG, professores Dr. Ângelo Catâneo e Dr. Jorim Souza das Virgens Filho, pelo empenho na condução do programa.

À equipe da Pró-reitoria de Pesquisa e Pós-graduação da UEPG, em especial à Márcia Belinski, pelo apoio e pela atenção.

À equipe da secretaria da pós-graduação da FCA/UNESP, Marilena do Carmo Santos, Jaqueline de Moura Gonçalves, Marlene Rezende Freitas, Taynan Ribeiro Moraes da Silva e Kátia Otomo Duarte, pela atenção e gentileza.

À Universidade Estadual de Ponta Grossa, pela oportunidade e apoio para a realização deste trabalho.

À CAPES pelo apoio e ajuda financeira, fundamentais para a realização deste trabalho.

AGRADEÇO.

SUMÁRIO

	Página
LISTA DE FIGURAS.....	VIII
LISTA DE TABELAS.....	X
LISTA DE ABREVIATURAS.....	XI
1 RESUMO	1
2 SUMMARY	3
3 INTRODUÇÃO.....	5
4 REVISÃO BIBLIOGRÁFICA	8
4.1 Geoprocessamento	8
4.1.1 Definição.....	8
4.1.2 Sistemas de informações geográficas	8
4.1.3 Aplicações na agricultura.....	9
4.2 Sensoriamento remoto	11
4.2.1 Definição.....	11
4.2.2 Radiação eletromagnética	13
4.2.3 Interações da energia com a atmosfera	17
4.2.4 Interações da energia com a superfície terrestre e sua resposta espectral	18
4.2.5 Sistemas sensores.....	22
4.2.6 Câmeras imageadoras dos satélites CBERS-2 e CBERS-2B	26
4.3 Processamento de imagens digitais em sensoriamento remoto	29
4.3.1 Correção geométrica	30
4.3.2 Correção radiométrica.....	31
4.3.3 Eliminação de ruído	32
4.3.4 Manipulação de contraste	33
4.3.5 Filtragem espacial	34
4.3.6 Razão espectral	35
4.3.7 Processamento da cor.....	36
4.3.8 Transformação por componentes principais	37
4.3.9 Índices de vegetação	38

4.3.10	Modelo linear de mistura espectral.....	40
4.3.11	Transformação espectral <i>tasseled-cap</i>	41
4.4	Classificação de imagens digitais	42
4.4.1	Classificação multiespectral	42
4.4.2	Treinamento	44
4.4.3	Algoritmos para classificação.....	45
4.4.4	Avaliação da classificação	47
4.5	Comparação entre métodos de classificação.....	51
4.6	Árvores de decisão.....	53
4.6.1	Descoberta de conhecimento em bancos de dados	53
4.6.2	Aprendizagem em árvores de decisão.....	54
4.6.3	Algoritmos de aprendizagem em árvores de decisão.....	56
4.6.4	Extração de regras de classificação a partir de árvores de decisão.....	62
5	MATERIAL E MÉTODOS.....	64
5.1	Área de estudo.....	64
5.2	Materiais	66
5.2.1	Equipamentos	66
5.2.2	Programas computacionais	66
5.2.3	Dados de sensoriamento remoto.....	66
5.3	Métodos	67
5.3.1	Aquisição e registro das imagens.....	68
5.3.2	Processamento das imagens.....	71
5.3.3	Coleta de dados de verdade terrestre	72
5.3.4	Determinação das classes de cobertura do solo	73
5.3.5	Classificação das imagens e mapeamento	73
5.3.6	Avaliação	74
6	RESULTADOS E DISCUSSÃO.....	75
6.1	Determinação das amostras de treinamento.....	75
6.2	Discriminação da cena 157/128.....	76
6.2.1	Classificação pelo algoritmo MAXVER	76

6.2.2 Classificação pelo algoritmo Árvore de Decisão.....	79
6.3 Discriminação da cena 158/27.....	83
6.3.1 Classificação pelo algoritmo MAXVER.....	83
6.3.2 Classificação pelo algoritmo Árvore de Decisão.....	85
6.4 Considerações finais.....	89
7 CONCLUSÕES.....	91
8 REFERÊNCIAS BIBLIOGRÁFICAS.....	92
APÊNDICE.....	101
APÊNDICE 1 – Rotina de conversão de DN para reflectância aparente.....	102
APÊNDICE 2 – Rotina de correção atmosférica.....	103
APÊNDICE 3 – Rotina de determinação do CTVI.....	104
APÊNDICE 4 – Rotina de determinação do GEMI.....	105
APÊNDICE 5 – Rotina de determinação do SAVI.....	106
APÊNDICE 6 – Rotina de determinação do TVI.....	107
APÊNDICE 7 – Rotina de classificação por árvore de decisão (cena 157/128).....	108
APÊNDICE 8 – Rotina de classificação por árvore de decisão (cena 158/127).....	109
APÊNDICE 9 – Rotina de geração do mapa temático (cena 157/128).....	111
APÊNDICE 10 – Rotina de geração do mapa temático (cena 158/127).....	112

LISTA DE FIGURAS

	Página
Figura 1 – Processo de aquisição de dados de sensoriamento remoto.....	12
Figura 2 – Esquema de propagação de uma onda eletromagnética	14
Figura 3 – Espectro eletromagnético	14
Figura 4 – Curvas de reflectância espectral típicas para vegetação, solo e água.....	19
Figura 5 – Curva de reflectância espectral da vegetação verde e sadia	21
Figura 6 – As três coordenadas de uma imagem multiespectral.....	43
Figura 7 – Árvore de decisão para o problema Jogar Tênis	55
Figura 8 – Algoritmo básico para indução de árvore de decisão.....	57
Figura 9 – Conjunto de regras extraídas da árvore de decisão da Figura 7	62
Figura 10 – Localização da área de estudo	65
Figura 11 – Grade de cenas do satélite CBERS-2, Estado do Paraná	67
Figura 12 – Fluxograma metodológico do processo utilizado para discriminação de classes de uso do solo em imagens do satélite CBERS-2	68
Figura 13 – Composição colorida R3G4B2 da cena 157/128 do sensor CCD/CBERS-2, de 07/03/2007.....	69
Figura 14 – Composição colorida R3G4B2 da cena 158/127 do sensor CCD/CBERS-2, de 02/09/2007.....	70
Figura 15 – Recorte monocromático da cena 157/128 relativo ao conjunto de amostras de treinamento localizadas na Fazenda Capão da Onça, pertencente à Universidade Estadual de Ponta Grossa	76
Figura 16 – Mapa temático resultante da classificação MAXVER, relativo à cena 157/128....	78
Figura 17 – Árvore decisão obtida a partir das amostras de treinamento, relativa à cena 157/128.....	82
Figura 18 – Mapa temático resultante da classificação por árvore de decisão, relativo à cena 157/128.....	83
Figura 19 – Mapa temático resultante da classificação MAXVER, relativo à cena 158/127....	85
Figura 20 – Árvore de Decisão obtida a partir das amostras de treinamento, relativa à cena 158/127.....	87

Figura 21 – Mapa temático resultante da classificação por árvore de decisão, relativo à cena 158/127.....	88
---	----

LISTA DE TABELAS

	Página
Tabela 1 – Bandas espectrais do sensor WFI (CBERS-2 e CBERS-2B)	27
Tabela 2 – Bandas espectrais do sensor CCD (CBERS-2 e CBERS-2B)	28
Tabela 3 – Bandas espectrais do sensor IRMSS (CBERS-2)	28
Tabela 4 – Banda espectral do sensor HRC (CBERS-2B)	29
Tabela 5 – Matriz de erros genérica	48
Tabela 6 – Classificação qualitativa quanto ao valor do coeficiente <i>kappa</i>	50
Tabela 7 – Matriz de erros de classificação relativa ao Classificador MAXVER, cena 157/128	77
Tabela 8 – Matriz de erros de classificação relativa ao Classificador Árvore de Decisão, cena 157/128	80
Tabela 9 – Emprego dos atributos selecionados na construção da árvore de decisão, relativo à cena 157/128	81
Tabela 10 – Matriz de erros de classificação relativa ao Classificador MAXVER, cena 158/127	84
Tabela 11 – Matriz de erros de classificação relativa ao Classificador Árvore de Decisão, cena 158/127	86
Tabela 12 – Emprego dos atributos selecionados na construção da árvore de decisão, relativo à cena 158/127	88
Tabela 13 – Resultados obtidos (MAXVER X árvore de decisão)	89

LISTA DE ABREVIATURAS

CBERS	<i>China-Brazil Earth Resources Satellite</i> (Satélite Sino-Brasileiro de Recursos Terrestres)
CCD	<i>Charge-coupled Device</i> (Câmara Imageadora de Alta Resolução)
CP1	Primeira Componente Principal
CP2	Segunda Componente Principal
CTVI	<i>Corrected Transformed Vegetation Index</i> (Índice de Vegetação Transformado Corrigido)
DN	<i>Digital Number</i> (Número Digital)
DVI	<i>Difference Vegetation Index</i> (Índice de Vegetação pela Diferença)
ETM	Enhanced Thematic Mapper
GEMI	<i>Global Environment Monitoring Index</i> (Índice Global de Monitoramento Ambiental)
GPS	<i>Global Positioning System</i> (Sistema de Posicionamento Global)
HRC	<i>High Resolution Camera</i> (Câmara Pancromática de Alta Resolução)
IFOV	<i>Instantaneous Field of View</i> (Campo de Instantâneo de Visada)
IHS	<i>Intensity-Hue-Saturation</i> (Intensidade-Matiz-Saturação)
INPE	Instituto Nacional de Pesquisas Espaciais
IRMSS	<i>Infrared Multispectral Scanner</i> (Imageador por Varredura de Média Resolução)
KDD	<i>Knowledge Discovery in Databases</i> (Descoberta de Conhecimento em Bancos de Dados)
LEGAL	Linguagem Espacial de Geoprocessamento Algébrico
MAXVER	Máxima Verossimilhança
MLC	<i>Maximum Likelihood Classifier</i>
MME_água	Imagem Fração Sombra/água do Modelo Linear de Mistura Espectral
MME_solo	Imagem Fração Solo do Modelo Linear de Mistura Espectral
MME_vegetação	Imagem Fração Vegetação do Modelo Linear de Mistura Espectral

NDVI	<i>Normalized Difference Vegetation Index</i> (Índice de Vegetação da Diferença Normalizada)
RGB	<i>Red-Green-Blue</i>
SAD-69	South American Datum 1969
SAVI	<i>Soil Adjusted Vegetation Index</i> (Índice de Vegetação Ajustado para o Solo)
SIG	Sistema de Informações Geográficas
SPRING	Sistema para Processamento de Informações Georreferenciadas
SR	<i>Simple Ratio</i> (Razão Simples)
TM	<i>Thematic Mapper</i>
TVI	<i>Transformed Vegetation Index</i> (Índice de Vegetação Transformado)
UTM	<i>Universal Transverse Mercator</i> (Universal Transversa de Mercator)
WFI	<i>Wide Field Imager</i> (Imageador de Amplo Campo de Visada)

1 RESUMO

Este trabalho teve por objetivo a discriminação de classes de cobertura do solo em imagens de sensoriamento remoto do satélite CBERS-2 por meio do Classificador Árvore de Decisão. O estudo incluiu a avaliação de combinações de atributos da imagem para melhor discriminação entre classes e a verificação da acurácia da metodologia proposta comparativamente ao Classificador Máxima Verossimilhança (MAXVER). A área de estudo está localizada na região dos Campos Gerais, no Estado do Paraná, que apresenta diversidade quanto aos tipos de vegetação: culturas de inverno e de verão, áreas de reflorestamento, mata natural e pastagens. Foi utilizado um conjunto de dezesseis (16) atributos a partir das imagens, composto por: bandas do sensor CCD (1, 2, 3, 4), índices de vegetação (CTVI, DVI, GEMI, NDVI, SR, SAVI, TVI), componentes de mistura (solo, sombra, vegetação) e os dois primeiros componentes principais. A acurácia da classificação foi avaliada por meio da matriz de erros de classificação e do coeficiente *kappa*. A coleta de amostras de verdade terrestre foi realizada utilizando-se um aparelho GPS de navegação para o processo de georreferenciamento, para serem usadas na fase de treinamento dos classificadores e também na verificação da acurácia. O processamento das imagens e a geração dos mapas temáticos foram realizados por meio do Sistema de Informações Geográficas SPRING, sendo as rotinas desenvolvidas na linguagem de programação LEGAL. Para a geração do Classificador Árvore de Decisão foi utilizada a ferramenta See5. Na definição das classes, buscou-se um alto nível discriminatório a fim de permitir a separação dos diferentes tipos de culturas presentes na região nas épocas de inverno

e de verão. A classificação por árvore de decisão apresentou uma acurácia total de 94,5% e coeficiente *kappa* igual a 0,9389, para a cena 157/128; para a cena 158/127, apresentou os valores 88% e 0,8667, respectivamente. Os resultados demonstraram que o desempenho do Classificador Árvore de Decisão foi superior ao do MAXVER, especialmente para as classes relativas às culturas. A utilização de dados de sensoriamento remoto CBERS-2, juntamente com os sistemas SPRING e See5, proveu uma metodologia simples para o nível de discriminação vegetal pretendido.

Palavras-chave: classificação de imagens, reconhecimento de padrões, mapeamento da vegetação, exatidão do mapeamento, CBERS.

LAND COVER CLASSIFICATION USING DECISION TREES AND REMOTE SENSING.

Botucatu, 2008. 112 p. Tese (Doutorado em Agronomia/Energia na Agricultura) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista.

Author: TATIANA MONTES CELINSKI

Adviser: CÉLIA REGINA LOPES ZIMBACK

2 SUMMARY

This work aimed to discriminate classes of land cover in remote sensing images of the satellite CBERS-2, using the Decision Tree Classifier. The study includes the evaluation of combinations of attributes of the image to a better discrimination between classes and the verification of the accuracy of the proposed methodology, comparatively to the Maximum Likelihood Classifier (MLC). The geographical area used is situated in the region of the “Campos Gerais”, in the Paraná State, which presents diversities concerning the different kinds of vegetations: summer and winter crops, reforestation areas, natural forests and pastures. It was used a set of sixteen (16) attributes from images, composed by bands of the sensor CCD (1, 2, 3, 4), vegetation indices (CTVI, DVI, GEMI, NDVI, SR, SAVI, TVI), mixture components (soil, shadow, vegetation) and the two first principal components. The accuracy of the classifications was evaluated using the classification error matrix and the *kappa* coefficient. The collect of the samples of ground truth was performed using a navigation device GPS to the georeference process to be used in the training stage of the classifiers and in the verification of the accuracy, as well. The processing of the images and the generation of the thematic maps were made using the Geographic Information System SPRING, and the routines were developed in the programming language LEGAL. The generation of the Decision Tree Classifier was made using the tool See5. A high discriminatory level was aimed during the definition of the classes in order to allow the separation of the different kinds of winter and summer crops. The classification accuracy by

decision tree was 94.5% and *kappa* coefficient was 0.9389 to the scene 157/128; to the scene 158/127, it presented the values 88% and 0.8667, respectively. Results showed that the performance of the Decision Tree Classifier was better than the MLC, especially to the classes related to the crops. The utilization of remotely sensed data CBERS-2 processed with the systems SPRING and See5 provided a simple methodology by using free access software to discrimination of vegetation.

Keywords: digital image classification, pattern recognition, vegetation mapping, mapping accuracy, CBERS.

3 INTRODUÇÃO

O sensoriamento remoto juntamente com os sistemas de informações geográficas (SIG's) constituem-se em ferramentas essenciais para o monitoramento da vegetação, a tomada de decisões, a gestão ambiental e também como subsídio para a definição de políticas públicas. Na agricultura são muitas as aplicações, dentre as quais se destacam a identificação e o mapeamento de culturas. A identificação de um determinado tipo de cultura é a base para cálculos de quantificação da biomassa, determinação da área plantada, previsão de safras, dentre outras aplicações.

A utilização de imagens de sensoriamento remoto tem se mostrado uma forma viável para tais fins devido à rapidez na aquisição e à periodicidade em que são ofertadas, bem como à possibilidade de aplicações tanto em escalas locais quanto globais. Imagens dos satélites brasileiros da família CBERS – lançado o primeiro em 1999 – são disponibilizadas gratuitamente pelo Instituto Nacional de Pesquisas Espaciais (INPE, 2007), o que tem contribuído para seu uso e disseminação. Além disso, as características dos sensores presentes nas plataformas CBERS permitem atender a múltiplos requisitos de aplicações.

Os SIG's, desenvolvidos com base em técnicas matemáticas e computacionais, permitem inserir e integrar, numa única base de dados, informações espaciais provenientes de diversas fontes, como dados de sensoriamento remoto, mapas, dados cadastrais, entre outros. Outra característica dos SIG's é permitir a manipulação dessas informações por meio de algoritmos de processamento de imagens, além de outras

funcionalidades, como a consulta, a recuperação, a visualização e a impressão do conteúdo da base de dados.

O sistema de informações geográficas SPRING (Sistema para Processamento de Informações Georreferenciadas), desenvolvido pelo INPE (INPE, 2007), é um software de acesso livre, distribuído gratuitamente e voltado ao geoprocessamento e ao processamento de imagens. Está em constante desenvolvimento, apresentando um conjunto de algoritmos e procedimentos inovadores. Dentre as suas funcionalidades, apresenta um grande número de técnicas de processamento de imagens digitais abrangendo as diversas etapas do processamento de imagens, desde o pré-processamento até a classificação.

Em aplicações voltadas à identificação e ao mapeamento de culturas, na etapa de classificação busca-se rotular cada *pixel* ou elemento da imagem segundo a ocupação do solo, obtendo-se um mapa de classes temáticas. A categorização é feita por meio de algoritmos de reconhecimento de padrões que utilizam os valores espectrais assim como, outros parâmetros obtidos a partir da assinatura espectral. A classificação, portanto, requer o uso de algoritmos complexos e de técnicas de seleção e extração de características.

O desenvolvimento da área de reconhecimento de padrões, intensificado nas últimas décadas, juntamente com a disponibilidade de grande quantidade de informação, incluindo dados de sensoriamento remoto, tem permitido o uso de algoritmos de diferentes abordagens para a classificação. Dentre essas abordagens, destacam-se os algoritmos estatísticos, as redes neurais e as árvores de decisão.

Os algoritmos estatísticos, em especial o algoritmo MAXVER (Máxima Verossimilhança), têm sido bastante usados no mapeamento do uso da terra, com resultados satisfatórios quando se considera um conjunto de classes abrangente. Entretanto, considerando-se áreas de variada e intensa atividade agrícola, há a necessidade de uma distinção entre subclasses correspondendo a diferentes culturas.

Algoritmos de árvores de decisão, embora menos usados em aplicações voltadas ao sensoriamento remoto, têm se mostrado uma referência no desenvolvimento e análise de novas propostas para classificação da cobertura da terra. Este fato decorre de características importantes das árvores de decisão, como boa acurácia na classificação, rapidez no treinamento e na execução. Acrescenta-se o fato de que não fazem suposições estatísticas

sobre os dados e habilidade para manipular dados de diferentes escalas de medidas e relacionamentos não-lineares entre características e classes, o que permite a utilização de um conjunto característico amplo e variado.

Diante dessas considerações, o presente trabalho teve por objetivo avaliar a acurácia da classificação de imagens de sensoriamento remoto do satélite CBERS-2 utilizando árvores de decisão, comparativamente ao classificador MAXVER. O trabalho visou também avaliar a utilização de um amplo conjunto de atributos de imagem a fim de prover informação para separar classes de uma região constituída de paisagem heterogênea devido à diversidade de culturas e reflorestamento.

4 REVISÃO BIBLIOGRÁFICA

4.1 Geoprocessamento

4.1.1 Definição

O termo geoprocessamento, de acordo com Câmara e Medeiros (1998), denota uma disciplina que utiliza técnicas matemáticas e computacionais para o tratamento de informações geográficas. As ferramentas computacionais do geoprocessamento, chamados de SIG's, permitem a realização de análises complexas ao integrar dados de diversas fontes e ao criar bancos de dados georreferenciados, além de automatizar a produção de documentos cartográficos.

Para Câmara e Monteiro (2001), as questões básicas do geoprocessamento envolvem a representação e a manipulação computacional de fenômenos do mundo real (mapas, cadastros, dados topográficos, imagens) por meio de estruturas de dados e algoritmos.

4.1.2 Sistemas de informações geográficas

De acordo com Davis e Câmara (2001), SIG's são sistemas computacionais que tratam de dados geográficos e recuperam informações não apenas com

base em suas características alfanuméricas, mas também por meio de sua localização espacial. As principais características dos SIG's podem ser resumidas em: *i*) inserir e integrar, numa única base de dados, informações espaciais provenientes de dados cartográficos, dados censitários e cadastro urbano e rural, imagens de satélite, redes e modelos numéricos de terreno; *ii*) oferecer mecanismos para combinar as várias informações, por meio de algoritmos de manipulação e análise, bem como para consultar, recuperar, visualizar e plotar o conteúdo da base de dados georreferenciados.

Os SIG's atualmente disponíveis no mercado apresentam um conjunto de funcionalidades que permitem seu uso de forma ampla. No entanto, apresentam especificidades relacionadas à modelagem do banco de dados, ao ambiente computacional em que podem ser executados, ao tipo de dados que suportam (vetorial e/ou matricial), aos procedimentos que oferecem, ao custo de aquisição, entre outras características.

O SIG SPRING (CÂMARA et al., 1996), desenvolvido pelo INPE, possui como características: suporte a dados matriciais e vetoriais permitindo integração entre ambos, modelagem do banco de dados relacional e possibilidade de ser executado em ambiente operacional Windows ou UNIX, mono ou multiusuário. Além dessas características, o SPRING é um software de livre acesso, distribuído gratuitamente pelo INPE (INPE, 2007).

4.1.3 Aplicações na agricultura

Em aplicações na agricultura, dados de sensoriamento remoto e SIG têm sido extensivamente usados em conjunto. Este fato se justifica pela quantidade de imagens de diferentes sensores que vêm sendo disponibilizadas periodicamente na atualidade. Por meio do SIG, é possível extrair informações importantes das imagens de sensoriamento remoto, que são utilizadas na identificação e mapeamento de culturas, no mapeamento do uso da terra, na estimativa da produtividade safras agrícolas, além de outras aplicações.

Venturieri e Santos (1998) apresentaram os métodos de classificação digital de imagens, cujos resultados geram um grande número de informações temáticas que podem ser aplicadas diretamente à agricultura. Neste contexto, demonstraram a importância dos produtos de sensoriamento remoto orbital não só na aquisição primária de informações

como no inventário e gerenciamento da paisagem agroflorestal em países de dimensões continentais, como o Brasil.

De acordo com Câmara e Medeiros (1998), o geoprocessamento tem influenciado diversas áreas de maneira crescente e apresenta um enorme potencial para a tomada de decisões sobre problemas urbanos e ambientais. Assad e Sano (1998), em seu livro, parte II, publicaram uma série de experiências de diversos autores, abrangendo os mais variados contextos de aplicações dos SIG's à agricultura.

A partir do lançamento do Programa CBERS – Satélite Sino-Brasileiro de Recursos Terrestres – em 1999, as pesquisas utilizando imagens da família CBERS têm se intensificado. Este fato se deve às características dos sensores, que possuem potencial para atender a múltiplos requisitos de aplicações. Além disso, as imagens são disponibilizadas gratuitamente pelo sítio do INPE na internet (INPE, 2007), o que contribui para sua maior disseminação e uso.

Atualmente, a literatura apresenta um grande número de trabalhos envolvendo a aplicação do geoprocessamento na agricultura. Alguns dos trabalhos realizados recentemente são descritos brevemente a seguir, nos quais se utilizaram como ferramentas de geoprocessamento o SIG SPRING (CÂMARA et al., 1996) e dados de sensoriamento remoto do satélite CBERS-2.

Arce et al. (2005) elaboraram um mapa de uso da terra para agricultura e estimaram áreas plantadas da safra 2003/04 em 14 municípios da região administrativa de Limeira (SP) a partir de dados dos sensores TM/Landsat, CCD e IRMSS/CBERS-2. Por meio do SIG SPRING, foi realizada a segmentação por crescimento de regiões e a classificação ISOSEG. Trabalho de campo confirmou que as imagens foram úteis na identificação das culturas de cana-de-açúcar, pastagem, floresta e área de reflorestamento. Entretanto, foi observada uma confusão entre as classes de café e citrus.

Servello et al. (2007) elaboraram um mapa de uso da terra de uma parte da região centro-sul do Paraná utilizando dados do sensor CCD do satélite CBERS-2 e o SIG SPRING. Foram consideradas as classes solo arenoso, solo avermelhado, área de pastagem, pastagem suja, agricultura, floresta em estágio secundário de sucessão, floresta em estágio avançado de sucessão e corpos d'água. A abordagem metodológica utilizada pelos

autores compreendeu segmentação por crescimento de regiões e classificação supervisionada Battacharya, a partir da imagem fração sombra. O valor de *kappa* para a classificação final foi de 0,6675, demonstrando a possibilidade de uso da metodologia como ferramenta de diagnóstico e modelagem do meio físico.

Trabalho semelhante foi realizado por Tambosi et al. (2007), que fizeram uma análise comparativa de classificações a partir de imagens ETM+/Landsat e CCD/CBERS-2 para fins de mapeamento do uso e cobertura da terra, utilizando o classificador MAXVER e as bandas dos sensores. Nas classificações, foram consideradas as classes mata eucalipto, cana-de-açúcar, laranja, campos, corpos d'água, solo exposto, nuvens e sombra. Os coeficientes *kappa* obtidos ficaram próximos a 0,50 e as matrizes de confusão indicaram confusão entre determinadas classes. Pelos resultados semelhantes obtidos para os dois sensores, os autores sugerem uso das imagens CBERS como alternativa às imagens Landsat para esse fim.

4.2 Sensoriamento remoto

4.2.1 Definição

Sensoriamento remoto, de acordo com Lillesand e Kiefer (1994), é a ciência e a arte de se obter informações sobre um alvo (objeto, área ou fenômeno) por meio da análise de dados adquiridos por meio de um dispositivo que não esteja em contato com o alvo sob investigação.

De acordo com Novo (1992), os dispositivos de aquisição são sensores ou equipamentos capazes de coletar a energia eletromagnética proveniente do alvo, convertê-la em sinal passível de ser registrado e apresentá-lo em forma adequada à extração de informações.

A Figura 1 ilustra o processo de aquisição de dados de sensoriamento remoto e os elementos envolvidos, que incluem a fonte de energia, a propagação da energia através da atmosfera, as interações da energia com as características da superfície terrestre, a retransmissão da energia através da atmosfera e os sensores transportados por via aérea e/ou

satélites. Como resultado do processo de aquisição, tem-se os dados na forma de imagem e/ou digital.

Neste processo, a fonte, representada pelo Sol, emite energia através da atmosfera. Esta energia atinge o alvo, representado pelas diferentes coberturas da superfície terrestre, como vegetação, água, solo, etc., sendo que o alvo reflete e/ou absorve a energia. A energia refletida é transmitida através da atmosfera e registrada por um sensor remoto, que pode estar acoplado em aeronaves ou satélites. As informações registradas pelo sensor são processadas para posterior análise.

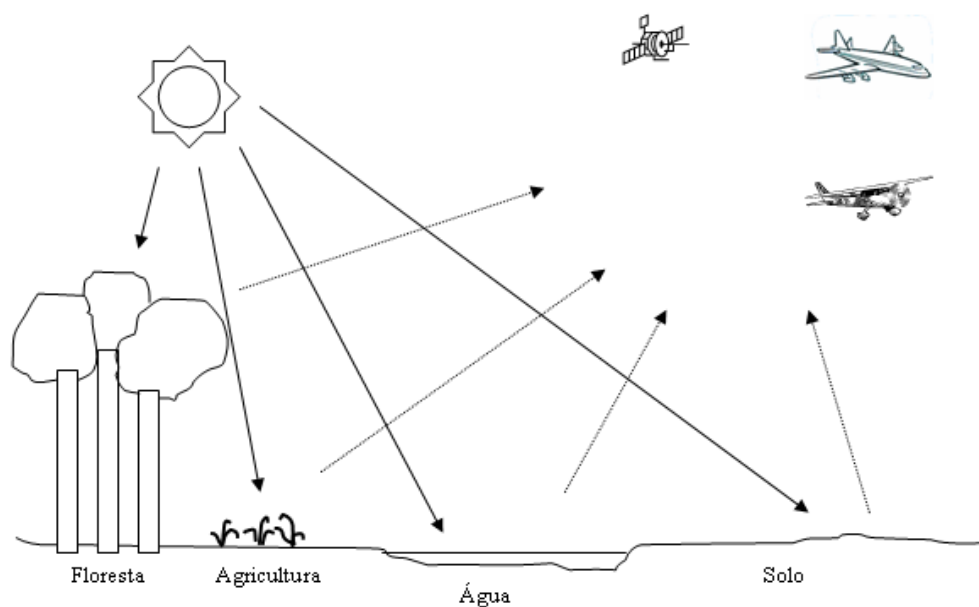


Figura 1 – Processo de aquisição de dados de sensoriamento remoto

O processo de análise dos dados envolve o exame dos dados usando vários recursos para interpretação e visualização no caso de imagens e/ou um computador para análise digital dos dados. Dados adicionais, como mapas de solo, estatísticas de safras ou dados obtidos em campo, entre outros, são usados no processo de análise a fim de extrair informação sobre a localização, o tipo, a extensão e as condições relativas ao objeto de estudo. Do processo de análise resultam mapas, tabelas e arquivos que podem ser combinados com

outras camadas de informação em um SIG que são utilizados pelos usuários em processos de tomada de decisão (LILLESAND; KIEFER, 1994).

4.2.2 Radiação eletromagnética

De acordo com Moreira (2001), a energia eletromagnética apresenta-se sob diversas formas, como luz visível, radiação infravermelha, ondas de rádio, radiação ultravioleta, raios-X, microondas, radiação gama, entre outras. O comportamento destas formas de energia é similar e está baseado na teoria ondulatória.

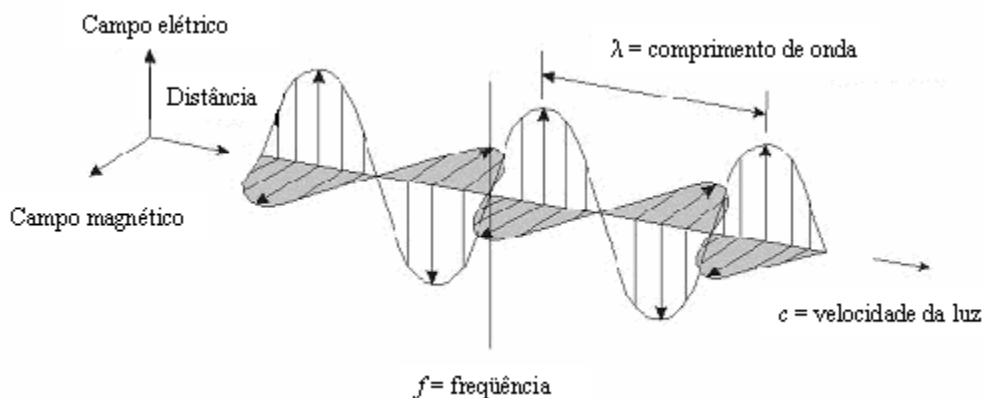
Segundo esta teoria, a aceleração de uma carga elétrica provoca perturbações no campo elétrico e magnético, que se propagam repetitivamente no vácuo. Estas perturbações são chamadas ondas eletromagnéticas. Assim, uma onda eletromagnética é uma oscilação do campo elétrico e magnético segundo um padrão harmônico de ondas. As ondas eletromagnéticas obedecem à equação geral:

$$c = f \cdot \lambda \quad (1)$$

onde c é a velocidade de propagação da onda eletromagnética, f é a frequência de onda e λ é o comprimento de onda (NOVO, 1992).

A velocidade de propagação da onda eletromagnética no vácuo é a velocidade da luz (3×10^8 m/s). A frequência de onda é diretamente proporcional à velocidade de propagação da radiação, mas a velocidade de propagação num dado meio é constante, pois é a velocidade da luz. A frequência f e o comprimento de onda λ para uma dada onda são inversamente proporcionais e cada qual pode ser usado para caracterizar uma onda de uma forma particular (LILLESAND; KIEFER, 1994; NOVO, 1992).

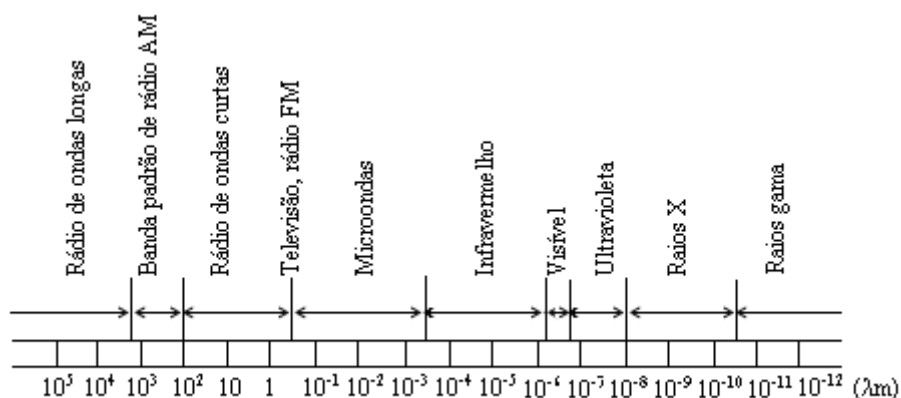
A Figura 2 representa esquematicamente uma onda eletromagnética, com os campos elétrico e magnético perpendiculares entre si e oscilando perpendicularmente à direção de propagação da onda. A distância entre um pico de onda e o próximo é o comprimento de onda (λ) e o número de picos passando por um ponto fixo por unidade de tempo é a frequência (f) (LILLESAND; KIEFER, 1994).



Fonte: Lillesand e Kiefer (1994)

Figura 2 – Esquema de propagação de uma onda eletromagnética

Em sensoriamento remoto, é muito comum caracterizar as ondas eletromagnéticas pela localização de seu comprimento de onda dentro do espectro eletromagnético (Figura 3). Conforme Moreira (2001), o espectro eletromagnético exibe o conjunto de todas as radiações de forma ordenada, em função do comprimento de onda.



Fonte: Moreira (2001)

Figura 3 – Espectro eletromagnético

Embora muitas características da radiação eletromagnética sejam mais facilmente descritas pela teoria ondulatória, outra teoria oferece o entendimento sobre como a energia eletromagnética interage com a matéria. Esta teoria – a teoria corpuscular – sugere que

a radiação eletromagnética é composta por muitas partículas discretas chamadas fótons ou quanta. A energia emitida por um quantum é dada pela Equação 2:

$$Q = h.f \quad (2)$$

onde Q é a energia de um quantum, h é a constante de Planck, igual a $6,626 \times 10^{-34}$ Js e f é a frequência (MOREIRA, 2001; NOVO, 1992).

Ao relacionar os modelos quântico e ondulatório do comportamento da radiação eletromagnética, substituindo f a partir da Equação 2, tem-se:

$$Q = \frac{hc}{\lambda} \quad (3)$$

donde se conclui que a energia de um quantum é inversamente proporcional ao comprimento de onda (LILLESAND; KIEFER, 1994; NOVO, 1992).

De acordo com esta teoria, a energia eletromagnética pode ser absorvida pela matéria em função de suas propriedades físico-químicas. Quando um elétron absorve energia, salta de um nível de energia para outro mais afastado do núcleo, tornando-se instável. Para retornar à estabilidade, o elétron emite a energia absorvida. Esta energia absorvida ou emitida pelo elétron é chamada de fóton (MOREIRA, 2001; NOVO, 1992).

A quantidade de energia que um objeto irradia é, entre outras coisas, uma função da temperatura superfície do objeto, sendo expressa pela Lei de Stefan-Boltzmann:

$$M = \sigma T^4 \quad (4)$$

onde M é a radiação total emitida de um material em Wm^{-2} , σ é a constante de Stefan-Boltzmann ($5,6697 \times 10^{-8} \text{ Wm}^{-2}\text{K}^{-4}$), e T é a temperatura absoluta (K) do material (LILLESAND; KIEFER, 1994).

O fenômeno de emissão dos corpos, inclusive do Sol, é explicado por meio do modelo do corpo negro. Um corpo negro é um radiador ideal hipotético que absorve totalmente e re-emite toda energia incidente sobre ele. Objetos reais, entretanto, somente se aproximam deste ideal, pois como a energia total emitida de um objeto varia com a temperatura, a distribuição espectral da energia emitida também varia (LILLESAND; KIEFER, 1994).

A Lei de Wien, expressa pela Equação 5, relaciona o comprimento de onda em que a curva de radiação de um corpo negro alcança um máximo e sua temperatura:

$$\lambda_m = \frac{A}{T} \quad (5)$$

onde λ_m é o comprimento de onda de máxima emitância espectral (μm), A é a constante de Wien igual a $2898 \mu\text{mK}$, e T a temperatura (K) (LILLESAND; KIEFER, 1994; MOREIRA, 2001).

Conforme Novo (1992), em sensoriamento remoto o Sol é a principal fonte de radiação eletromagnética. Entretanto, como toda matéria a uma temperatura absoluta acima de zero (-273^0 C ou 0 K) emite continuamente radiação eletromagnética, a superfície terrestre também é fonte de radiação, embora em magnitude e composição espectral diferentes da do Sol.

A emissão de energia do Sol é comparada à de um corpo negro cuja temperatura está em torno de 6000 K , enquanto que a temperatura do ambiente terrestre está em torno de 300 K . O pico de emissão de energia eletromagnética do Sol está entre $0,4$ e $0,7 \mu\text{m}$, enquanto que o da Terra está em torno de $9 \mu\text{m}$, o que pode ser demonstrado pela Lei de Wien (Equação 5) (NOVO, 1992).

Desta forma, segundo Novo (1992), o Sol e a Terra são duas importantes fontes naturais e contínuas de radiação eletromagnética para o sensoriamento remoto, considerando que os sensores adquirem dados relativos à energia refletida pelos diversos objetos da superfície terrestre. Entretanto, outros tipos de sensores podem ser usados

em sensoriamento remoto, os quais possuem sua própria fonte de radiação que interage com a superfície terrestre.

4.2.3 Interações da energia com a atmosfera

De acordo com Lillesand e Kiefer (1994), toda radiação detectada por sensores remotos, independentemente de sua origem, atravessa a atmosfera, desde a sua origem até o sensor. O comprimento do caminho percorrido pela energia em sua jornada desde a origem até o sensor varia muito com o sistema sensor usado, constituindo em um fator que afeta a intensidade e a composição espectral da radiação avaliada por um determinado sistema sensor.

Segundo Moreira (2001), isto ocorre devido à natureza complexa da atmosfera, constituindo-se de várias zonas ou camadas, com diversos gases em sua composição. Há também na atmosfera a presença de partículas dispersas como poeira, gotas de chuva, nuvens, entre outras. Os mecanismos atmosféricos que ocorrem devido a estes fatores são denominados espalhamento e absorção.

O espalhamento atmosférico é um processo físico que resulta da obstrução das ondas eletromagnéticas por partículas existentes nas suas trajetórias. Essa obstrução pode ocorrer tanto em relação à energia incidente quanto à energia refletida. A intensidade e a direção do espalhamento dependem fortemente da razão entre os diâmetros das partículas presentes na atmosfera e do comprimento de onda da energia eletromagnética incidente ou refletida (MOREIRA, 2001).

São manifestações do espalhamento atmosférico: o céu azul, os tons do laranja e do vermelho ao nascer e ao pôr-do-sol, a aparência branca das nuvens e também a aparência esbranquiçada do céu quando há grande concentração de aerossóis (MOREIRA, 2001).

Segundo Lillesand e Kiefer (1994), em contraste com o espalhamento, a absorção atmosférica resulta em efetiva perda de energia para os elementos atmosféricos. Os principais elementos responsáveis pela absorção da radiação são o vapor d'água, o dióxido de carbono e o ozônio, entre outros. As regiões do espectro eletromagnético para as quais a

atmosfera não absorve ou pouco absorve a radiação são denominadas “janelas atmosféricas”. Desta forma, a aquisição de dados de sensoriamento remoto está limitada a essas regiões espectrais não bloqueadas para a radiação eletromagnética.

4.2.4 Interações da energia com a superfície terrestre e sua resposta espectral

Quando a energia eletromagnética incide sobre a superfície terrestre, ocorrem diferentes interações dependendo das características dos alvos. A energia incidente sobre os alvos pode ser refletida, absorvida e/ou transmitida, e a relação entre estas interações é expressa pela Equação 6, baseada no princípio da conservação de energia:

$$E_I(\lambda) = E_R(\lambda) + E_A(\lambda) + E_T(\lambda) \quad (6)$$

onde E_I é a energia incidente, E_R é a energia refletida, E_A é a energia absorvida, E_T é a energia transmitida, estando todas em função do comprimento de onda λ (LILLESAND; KIEFER, 1994).

Como as proporções de energia refletida, absorvida e transmitida variam de acordo com as características da superfície, é possível a distinção entre diferentes características presentes em uma imagem. A maioria dos sistemas de sensoriamento remoto opera em regiões do espectro eletromagnético nas quais predomina a energia refletida. Desta forma, o conhecimento das propriedades de reflectância dos objetos presentes na superfície terrestre é fundamental (LILLESAND; KIEFER, 1994).

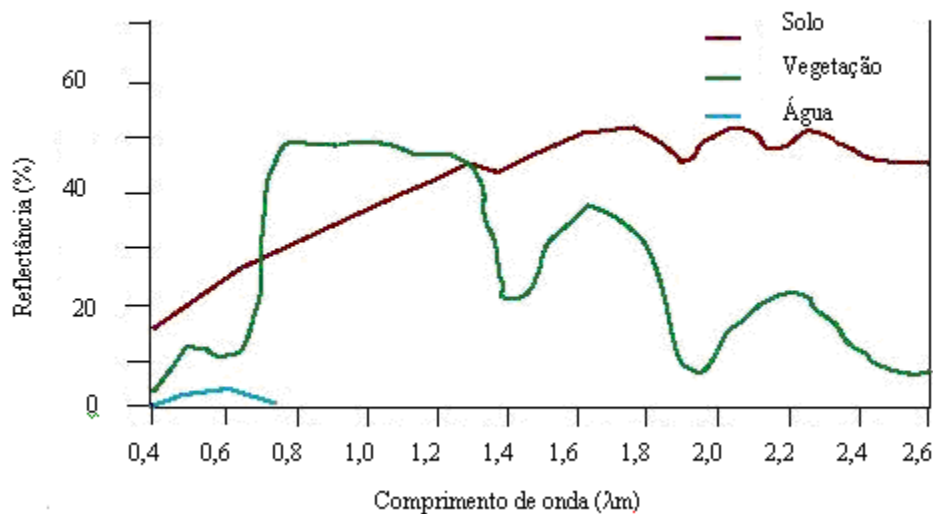
Segundo Lillesand e Kiefer (1994), a reflectância dos alvos da superfície terrestre pode ser quantificada por meio da medida da porção de energia incidente que é refletida. Esta medida, denominada reflectância espectral ρ_λ , é uma função do comprimento de onda e matematicamente definida como:

$$\rho_\lambda = \frac{E_R(\lambda)}{E_I(\lambda)} \times 100 \quad (7)$$

onde $E_R(\lambda)$ é a energia de comprimento de onda λ refletida do objeto, e $E_I(\lambda)$ é a energia de comprimento de onda λ incidente no objeto.

Conforme Lillesand e Kiefer (1994), o gráfico que mostra a resposta espectral de determinado objeto para os diferentes comprimentos de onda do espectro eletromagnético é denominado curva espectral. Esse gráfico é de fundamental importância para a escolha da região do espectro sobre a qual se pretende adquirir os dados de sensoriamento remoto para uma determinada aplicação.

A Figura 4 apresenta as curvas de reflectância espectral de três objetos típicos da superfície terrestre: vegetação verde saudável, solo exposto seco e água límpida. As linhas representam as curvas de reflectância média calculada a partir de uma grande amostragem de características (LILLESAND; KIEFER, 1994).



Fonte: Lillesand e Kiefer (1994)

Figura 4 – Curvas de reflectância espectral típicas para vegetação, solo e água

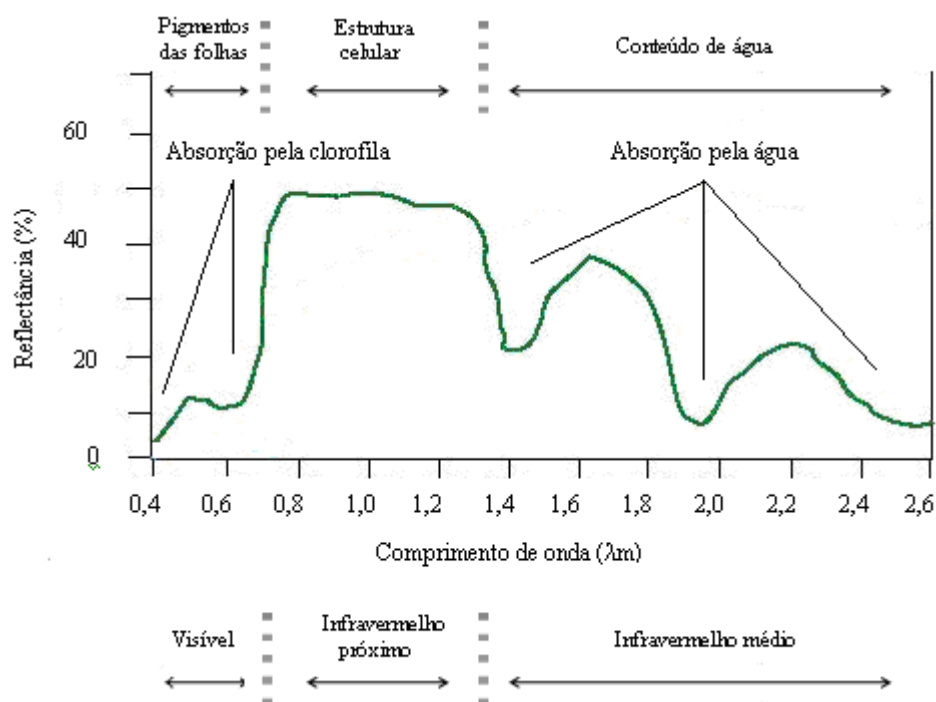
Conforme mostra a Figura 4, a água límpida em seu estado líquido apresenta baixa reflectância entre 0,38 e 0,7 μm – em torno de 5% – absorvendo toda a radiação acima de 0,7 μm. De acordo com Moreira (2001), a presença de material suspenso na água provoca mudanças nos seus valores de reflectância. A presença de material orgânico, por

exemplo, diminui a reflectância na região do visível. Outras características, como pH, presença de sais, partículas suspensas resultantes de erosão, entre outras, podem ser correlacionadas com a reflectância observada. A água na forma gasosa apresenta reflectância elevada – em torno de 70% – e, na forma de neve, ainda maior.

Considerando a reflectância espectral do solo, esta apresenta uma variação que vai de 20 a pouco mais de 55%, com alguns picos e vales em certas faixas espectrais. Conforme Lillesand e Kiefer (1994), alguns dos fatores que afetam a reflectância do solo são a composição, a umidade, a textura, a rugosidade, a presença de óxido de ferro e de matéria orgânica. Esses fatores são complexos, variáveis e inter-relacionados. Segundo Moreira (2001), muitos estudos têm mostrado correlações existentes entre certas características do solo e sua reflectância, o que demonstra o potencial do sensoriamento remoto como ferramenta para o levantamento e reconhecimento dos solos.

A curva de reflectância espectral da vegetação verde saudável manifesta-se em picos e vales. Os principais fatores que influenciam a reflectância da vegetação são os pigmentos, o conteúdo de água e as estruturas celulares presentes nas folhas. A reflectância de uma folha de vegetação verde e sadia, considerando os fatores de influência anteriormente citados, é mostrada na Figura 5. A faixa do espectro eletromagnético considera os comprimentos de onda compreendidos entre 0,4 e 3,0 μm , denominado espectro refletivo (MOREIRA, 2001).

Na faixa do visível, de acordo com Lillesand e Kiefer (1994), ocorre a absorção pela clorofila em pontos em torno de 0,45 e 0,67 μm . A absorção é alta nas bandas azul e vermelho, enquanto que a reflexão é alta no verde, fazendo com que nossos olhos percebam a vegetação sadia como verde. Na porção do infravermelho médio do espectro eletromagnético, a energia incidente na vegetação é essencialmente absorvida ou refletida, quase não havendo transmissão. Considerando a Figura 5, os vales ocorrem nos pontos 1,4, 1,9 e 2,5 μm devido à presença de água nas folhas, que propicia a absorção destes comprimentos de onda.



Fonte: Moreira (2001)

Figura 5 – Curva de reflectância espectral da vegetação verde e sadia

Na porção do infravermelho próximo do espectro eletromagnético, a reflectância da vegetação verde sadia aumenta sensivelmente, podendo chegar a 50%. De acordo com Lillesand e Kiefer (1994), a maior parte da energia remanescente é transmitida, já que a absorção nesta região espectral é mínima. A reflectância nesse intervalo resulta principalmente da estrutura interna das folhas. Como a estrutura celular é altamente variável entre espécies vegetais, a medida da reflectância neste intervalo permite a discriminação entre espécies.

Moreira (2001) descreveu com maior detalhe as questões que envolvem a interação da energia eletromagnética com a vegetação. Segundo o autor, fatores morfológicos e fisiológicos da planta estão diretamente envolvidos na interceptação e na absorção da radiação fotossinteticamente ativa. Os fatores morfológicos mais importantes dizem respeito à organização espacial das folhas, e os fatores fisiológicos incluem idade da planta, déficit hídrico, a estrutura interna das folhas, deficiência em nutrientes e conteúdo de água nas folhas.

É importante salientar que as colocações feitas anteriormente sobre o comportamento espectral da vegetação dizem respeito à folha. Quando se pretende utilizar o sensoriamento remoto para obter informações a respeito da cobertura vegetal de uma região da superfície terrestre, é preciso levar em consideração a interação da energia eletromagnética com múltiplas camadas de folhas de um dossel vegetativo (MOREIRA, 2001).

De acordo com Moreira (2001), dossel vegetativo é o conjunto de todas as copas da vegetação, numa determinada área, independente da espécie. Um dossel vegetativo pode ser homogêneo, como uma cultura agrícola, por exemplo, ou heterogêneo, como uma mata natural.

Um dossel vegetativo em condições normais, com as suas múltiplas camadas de folhas, propicia um aumento na reflectância espectral na porção do infravermelho próximo. Por outro lado, como descreve Moreira (2001) com base em trabalhos realizados, são muitos os fatores que interferem na resposta espectral de dosséis. Entre estes, está a morfologia das folhas que compõem o dossel, a orientação e distribuição das fileiras, o teor de água nas plantas e no solo, a condição fitossanitária, o estágio de desenvolvimento da cultura, ângulos zenital e azimutal do Sol, além de outros.

4.2.5 Sistemas sensores

Os sistemas sensores para sensoriamento remoto são dispositivos capazes de detectar e registrar a radiação eletromagnética em determinada faixa do espectro eletromagnético, gerando informações que possam ser transformadas num produto passível de interpretação como imagem, gráfico ou tabela (MOREIRA, 2001).

De acordo com a literatura (MOREIRA, 2001; NOVO, 1992; LILLESAND; KIEFER, 1994), existem muitas formas de classificar e re-classificar os sistemas sensores, levando em conta as diferentes características que estes apresentam. De maneira geral, as formas mais comuns de classificação levam em consideração três aspectos: a fonte de radiação utilizada pelo sistema sensor, o princípio de funcionamento e o tipo de produto gerado.

Quanto à fonte, segundo Moreira (2001) e Novo (1992), podem ser passivos ou ativos. Os sensores passivos detectam a radiação solar ou a radiação emitida pelos objetos da superfície, ou seja, dependem de uma fonte externa para operar. Constituem exemplos desta categoria o sensor TM (*Thematic Mapper*) do satélite Landsat e o sensor CCD (*Charge-coupled Device*) do satélite CBERS, entre outros.

Os sensores ativos, por outro lado, possuem uma fonte de radiação própria e não dependem de uma fonte externa. Estes sensores emitem radiação em determinada faixa espectral, que interage com os alvos da superfície, captando então a energia refletida pelos alvos. Exemplos de sensores ativos são os radares, os radiômetros de microondas e câmeras fotográficas que utilizam “flash”, entre outros (MOREIRA, 2001; NOVO, 1992).

Outra forma comum de classificação dos sistemas sensores ocorre em função do princípio de funcionamento. De acordo com Moreira (2001), os sistemas sensores de não-varredura (*framing systems*) registram a radiação refletida de uma área da superfície terrestre em sua totalidade num mesmo instante. Nos sistemas de varredura (*scanning systems*), a imagem da cena é formada pela aquisição seqüencial de imagens elementares do terreno ou “elementos de resolução”, também chamados *pixels*.

De acordo com Novo (1992), os sistemas sensores podem também ser agrupados em duas categorias quanto ao tipo de transformação sofrida pela radiação detectada. Os sistemas sensores não-imageadores têm como saída dados na forma de dígitos e gráficos, como é o caso de alguns tipos de radiômetros que fornecem informações detalhadas sobre o comportamento espectral dos alvos. Os sistemas sensores imageadores fornecem uma imagem da superfície observada, com informações sobre a variação espacial da resposta espectral dos alvos. Nesta categoria estão os sistemas fotográficos, os sistemas eletro-ópticos e os radares de visada lateral.

De acordo com Lillesand e Kiefer (1994), a detecção de energia eletromagnética pode ser realizada fotograficamente ou eletronicamente. O processo de fotografia usa reações químicas na superfície de um filme sensível à luz para detectar as variações de energia dentro de uma cena. Os sensores eletro-ópticos e radares, por sua vez, geram um sinal elétrico que corresponde às variações de energia na cena original.

Embora sejam consideravelmente mais complexos, os sistemas não-fotográficos possuem a vantagem de operar numa ampla faixa do espectro eletromagnético, que se estende do ultravioleta às microondas. São capazes, portanto, de operar durante o dia e à noite, como é o caso dos imageadores que atuam na faixa do infravermelho termal. Além disso, os radares podem operar em condições de nebulosidade, uma vez que as nuvens são transparentes na faixa de microondas (NOVO, 1992).

Para Lillesand e Kiefer (1994), a principal vantagem dos sistemas não-fotográficos é a aquisição de dados na forma de sinais elétricos passíveis de transmissão eletrônica ou à distância. Estes dados podem também ser facilmente digitalizados e analisados por meio de técnicas computacionais, de forma automatizada.

De acordo com Moreira (2001), as características dos sistemas sensores imageadores não-fotográficos são expressas em função de quatro domínios de resolução: espectral, espacial ou geométrica, temporal e radiométrica.

Segundo Novo (1992), a resolução espectral de um sensor refere-se à largura de faixa ou banda espectral na qual ele opera. Quanto menor a faixa, melhor a resolução espectral ou o poder de discriminação do sensor. Um sistema sensor pode operar em várias faixas ou bandas espectrais, as quais podem ou não apresentar a mesma resolução espectral. Os objetivos de utilização de um sistema sensor determinam a quantidade e a largura das faixas espectrais nas quais ele opera.

A resolução espacial ou geométrica, de acordo com Moreira (2001), expressa a capacidade que um sensor tem de distinguir objetos espacialmente próximos, ou ainda, a menor área de terreno que o sensor pode individualizar. Esta medida, definida pelo campo de instantâneo de visada ou IFOV (*Instantaneous Field of View*), tem papel importante na interpretação e análise de imagens, pois está relacionada ao nível de detalhe das informações adquiridas pelo sensor.

A resolução temporal, para Moreira (2001), é definida em função da plataforma na qual o sensor está colocado. Considerando os sensores orbitais, a resolução temporal indica o intervalo de tempo que o satélite leva para voltar a recobrir a área de interesse, que está diretamente relacionado à largura da faixa imageada no solo. Quanto maior a largura da faixa, menor o intervalo de tempo de cobertura.

Em estudos da vegetação, entre outros, a resolução temporal é de fundamental importância por permitir um acompanhamento dinâmico dos alvos na superfície terrestre. O sensor CCD/CBERS-2 possui uma resolução temporal de 26 dias, enquanto que a do sensor TM/Landsat é de 16 dias.

Para definir a resolução radiométrica, é importante destacar que uma imagem de sensoriamento remoto digital é composta por um conjunto de elementos denominados *pixels* dispostos na forma de uma matriz bidimensional. Cada *pixel* representa uma porção da superfície terrestre, e o conjunto de *pixels* corresponde à área total coberta pela imagem. A cada *pixel* é associado um valor de intensidade denominado número digital (DN), que representa a medida física da quantidade de energia eletromagnética refletida ou emitida pelos alvos e detectada pelo sensor (radiância). O número digital é armazenado com uma quantidade finita de bits, e o número de bits utilizados para armazenar uma imagem digital expressa a resolução radiométrica (LILLESAND; KIEFER, 1994).

Desta forma, segundo Moreira (2001), a resolução radiométrica de um sensor indica a quantidade máxima de níveis de cinza que podem ser utilizados para representar uma imagem, que depende do sistema de gravação do sensor. Para um sensor que possui resolução radiométrica de 8 bits, por exemplo, serão usados $2^8=256$ níveis de cinza para representar a imagem, onde o valor zero é associado à cor preta e o valor 255 à cor branca.

Além das características dos sistemas sensores anteriormente descritas, outro fator interfere na qualidade e na intensidade do sinal, assim como na forma de registro e análise dos dados (NOVO, 1992). Este fator diz respeito ao nível de aquisição dos dados, que está diretamente relacionado à altura do sensor em relação aos alvos.

De acordo com Novo (1992), os níveis de aquisição são genericamente chamados de: nível de laboratório/campo, nível de aeronave e nível orbital. No nível de laboratório/campo, o sensor é fixado em mastros, barcos ou outro meio físico para fixação. No nível orbital, os sensores são colocados a bordo de satélites artificiais.

Em sensoriamento remoto, o nível de aquisição, juntamente com o campo instantâneo de visada do sensor, interferem diretamente na resolução espacial da imagem obtida. Ao nível de laboratório as áreas analisadas são pequenas, sendo possível, por

exemplo, medir a resposta espectral de uma folha, enquanto que no nível orbital, mede-se a resposta espectral do dossel (NOVO, 1992).

Quanto mais distante dos alvos se encontra o sensor, mais complexa é a caracterização espectral. No nível de laboratório, é possível gerar dados sob condições controladas, tanto do sensor como da atmosfera presente entre o alvo e o sensor (NOVO, 1992).

Ao nível de aeronave e mais intensamente ao nível orbital, as interferências ambientais estão presentes, determinando formas diferenciadas de análise dos dados e, conseqüentemente, no nível de informação deles derivada. Nesses níveis é possível trabalhar com áreas maiores, mas nem todos os objetos são detectados individualmente. A energia registrada resulta da integração da resposta espectral de diferentes objetos (NOVO, 1992).

Para Moreira (2001), a escolha do sistema sensor, num determinado nível de coleta, depende, sobretudo, de fatores relacionados ao objetivo da pesquisa, ao tamanho da área imageada, à disponibilidade de equipamentos e ao custo e precisão dos resultados obtidos.

4.2.6 Câmeras imageadoras dos satélites CBERS-2 e CBERS-2B

O Programa CBERS surgiu de uma parceria entre o Brasil e a China no setor técnico-científico espacial a fim de permitir o monitoramento de suas extensas áreas despovoadas e vastos recursos naturais, além dos grandes potenciais agrícola e ambiental, permitindo uma importante autonomia neste segmento (INPE, 2007).

Com o sucesso do programa, que se concretizou com o lançamento dos satélites CBERS-1, em outubro de 1999, e CBERS-2, em outubro de 2003, o acordo foi expandido com a inclusão dos satélites CBERS-3 e CBERS-4. Diante de um possível final de vida útil do CBERS-2 antes de 2009, data prevista para o lançamento do CBERS-3, foi construído o CBERS-2B, lançado em setembro de 2007 (INPE, 2007).

No Brasil, o INPE, que projetou e construiu os satélites, cuida também da sua operação além de distribuir os dados gratuitamente aos usuários e pela internet (INPE, 2007).

Os satélites CBERS-2 e CBERS-2B são semelhantes, possuindo três tipos de sistemas sensores de coleta de dados de sensoriamento remoto para recursos naturais. O CBERS-2 é composto pelos sistemas ópticos: CCD (Câmera Imageadora de Alta Resolução), IRMSS (Imageador por Varredura de Média Resolução) e WFI (Câmera Imageadora de Amplo Campo de Visada). No CBERS-2B, o sistema IRMSS é substituído pelo HRC (Câmera Pancromática de Alta Resolução) (INPE, 2007).

Os satélites da família CBERS estão inseridos em uma órbita síncrona com o Sol, a uma altitude de 778 km, de modo a recobrir quatorze faixas da superfície terrestre por dia. Esta configuração de órbita permite que o satélite cruze a linha do Equador às 10 h e 30 min da manhã, horário local, provendo as mesmas condições de iluminação solar para efeitos de comparação entre imagens adquiridas em dias diferentes (INPE, 2007).

O sensor WFI produz imagens de uma faixa de 890 km de largura, permitindo a obtenção de imagens com resolução espacial de 260 m. No período aproximado de 5 dias é possível obter uma cobertura completa do globo terrestre. O sensor opera em duas faixas espectrais do espectro eletromagnético, conforme descrito na Tabela 1 (INPE, 2007).

Tabela 1 – Bandas espectrais do sensor WFI (CBERS-2 e CBERS-2B)

BANDAS ESPECTRAIS (μm)	REGIÃO DO ESPECTRO
0,63 – 0,69	Vermelho
0,77 – 0,89	Infravermelho

O sensor CCD fornece imagens de uma faixa de 113 km de largura, com uma resolução espacial de 20 m. Este sistema sensor possui a capacidade de orientar seu campo de visada dentro de $\pm 32^\circ$, o que permite a obtenção de imagens estereoscópicas de uma determinada região. Além disso, qualquer fenômeno detectado pelo sensor WFI pode ser focalizado pela câmera CCD por meio de seu campo de visada, dentro de três dias, no

máximo. O sistema CCD opera em cinco faixas espectrais, conforme descrição na Tabela 2, e possui uma resolução temporal de 26 dias (INPE, 2007).

Tabela 2 – Bandas espectrais do sensor CCD (CBERS-2 e CBERS-2B)

BANDAS ESPECTRAIS (μm)	REGIÃO DO ESPECTRO
0,51 – 0,73	Pancromática
0,45 – 0,52	Azul
0,52 – 0,59	Verde
0,63 – 0,69	Vermelho
0,77 – 0,89	Infravermelho próximo

O sensor IRMSS é uma câmera de varredura que opera em quatro faixas espectrais do espectro magnético, desde o visível até o infravermelho termal (Tabela 3). Este sensor produz imagens de uma faixa de 120 km de largura com uma resolução espacial de 80 m, sendo 160 m no canal termal. Em vinte e seis dias obtém-se uma cobertura completa da Terra, que pode ser correlacionada com aquela obtida pelo sensor CCD, que possui a mesma resolução temporal (INPE, 2007).

Tabela 3 – Bandas espectrais do sensor IRMSS (CBERS-2)

BANDAS ESPECTRAIS (μm)	REGIÃO DO ESPECTRO
0,50 – 1,10	Pancromática
1,55 – 1,75	Infravermelho médio
2,08 – 2,35	Infravermelho médio
10,40 – 12,50	Infravermelho termal

O sensor HRC opera numa única faixa espectral, que cobre o visível e parte do infravermelho próximo (Tabela 4). Produz imagens de uma faixa de 27 km de largura com uma resolução de 2,7 m, permitindo a observação dos alvos com grande detalhamento.

São necessários cinco ciclos de 26 dias, ao todo 130 dias, para que os 113 km padrão do sensor CCD sejam cobertos pelo HRC (INPE, 2007).

Tabela 4 – Banda espectral do sensor HRC (CBERS-2B)

BANDA ESPECTRAL (μm)	REGIÃO DO ESPECTRO
0,50 – 0,80	Pancromática

4.3 Processamento de imagens digitais em sensoriamento remoto

O processamento de imagens digitais, de acordo com Lillesand e Kiefer (1994), abrange técnicas em diferentes contextos: pré-processamento, realce e classificação. As técnicas de pré-processamento têm por objetivo a retificação e a restauração das distorções dos dados da imagem originadas durante o processo de aquisição. Essas técnicas referem-se às rotinas de correção geométrica e radiométrica das imagens, correções quanto aos efeitos atmosféricos e eliminação de ruídos.

As técnicas de realce de imagens visam melhorar a qualidade visual das imagens, aumentando a distinção entre as características da cena. De um modo geral, essas técnicas abrangem: manipulação de contraste, filtros e a integração de bandas para destacar objetos de interesse ou reduzir a dimensionalidade dos dados para posterior classificação (LILLESAND; KIEFER, 1994).

As técnicas de classificação conduzem ao mapeamento ou reconhecimento de características da superfície terrestre por meio de um processo de decisão que atribui *pixels* de uma imagem a determinadas classes (LILLESAND; KIEFER, 1994).

Nesta seção, são abordadas as principais técnicas de processamento de imagens digitais de sensoriamento remoto dentro do escopo deste trabalho envolvendo as etapas de pré-processamento e de realce. As técnicas de classificação de imagens são abordadas na próxima seção.

4.3.1 Correção geométrica

A correção geométrica tem por objetivo compensar as distorções que ocorrem nas imagens de sensoriamento remoto de modo que estas adquiram a integridade geométrica de um mapa. As principais fontes de erros são as movimentações da plataforma do sensor e a curvatura da Terra (LILLESAND; KIEFER, 1994).

De acordo com Lillesand e Kiefer (1994), o processo de correção geométrica é normalmente realizado em duas etapas. Na primeira, são consideradas as distorções sistemáticas devido à movimentação da plataforma do sensor. Essas distorções são corrigidas facilmente pela aplicação de fórmulas matemáticas.

Na segunda etapa, são corrigidas as distorções aleatórias e as distorções sistemáticas residuais desconhecidas pela análise de pontos de controle no terreno bem distribuídos. Essa segunda etapa é também conhecida por registro da imagem, cujo objetivo é rearranjar os *pixels* da imagem de acordo com determinado sistema de projeção cartográfica. Para a reamostragem, são necessários pontos de controle no terreno facilmente identificáveis na base cartográfica e na cena a ser corrigida geometricamente (LILLESAND; KIEFER, 1994).

Os pontos de controle são localizados na imagem distorcida por suas coordenadas (x, y) e, na imagem base, por suas coordenadas geográficas (latitude, longitude). As coordenadas dos pontos de controle podem também ser obtidas diretamente por meio de um aparelho GPS. Os valores dos pontos de controle são, então, submetidos a um processo de regressão pelo método dos mínimos quadrados para a determinação da função que irá mapear as coordenadas da imagem distorcida para suas respectivas posições geográficas por meio de reamostragem (NOVO, 1992).

O processo de reamostragem transforma as coordenadas de cada elemento da matriz de saída (corrigida geometricamente) para determinar sua localização correspondente na matriz de entrada (imagem distorcida original). Este processo envolve também a determinação do número digital (DN) atribuído a cada elemento da matriz de saída (LILLESAND; KIEFER, 1994).

Há diversos métodos que são utilizados para o processo de reamostragem, como alocação de vizinho mais próximo (*nearest neighbour*), interpolação bilinear e convolução cúbica, cada qual com suas vantagens e desvantagens (NOVO, 1992).

Segundo o INPE (2007), as imagens das câmeras dos satélites CBERS-2 e CBERS-2B disponibilizadas pelo catálogo de imagens possuem correção geométrica de sistema. Entretanto, devem passar por um processo externo de georreferenciamento para eliminar o erro de posicionamento, permitindo refinar o erro interno. Após a eliminação do erro de posicionamento, o erro interno é o erro residual quando se tenta sobrepor a imagem a outros dados georreferenciados, garantindo uma boa sobreposição.

4.3.2 Correção radiométrica

A medida da radiância de uma cena é influenciada pelo tipo de sensor e também por outros fatores, como as condições atmosféricas, as trocas na iluminação, entre outros. Como são muitos os fatores que influenciam a medida da radiância por um sistema sensor, os procedimentos de correção radiométrica são variados e dependem diretamente da aplicação a ser realizada (LILLESAND; KIEFER, 1994).

Em aplicações de sensoriamento remoto nas regiões do espectro do visível e do infravermelho próximo, é freqüentemente desejável gerar mosaicos de imagens tomadas em diferentes épocas ou estudar as trocas na reflectância de características terrestres em diferentes épocas ou localizações. Nesses casos, é necessário aplicar correções da elevação do Sol e da distância do Sol à Terra. Na primeira correção, os diferentes ângulos de iluminação solar são normalizados e, na segunda, a distância da terra ao Sol é normalizada em função das suas trocas sazonais (LILLESAND; KIEFER, 1994).

Outro procedimento comum na correção radiométrica de imagens digitais é a redução dos efeitos atmosféricos sobre os valores de radiância registrados para uma cena, o que pode ser feito por meio de diversos métodos, que variam em sofisticação e conseqüente custo computacional. Um método muito simples consiste em observar a radiância registrada em áreas onde a reflectância é essencialmente zero, como em lagos de água limpa e áreas de sombra. Os sinais registrados acima de zero para essas regiões indicam o efeito

atmosférico, e seu valor deve ser subtraído de todos os *pixels* da imagem naquela banda (NOVO, 1992). Este método de correção atmosférica pelo *pixel* escuro foi proposto por Chavez (1988) e deve ser aplicado a cada banda espectral.

Segundo Lillesand e Kiefer (1994), a conversão de números digitais (DN) em dados físicos, como radiância absoluta e reflectância, é outro procedimento radiométrico comum em muitas aplicações. Este tipo de conversão é essencial na comparação de medidas de reflectância de diferentes sensores, ou no desenvolvimento de modelos matemáticos que relacionam dados físicos da imagem com medidas quantitativas dos objetos. O trabalho de Markham e Barker (1986) apresenta uma metodologia para realizar este tipo de conversão usando parâmetros de calibração específicos para cada sensor.

Ponzoni e Shimabukuro (2007) destacaram a importância da transformação de números digitais para valores de reflectância aparente a fim de permitir a caracterização espectral de objetos em uma mesma escala radiométrica nas diferentes bandas. Da mesma forma, os autores destacaram a sua importância para a geração das imagens resultantes da aplicação de índices de vegetação de modo a se obter valores comparáveis com os de trabalhos disponíveis na literatura.

O INPE tem realizado estudos no sentido de avaliar a qualidade radiométrica do satélite CBERS-2 e também de apresentar a metodologia e os respectivos coeficientes de calibração absoluta da câmera CCD/CBERS-2. Resultados desses estudos podem ser vistos na literatura (FONSECA et al., 2004; PONZONI et al., 2005; PONZONI et al., 2006).

4.3.3 Eliminação de ruído

De acordo com Lillesand e Kiefer (1994), o ruído em uma imagem digital é um distúrbio indesejado nos dados da imagem causado pelas limitações do sensor, pela digitalização do sinal ou pelo processo de gravação dos dados. A presença de ruído em uma imagem digital pode degradar ou mascarar totalmente a informação radiométrica verdadeira desta imagem. Assim, a remoção de ruído tem por objetivo recuperar uma imagem

para aproximá-la da cena original tanto quanto possível, o que é de fundamental importância para as etapas seguintes de melhoramento e classificação.

Os procedimentos de recuperação variam de acordo com a natureza do ruído, ou seja, se é periódico, aleatório ou isolado. Schowengerdt (1983) descreve métodos como os filtros passa-baixa e mediana, enquanto que Lillesand e Kiefer (1994) abordam os procedimentos de ajuste de histograma e de comparação de cada *pixel* com sua vizinhança, sendo que neste último uma máscara é aplicada a todos os *pixels* da imagem pelo processo de convolução.

Como as técnicas de remoção de ruído acarretam alteração nos dados, a sua aplicação descuidada pode levar à degradação do sinal original como, por exemplo, diminuição de informação sobre o relevo de uma cena, causada pela suavização ou redução do contraste. Desta forma, é importante que o usuário conheça a natureza dos dados de forma a selecionar as técnicas mais adequadas ao seu objetivo (NOVO, 1992).

4.3.4 Manipulação de contraste

Para Schowengerdt (1983), a manipulação de contraste é uma transformação radiométrica *pixel-a-pixel* que visa melhorar a discriminação visual de características da cena com baixo contraste. Cada nível de cinza de *pixel* é substituído por uma transformação específica, sem considerar os níveis de cinza dos *pixels* vizinhos.

O primeiro passo na manipulação de contraste de uma imagem é a análise de seu histograma. O histograma descreve a distribuição estatística de níveis de cinza em uma imagem em termos da frequência de ocorrência de *pixels* para cada valor digital dentro do intervalo definido pela resolução radiométrica. No entanto, o histograma não contém informação sobre a distribuição espacial dos níveis de cinza na imagem (NOVO, 1992).

Segundo Novo (1992), os histogramas geralmente tendem a apresentar uma forma próxima a uma distribuição gaussiana, com um alongamento da curva na direção dos níveis de radiância mais altos.

Uma transformação linear simples é a ampliação de contraste (*contrast stretch*), que consiste na expansão do intervalo de níveis de cinza original, resultando em uma imagem com um contraste mais acentuado entre as características de interesse (NOVO, 1992).

No caso de um histograma assimétrico, utiliza-se a transformação linear por partes (*piecewise linear transformation*), que permite ampliar o contraste, reduzindo a assimetria e fazendo melhor uso do intervalo de níveis de cinza disponível (NOVO, 1992).

Outra técnica de manipulação de contraste, segundo Lillesand e Kiefer (1994), é a limiarização (*thresholding*). Nesta técnica, utiliza-se um limiar (nível de cinza) para segmentar a imagem em duas classes – uma cujos *pixels* possuem valores abaixo do limiar e outra cujos *pixels* possuem valores acima do limiar.

A aplicação da limiarização não tem por objetivo a melhora visual da imagem em si, mas é usada para vários fins. Um exemplo é a detecção de mudanças entre duas imagens multitemporais, processo descrito por Schowengerdt (1983). Gonzalez (2000) descreveu uma variedade de técnicas de limiarização comumente usadas na segmentação de imagens.

4.3.5 Filtragem espacial

A filtragem espacial é uma operação de realce e, da mesma forma que a manipulação de contraste, é uma transformação *pixel-a-pixel* de uma imagem. Entretanto, esta transformação não depende somente do nível de cinza do *pixel* sendo processado, mas também dos níveis de cinza dos *pixels* vizinhos. Assim, a filtragem espacial é uma operação dependente do contexto em que se insere determinado *pixel* (SCHOWENGERDT, 1983).

De acordo com Novo (1992), o processo de filtragem é realizado por meio da convolução de uma máscara, isto é, de uma matriz de dimensões 3x3, 5x5 ou 7x7, em geral, que se movimenta pela imagem modificando todos os valores dos *pixels* originais de acordo com os valores da imagem e os pesos da máscara.

Segundo Lillesand e Kiefer (1994), filtros do tipo passa-baixa realçam características de baixa frequência e suavizam os componentes de alta frequência de uma imagem, de forma a eliminar informações muito discrepantes que constituem, em geral,

ruídos. Como resultado, tem-se a suavização da imagem ou uma imagem mais homogênea em relação à imagem original. Entretanto, perde-se em nitidez e contraste. Ao contrário dos filtros passa-baixa, os filtros do tipo passa-alta realçam os detalhes da imagem, aumentando a nitidez ao destacar as transições entre diferentes regiões da imagem.

A operação de filtragem espacial é também utilizada na detecção de pontos, linhas e bordas. De acordo com Schowengerdt (1983), o realce produzido por um único filtro é predominantemente em uma direção. O realce de bordas em todas as direções pode ser obtido pela filtragem da imagem em duas direções ortogonais, em geral, horizontal e verticalmente, e combinação dos resultados pela função gradiente.

Nesta categoria, estão os operadores de Sobel, que são máscaras utilizadas para o cálculo do gradiente de uma imagem. Mais detalhes sobre a detecção de pontos, linhas e bordas podem ser encontradas em Gonzalez (2000).

4.3.6 Razão espectral

A razão espectral é uma operação de realce que resulta da divisão dos valores de reflectância de uma banda espectral pelos valores correspondentes de outra banda espectral. A reflectância relativa resultante da razão espectral entre bandas pode prover informação significativa para determinadas aplicações em sensoriamento remoto (SCHOTT, 1997).

De acordo com Lillesand e Kiefer (1994), a maior vantagem de imagens razão é que elas carregam características espectrais ou de cor independentemente de variações nas condições de iluminação da cena. Assim, um determinado tipo de vegetação que apresenta valores digitais diferentes em função da variação da topografia e conseqüentemente da iluminação, irá apresentar valores razão aproximadamente idênticos.

A utilidade de uma determinada razão espectral depende de características de reflectância dos alvos envolvidos e também da aplicação que se tem em mãos. A forma e o número de combinações de razões possíveis dependem da origem dos dados digitais, ou seja, para n bandas de dados o número é igual a $n(n-1)$ (LILLESAND; KIEFER, 1994).

4.3.7 Processamento da cor

De acordo com Lillesand e Kiefer (1994), imagens digitais são normalmente exibidas como composições coloridas usando as três cores primárias: vermelho, verde e azul. Este padrão é conhecido pela sigla RGB, de: *red, green, blue*. Para um vídeo com codificação de dados de 8 bits/*pixel*, o intervalo de níveis digitais possível para cada componente de cor vai de 0 a 255. Portanto, há 256^3 possíveis combinações de vermelho, verde e azul de níveis digitais que podem ser exibidos por este dispositivo. Em um vídeo com essa codificação, cada *pixel* pode ser representado por uma posição de coordenada tri-dimensional.

Um subconjunto de três bandas de uma imagem é usado para gerar uma composição colorida, associando-se cada banda a uma componente de cor. As combinações coloridas possíveis são muitas e a melhor escolha depende das características espectrais dos objetos de estudo e também do tipo de sensor. É possível também gerar composições coloridas a partir de conjuntos de três imagens razão, assim como, de outras composições, como as imagens geradas por meio da transformação de componentes principais (SCHOWENGERDT, 1983).

Uma composição de cor natural é obtida atribuindo-se as cores vermelho, verde e azul às respectivas bandas do vermelho, verde e azul, ou bandas 3, 2 e 1 do sensor CCD/CBERS-2. Em estudos da vegetação, é comum o uso da combinação cor-banda: R - infravermelho próximo, G - vermelho, B - verde. Nas composições coloridas é possível aplicar a ampliação de contraste pela manipulação de contraste em cada um dos três canais RGB (LILLESAND; KIEFER, 1994).

Uma alternativa para uma descrição de cor mais intuitiva do que combinações de um conjunto de cores primárias é o sistema intensidade-matiz-saturação (IHS), sigla originada dos termos *intensity-hue-saturation*. Esses atributos podem ser analisados e manipulados individualmente, ao contrário do sistema RGB, no qual os componentes estão intrinsecamente interligados. Além desta vantagem, o sistema IHS descreve a formação de cores de um modo mais próximo do modo pelo qual o sistema visual humano percebe as cores (SCHOWENGERDT, 1983).

A intensidade ou brilho se relaciona com medida da energia total em todos os comprimentos de onda. O matiz se relaciona com a medida do comprimento de onda médio ou dominante da luz refletida ou emitida, definindo a cor do objeto. A saturação ou pureza da cor expressa o intervalo ao redor do comprimento de onda dominante relativo à energia refletida ou emitida (LILLESAND; KIEFER, 1994).

Por meio do estabelecimento de uma relação espacial entre o espaço RGB e o espaço IHS, é possível realizar a transformação de componentes RGB em componentes IHS. Esta transformação, quando realizada antes do processamento, pode prover mais controle sobre o realce da cor. Após o processamento, os componentes IHS modificados são transformados de volta para o sistema RGB, para exibição (SCHOWENGERDT, 1983).

4.3.8 Transformação por componentes principais

Segundo Schott (1997), imagens geradas por dados digitais de bandas de vários comprimentos de onda muitas vezes são similares, contendo as mesmas informações. A alta correlação entre bandas não só aumenta o tempo de processamento como reduz a eficiência dos algoritmos de processamento. Operações de transformações em imagens são usadas para superar essas limitações. Essas transformações redefinem o espaço característico de forma que as características tornam-se mais descorrelacionadas.

A transformação mais comum é a transformação por componentes principais, sendo considerada também uma técnica de realce. Para Novo (1992), esta técnica consiste em criar um novo conjunto de dados em k dimensões, por meio da combinação linear das informações contidas em k canais.

Para canais de dados espectrais, a primeira componente principal contém a maior porcentagem de variância total da cena e representa o brilho. A segunda e as subsequentes componentes principais apresentam gradativamente uma porcentagem menor de variância, sendo que as últimas contêm principalmente ruído (SCHOTT, 1997).

Imagens resultantes da transformação por componentes principais podem ser usadas na classificação de imagens, melhorando a sua eficiência. Também é possível gerar composições coloridas a partir de três imagens componentes (NOVO, 1992).

4.3.9 Índices de vegetação

Relações entre as características da vegetação e dados de sensoriamento remoto são estabelecidas pelo uso de razões, diferenças, somas ou mesmo outras combinações entre bandas para produzir índices de vegetação. Segundo Ponzoni e Shimabukuro (2007), diversos índices de vegetação têm sido propostos na literatura com o objetivo de explorar as propriedades espectrais da vegetação, especialmente nas regiões do visível e do infravermelho próximo. Estes índices são relacionados a parâmetros biofísicos da cobertura vegetal, como biomassa e índice de área foliar, além de minimizarem os efeitos de iluminação da cena, declividade da superfície e geometria de aquisição.

Ponzoni e Shimabukuro (2007) detalharam diversos índices de vegetação, dentre os quais alguns são descritos a seguir. O índice de vegetação da razão simples (SR) é obtido pela Equação 8:

$$SR = \frac{\rho_{IVP}}{\rho_V} \quad (8)$$

onde ρ_{IVP} é a reflectância aparente no infravermelho próximo e ρ_V é a reflectância aparente no vermelho (JORDAN, 1969).

O índice de vegetação da diferença normalizada (NDVI), proposto por Rouse et al. (1973), corresponde à normalização da razão simples no intervalo -1 a +1. Trata-se de um índice amplamente usado em estudos de vegetação. O NDVI é dado pela Equação 9:

$$NDVI = \frac{\rho_{IVP} - \rho_V}{\rho_{IVP} + \rho_V} \quad (9)$$

No índice de vegetação ajustado para o solo (SAVI), proposto por Huete et al. (1985), é introduzida uma constante L que minimiza o efeito do solo. Segundo Huete (1988), os valores ótimos de L são: 1, para densidades baixas de vegetação; 0,5, para densidades médias; e 0,25, para densidades altas. Este índice é dado pela Equação 10:

$$SAVI = \frac{\rho_{IVP} - \rho_V}{\rho_{IVP} + \rho_V + L} \times (1 + L) \quad (10)$$

Pinty e Verstraete (1992) propuseram, para o monitoramento global da vegetação, o índice GEMI (Índice Global de Monitoramento Ambiental), concebido para minimizar a influência dos efeitos atmosféricos no valor final do índice. O cálculo deste índice é dado por:

$$GEMI = \eta(1 - 0,25\eta) \frac{\rho_V - 0,125}{1 - \rho_V} \quad (11)$$

onde:

$$\eta = \frac{2(\rho_{IVP}^2 - \rho_V^2) + 1,5\rho_{IVP} + 0,5\rho_V}{\rho_{IVP} + \rho_V + 0,5} \quad (12)$$

Liu (2006), em seu livro, também apresentou diversos índices de vegetação. Desta forma, é possível acrescentar à descrição anterior o índice de vegetação pela diferença (DVI), proposto por Richardson e Wiegand (1977), e o índice de vegetação transformado (TVI), proposto por Rouse et al. (1974).

O índice de vegetação pela diferença (DVI) infere a quantidade de vegetação verde e é calculado pela diferença:

$$DVI = \rho_{IVP} - \rho_V \quad (13)$$

O índice de vegetação transformado (TVI) foi proposto com o objetivo de evitar o valor negativo do NDVI e é dado pela Equação 14:

$$TVI = (NDVI + 0,5)^{1/2} \quad (14)$$

Oliveira et al. (2007) compararam nove diferentes índices de vegetação derivados de dados do sensor ETM+/Landsat 7 referentes à uma área localizada no Mato Grosso do Sul, cidade de Campo Grande. A análise dos resultados demonstrou alta correlação para todos os índices estudados, com exceção do índice CTVI. O índice CTVI, elaborado por Perry e Lautenschlager (1984) é calculado pela Equação 15:

$$CTVI = \frac{NDVI + 0,5}{|NDVI + 0,5| \times \sqrt{|NDVI + 0,5|}} \quad (15)$$

Muitos estudos têm sido feitos no sentido de estabelecer e avaliar as relações entre características da vegetação e dados de sensoriamento remoto. Tanajura et al. (2005), em seu trabalho, avaliaram índices de vegetação (NDVI, PVI, SAVI, WDI) que melhor se ajustam ao mapeamento de superfícies com diferentes culturas e vegetação natural. Embora tenham obtido dados comparativos entre os índices estudados, sugerem o uso dos mesmos em um número maior de datas e em classificadores digitais de imagens.

4.3.10 Modelo linear de mistura espectral

De acordo com Moreira (2001), a resposta espectral contida no *pixel* é uma mistura de três componentes – solo, vegetação e sombra (ou água) – presentes dentro da unidade de resolução do terreno. O modelo linear de mistura espectral é uma transformação que decompõe a imagem original nesses três componentes.

De acordo com Ponzoni e Shimabukuro (2007), as imagens fração podem ser consideradas como uma forma de reduzir a dimensionalidade dos dados e como uma forma de realce das informações. Além disso, o modelo de mistura espectral transforma a informação espectral em informação física (valores de proporção das componentes no *pixel*). A imagem fração vegetação realça as áreas de cobertura vegetal; a imagem fração solo realça as áreas de solo exposto; enquanto que a imagem fração sombra/água realça as áreas ocupadas com corpos d'água e também áreas de queimadas, áreas alagadas, etc.

As imagens fração resultantes da decomposição linear são freqüentemente usadas em processos de classificação. Como exemplo, no trabalho de Servello et al. (2007), a imagem fração-sombra resultante da aplicação do modelo linear de mistura espectral foi utilizada na classificação de imagens CCD/CBERS-2 para o mapeamento de uso da terra na região Centro-Sul do Paraná.

4.3.11 Transformação espectral *tasseled-cap*

A transformação *tasseled cap*, assim como outras transformações mencionadas anteriormente, é uma ferramenta útil para o monitoramento da vegetação assim como para a redução da dimensionalidade dos dados. Conforme Schott (1997), esta transformação é específica a cada sensor e a tipos de cenas particulares.

Segundo citação de Lillesand e Kiefer (1994), a transformação *tasseled cap* foi desenvolvida a partir de uma transformação linear de quatro bandas MSS/Landsat estabelecendo quatro novos eixos nos dados espectrais. As componentes geradas correspondem aos componentes brilho dos solos (*brightness*), biomassa da vegetação (*greenness*), senescência da vegetação (*yellowness*), sendo a quarta componente sem significado prático. Mais tarde, o conceito *tasseled cap* foi estendido aos dados TM/Landsat, definindo planos de solos, de vegetação e a zona de transição entre estes (três das componentes não apresentaram significado prático). A partir desses planos obtêm-se três componentes relevantes: o brilho (*brightness*), o verdor (*greenness*) e a umidade (*wetness*).

Trabalho realizado por Kuntschik e Gleriani (2007) concluiu que os coeficientes gerados pela transformação *tasseled cap* são específicos para cada sensor, para a grandeza radiométrica utilizada e para o tipo de solo da região. Os resultados obtidos indicam que os valores determinados para as condições dos Estados Unidos da América, embora usados em outros locais do mundo, não são adequados para a área de estudo, na Argentina.

4.4 Classificação de imagens digitais

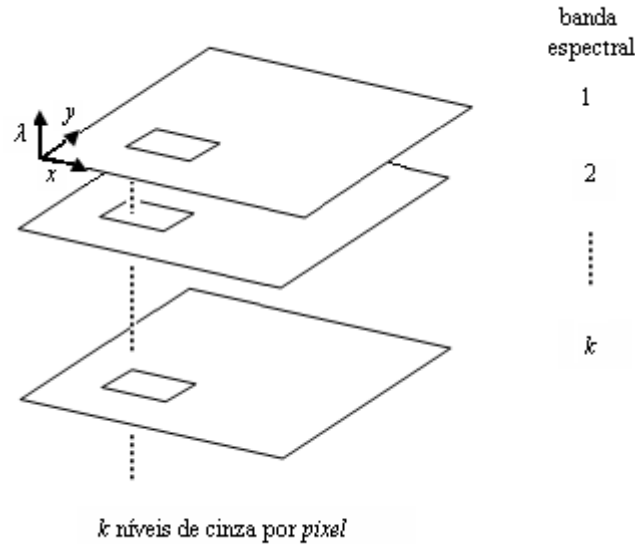
Segundo Novo (1992), as técnicas de classificação digital implicam na implementação de um processo computacional de decisão que atribui certos conjuntos de pontos ou *pixels* de uma imagem a uma determinada classe. Desta forma, o objetivo das técnicas de classificação digital é tornar o processo de mapeamento ou reconhecimento de características da superfície terrestre menos subjetivo e com maior potencial de repetição em situações subseqüentes.

Para Lillesand e Kiefer (1994), o objetivo das técnicas de classificação é categorizar todos os *pixels* de uma imagem digital dentro de uma das várias classes de cobertura da terra, ou temas. Estes dados categorizados podem ser usados para produzir mapas temáticos da cobertura da terra presentes em uma imagem, e/ou produzir resumos estatísticos sobre as áreas cobertas por cada tipo de cobertura da terra.

As técnicas de classificação digital podem ser aplicadas a imagens de apenas um canal espectral (unidimensionais) ou a imagens multiespectrais. Neste trabalho, são focalizadas as técnicas de classificação voltadas a imagens multiespectrais, que é o caso das imagens CCD/CBERS. As seções a seguir abordam a classificação de imagens multiespectrais, a questão do treinamento na classificação, os principais classificadores desta categoria e, também, a questão da acurácia da classificação.

4.4.1 Classificação multiespectral

Em sensoriamento remoto, a informação espectral referente a uma cena pode ser registrada com imagens multiespectrais, isto é, um conjunto de imagens da mesma cena, cada qual adquirida por um filtro espectral diferente. Cada *pixel* em uma imagem multiespectral tem coordenadas espaciais x e y , e uma coordenada espectral λ (comprimento de onda), conforme ilustra a Figura 6. Para uma imagem de k bandas, há k níveis de cinza associados a cada *pixel*, um para cada banda espectral, de forma que cada *pixel* é representado por um vetor k -dimensional (SCHOWENGERDT, 1983).



Fonte: Schowengerdt (1983)

Figura 6 – As três coordenadas de uma imagem multiespectral

De acordo com Schowengerdt (1983), em geral, a separação de todas as classes requer mais do que duas bandas espectrais. Isto ocorre porque as partições são superfícies em k dimensões e sobreposições entre classes são comuns. Desta forma, além das bandas espectrais, outras imagens delas derivadas podem ser úteis no processo de classificação, como razões espectrais e outras transformações, as quais definem o espaço característico usado na classificação.

Schowengerdt (1983) destacou inúmeros outros fatores que podem causar variabilidade dentro das classes e sobreposição entre classes, como o espalhamento atmosférico, a topografia, *pixels* contendo mistura, dentre outros. Considerando isto, técnicas de correção atmosférica, cálculo de razões espectrais, ente outras técnicas de pré-processamento e realce devem ser usadas para uma classificação adequada.

Da mesma forma, Schott (1997) destacou o uso de transformações de imagem para redefinir o espaço característico multidimensional dentro de um outro espaço onde as características são mais descorrelacionadas. Assim, poucas características podem carregar a informação necessária para classificadores multiespectrais. Essas transformações

também são freqüentemente usadas para normalização de efeitos atmosféricos e de calibração de sensores.

4.4.2 Treinamento

Para Schowengerdt (1983), o primeiro passo de qualquer procedimento de classificação é o treinamento do programa computacional para reconhecer as classes de interesse. Este aspecto da classificação é crítico para o sucesso de todo o processo e freqüentemente ocupa a maior parte do tempo do analista.

O treinamento, segundo Schowengerdt (1983), pode ser realizado de duas formas: supervisionado e não-supervisionado. No treinamento supervisionado o analista usa conhecimento anterior derivado de estudos de campo, fotointerpretação e outras fontes sobre pequenas regiões na imagem a ser classificada para identificar aqueles *pixels* que pertencem às classes de interesse. Os vetores característicos desses *pixels* são usados para descrever os atributos de cada classe e, posteriormente, na fase de classificação, reconhecer *pixels* similares em toda a imagem.

Essas pequenas áreas de treinamento são também chamadas de amostras de treinamento, segundo Novo (1992), que destaca a importância de que as amostras de treinamento devem ser homogêneas e representativas de cada classe.

No treinamento não-supervisionado, segundo Schowengerdt (1983), o analista utiliza um algoritmo computacional que localiza as concentrações de vetores característicos ou agrupamentos que ocorrem naturalmente a partir de amostras de *pixels* heterogêneas. Cada grupo representa a distribuição de probabilidade para uma classe. Posteriormente, na fase de classificação, um analista determina a identidade desses grupos espectrais comparando-os com dados de referência.

Os algoritmos utilizados para treinamento não-supervisionado são conhecidos por algoritmos de agrupamento ou *clustering*. Os métodos mais comuns são os algoritmos K-médias e ISODATA. Explicações mais detalhadas sobre estes algoritmos podem ser encontradas em Celinski (1998).

Schowengerdt (1983) destacou que o treinamento supervisionado não resulta necessariamente em classes numericamente separáveis no espaço característico, embora sejam significativas para o analista. Por outro lado, o treinamento não-supervisionado determina a estrutura inerente aos dados, embora os grupos possam não corresponder às classes de interesse do analista.

Desta forma, o treinamento não-supervisionado pode ser útil na determinação de áreas homogêneas como potenciais amostras de treinamento para posterior classificação supervisionada. Neste contexto combinado, segundo Schowengerdt (1983), o analista, após o treinamento não-supervisionado, revisa o agrupamento obtido, dividindo ou combinando grupos, para depois aplicar o algoritmo de classificação na imagem toda.

4.4.3 Algoritmos para classificação

Os métodos de classificação usados em sensoriamento remoto estão baseados em procedimentos de reconhecimento de padrões, onde os padrões são constituídos por vetores característicos de *pixels*. De acordo com Schowengerdt (1983), os algoritmos de classificação podem ser agrupados dentro de um dos dois grupos: paramétricos e não-paramétricos. Algoritmos paramétricos admitem uma distribuição estatística de classe particular, comumente uma distribuição normal, e então estimam os parâmetros de tal distribuição, tal como vetor médio e matriz de covariância, para usar no algoritmo de classificação. Algoritmos não-paramétricos, por outro lado, não fazem suposições sobre as distribuições de classes.

Pertencem à classe dos algoritmos paramétricos classificadores tradicionais como: distância mínima até a média, paralelepípedo e máxima verossimilhança (MAXVER). Conforme Lillesand e Kiefer (1994), no método da distância mínima até a média, cada *pixel* é atribuído à classe cuja média ele é mais próximo. Embora matematicamente simples e computacionalmente eficiente, o método da distância mínima até a média não é adequado quando as classes são próximas e têm variância elevada.

No método do paralelepípedo, é definido um paralelepípedo ao redor de cada área de treinamento, estabelecendo um intervalo de valores digitais para cada

categoria. Para Lillesand e Kiefer (1994), este método é muito rápido e computacionalmente eficiente, mas apresenta dificuldades quando há sobreposições entre classes.

O classificador MAXVER considera que a nuvem de pontos que forma cada categoria dos dados de treinamento possui uma distribuição normalmente distribuída ou gaussiana no espaço característico. Sob esta suposição, uma classe pode ser completamente descrita pelo vetor médio e pela matriz de covariância. Por meio desses parâmetros, é calculada a probabilidade estatística de um dado *pixel* pertencer a cada classe, sendo então rotulado à classe com a maior probabilidade (LILLESAND; KIEFER, 1994).

Dentre as técnicas não-paramétricas, as redes neurais artificiais, conforme Lillesand e Kiefer (1994), não requerem que os dados de treinamento tenham uma distribuição estatística gaussiana, que é uma exigência do Classificador Máxima Verossimilhança. Isto permite que redes neurais sejam usadas com uma maior variedade de tipos de dados de entrada. Além disso, uma vez tenham sido inteiramente treinadas, redes neurais podem realizar a classificação de imagens de forma relativamente rápida, embora o processo de treinamento possa consumir muito tempo.

Segundo Lillesand e Kiefer (1994), as redes neurais artificiais consistem de um conjunto de três ou mais camadas, cada qual com múltiplos nós. Os nós são análogos aos neurônios de uma rede neural biológica. As camadas da rede incluem uma camada de entrada, uma camada de saída, e uma ou mais camadas ocultas. Os nós na camada de entrada representam variáveis usadas como entrada na rede neural, podendo incluir bandas espectrais de uma imagem de sensoriamento remoto, características texturais ou outros produtos derivados da imagem, ou ainda dados adicionais sobre a região a ser analisada, como topografia, tipos de solos, clima entre outros.

Na camada de saída, cada nó representa uma classe no sistema de classificação. Entre a camada de entrada e a camada de saída há uma ou mais camadas ocultas. As camadas ocultas consistem de múltiplos nós, que estão ligados a muitos nós na camada precedente e a muitos nós na camada seguinte. As ligações entre os nós são representadas por pesos, os quais guiam o fluxo da informação através da rede. O número de camadas ocultas é arbitrário e o seu aumento permite que a rede seja usada para operações mais complexas,

embora diminua a habilidade para generalizar e aumente o tempo de treinamento (LILLESAND; KIEFER, 1994).

Também pertencentes à classe dos algoritmos não-paramétricos, estão os classificadores baseados em regras utilizando análise de árvores de decisão. De acordo com Tso e Mather (2001,), estes classificadores realizam a categorização por meio da divisão hierárquica dos dados, na forma de uma seqüência de decisões. A construção do classificador ou árvore de decisão envolve o particionamento recursivo de um conjunto de dados de treinamento, que é subdividido em conjuntos cada vez mais homogêneos sobre a base de testes aplicada a um ou mais dos valores característicos. Esses testes são representados por nós.

Segundo Schowengerdt (1983), a Classificação por Árvore de Decisão é uma abordagem muito flexível que permite que diferentes características e regras de classificação sejam usadas na separação de diversas classes. São particularmente úteis para dados multitemporais e de múltiplas fontes devido a essa flexibilidade.

Há aproximadamente duas décadas, diversas pesquisas têm sido realizadas voltadas à modelagem automática de árvores de decisão. Neste contexto, destacam-se os algoritmos ID3 (QUINLAN, 1986) e seu sucessor C4.5 (QUINLAN, 1993), CART (BREIMAN et al., 1984) e QUEST (LOH; SHIH, 1997).

4.4.4 Avaliação da classificação

Para Schowengerdt (1983), um teste completo da acurácia de um mapa de classificação exigiria a verificação da classe de cada *pixel*. Devido à impossibilidade real de tal teste, áreas de teste representativas devem ser usadas para estimar a acurácia do mapa, que é quase sempre estimada pela divisão do número de *pixels* de teste classificados corretamente na classe pelo número total de *pixels* de teste na classe.

Segundo Lillesand e Kiefer (1994), um dos mais comuns instrumentos usados para expressar a acurácia da classificação é a matriz de erros de classificação, também conhecida por matriz de confusão ou tabela de contingência. A matriz de erros estabelece o relacionamento entre os dados de referência (verdade terrestre) e os correspondentes resultados

da classificação. Tal matriz é quadrada, com número de linhas e de colunas igual ao número de categorias cuja acurácia está sendo determinada.

Tabela 5 – Matriz de erros genérica

		Dados de referência (verdade terrestre)				
		Classe 1	Classe 2	...	Classe C	Total (linha)
Dados da classificação	Classe 1	a_{11}	a_{12}	...	a_{1C}	$\sum_{k=1}^C a_{1k}$
	Classe 2	a_{21}	a_{22}	...	a_{2C}	$\sum_{k=1}^C a_{2k}$

	Classe C	a_{C1}	a_{C2}	...	a_{CC}	$\sum_{k=1}^C a_{Ck}$
	Total (coluna)	$\sum_{k=1}^C a_{k1}$	$\sum_{k=1}^C a_{k2}$...	$\sum_{k=1}^C a_{kC}$	$N = \sum_{i=1}^C \sum_{k=1}^C a_{ik}$

A Tabela 5 corresponde a uma matriz de erros genérica. Os valores ao longo da diagonal principal representam o número de pixels classificados corretamente para cada classe. Os elementos da matriz que não estão na diagonal principal representam erros de omissão ou comissão. Cada erro representa uma omissão da classe correta e, ao mesmo tempo, uma comissão para a classe incorreta (LILLESAND; KIEFER, 1994).

Da matriz de erro derivam várias medidas descritivas. Segundo Lillesand e Kiefer (1994), a acurácia total é calculada pela divisão do número total de pixels classificados corretamente pelo número total de pixels de referência. Da mesma forma, a acurácia individual de cada classe é obtida pela divisão do número de pixels classificados corretamente na categoria pelo número total de pixels na correspondente linha ou coluna.

Schowengerdt (1983) menciona outra medida derivada da matriz de erros, a acurácia média, que é obtida pela média aritmética das acurácias de cada classe.

Ao dividir-se pelo número total de pixels na coluna correspondente, obtém-se a acurácia do produtor, que indica quão bem os pixels do conjunto de teste de um determinado tipo de cobertura foram classificados. A acurácia do usuário é resultante da divisão do número de pixels classificados corretamente na classe pelo número total de pixels que foram classificados na categoria (total na linha). Esta medida é o erro de comissão e indica a probabilidade de um pixel classificado em uma classe de fato pertencer a esta categoria (LILLESAND; KIEFER, 1994).

Além das medidas já descritas anteriormente, derivadas da matriz de erros, o coeficiente *kappa* (k) é uma medida estatística que indica como cada classificação difere de uma classificação aleatória dos tipos de cobertura, segundo Lillesand e Kiefer (1994). O coeficiente *kappa* é calculado pela Equação 16:

$$k = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \cdot x_{+i})} \quad (16)$$

onde r é o número de linhas na matriz de erros, x_{ii} é o número de observações na linha i e coluna i , x_{i+} é o total de observações na linha i , x_{+i} é o total de observações na coluna i , e N é o número de observações.

A fim de interpretar a fórmula do coeficiente *kappa*, a formulação seguinte é mais útil, pois dá a idéia conceitual desta medida (LILLESAND; KIEFER, 1994; DWIVEDI et al., 2004):

$$k = \frac{p_o - p_c}{1 - p_c} \quad (17)$$

onde p_o é a acurácia da concordância observada ou

$$p_0 = \frac{\sum x_{ii}}{N} \quad (18)$$

e p_c é a estimativa de concordância casual dada pela Equação 19.

$$p_c = \frac{\sum x_{i+}x_{+i}}{N^2} \quad (19)$$

O valor do coeficiente *kappa* varia entre 0 e 1, sendo que o valor 1 indica uma concordância total entre o resultado da classificação das amostras de treinamento e os dados de referência. Landis e Koch (1977) apresentaram uma tabela que permite avaliar o valor do coeficiente *kappa* obtido a partir de uma classificação. A Tabela 6 exibe uma adaptação da referida tabela.

Tabela 6 – Classificação qualitativa quanto ao valor do coeficiente *kappa*

VALOR DE k	QUALIDADE DA CLASSIFICAÇÃO
$k = 0,0$	Péssima
$0,0 < k \leq 0,2$	Ruim
$0,2 < k \leq 0,4$	Razoável
$0,4 < k \leq 0,6$	Boa
$0,6 < k \leq 0,8$	Muito boa
$0,8 < k \leq 1,0$	Excelente

Uma questão importante a ser considerada na avaliação da acurácia, destacada por Lillesand e Kiefer (1994) e por Schowengerdt (1983), diz respeito à escolha das áreas de teste. Comumente essas áreas constituem um subconjunto das áreas selecionadas para o estágio do treinamento supervisionado. A acurácia obtida dessas áreas pode não prover uma indicação válida da acurácia da classificação, sendo o pior caso quando são usadas as mesmas amostras para o treinamento do classificador e para a estimativa da acurácia.

Uma forma de assegurar uma determinação adequada da acurácia é determinar um número maior de áreas para o treinamento, separando uma parte para uso exclusivo na etapa de teste. Como todas as áreas são selecionadas pelo mesmo analista, utilizando as mesmas informações (levantamentos de campo, fotografias aéreas, etc.), é importante que as áreas de teste sejam bastante dispersas pela área de estudo (SCHOWENGERDT, 1983).

Há ainda a possibilidade de realizar uma seleção de áreas de teste de forma aleatória, o que evitaria a correlação entre os dados de teste e de treinamento do classificador, e a conseqüente superestimação da acurácia. Entretanto, a validação das áreas aleatórias pode ser muito difícil e custosa. Além disso, é necessário usar uma estratégia para garantir que as áreas selecionadas aleatoriamente sejam significativas para a análise em questão (LILLESAND; KIEFER, 1994; SCHOWENGERDT, 1983).

Hashemian et al. (2004) realizaram estudo sobre métodos de amostragem como um dos fatores que afetam o desempenho da determinação da acurácia da classificação de dados de sensoriamento remoto. Os resultados obtidos demonstraram que, dependendo de condições específicas tal como tipo e tamanho da região de estudo e características do objeto, diferentes métodos de amostragem e tamanho de amostra são preferidos.

4.5 Comparação entre métodos de classificação

Há, na literatura, trabalhos abrangentes que estabelecem uma comparação entre diversos algoritmos das categorias estatísticos, redes neurais e árvores de decisão, como os realizados por King et al. (1995) e Lime et al. (2000). Os critérios de comparação utilizados incluem determinação da acurácia, tempo de treinamento e execução e número de folhas, além de critérios subjetivos como facilidade de uso e compreensibilidade. Os algoritmos foram aplicados a diferentes conjuntos de dados, incluindo dados de satélite multiespectrais. De um modo geral, os resultados obtidos demonstram que, quanto à acurácia, as diferenças são pouco significativas. Entretanto, diferem quanto ao tempo de treinamento e interpretabilidade dos dados, vantajosos para a categoria árvores de decisão.

Os diversos métodos, em geral, quando aplicados à classificação de dados de sensores remotos de resolução média – como os sensores CCD/CBERS-2 – para fins de mapeamento da cobertura da terra, apresentam resultados muito bons quando o conjunto de classes reflete os tipos de cobertura não fazendo distinção entre os diferentes tipos de culturas agrícolas. Em geral, as classes relativas à água, solo e floresta apresentam acurácias excelentes.

Neste contexto, Silva e Pereira (2007) compararam o desempenho dos algoritmos distância mínima até a média, paralelepípedo e máxima verossimilhança quando aplicados à classificação de imagens CCD/CBERS-2, utilizando como dados as bandas 2, 3 e 4 do sensor e considerando as classes mata, reflorestamento, pastagem, rio, lagoa e urbanização. Os resultados foram excelentes para os algoritmos distância mínima até a média e máxima verossimilhança, com valores *kappa* próximos a 0,90, e insatisfatórios para o método do paralelepípedo.

Da mesma forma, Freitas e Cruz (2005) avaliaram o desempenho de três diferentes combinações de atributos a partir de dados ETM+/Landsat 7 – bandas com correção atmosférica, quatro bandas e imagens fração (solo, sombra e vegetação), imagens fração e três componentes principais – na discriminação de classes de vegetação na mata atlântica. O procedimento de classificação constituiu-se pela seqüência: segmentação por crescimento de regiões, algoritmo ISOSEG e algoritmo Bhattacharya. Os resultados acusaram acurácias muito próximas para as três combinações de atributos, próximas a 64%, devido à dificuldade em separar as classes.

Figueiredo e Carvalho (2006) avaliaram a exatidão do mapeamento da cobertura da terra em Capixaba – Acre usando classificação por árvore de decisão. O conjunto de atributos utilizado incluiu as bandas do sensor TM/Landsat 5, as imagens fração derivadas do modelo de mistura espectral e o índice de vegetação NDVI. Para as classes temáticas consideradas neste estudo – floresta, capoeira, pasto alto, pasto baixo, solo e água – o desempenho da classificação por árvore de decisão apresentou valor *kappa* igual a 0,90. Comparativamente aos métodos MAXVER e ISODATA, os valores *kappa* foram de 0,89 e 0,79, respectivamente.

Em trabalho dos mesmos autores, Figueiredo e Carvalho (2007), outras comparações foram realizadas entre os algoritmos ISODATA, MAXVER e árvore de decisão,

utilizando diferentes composições de atributos a partir das bandas dos sensores TM/Landsat 5, ETM+/Landsat 7, das imagens fração do modelo de mistura espectral e do índice NDVI, para as mesmas classes de cobertura. Os resultados foram superiores para o algoritmo MAXVER com *kappa* próximo a 0,90, utilizando somente as bandas dos sensores ou somente as imagens fração. Entretanto, a classificação por árvore de decisão apresentou resultados próximos aos do classificador MAXVER, utilizando todos os atributos.

Quando a categorização é definida sobre classes específicas de cultivos agrícolas, os índices de acurácia apresentam-se relativamente menores, em função das semelhanças espectrais entre espécies vegetais. No trabalho de Fonseca et al. (2001), foram realizadas classificações pelos métodos MAXVER e ISOSEG, obtendo-se baixas acurácias de, respectivamente, 54,4% e 50%. O vetor característico usado foi composto das bandas 3, 4 e 5 do sensor TM/Landsat 5 e as classes consideradas foram milho, sorgo, cana-de-açúcar, pasto, sem vegetação, água e floresta.

4.6 Árvores de decisão

4.6.1 Descoberta de conhecimento em bancos de dados

A descoberta de conhecimento em bancos de dados, do inglês *knowledge discovery in databases* (KDD), estabeleceu-se como uma área de pesquisa interdisciplinar bastante produtiva em função da grande quantidade de dados armazenada em bancos de dados e da necessidade de transformação destes dados em conhecimento útil. A meta do processo KDD é extrair conhecimento de alto nível de grandes conjuntos de dados.

Para Fayyad et al. (1996a, 1996b, 1996c), o processo de KDD inclui um conjunto de etapas: seleção, pré-processamento, transformação, *data mining*, interpretação e avaliação. *Data mining* corresponde a uma etapa particular do processo – aplicação de algoritmos específicos para extração de padrões dos dados. A maioria dos métodos de *data mining* está baseada em conceitos de áreas como aprendizado de máquina (*machine learning*), reconhecimento de padrões (*pattern recognition*) e estatística. Dentre as técnicas mais populares estão as árvores de decisão, as redes neurais e as redes bayesianas.

4.6.2 Aprendizagem em árvores de decisão

Para Russell e Norvig (2004), o problema da aprendizagem supervisionada envolve a aprendizagem de uma função a partir de exemplos de suas entradas e saídas. Um algoritmo para aprendizagem supervisionada determinística recebe como entrada o valor correto da função desconhecida para entradas específicas e deve tentar recuperar a função desconhecida ou algo perto disso. Mais formalmente, diz-se que um exemplo é um par $(x, f(x))$, onde x é a entrada e $f(x)$ é a saída da função aplicada a x . A tarefa da inferência indutiva pura (ou indução) é: “Dada uma coleção de exemplos de f , retornar uma função h que se aproxime de f ”. A função h é chamada hipótese. Uma boa hipótese irá generalizar bem, isto é, irá prever corretamente exemplos ainda não-vistos.

De acordo com Mitchell (1997), o conceito de aprendizagem pode ser visto como a tarefa de busca pelo amplo espaço de hipóteses implicitamente definido pela representação de hipótese. A meta dessa busca é encontrar a hipótese que melhor se ajusta aos exemplos de treinamento. Sob esse ponto de vista, algoritmos de aprendizagem examinarão diferentes estratégias de busca no espaço de hipóteses.

A indução de árvores de decisão, de acordo com Russel e Norvig (2004), é uma das formas mais simples, e ainda assim mais bem-sucedidas, de algoritmos de aprendizagem. Esta afirmação é corroborada por diversos autores. Dentre estes, Mitchell (1997) destacou que a aprendizagem em árvore de decisão é um dos mais amplamente usados métodos para inferência indutiva. Métodos de aprendizagem em árvore de decisão realizam uma busca expressiva e completa no espaço de hipóteses e assim esvaziam as dificuldades relacionadas a espaços de hipóteses restritos.

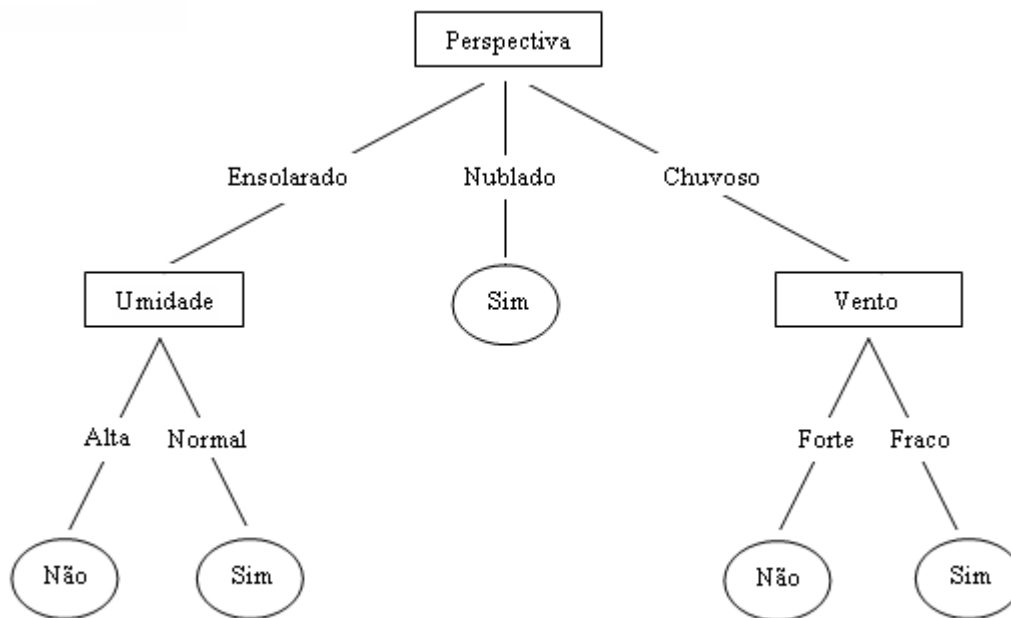
Segundo Fayyad et al. (1996a), algoritmos de árvores de decisão são métodos supervisionados de aprendizagem de máquina que analisam atributos de um conjunto de amostras de treinamento, gerando árvores que são usadas posteriormente para classificação. Árvores são naturais para classificação e, provavelmente, o modelo mais fácil para interpretação.

Uma árvore de decisão toma como entrada um objeto ou situação descrito por um conjunto de atributos e retorna uma “decisão” – o valor de saída previsto de

acordo com a entrada. Os atributos de entrada podem ser discretos ou contínuos. O valor de saída também pode ser discreto ou contínuo. A aprendizagem de uma função de valores discretos é chamada de aprendizagem de classificação; a aprendizagem de uma função contínua é chamada regressão (RUSSELL; NORVIG; 2004).

Uma árvore de decisão é um fluxograma como uma estrutura de árvore, onde cada nó interno denota um teste sobre um atributo, cada aresta representa uma saída do teste, e nós folhas representam classes ou distribuições de classes. O nó superior na árvore é o nó raiz (HAN; KAMBER, 2001).

A Figura 7 ilustra uma típica árvore de decisão aprendida. Essa árvore de decisão classifica “manhãs de sábado” conforme estas sejam adequadas para jogar tênis. Os nós são representados por retângulos, enquanto que as folhas são representadas por elipses.



Fonte: Mitchell (1997)

Figura 7 – Árvore de decisão para o problema Jogar Tênis

Uma árvore de decisão alcança sua decisão executando uma seqüência de testes. Cada nó interno na árvore corresponde a um teste do valor de uma das propriedades,

e as ramificações a partir do nó são identificadas com os valores possíveis do teste. Cada nó folha na árvore especifica o valor a ser retornado se aquela folha for alcançada (RUSSELL; NORVIG, 2004).

4.6.3 Algoritmos de aprendizagem em árvores de decisão

De acordo com Safavian e Landgrebe (1991), os objetivos principais dos classificadores por árvore de decisão são: classificar corretamente tantas amostras de treinamento quanto possível; generalizar além das amostras de treinamento de forma que exemplos não vistos possam ser classificados com alta acurácia tanto quanto possível; ser fácil de atualizar quando mais amostras de treinamento se tornam disponíveis; e, ter uma estrutura tão simples quanto possível.

Em abordagens *top-down*³, a modelagem de um classificador por árvore de decisão se reduz às seguintes tarefas: a seleção de uma regra de divisão de nó; a decisão de quais nós são terminais; e, a atribuição de cada nó terminal a um rótulo de classe (SAFAVIAN; LANDGREBE, 1991).

Segundo Mitchell (1997), o algoritmo básico para indução de árvore de decisão é um algoritmo que utiliza uma técnica *top-down* de busca gulosa através do espaço de árvores de decisão possíveis. Esta abordagem é exemplificada pelo algoritmo ID3 (QUINLAN, 1986) e seu sucessor C4.5 (QUINLAN, 1993). A Figura 8 exhibe o algoritmo básico para indução de árvore de decisão a partir de amostras de treinamento.

De acordo com Han e Kamber (2001), a construção da árvore se inicia com a escolha do atributo a ser testado na raiz da árvore. Esta escolha é feita por meio de um teste estatístico para determinar quão bem um atributo classifica os exemplos de treinamento. Uma vez selecionado o melhor atributo, este é usado como teste no nó raiz da árvore. Um descendente do nó raiz é então criado para cada valor possível de seu atributo, e os exemplos de treinamento são classificados para o nó descendente apropriado. O processo é repetido

³ Em uma abordagem *top-down*, um processo é descrito de forma incremental e suas iterações se iniciam de um nível mais abrangente do processo para níveis de detalhamento progressivos.

usando os exemplos de treinamento associados com cada nó descendente para seleccionar o melhor atributo para testar neste ponto da árvore. Um atributo que tenha sido escolhido em um nó não é mais considerado em qualquer nó descendente.

Algoritmo *aprendizagem_árvore_decisão*.

Entradas: *amostras*, conjunto de exemplos de treinamento
atributos, conjunto de atributos

Saída: árvore de decisão

Método:

Crie um nó *N*;

Se *amostras* são todas da mesma classe *C* então
 Retorne *N* como um nó folha rotulado com a classe *C*;

Se *atributos* é vazio então
 Retorne *N* como nó folha rotulado com a classe da maioria em *amostras*;

Selecione *atributo-teste* de *atributos* com o maior ganho de informação;

Rotule nó *N* com *atributo-teste*;

Para cada valor *a_i* de *atributo-teste* // particionamento das amostras
 Acrescente uma ramificação do nó *N* para a condição *atributo-teste*= *a_i*;

Faça *s_i* o conjunto de exemplos em *amostras* para os quais *atributo-teste*= *a_i*;

Se *s_i* é vazio então
 Anexe um nó folha rotulado com a classe da maioria em *amostras*;

Senão anexe o nó retornado de *aprendizagem_árvore_decisão* (*s_i*, *atributos - atributo-teste*);

Fonte: Han e Kamber (2001)

Figura 8 – Algoritmo básico para indução de árvore de decisão

Conforme o algoritmo exibido na Figura 8, o particionamento recursivo pára quando uma das seguintes condições é verdadeira: *i*) todos os exemplos, para um dado nó, pertencem à mesma classe, quando então o nó se torna uma folha e é rotulado com esta classe; *ii*) não há atributos remanescentes para particionar os exemplos. Neste caso, o nó é convertido em folha e rotulado com a classe da maioria dos exemplos; *iii*) não há exemplos que verificam o teste. Neste caso, uma folha é criada e rotulada com a classe da maioria dos exemplos (HAN; KAMBER, 2001).

Conforme Pal e Mather (2003), diversos métodos de seleção de atributos são descritos na literatura, cujo objetivo é maximizar a dissimilaridade ou minimizar a similaridade dos nós descendentes, no caso de árvores de decisão univariadas. Os mais

freqüentemente usados são: ganho de informação, razão de ganho, índice *Gini* e medida qui-quadrado.

O algoritmo ID3, de acordo com Mitchell (1997), usa a medida “ganho de informação” para selecionar entre atributos candidatos em cada etapa durante a geração da árvore. O atributo com maior ganho de informação (ou elevada redução de entropia) é escolhido como atributo de teste do nó corrente. Este atributo minimiza a informação necessária para classificar as amostras nas partições resultantes e reflete a mínima impureza nestas partições.

Mais precisamente, o ganho de informação $Ganho(E, A)$ de um atributo A , relativo a uma coleção de exemplos E , é definido como:

$$Ganho(E, A) = Entropia(E) - \sum_{v \in valores(A)} \frac{|E_v|}{|E|} Entropia(E_v) \quad (20)$$

onde $valores(A)$ é o conjunto de todos os possíveis valores para o atributo A , e E_v é o subconjunto de E para o qual o atributo A tem valor v . O primeiro termo da Equação 11 é a entropia da coleção original E , e o segundo termo é o valor esperado da entropia depois que E é particionado usando o atributo A (MITCHELL, 1997).

A entropia, por sua vez, caracteriza a impureza de uma coleção arbitrária de exemplos. De uma forma geral, se o atributo objeto pode assumir c diferentes valores, então a entropia de E relativa a esta classificação é definida como:

$$Entropia(E) = \sum_{i=1}^c -p_i \log_2 p_i \quad (21)$$

onde p_i é a proporção de E pertencente à classe i . A base 2 do logaritmo explica-se pelo fato da entropia ser uma medida do conteúdo de informação esperado, em *bits*. Se o atributo objeto pode ter possíveis valores, a entropia pode ser tão extensa quanto $\log_2 c$ (MITCHELL, 1997).

De acordo com Kohavi e Quinlan (2002), o algoritmo C4.5, sucessor do ID3, apresenta diversas características adicionais, o que permite aplicá-lo a uma variedade

mais ampla de problemas. A primeira delas diz respeito aos atributos que descrevem os dados. O algoritmo C4.5 permite usar atributos de entrada tanto inteiros quanto contínuos.

Quanto à seleção de testes de atributos, o algoritmo C4.5, por meio de uma busca gulosa, seleciona o teste candidato que maximiza uma heurística baseada em um critério de divisão, obtido a partir do ganho de informação descrito anteriormente. Este critério, denominado razão de ganho, leva em conta a informação potencial em si mesma:

$$InfoDiv(E, A) = - \sum_{v \in \text{valores}(A)} \frac{|E_v|}{|E|} \log \frac{|E_v|}{|E|} \quad (22)$$

O critério razão de ganho então escolhe, dentre os testes com o menor ganho médio, o teste E que maximiza a razão de ganho (KOHAVI; QUINLAN, 2002):

$$RazãodeGanho = \frac{Ganho(E, A)}{InfoDiv(E, A)} \quad (23)$$

Dentre as características que diferem o algoritmos C4.5 e ID3, está a possibilidade de lidar com omissão de dados. A omissão de dados é um fato comum, causado ou por erros no registro dos dados ou porque eles foram considerados irrelevantes para um caso particular. Tais lacunas afetam tanto a modelagem da árvore de decisão como seu uso para classificar um novo caso (KOHAVI; QUINLAN, 2002).

No algoritmo C4.5, as equações anteriores são modificadas:

$$Ganho(E, A) = \frac{|E - E_0|}{|E|} Ganho(E - E_0, A) \quad (24)$$

$$InfoDiv(E, A) = - \frac{|E_0|}{|E|} \log \frac{|E_0|}{|E|} - \sum_{v \in \text{valores}(A)} \frac{|E_v|}{|E|} \log \frac{|E_v|}{|E|} \quad (25)$$

onde E_0 é o subconjunto de casos em E com atributos desconhecidos e cuja saída do teste não pode ser determinada, e E_v é o subconjunto de casos em E com atributos conhecidos e cuja saída do teste pode ser determinada. O ganho de informação, nessa nova equação, é reduzido porque não há aprendizagem sobre os casos em E_0 . Da mesma forma, o critério de divisão tem sua equação aumentada para refletir o resultado adicional do teste (KOHAVI; QUINLAN, 2002).

De acordo com Kohavi e Quinlan (2002), algoritmos de árvores de decisão usam o método dividir e conquistar para construir uma árvore adequada aos dados de treinamento. Este tipo de algoritmo particiona os dados até cada folha conter casos de uma única classe, ou até que o particionamento seja impossível porque dois casos possuem os mesmos valores para cada atributo, mas pertencem a classes diferentes.

Segundo Nilsson (1996), o resultado desse procedimento é comumente uma árvore grande (em largura) e complexa. Em alguns casos, a adequação da árvore de decisão até todas as folhas conterem dados para uma única classe pode superadaptar ao ruído nas amostras de treinamento, assim como algumas amostras de treinamento podem não ser membros da classe que deveriam representar. Desta forma, se as amostras de treinamento contêm erros, a superadaptação (*overfitting*) da árvore a tais dados pode levar a um desempenho pobre na generalização de casos não vistos.

A superadaptação pode ser evitada pelo uso de um critério de parada ou poda que impede a divisão de alguns conjuntos de dados de treinamento com base em algum teste estatístico de significância, ou pela remoção de algumas sub-árvores depois que a árvore foi produzida. O algoritmo C4.5 utiliza o segundo mecanismo, permitindo o desenvolvimento da árvore ao máximo para depois realizar a poda em um processo retrospectivo (*bottom-up*) que remove partes da árvore que não respondem a uma condição baseada em uma taxa de erro (KOHAVI; QUINLAN, 2002).

O método de poda implementado no algoritmo C4.5 – *error-based pruning* – visita os nós da árvore máxima obtida a partir das amostras de treinamento, no sentido *bottom-up*, e simplifica a árvore permitindo a substituição de um nó não-folha por uma folha ou por uma sub-árvore da qual é pai. Desta forma, é possível remover testes intermediários que parecem inúteis (ESPOSITO et al., 1997).

Considerando um conjunto de exemplos cobertos por uma folha t como uma amostra estatística, é possível estimar um intervalo de confiança $[I_{CF}(t), S_{CF}(t)]$ para a probabilidade de má classificação de t . O limite superior do intervalo é de particular interesse para uma análise do pior caso, e é definido como o valor real tal que:

$$P\left(\frac{e(t)}{n(t)} \leq S_{CF}\right) = CF \quad (26)$$

onde: CF é o nível de confiança; $n(t)$ é o número total de exemplos em um nó t ; e $e(t)$ é o número de exemplos não pertencentes à classe da maioria (ESPOSITO et al., 1997).

Assumindo que erros no conjunto de treinamento são binomialmente distribuídos com probabilidade p em $n(t)$ testes, é possível calcular o valor exato de S_{CF} como o valor de p para o qual uma variável aleatória X binomialmente distribuída mostra $e(t)$ sucessos em $n(t)$ testes com probabilidade CF , que é (ESPOSITO et al., 1997):

$$P(X \leq e(t)) = CF \quad (27)$$

Uma vez encontrado o limite superior, as estimativas de erro das folhas e sub-árvores são calculadas considerando que elas são usadas para classificar um conjunto de casos não vistos do mesmo tamanho do conjunto de treinamento. Assim, a taxa de erro de predição para t será $n(t) \cdot S_{CF}$. A soma das taxas de erro de predição de todas as folhas em uma sub-árvore T_t é considerada uma estimativa da taxa de erro da sub-árvore. Desta forma, comparando a taxa de erro de predição para t com a da sub-árvore T_t e com a da maior sub-árvore $T_{t'}$ enraizada em um nó filho t' de t , é possível decidir se é conveniente: *i*) conservar T_t ; *ii*) substituir T_t por $T_{t'}$; ou, *iii*) substituir T_t pela folha rotulada com a classe mais frequente em E (ESPOSITO et al., 1997).

De acordo com Kohavi e Quinlan (2002), este método é computacionalmente eficiente e dá resultados bem razoáveis na maioria das aplicações. Espósito et al. (1997) fizeram uma análise comparativa de métodos de poda em árvores de decisão que utilizam uma abordagem *top-down*, com o objetivo de compreender a

fundamentação teórica, a complexidade computacional e os pontos fracos e fortes de seis métodos de poda bastante conhecidos.

4.6.4 Extração de regras de classificação a partir de árvores de decisão

Han e Kamber (2001) destacaram que o conhecimento representado em árvores de decisão pode ser extraído e representado na forma de regras de classificação do tipo “se-então”. Uma regra é criada para cada caminho do nó raiz até um nó folha. Esta característica, que permite transformar processos de decisão complexos em conjuntos de decisões simples, é a mais importante característica dos classificadores por árvore de decisão, provendo uma solução geralmente mais fácil para interpretação. A Figura 9 exhibe o conjunto de regras extraído a partir da árvore de decisão contida na Figura 7.

```
Se Perspectiva = "ensolarado" e Umidade = "alta" então Jogar tênis = "não"  
Se Perspectiva = "ensolarado" e Umidade = "normal" então Jogar tênis = "sim"  
Se Perspectiva = "nublado" então Jogar tênis = "sim"  
Se Perspectiva = "chuvoso" e Vento = "forte" então Jogar tênis = "não"  
Se Perspectiva = "chuvoso" e Vento = "fraco" então Jogar tênis = "sim"
```

Fonte: Mitchell (1997)

Figura 9 – Conjunto de regras extraídas da árvore de decisão da Figura 7

De acordo com Russel e Norvig (2004), para verificar o quão boa é a hipótese gerada para classificar exemplos não-vistos, utilizam-se as amostras de treinamento para calcular a acurácia das regras. Para tanto, divide-se o conjunto de amostras ou exemplos em dois conjuntos – de treinamento e de teste. O algoritmo de aprendizagem é aplicado ao conjunto de treinamento, gerando a árvore de decisão ou hipótese. A hipótese é então aplicada ao conjunto de teste, calculando-se a porcentagem de exemplos corretamente classificados.

Quinlan (1987) descreveu um método para transformar ou re-expressar classificadores de árvore de decisão na forma de uma pequena coleção de regras de produção. O método utiliza o conjunto de exemplos de treinamento a partir do qual a árvore de decisão foi gerada, primeiro para generalizar e determinar a confiança de regras individuais extraídas da árvore, e subseqüentemente refinar a coleção de regras como um todo. O conjunto final de regras de produção é usualmente tanto mais simples que a árvore de decisão da qual ele foi obtido, quanto mais acurado quando da classificação de casos não vistos. A transformação em regras de produção também provê uma maneira de combinação de árvores de decisão diferentes para o mesmo domínio de classificação.

O programa C4.5, desenvolvido por Quinlan (1993), tem toda sua teoria descrita em livro, incluindo os programas fontes, o que permitiu sua rápida disseminação. Este programa possui um módulo de geração de regras, estas geradas a partir da árvore de decisão criada pelo módulo gerador de árvores de decisão.

5 MATERIAL E MÉTODOS

5.1 Área de estudo

A área de estudo está localizada no Estado do Paraná, na região conhecida por Campos Gerais. Esta área foi selecionada levando-se em consideração a diversidade de espécies vegetais presentes na região. O trabalho concentrou-se em alguns dos municípios, dentre aqueles que compõem a região dos Campos Gerais, a saber: Ponta Grossa, Carambeí, Castro, Imbaú, Ortigueira, Palmeira, Telêmaco Borba, Tibagi e Ventania. A Figura 10 exibe a localização da área de estudo.

Em termos de localização geográfica, considerou-se a área de estudo dividida em duas cenas, na qual a primeira, tendo como referência o Município de Ponta Grossa, ficou delimitada pelas coordenadas UTM 570000 e 620000 m E, 7180000 e 7282000 m S, Datum SAD-69. A segunda, tendo como referência o Município de Telêmaco Borba, ficou delimitada pelas coordenadas UTM 506000 e 598000 m E, 7280000 e 7348000 m S, Datum SAD-69.

A região dos Campos Gerais recebeu originalmente este nome devido a sua caracterização fitogeográfica natural, com campos limpos e matas galerias ou capões isolados de floresta ombrófila mista, onde aparece o pinheiro araucária. O clima é do tipo subtropical úmido, com verão brando e, no inverno, geadas. As altitudes variam de 800 m a 1200 m, aproximadamente.

Quanto à geomorfologia, a região caracteriza-se por estar situada no segundo planalto paranaense, denominado Planalto de Ponta Grossa ou Planalto dos Campos Gerais. Este planalto está naturalmente limitado pela escarpa Devoniana, a leste, e pela escarpa da Esperança (Serra Geral), a oeste. A estrutura geológica e natureza das rochas são responsáveis pelos solos rasos e arenosos, pouco férteis.

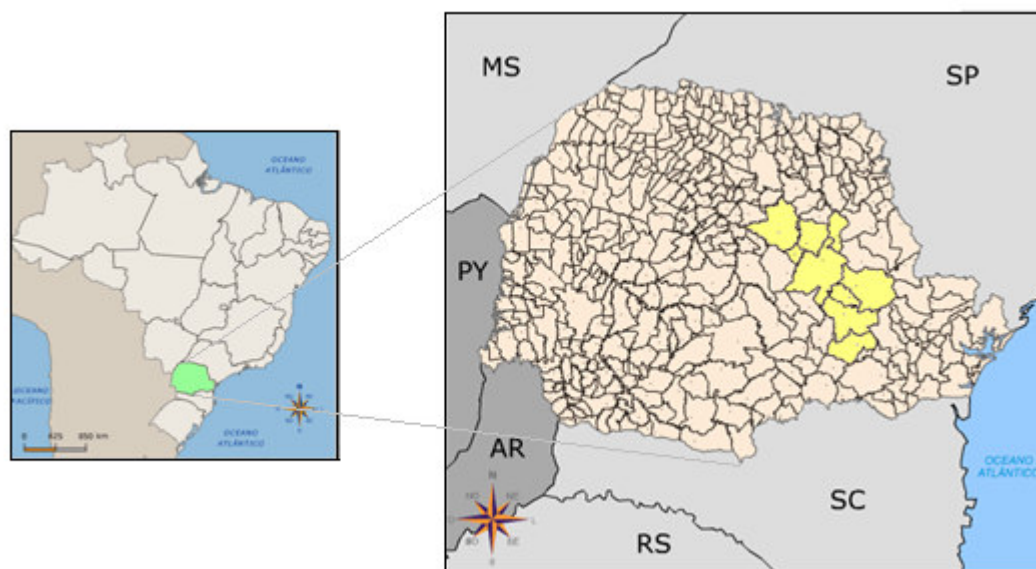


Figura 10 – Localização da área de estudo

É uma região de agricultura intensa, na qual se utiliza o sistema de plantio direto. Prevalece o plantio da soja e do milho no verão e, em escala menor, do sorgo e do feijão. No inverno, predomina a cultura do trigo e, em menor escala, culturas como triticales, centeio, cevada, girassol, canola, nabo forrageiro, aveia preta e aveia branca. Há também, na região, a ocorrência de pastagens utilizadas na criação de gado. A região possui, ainda, grandes áreas de reflorestamento de pinus e de eucalipto, principalmente no município de Telêmaco Borba e entorno.

5.2 Materiais

5.2.1 Equipamentos

Os experimentos foram conduzidos utilizando-se um computador com processador Pentium D/3.40 GHz, com 2.00 GB de RAM e disco rígido de 160 GB.

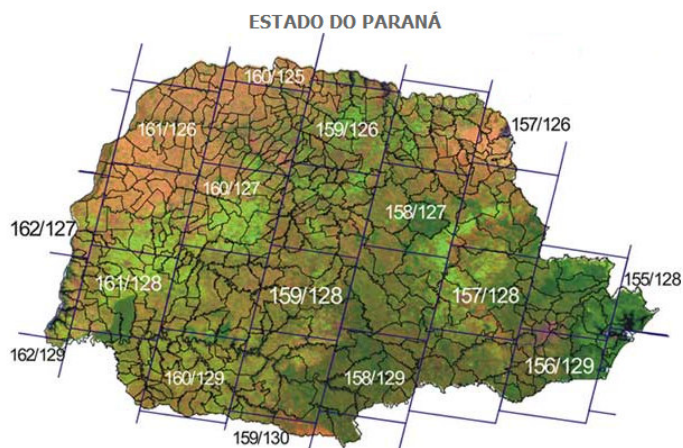
Na coleta de amostras de verdade terrestre, tanto para serem utilizadas no treinamento dos classificadores quanto na avaliação da acurácia, foi utilizado um aparelho GPS de navegação da marca Garmin eMap, do Departamento de Solos da FCA/UNESP.

5.2.2 Programas computacionais

Para o processamento dos dados de sensoriamento remoto, em todas as etapas foi utilizado o sistema de informações geográficas SPRING (CÂMARA et al., 1996), versão 4.3.2 e, para a Classificação por Árvore de Decisão, o programa See5 (Quinlan, 1993).

5.2.3 Dados de sensoriamento remoto

Os dados de sensoriamento remoto foram obtidos junto ao Catálogo de Imagens disponibilizado no sítio do INPE na internet (INPE, 2007). A Figura 11 exibe a grade de cenas dos satélites CBERS. Foram utilizadas as cenas 157/128 e 158/127 do sensor CCD (bandas 1, 2, 3 e 4), referentes às datas de passagem 07/03/2007 e 02/09/2007, respectivamente.



Fonte: Engesat (2008)

Figura 11 – Grade de cenas do satélite CBERS-2, Estado do Paraná

5.3 Métodos

A metodologia adotada pode ser observada de forma resumida na forma de fluxograma (Figura 12). Os tópicos a seguir detalham as etapas adotadas na metodologia, que foi aplicada a cada uma das cenas em estudo.

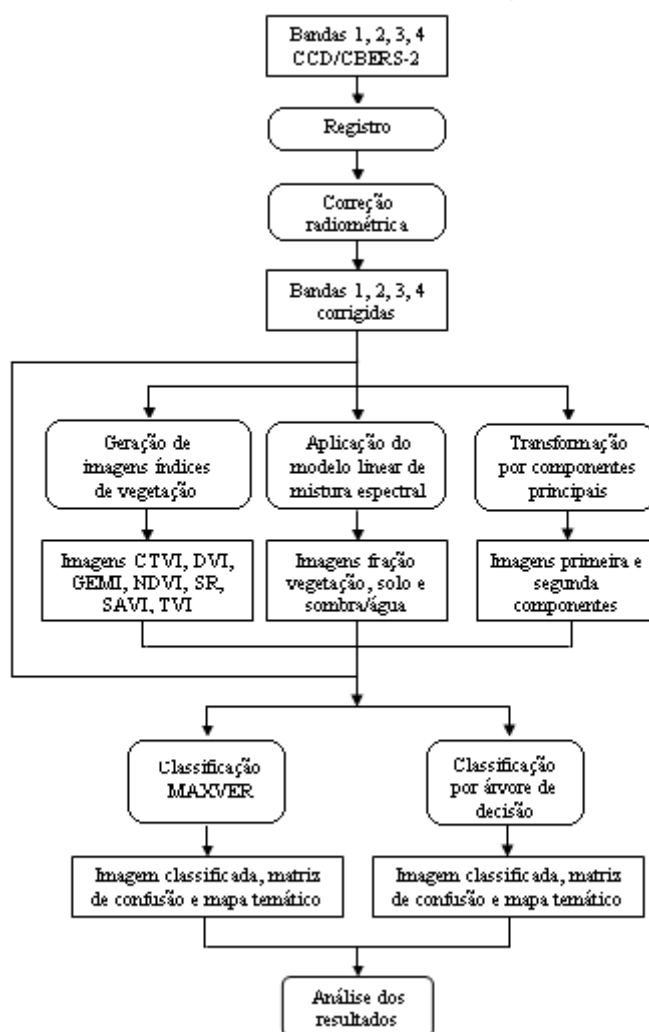


Figura 12 – Fluxograma metodológico do processo utilizado para discriminação de classes de uso do solo em imagens do satélite CBERS-2

5.3.1 Aquisição e registro das imagens

Imagens das regiões de estudo, do satélite CBERS-2, sensor CCD, foram selecionadas por meio do catálogo disponível no sítio do INPE (2007) na internet, com correção geométrica de sistema. A seleção obedeceu a dois critérios: a inexistência de nuvens na região de estudo e datas de passagem em acordo com as épocas de cultura de inverno e de verão. Uma vez obtidas as imagens, estas foram convertidas para o formato GRIB pelo módulo IMPIMA do SPRING (CÂMARA et al., 1996), que é o formato de leitura do SPRING.

As cenas destacadas na Figura 11 (157/128 e 158/127) foram recortadas com o objetivo de delimitar áreas de grande atividade agrícola e subsequente variedade de cobertura vegetal. A primeira, de 07/03/2007 (Figura 13), tendo como referência o Município de Ponta Grossa, ficou delimitada pelas coordenadas UTM 570000 e 620000 m E, 7180000 e 7282000 m S, Datum SAD-69. A segunda, de 02/09/2007 (Figura 14), tendo como referência o Município de Telêmaco Borba, ficou delimitada pelas coordenadas UTM 506000 e 598000 m E, 7280000 e 7348000 m S, Datum SAD-69.




Figura 13 – Composição colorida R3G4B2 da cena 157/128 do sensor CCD/CBERS-2, de 07/03/2007




Figura 14 – Composição colorida R3G4B2 da cena 158/127 do sensor CCD/CBERS-2, de 02/09/2007

Para eliminar o erro de posicionamento das imagens com correção de sistema e refinar o erro interno, as imagens passaram pelo processo de registro ou georreferenciamento. O procedimento de registro adotado neste trabalho – um dos modos de registro possíveis pelo SPRING – utiliza uma imagem georreferenciada e ortorretificada para servir de referência. A imagem de referência foi obtida gratuitamente por meio de sítio, da internet, de distribuição de imagens Landsat para pesquisadores e outros grupos de interesse (LANDSAT, 2007).

No processo de registro, pontos de controle da imagem de referência foram adquiridos e relacionados a pontos homólogos reconhecidos na imagem a ser registrada. Os pontos de controle adquiridos foram selecionados com base no erro calculado e apresentado, considerando-se o grau do polinômio usado no registro.

A escolha do grau do polinômio e do número de pontos de controle, em função do erro apresentado, obedeceu às recomendações para o usuário do software SPRING. Desta forma, para a cena 157/128, foram selecionados 15 pontos de controle e polinômio de 3.º grau, obtendo-se 0,2 *pixel* de erro, aproximadamente. Para a imagem

158/127, foram selecionados 14 pontos de controle e polinômio de 3.º grau, obtendo-se, aproximadamente, 0,3 *pixel* de erro.

5.3.2 Processamento das imagens

Nesta etapa, as imagens correspondentes às duas cenas em estudo foram processadas a fim de realizar a correção radiométrica e também de gerar o conjunto de atributos a ser utilizado na etapa de classificação.

Após o registro, foi realizada a etapa de correção radiométrica, incluindo os procedimentos de conversão dos números digitais (DN) para valores de reflectância aparente e de correção atmosférica. Estes procedimentos foram realizados por meio de programas escritas na linguagem de programação LEGAL (Linguagem Espacial de Geoprocessamento Algébrico) do SPRING (CÂMARA et al., 1996).

A conversão para valores de reflectância aparente foi realizada de acordo com o método proposto por Markham e Barker (1986), usando os coeficientes de calibração absoluta da câmara CCD/CBERS-2 apresentados por Ponzoni et al. (2006). Esta conversão foi aplicada a cada uma das quatro bandas utilizadas (Apêndice 1).

Após a conversão para valores físicos, foi realizada a correção atmosférica pelo método de correção atmosférica pelo *pixel* escuro (CHAVEZ, 1988). Os valores subtraídos de cada banda foram obtidos observando-se os respectivos histogramas, no SPRING. Esta conversão foi realizada por meio de um programa escrito em LEGAL (Apêndice 2).

Nas imagens resultantes da correção radiométrica, foram aplicados os índices de vegetação: CTVI, DVI, GEMI, NDVI, SR, SAVI e TVI. Destes, os índices DVI, NDVI e SR foram gerados pelo módulo de operações aritméticas do SPRING. Os demais foram determinados a partir de programas escritos na linguagem LEGAL do SPRING (Apêndices 3 a 6).

Além dos índices de vegetação, transformações foram efetuadas nas imagens resultantes da correção radiométrica, a fim de permitir a melhor discriminação entre as classes. Foram geradas as imagens resultantes da aplicação da transformação por

componentes principais e do modelo linear de mistura espectral, por meio do SPRING. A partir das bandas 2, 3 e 4, foram geradas as imagens fração vegetação, solo e sombra/água. Utilizando-se as mesmas bandas, foram geradas as componentes primeira, segunda e terceira aplicando-se a transformação por componentes principais, sendo que a terceira componente foi desprezada por corresponder essencialmente a ruído.

5.3.3 Coleta de dados de verdade terrestre

Foram realizadas saídas de campo a fim de identificar as diferentes culturas existentes bem como sua distribuição nas áreas de estudo. A coleta foi realizada utilizando-se um aparelho GPS de navegação para individualizar as amostras, buscando-se atingir a diversidade de culturas presente nas regiões de estudo.

Para assegurar uma determinação adequada da acurácia, tomou-se o cuidado de escolher o maior número de áreas de treinamento e de teste possível, de forma dispersa pela área de estudo, conforme as recomendações destacadas por Lillesand e Kiefer (1994) e por Schowengerdt (1983).

As informações coletadas serviram de base para a definição das classes de cobertura vegetal bem como para a definição dos conjuntos de amostras de treinamento para a classificação e de teste para a verificação da acurácia do Classificador Árvore de Decisão. Os dados foram coletados em datas próximas às datas de passagem do satélite das imagens selecionadas para garantir confiabilidade às amostras.

A definição das classes buscou um nível discriminatório elevado, considerando as imagens de resolução média utilizadas no estudo. Alguns tipos de culturas específicos foram aglutinados em uma única classe devido à dificuldade de se obter amostras representativas dessas culturas. Foi o caso da cultura da aveia no período de inverno, na região de estudo, que é usada como cobertura do solo. Esta aparece, na maioria das vezes, consorciada com nabo forrageiro ou ervilhaca. Durante a amostragem, nem sempre é possível perceber as diferenças entre essas subclasses, de forma que foi considerada apenas uma classe denominada aveia.

No caso do sorgo e do milho, essas espécies foram aglutinadas em uma única classe devido às semelhanças espectrais existentes e também pelo fato de apresentarem, à época da aquisição da cena pelo satélite, uma quantidade de amostras pequena, estando já em fase de final de safra.

Para o pasto, foi considerada uma única classe, nos dois períodos de estudo, devido à dificuldade de estabelecer subclasses já que, numa mesma área ou talhão, o pasto se apresentava heterogêneo, especialmente ao final do verão.

5.3.4 Determinação das classes de cobertura do solo

As classes de mapeamento e cobertura do solo foram determinadas com base nas características da vegetação e das culturas presentes na região de estudo. Para o período de verão, foram estabelecidas as classes: corpos d'água, solo exposto, eucalipto, pinus, mata natural, sorgo-milho, pasto, soja, feijão e área urbana. Para o período de inverno, foram consideradas as classes: corpos d'água, solo exposto, eucalipto, pinus, araucária, mata natural, trigo, aveia, pasto e área urbana.

5.3.5 Classificação das imagens e mapeamento

Antes da classificação propriamente dita, o treinamento supervisionado foi realizado no SPRING, com base na amostragem realizada em campo e nas classes de cobertura estabelecidas. Imagens relativas ao treinamento são apresentadas no próximo capítulo.

Para a etapa de classificação foi considerado o conjunto característico com dezesseis (16) atributos: as bandas corrigidas 1, 2, 3 e 4, os índices de vegetação CTVI, DVI, GEMI, NDVI, SR, SAVI e TVI, as imagens fração vegetação (MME_vegetação), solo (MME_solo) e sombra/água (MME_água), e as componentes primeira (CP1) e segunda (CP2) derivadas da transformação por componentes principais.

A classificação MAXVER foi executada no SPRING a partir das amostras de treinamento selecionadas, utilizando-se diversas combinações

de atributos e analisando-se a acurácia obtida a partir de cada combinação. Após a classificação, foi gerado o mapa de classes de cobertura no SPRING.

Para a Classificação por Árvore de Decisão, foram gerados os conjuntos de amostras de treinamento e de teste, cada qual com duzentas amostras, sendo que cada amostra se constituiu em um vetor característico com dezesseis atributos da imagem. Essas amostras foram obtidas a partir do conjunto de treinamento gerado no SPRING para o classificador MAXVER, a fim de que as amostras utilizadas nos dois classificadores pertencessem à mesma localização na imagem, para fins de comparação.

Os arquivos de amostras de treinamento e de teste, juntamente com o arquivo contendo a definição dos dezesseis atributos e das classes, foram utilizados no programa See5 para a geração do Classificador Árvore de Decisão, a partir dos valores *default*⁴ de todas as opções apresentadas na caixa de diálogo do programa. A partir do classificador obtido, foram implementadas rotinas em LEGAL, no SPRING, para classificar a imagem e gerar o mapa de cobertura (Apêndices 7 a 10).

5.3.6 Avaliação

A análise estatística dos resultados de classificação obtidos pelos classificadores foi feita com base na matriz de erros de classificação, ou matriz de confusão, obtida de cada classificação. A análise estendeu-se também à acurácia total, às acurácias individuais de cada classe e ao coeficiente *kappa* (LILLESAND; KIEFER, 1994), obtidos a partir dos valores da matriz de confusão.

⁴ O termo *default* refere-se a uma escolha padrão, a qual é feita automaticamente pelo programa quando o usuário não especifica uma opção.

6 RESULTADOS E DISCUSSÃO

Foi realizada a aplicação dos métodos de classificação de imagens digitais MAXVER e árvore de decisão nas duas cenas consideradas no estudo. Anteriormente à classificação, foi realizado o treinamento supervisionado a partir da amostragem feita em trabalho de campo e das classes de cobertura estabelecidas.

Os resultados da classificação das cenas foram analisados com base na matriz de erros de classificação ou matriz de confusão. A partir das imagens classificadas, foram gerados os mapas temáticos correspondentes.

6.1 Determinação das amostras de treinamento

O conjunto de amostras foi obtido a partir do treinamento supervisionado, realizado por meio do SIG SPRING. As amostras foram individualizadas nas cenas 157/128 e 158/127 a partir de sua localização geográfica, a qual foi determinada pela utilização de aparelho GPS de navegação durante o trabalho de campo.

A Figura 15 exemplifica o processo de treinamento supervisionado, exibindo amostras relativas às culturas presentes em uma área da Fazenda Escola Capão da Onça, pertencente à Universidade Estadual de Ponta Grossa. A imagem exibida é um recorte monocromático da cena 157/128, banda 4.




Figura 15 – Recorte monocromático da cena 157/128 relativo ao conjunto de amostras de treinamento localizadas na Fazenda Capão da Onça, pertencente à Universidade Estadual de Ponta Grossa

6.2 Discriminação da cena 157/128

6.2.1 Classificação pelo algoritmo MAXVER

Em relação à cena 157/128, a classificação realizada pelo algoritmo MAXVER usando combinações feitas a partir do conjunto característico contendo os dezesseis atributos (bandas corrigidas 1, 2, 3 e 4; índices de vegetação CTVI, DVI, GEMI, NDVI, SR, SAVI e TVI; imagens fração vegetação, solo e sombra/água; componentes primeira e segunda derivadas da transformação por componentes principais) resultou em diferentes valores para as acurácias. O melhor resultado, entretanto, foi obtido considerando-se somente as quatro bandas corrigidas, sendo a respectiva matriz de erros de classificação apresentada na Tabela 7.

Quanto à avaliação do resultado da classificação, a acurácia total foi igual a 84,86% e o coeficiente *kappa* foi 0,8099, sendo este último considerado excelente de

acordo com a classificação de Landis e Koch (1977). Entretanto, os valores das acurácias das classes relativas às culturas – eucalipto, sorgo/milho, feijão e soja – e também à classe pasto, foram inferiores a 70%. Observou-se claramente confusão entre as classes mata e eucalipto, mata e pinus, pasto e sorgo/milho, soja e pasto, além de feijão, soja e pasto, expressa por meio da acurácia do produtor, que indica quão bem os *pixels* foram classificados para determinada classe. Este fato também pode ser observado por meio do erro de omissão das classes.

Tabela 7 – Matriz de erros de classificação relativa ao Classificador MAXVER, cena 157/128

Classificação	Dados de referência										Total	Acurácia do usuário
	AG	EU	SM	PI	MA	SO	PA	AU	SJ	FE		
Água (AG)	278	0	0	0	0	0	0	0	0	0	278	100,00%
Eucalipto (EU)	0	12	0	2	0	0	0	0	0	0	14	85,71%
Sorgo/milho (SM)	0	0	8	0	0	0	12	0	0	4	24	33,33%
Pinus (PI)	0	0	0	108	24	0	0	0	0	0	132	81,82%
Mata (MA)	0	28	1	2	250	0	0	0	0	0	281	88,97%
Solo (SO)	0	0	0	0	0	42	0	0	0	0	42	100,00%
Pasto (PA)	0	0	43	0	0	0	22	0	21	4	90	24,44%
Área urbana (AU)	0	0	0	0	0	0	0	26	0	1	27	96,30%
Soja (SJ)	0	0	0	0	0	0	0	0	43	0	43	100,00%
Feijão (FE)	0	0	0	0	0	0	0	0	0	7	7	100,00%
Total	278	40	52	112	274	42	34	26	64	16	938	
Acurácia do produtor	100,00%	30,00%	15,38%	96,43%	91,24%	100,00%	64,71%	100,00%	67,19%	43,75%		
Acurácia total = 84,86%		Kappa = 80,99%										

O erro de inclusão ou comissão, assim como a acurácia do usuário, também são indicadores da qualidade da classificação. Estas medidas indicam a probabilidade de um *pixel* classificado para uma determinada classe de fato pertencer a esta classe. Com relação às classes eucalipto, mata, pasto, pinus e sorgo/milho, verificaram-se erros de inclusão superiores a 10%.

Analisando outras combinações de atributos verificou-se acurácias totais superiores a 80% para diversas combinações, envolvendo as bandas corrigidas, as imagens fração, as componentes primeira e segunda, e os índices GEMI, NDVI, SAVI e TVI. Todavia, as acurácias individuais de cada classe, em especial das classes de interesse, em

geral, não melhoraram. Quanto às combinações envolvendo os demais índices de vegetação em conjunto, não houve melhora nos resultados em termos de acurácia total nem individual de cada classe.

A Figura 16 exibe o mapa temático correspondente à classificação MAXVER realizada a partir das quatro bandas corrigidas, a qual apresentou o maior valor para a acurácia total assim como, para as acurácias relativas às culturas agrícolas.




Figura 16 – Mapa temático resultante da classificação MAXVER, relativo à cena 157/128

A análise visual do mapa temático, com base no trabalho de campo realizado, confirma a presença de áreas de reflorestamento de pinus em diversos pontos e também a mata natural da região de Itaiacoca, distrito do Município de Ponta Grossa, que se

destaca à direita. Da mesma forma, visualiza-se a confusão entre diversas classes, especialmente envolvendo as classes sorgo/milho e pasto.

As classes eucalipto, sorgo/milho e feijão apresentaram um número de amostras de referência menor em relação às outras classes porque ocorreram em menor quantidade na cena 157/128. Este fato pode explicar a confusão e os erros relativos a essas classes.

À época da aquisição da cena 157/128, o pasto apresentava-se heterogêneo, por tratar-se de final da estação de verão, fato que foi observado durante as visitas a campo. Na matriz de erros de classificação correspondente, a classe pasto apresentou erro de inclusão igual a 75,56% e confusão com a classe sorgo/milho.

6.2.2 Classificação pelo algoritmo **Árvore de Decisão**

As saídas resultantes da aplicação do algoritmo árvore de decisão, a partir do conjunto de treinamento, correspondem à árvore de decisão ou classificador, à matriz de erros de classificação relativa aos dados de teste, assim como informação relativa à contribuição individual dos atributos para o classificador. A Tabela 8 apresenta a matriz de erros de classificação relativa ao conjunto de teste, que corresponde a casos não usados no treinamento, para a cena 157/128.

Ressalta-se que estes resultados foram obtidos considerando-se os valores *default*⁵ para as opções da caixa de diálogo do programa See5, visto que os resultados foram satisfatórios para os mesmos. Nesta situação, fica habilitado o recurso de poda da árvore em até 25%, e o número mínimo de casos de treinamento estabelecido para os ramos igual a 2.

A acurácia total obtida a partir do Classificador Árvore de Decisão foi de 94,50%, superior à acurácia obtida pelo classificador MAXVER para a mesma cena (84,86%). Da mesma forma, o valor do coeficiente *kappa*, igual a 0,9389, foi superior. De acordo com Landis e Koch (1977), este valor é considerado excelente. Algumas acurácias

⁵ O termo *default* refere-se a uma escolha padrão, a qual é feita automaticamente pelo programa quando o usuário não especifica uma opção.

individuais de cada classe foram igualmente superiores, permitindo uma melhor discriminação entre as classes. Para as classes feijão, soja, pasto, solo, mata, sorgo/milho e eucalipto, verificou-se uma melhora importante. Os erros de omissão e inclusão ficaram abaixo de 10%, com exceção das classes mata (omissão: 13,64%), eucalipto e pasto (inclusão: 15,00%).

Tabela 8 – Matriz de erros de classificação relativa ao Classificador Árvore de Decisão, cena 157/128

Classificação	Dados de referência										Total	Acurácia do usuário
	AG	EU	SM	PI	MA	SO	PA	AU	SJ	FE		
Água (AG)	19	0	0	0	0	1	0	0	0	0	20	95,00%
Eucalipto (EU)	0	17	0	1	2	0	0	0	0	0	20	85,00%
Sorgo/milho (SM)	0	0	19	0	0	0	1	0	0	0	20	95,00%
Pinus (PI)	0	0	0	19	1	0	0	0	0	0	20	95,00%
Mata (MA)	0	1	0	0	19	0	0	0	0	0	20	95,00%
Solo (SO)	0	0	0	0	0	19	0	0	0	0	20	95,00%
Pasto (PA)	0	0	1	0	0	0	17	0	1	1	20	85,00%
Área urbana (AU)	0	0	0	0	0	0	0	20	0	0	20	100,00%
Soja (SJ)	0	0	0	0	0	0	0	0	20	0	20	100,00%
Feijão (FE)	0	0	0	0	0	0	0	0	0	20	20	100,00%
Total	21	18	18	21	21	19	20	22	20	20	200	
Acurácia do produtor	100,00%	94,44%	95,00%	90,48%	86,36%	95,00%	94,44%	100,00%	95,24%	95,24%		
Acurácia total = 94,50%		Kappa = 93,89%										

Comparados aos resultados obtidos por Fonseca et al. (2001) com os classificadores MAXVER e ISOSEG, que buscaram a categorização nas classes milho, sorgo, cana-de-açúcar, pasto, sem vegetação, água e floresta, as acurácias total e individual das classes foram superiores. Os autores utilizaram como atributos as bandas 3, 4 e 5 do sensor TM/Landsat 5, obtendo acurácias totais de 54,4% e 50%, respectivamente, para os classificadores MAXVER e ISOSEG.

No processo de geração do classificador, a cada passo é selecionado o atributo que maximiza a razão de ganho, a partir do conjunto de dezesseis atributos. A Tabela 9 relaciona os atributos selecionados na construção da árvore e seu porcentual de contribuição para a mesma.

Tabela 9 – Emprego dos atributos selecionados na construção da árvore de decisão, relativo à cena 157/128

Percentual	Atributo
100%	NDVI
90%	MME_água
60%	Banda4
41%	Banda2
32%	GEMI
30%	CP1
27%	Banda1
11%	CP2
4%	DVI

A árvore de decisão obtida (Figura 17), ou classificador, explicita de forma simples e clara como é feita a classificação dos *pixels* de toda a imagem a partir do conjunto de treinamento. O classificador obtido foi traduzido em um programa em linguagem de programação LEGAL (Apêndice 7) para classificar a imagem. A Figura 18 exhibe o mapa temático correspondente à classificação utilizando o Classificador Árvore de Decisão, para a cena 157/128, de 07/03/2007.

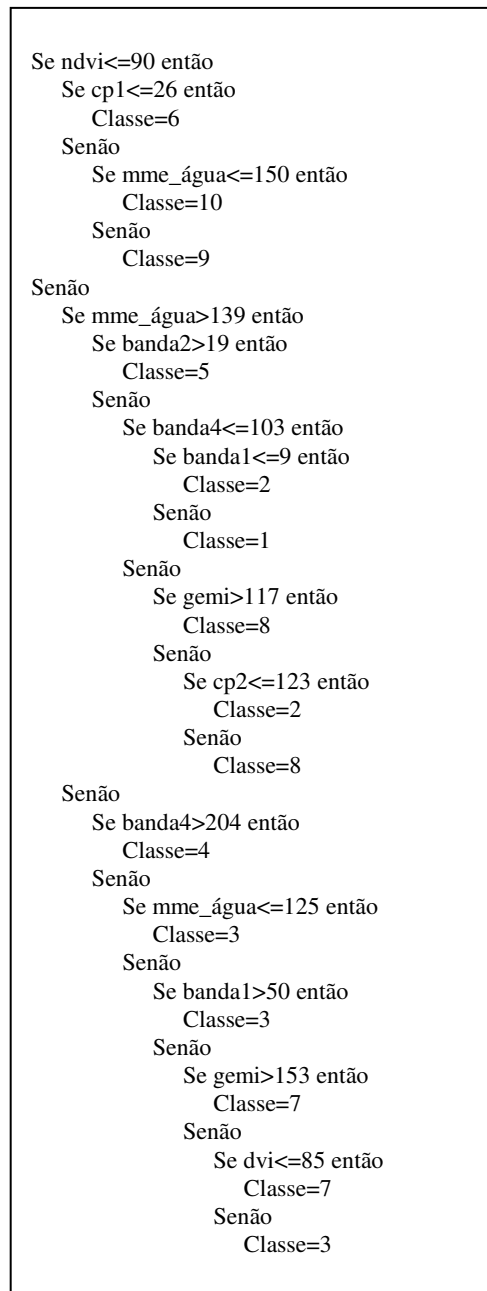


Figura 17 – Árvore decisão obtida a partir das amostras de treinamento, relativa à cena 157/128

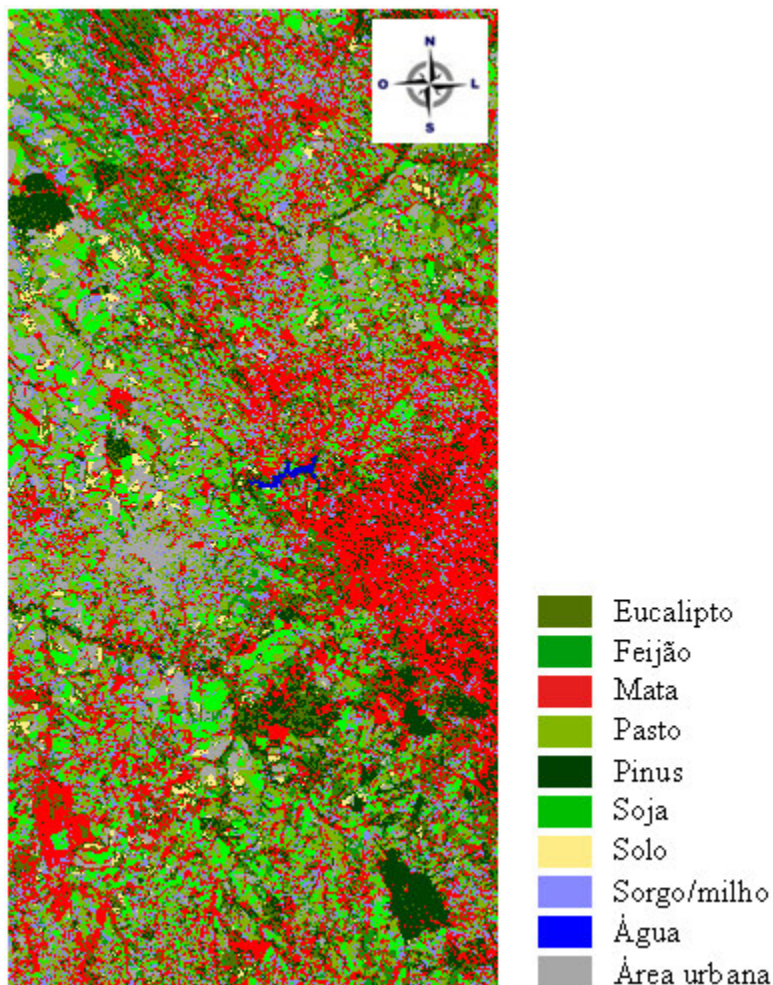


Figura 18 – Mapa temático resultante da classificação por árvore de decisão, relativo à cena 157/128

6.3 Discriminação da cena 158/27

6.3.1 Classificação pelo algoritmo MAXVER

O mesmo procedimento metodológico foi aplicado à cena 158/127, de 02/09/2007, considerados os mesmos dezesseis atributos, resultando na matriz de erros de classificação exibida na Tabela 10. Da mesma forma que para a cena 157/128, os melhores resultados também ocorreram para a classificação realizada a partir das quatro bandas

corrigidas. Outras combinações de atributos não resultaram em melhores resultados quanto à acurácia.

Embora o valor da acurácia total obtido seja de 77,90%, as classes aveia, araucária e área urbana apresentaram acurácias individuais inferiores a 60%. Ficaram evidentes as confusões entre as classes araucária e pinus, eucalipto e pinus, assim como aveia e trigo. Os erros de omissão das classes aveia, trigo, eucalipto, pinus, araucária e área urbana ficaram acima de 10%, sendo os mais elevados relativos às classes aveia e araucária.

Os menores valores para a acurácia do usuário ocorreram para as classes pinus e araucária, com respectivos erros de inclusão maiores, indicando uma menor probabilidade de um *pixel* pertencer a estas classes, de fato.

Tabela 10 – Matriz de erros de classificação relativa ao Classificador MAXVER, cena 158/127

Classificação	Dados de referência										Total	Acurácia do usuário
	AV	TR	EU	PI	AR	MA	SO	PA	AU	AG		
Aveia (AV)	16	1	2	0	0	3	0	0	0	0	22	72,73%
Trigo (TR)	21	73	7	0	0	0	0	0	0	0	101	72,28%
Eucalipto (EU)	0	8	53	6	0	2	0	0	0	0	69	76,81%
Pinus (PI)	0	0	8	34	18	1	0	0	0	0	61	55,74%
Araucária (AR)	0	0	0	9	11	0	0	0	0	0	20	55,00%
Mata (MA)	0	0	6	1	0	88	0	1	0	0	96	91,67%
Solo (SO)	0	0	0	0	0	0	64	3	11	0	78	82,05%
Pasto (PA)	6	0	0	0	0	0	0	42	0	0	48	87,50%
Área urbana (AU)	0	0	0	0	0	0	4	0	13	0	17	76,47%
Água (AG)	0	0	0	0	0	0	0	0	0	22	22	100,00%
Total	43	82	76	50	29	94	68	46	24	22	534	
Acurácia do produtor	37,21%	89,02%	69,74%	68,00%	37,93%	93,62%	94,12%	91,30%	54,17%	100,00%		
Acurácia total = 77,90%		Kappa = 74,76%										

O mapa temático resultante da classificação MAXVER aplicada à cena 158/127 é exibido na Figura 19. Da análise visual do mapa temático correspondente à classificação MAXVER para esta cena, é possível perceber a área de reflorestamento no entorno do Município de Telêmaco Borba. Entretanto, nesta área, a espécie predominante é o

pinus, seguido do eucalipto e em menor escala a araucária, o que não ocorre no mapa resultante. De fato, a matriz de erros de classificação expressa confusão entre essas classes.




Figura 19 – Mapa temático resultante da classificação MAXVER, relativo à cena 158/127

6.3.2 Classificação pelo algoritmo Árvore de Decisão

Para a cena 158/127, de 02/09/2007, que corresponde ao período de inverno, os resultados obtidos da aplicação da classificação por árvore de decisão foram superiores em relação ao classificador MAXVER, da mesma forma que ocorreu para a cena 157/128. A matriz de erros de classificação correspondente é exibida na Tabela 11. Para a obtenção desses resultados, foram utilizados os valores *default*⁶ do programa See5.

A acurácia total foi de 88%, superior àquela obtida pelo classificador MAXVER para a mesma cena (77,9%). Quanto às acurácias individuais de cada classe, os valores obtidos apresentaram valores superiores em relação ao Classificador MAXVER para a

⁶ O termo *default* refere-se a uma escolha padrão, a qual é feita automaticamente pelo programa quando o usuário não especifica uma opção.

mesma cena, para as classes aveia, trigo, eucalipto pinus, araucária, mata e área urbana. Do ponto de vista dos erros de omissão e inclusão, estes apresentaram valores relativamente menores para a mesma cena, em relação à classificação MAXVER. As classes pinus e araucária foram as que apresentaram maior confusão.

Tabela 11 – Matriz de erros de classificação relativa ao Classificador Árvore de Decisão, cena 158/127

Classificação	Dados de referência										Total	Acurácia do usuário
	V	R	U	I	R	A	O	A	U	G		
Aveia (AV)	19	1	0	0	0	0	0	0	0	0	20	95,00%
Trigo (TR)	1	19	0	0	0	0	0	0	0	0	20	95,00%
Eucalipto (EU)	0	0	20	0	0	0	0	0	0	0	20	100,00%
Pinus (PI)	0	0	0	13	6	1	0	0	0	0	20	65,00%
Araucária (AR)	0	0	0	2	18	0	0	0	0	0	20	90,00%
Mata (MA)	0	0	0	3	0	16	0	1	0	0	20	80,00%
Solo (SO)	0	0	0	0	0	0	15	2	3	0	20	75,00%
Pasto (PA)	1	0	0	0	0	0	0	19	0	0	20	95,00%
Área urbana (AU)	0	0	0	0	0	0	2	1	17	0	20	85,00%
Água (AG)	0	0	0	0	0	0	0	0	0	20	20	100,00%
Total	21	20	20	18	24	17	17	23	20	20	200	
Acurácia do produtor	90,48%	95,00%	100,00%	72,22%	75,00%	94,12%	88,24%	82,61%	85,00%	100,00%		
Acurácia total = 88,00%		Kappa = 86,67%										

A árvore de classificação obtida como saída é exibida na Figura 20, e a contribuição dos atributos da imagem na geração do classificador aparece na Tabela 12. Na Figura 21, é mostrado o mapa temático resultante da classificação pelo classificador gerado. Para a migração da imagem classificada para o mapa, foi feito um programa em linguagem de programação LEGAL no SPRING (Apêndice 10).

```

Se tvi>175 então
  Se banda2<=20 então
    Se mme_solo<=79 então
      Classe=5
    Senão
      Se mme_veget<=223 então
        Classe=4
      Senão
        Se banda4<=60 então
          Classe=5
        Senão
          Classe=4
    Senão
      Se banda4>66 então
        Se mme_solo<=142 então
          Se banda3<=30 então
            Classe=2
          Senão
            Classe=8
        Senão
          Se mme_veget<=227 então
            Classe=1
          Senão
            Classe=2
    Senão
      Se banda2>23 então
        Classe=8
      Senão
        Se banda3>25 então
          Classe=1
        Senão
          Se banda1<=22 então
            Classe=4
          Senão
            Classe=6
    Senão
      Se cp1<=96 então
        Classe=10
      Senão
        Se ctvi<=161 então
          Classe=3
        Senão
          Se mme_água<=64 então
            Classe=7
          Senão
            Se banda2<=27 então
              Classe=7
            Senão
              Se cp1<=121 então
                Classe=9
              Senão
                Se sr<=14 então
                  Classe=7
                Senão
                  Classe=9

```

Figura 20 – Árvore de Decisão obtida a partir das amostras de treinamento, relativa à cena 158/127

Tabela 12 – Emprego dos atributos selecionados na construção da árvore de decisão, relativo à cena 158/127

PERCENTUAL	ATRIBUTO
100%	TVI
76%	Banda2
47%	Banda4
40%	CP1
39%	MME_solo
30%	CTVI
23%	Banda3
20%	MME_vegetação
20%	MME_água
12%	Banda1
4%	SR




Figura 21 – Mapa temático resultante da classificação por árvore de decisão, relativo à cena 158/127

6.4 Considerações finais

A Tabela 13 resume os resultados relacionados à exatidão obtidos da aplicação dos métodos de classificação MAXVER e árvore de decisão em relação às duas cenas estudadas. Para as duas as cenas, o Classificador Árvore de Decisão resultou em uma maior acurácia total. O coeficiente *kappa*, que leva em conta também os valores da matriz de confusão que estão fora da diagonal principal, foi igualmente superior, indicando uma concordância maior em relação aos dados usados como referência.

Tabela 13 – Resultados obtidos (MAXVER X árvore de decisão)

Classificador	Cena 157/128 (07/-3/2007)		Cena 158/127 (02/09/2007)	
	Acurácia	<i>Kappa</i>	Acurácia	<i>Kappa</i>
	total		total	
MAXVER	84,86%	80,99%	77,90%	74,76%
Árvore de decisão	94,50%	93,89%	88,00%	86,67%

A partir da comparação entre as Tabelas 9 e 11, que exibem a contribuição dos atributos da imagem, em porcentual, na geração dos classificadores para as duas cenas, é possível verificar que os atributos utilizados não tiveram a mesma importância. A árvore de decisão define a categorização buscando um padrão para cada classe por meio das propriedades espectrais definidas pelos atributos da imagem, selecionando os atributos que melhor particionam o conjunto de treinamento. O conhecimento adquirido nesse processo fica expresso pela árvore de decisão gerada, de forma clara e simples.

Para o Classificador Árvore de Decisão, o uso de um amplo e variado conjunto de atributos demonstrou ser conveniente, enquanto que para o Classificador MAXVER isto não se verificou. Desta forma, é possível incorporar outros atributos, os quais podem ser adquiridos de outras fontes, de forma a garantir uma discriminação que mais se aproxime da realidade.

A metodologia utilizada para o mapeamento a partir de classificação por árvore de decisão incluiu dados de sensoriamento remoto e softwares disponíveis na internet, provendo uma forma simples para utilização e de resultados excelentes para a discriminação das classes presentes nas cenas de estudo.

7 CONCLUSÕES

O estudo mostrou a possibilidade de obtenção de um mapeamento da cobertura vegetal incluindo a discriminação entre culturas espectralmente próximas, a partir de dados de sensoriamento remoto de nível médio como o sensor CCD/CBERS-2, utilizando o Classificador Árvore de Decisão.

Em comparação ao Classificador MAXVER, verificaram-se resultados superiores em termos de acurácia total, bem como em relação às acurácias individuais das classes, especialmente daquelas relativas às culturas.

Os resultados demonstraram que a utilização de um grande número de atributos obtidos a partir das bandas do sensor é vantajosa para o Classificador Árvore de Decisão, que seleciona aqueles que melhor separam as classes durante o processo de geração da árvore de decisão.

O estudo evidenciou a necessidade de incorporar o Classificador Árvore de Decisão a um sistema de informações geográficas, a fim de facilitar o seu uso e permitir uma melhor funcionalidade para o usuário.

8 REFERÊNCIAS BIBLIOGRÁFICAS

ARCE, E. C.; RUDORFF, B. F. T.; BERKA, L. M. S.; PEREIRA, P. F. C. Imágenes Landsat e CBERS em la identificación del uso del suelo com cultivos agrícolas. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. Anais eletrônicos... São José dos Campos: INPE, 2005. Disponível em: <<http://www.dsr.inpe.br/sbsr2007/biblioteca/>>. Acesso em: 16 abr. 2007.

ASSAD, E. D.; SANO, E. E. **Sistema de informações geográficas: aplicações na agricultura**. 2. ed. Brasília: Embrapa-SPI/Embrapa-CPAC, 1998. 434p. (ISBN 857383045).

BREIMAN, L.; FRIEDMAN, J. H.; STONE, C. J.; OLSHEN, R. A. **Classification and regression trees**. California: Chapman & Hall/CRC, 1984. 368p. (ISBN 0412048418).

CÂMARA, G.; MEDEIROS, J. S. de. Princípios básicos em geoprocessamento. In: ASSAD, E. D.; SANO, E. E. **Sistema de informações geográficas: aplicações na agricultura**. 2. ed. Brasília: Embrapa-SPI/Embrapa-CPAC, 1998. cap. 1.

CÂMARA, G.; MONTEIRO, A. M. V. Conceitos básicos em ciência da geoinformação. In: CÂMARA, G.; DAVIS, C.; MONTEIRO, A. M. V. **Introdução à ciência da geoinformação**.

São José dos Campos: INPE, 2001. cap. 1. Disponível em: <<http://urlib.net/sid.inpe.br/sergio/2004/04.22.07.43>>. Acesso em: 10 mar. 2008.

CÂMARA, G.; SOUZA, R. C. M.; FREITAS, U. M.; GARRIDO, J. SPRING: integrating remote sensing and GIS by object-oriented data modelling. **Computers & Graphics**, v. 20, n. 3, p. 395-403, may./jun. 1996.

CELINSKI, T. M. **Métodos de agrupamento: uma abordagem comparativa com aplicação em segmentação de imagens de profundidade**, 1998. Dissertação. 142p. (Mestrado em Informática), Universidade Federal do Paraná – UFPR, Curitiba, 1998.

CHAVEZ, P. S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v. 24, n. 3, p. 459-479, 1988.

DAVIS, C.; CÂMARA, G. Arquitetura de sistemas de informação geográfica. In: CÂMARA, G.; DAVIS, C.; MONTEIRO, A. M. V. **Introdução à ciência da geoinformação**. São José dos Campos: INPE, 2001. cap. 3. Disponível em: <<http://urlib.net/sid.inpe.br/sergio/2004/04.22.07.43>>. Acesso em: 10 mar. 2008.

DWIVEDI, R. S.; KANDRIKA, S.; RAMANA, K. V. Comparison of classifiers of remote-sensing data for land-use/land-cover mapping. **Current Science**, v. 86, n. 2, p. 328-335, 25 jan. 2004.

ENGESAT, Web: http://www.engesat.com.br/produtos/grade_cbbers/pr_tm.htm. Acesso: 10 mar. 2008.

ESPOSITO, F.; MALERBA, D.; SEMERARO, G. A comparative analysis of methods for pruning decision trees. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 19, n. 5, p. 476-491, may. 1997.

FAYYAD, U. M.; PIATETSKY-SHAPIRO, G; SMYTH, P. From data mining to knowledge discovery: an overview. In: FAYYAD, U. M.; PIATETSKY-SHAPIRO, G; SMYTH, P;

UTHURUSAMY, R. **Advances in knowledge discovery and data mining**. MIT Press, 1996a. 560 p. (ISBN 0262560976).

FAYYAD, U.; PIATETSKY-SHAPIRO, G; SMYTH, P. From data mining to knowledge discovery in databases. **AI Magazine**, v. 17, n. 3, p. 37-54, Fall 1996b.

FAYYAD, U.; PIATETSKY-SHAPIRO, G; SMYTH, P. The KDD process for extracting useful knowledge from volumes of data. **Communications of de ACM**, v. 39, n. 11, p. 27-34, nov. 1996c.

FIGUEIREDO, S. M. de M.; CARVALHO, L. M. T. de. Análise comparativa entre técnicas de classificação digital em imagens Landsat no mapeamento do uso e ocupação do solo em Capixaba, Acre. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. Anais eletrônicos... São José dos Campos: INPE, 2007. Disponível em: <<http://www.dsr.inpe.br/sbsr2007/biblioteca/>>. Acesso em: 23 ago. 2007.

FIGUEIREDO, S. M. de M.; CARVALHO, L. M. T. de. Avaliação da exatidão do mapeamento da cobertura da terra em Capixaba, Acre, utilizando classificação por árvore de decisão. **Cerne**, v. 12, n. 1, p. 38-47, jan./mar. 2006.

FONSECA, E. L. da; OLIVEIRA, J. C. de; RIZZI, R. Avaliação da identificação de áreas agrícolas para fins de previsão de safras utilizando procedimentos de classificação digital de imagens do sensor TM/Landsat 5. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 10., 2001, Foz do Iguaçu. Anais eletrônicos... São José dos Campos: INPE, 2001. Disponível em: <<http://www.dsr.inpe.br/sbsr2007/biblioteca/>>. Acesso em: 16 nov. 2006.

FONSECA, L.; PONZONI, F.; CARTAXO, R. **Radiometric quality assessment of CBERS-2**. [S.I.] Deposited in the URLib collection, 2004. Official; Documents; (APPL-06-2004). Disponível em: <<http://urlib.net/dpi.inpe.br/banon/2006/08.03.19.18>>. Acesso em: 7 mar. 2008.

FREITAS, S. R.; CRUZ, C. B. M. Análise de componentes principais e modelo linear de mistura na discriminação de classes de vegetação na Mata Atlântica. In: SIMPÓSIO

BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. Anais eletrônicos... São José dos Campos: INPE, 2005. Disponível em: <<http://www.dsr.inpe.br/sbsr2007/biblioteca/>>. Acesso em: 9 abr. 2007.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. São Paulo: Ed. Edgard Blücher, 2000. 528p. (ISBN 8521202644).

HAN, J.; KAMBER, M. **Data mining: concepts and techniques**. Morgan Kaufmann, 2001. 550 p. (ISBN 1558604898).

HASHEMIAN, M. S.; ABKAR, A. A.; FATEMI, S. B. Study of sampling methods for accuracy assessment of classified remotely sensed data. In: ISPRS Congress, 20., 2004, Istanbul. Proceedings... Singapore, ISPRS, 2004. Disponível em: <<http://www.isprs.org/istanbul2004/comm4/comm4.html>>. Acesso em: 07 mar. 2008.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, p. 295-309, 1988.

HUETE, A. R.; JACKSON, R. D.; POST, D. F. Spectral response of plant canopies with different soil background. **Remote Sensing of Environment**, v. 17, p. 37-53, 1985.

INPE, Web: <http://www.cbbers.inpe.br/?content=index>. Acesso: 15 dez. 2007.

JORDAN, C. F. Derivation of leaf area index from quality of light on the forest floor. **Ecology**, v. 50, p. 663-666, 1979.

KING, R.; FENG, C.; SHUTHERLAND, A. StatLog: comparison of classification algorithms on large real-world problems. **Applied Artificial Intelligence**, v. 9, n. 3, p. 259-287, may./jun.1995. Disponível em: <<http://citeseer.ist.psu.edu/lim00comparison.html>>. Acesso em: 21 jun. 2007.

KOHAVI, R.; QUINLAN, J. R. Data mining tasks and methods: Classification: decision-tree discovery. In: **Handbook of data mining and knowledge discovery**. New York: Oxford University Press, 2002.

KUNTSCHIK, G.; GLERIANI, J. M. C.; PIVELLO, V. R. Coeficientes das componentes *greeness*, *brightness* e *wetness* da transformação Tasseled Cap para chernossolos da província de Buenos Aires, Argentina. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. Anais eletrônicos... São José dos Campos: INPE, 2007. Disponível em: <<http://www.dsr.inpe.br/sbsr2007/biblioteca/>>. Acesso em: 26 mar. 2008.

LANDIS, J.; KOCH, G. G. The measurements of agreement for categorical data. **Biometrics**, Washington, v. 33, n. 3, p. 159-179, mar. 1977.

LANDSAT, Web: <http://www.landsat.org>. Acesso: 10 mar. 2007.

LILLESAND, T. M.; KIEFER, R. W. **Remote sensing and image interpretation**. 3. ed. United States of América: John Wiley & Sons, 1994. 1040 p. (ISBN 8535211772).

LIM, T.-S.; LOH, W.-I.; SHIH, Y.-S. A comparison of prediction accuracy, complexity, and training time of thirty-three old and new classification algorithms. **Machine Learning**, Boston, v. 40, p. 203-229, 2000. Disponível em: <<http://citeseer.ist.psu.edu/lim00comparison.html>>. Acesso em: 18 out. 2007.

LIU, W. T. H. **Aplicações de sensoriamento remoto**. Campo Grande: UNIDERP, 2006. 881 p. (ISBN 8577040400).

LOH, W.-I.; SHIH, Y.-S. Split selection methods for classification trees. **Statistica Sinica**, v. 7, p. 815-840, 1997.

MARKHAM, B. L.; BARKER, J. L. Landsat MSS and TM post-calibration dynamic ranges, exoatmospheric reflectances and at-satellite temperatures. **EOSAT Landsat Technical Notes**, n. 1, p. 3-8, aug. 1986.

MITCHELL, T. M. **Machine learning**. McGraw-Hill, 1997. 432 p. (ISBN 0070428077).

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2001. 250 p. (ISBN 901991).

NILSSON, N. J. **Introduction to machine learning**: an early draft of a proposed textbook. Stanford: 1996. Disponível em: <<http://robotics.stanford.edu/people/nilsson/MLDraftBook/MLBOOK.pdf>>. Acesso em: 22 ago. 2007.

NOVO, E. M. L. de. **Sensoriamento remoto**: princípios e aplicações. 2. ed. São Paulo: Edgard Blücher, 1992. 328 p. (ISBN 8521200579).

OLIVEIRA, L. G. L. de; PEREIRA, L. M.; PEREIRA, G.; MORAES, E. C.; MAEDA, E. E. Estudo da variabilidade de índices de vegetação através de imagens do ETM+/LANDSAT 7. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. Anais eletrônicos... São José dos Campos: INPE, 2007. Disponível em: <<http://www.dsr.inpe.br/sbsr2007/biblioteca/>>. Acesso em: 14 abr. 2007.

PAL, M.; MATHER, P. M. Na assessment of the effectiveness of decision tree methods for land cover classification. **Remote Sensing of Environment**, v. 86, p. 554-565, 2003.

PERRY, C. R.; LAUTENSCHLAGER, L. F. Functional equivalence of spectral vegetation indices. **Remote Sensing of Environment**, v. 14, n. 1-3, p. 169-182, jan. 1984.

PINTY, B.; VERSTRAETE, M. M. GEMI: a non-linear index to monitor global vegetation form satellites. **Vegetation**, n. 101, p. 15-20, 1992.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos: Parêntese, 2007. 136 p. (ISBN 9788560507023).

PONZONI, F. J.; ZULLO JUNIOR, J.; LAMPARELLI, R. A. C. Calibração absoluta da câmera CCD/CBERS-2. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. Anais eletrônicos... São José dos Campos: INPE, 2005. Disponível em: <<http://www.dsr.inpe.br/sbsr2007/biblioteca/>>. Acesso em: 10 mar. 2008.

PONZONI, F. J.; ZULLO JUNIOR, J.; LAMPARELLI, R. A. C. Transformações radiométricas dos dados dos sensores do satélite CBERS-2. In: SIMPÓSIO DE

GEOTECNOLOGIAS NO PANTANAL, 1., 2006, Campo Grande. Anais eletrônicos... Campinas: Embrapa Informática Agropecuária; São José dos Campos: INPE, 2006. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m17@80/2006/12.08.13.51.31>>. Acesso em: 27 ago. 2007.

QUINLAN, J. R. **C4.5**: programs for machine learning. San Francisco, California: Morgan Kaufmann, 1993. 302 p. (ISBN 1558602380).

QUINLAN, J. R. Generating production rules from decision trees. In: INTERNATIONAL JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE, 10., 1987, Milan, Italy. Proceedings... Milan, Italy, Morgan Kaufmann, 1987. p. 304-307.

QUINLAN, J. R. Induction of decision trees. **Machine Learning**, v. 1, n. 1, p. 81-106, mar. 1986.

RICHARDSON, A. J.; WIEGAND, C. L. Distinguishing vegetation from soil background information. **Photogrammetric Engineering and Remote Sensing**, n. 43, p. 207-216, 1977.

ROUSE, J. W.; HASS, R. H.; SCHELL, J. A.; DEERING, D. W. **Monitoring the vernal advancement and retrogradation (Greenwave effect) of nature vegetation**. NASA/GSFCT Type III Final Report, 1974. 64p.

ROUSE, J. W.; HASS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In: SYMPOSIUM OF EARTH RESOURCES TECHNOLOGY SATELLITE, 3., 1973, Maryland, USA. Proceedings... Washington, Greenbelt, 1973. p. 309-317.

RUSSEL, S.; NORVIG, P. **Inteligência artificial**. Rio de Janeiro: Elsevier, 2004. 1040 p. Tradução da 2. ed. (ISBN 8535211772).

SAFAVIAN, S. R.; LANDGREBE, D. A survey of decision tree classifier methodology. **IEEE Transactions on Systems, Man and Cybernetics**, v. 21, n. 3, p. 660-674, may. 1991.

SCHOTT, J. R. **Remote sensing: the image chain approach**. New York: Oxford University Press, 1997. 394 p. (ISBN 0195087267).

SCHOWENGERDT, R. A. **Techniques for image processing and classification in remote sensing**. New York: Academic Press, 1983. 249 p. (ISBN 0126289808).

SERVELLO, E. L.; DISPERATI, A. A.; LOPES, A. L. de B.; SANTOS, J. R. dos; OLIVEIRA FILHO, P. C. de. Mapeamento de uso da terra na região Centro-Sul do Paraná com imagem CBERS a partir da técnica de modelo linear de mistura espectral. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. Anais eletrônicos... São José dos Campos: INPE, 2007. Disponível em: <<http://www.dsr.inpe.br/sbsr2007/biblioteca/>>. Acesso em: 23 ago. 2007.

SILVA, M. L. M. de; PEREIRA, G. P. M. Avaliação de algoritmos de classificação supervisionada para imagens do Cbers-2 da Região do Parque Estadual do Rio Doce-MG. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. Anais eletrônicos... São José dos Campos: INPE, 2007. Disponível em: <<http://www.dsr.inpe.br/sbsr2007/biblioteca/>>. Acesso em: 17 abr. 2007.

TAMBOSI, L. R.; IGARI, A. T.; RIBEIRO, M. C.; PIVELLO, V. R. Análise comparativa entre classificações realizadas a partir de imagens Landsat-7 ETM+ e CBERS-2 CCD. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. Anais eletrônicos... São José dos Campos: INPE, 2007. Disponível em: <<http://www.dsr.inpe.br/sbsr2007/biblioteca/>>. Acesso em: 21 nov. 2007.

TANAJURA, E. L. X.; ANTUNES, M. A. H.; UBERTI, M. S. Avaliação de índices de vegetação para a discriminação de alvos agrícolas em imagens de satélites. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. Anais eletrônicos... São José dos Campos: INPE, 2005. Disponível em: <<http://www.dsr.inpe.br/sbsr2007/biblioteca/>>. Acesso em: 09 abr. 2007.

TSO, B.; MATHER, P. M. **Classification methods for remotely sensed data.** London: Taylor & Francis, 2001. 332 p. (ISBN)

VENTURIERI, A.; SANTOS, J. R. dos. Técnicas de classificação de imagens para análise de cobertura vegetal. In: ASSAD, E. D.; SANO, E. E. **Sistema de informações geográficas: aplicações na agricultura.** 2. ed. Brasília: Embrapa-SPI/Embrapa-CPAC, 1998. cap. 18.

APÊNDICE

APÊNDICE 1 – Rotina de conversão de DN para reflectância aparente

```
{
//Declaração
Imagem b1 ("CCD");
Imagem b2 ("CCD");
Imagem b3 ("CCD");
Imagem b4 ("CCD");
Imagem novabanda1 ("CCD");
Imagem novabanda2 ("CCD");
Imagem novabanda3 ("CCD");
Imagem novabanda4 ("CCD");
//Instanciação
b1 = Recuperar (Nome = "Banda1");
b2 = Recuperar (Nome = "Banda2");
b3 = Recuperar (Nome = "Banda3");
b4 = Recuperar (Nome = "Banda4");
novabanda1 = Novo (Nome = "B1_ref_ap_", ResX=20, ResY=20);
novabanda2 = Novo (Nome = "B2_ref_ap", ResX=20, ResY=20);
novabanda3 = Novo (Nome = "B3_ref_ap", ResX=20, ResY=20);
novabanda4 = Novo (Nome = "B4_ref_ap", ResX=20, ResY=20);
//Operação
pi=3.1416;
a=1.0167;
b=46.4297*pi/180;
novabanda1 = ((3.1423 * (b1 / 1.009) * (a ^2)) / (1934.03 * cos(b))) * 350;
novabanda2 = ((3.1423 * (b2 / 1.930) * (a ^2)) / (1787.10 * cos(b))) * 350;
novabanda3 = ((3.1423 * (b3 / 1.154) * (a ^2)) / (1548.97 * cos(b))) * 350;
novabanda4 = ((3.1423 * (b4 / 2.127) * (a ^2)) / (1069.21 * cos(b))) * 350; }
```

APÊNDICE 2 – Rotina de correção atmosférica

```

{
//Declaração
Imagem b1 ("CCD");
Imagem b2 ("CCD");
Imagem b3 ("CCD");
Imagem b4 ("CCD");
Imagem novabanda1 ("CCD");
Imagem novabanda2 ("CCD");
Imagem novabanda3 ("CCD");
Imagem novabanda4 ("CCD");
//Instanciação
b1 = Recuperar (Nome = "B1_ref_ap");
b2 = Recuperar (Nome = "B2_ref_ap");
b3 = Recuperar (Nome = "B3_ref_ap");
b4 = Recuperar (Nome = "B4_ref_ap");
novabanda1 = Novo (Nome = "B1_corr_atm", ResX=20, ResY=20);
novabanda2 = Novo (Nome = "B2_corr_atm", ResX=20, ResY=20);
novabanda3 = Novo (Nome = "B3_corr_atm", ResX=20, ResY=20);
novabanda4 = Novo (Nome = "B4_corr_atm", ResX=20, ResY=20);
//Operação
menorvalorb1 = <menor valor para a B1_corr_atm>;
menorvalorb2 = <menor valor para a B2_corr_atm>;
menorvalorb3 = <menor valor para a B3_corr_atm>;
menorvalorb4 = <menor valor para a B4_corr_atm>;
novabanda1 = b1 – menorvalorb1;
novabanda2 = b2 – menorvalorb2;
novabanda3 = b3 – menorvalorb3;
novabanda4 = b4 – menorvalorb4; }

```

APÊNDICE 3 – Rotina de determinação do CTVI

```
{
//Declaração
Imagem b3 ("CCD");
Imagem b4 ("CCD");
Imagem novabanda ("CCD");
//Instanciação
b3 = Recuperar (Nome = "B3_corr_atm");
b4 = Recuperar (Nome = "B4_corr_atm");
novabanda = Novo (Nome = "CTVI", ResX=20, ResY=20);
//Operação
novabanda = (((b4 - b3) / (b4 + b3)) + 0.5) / ((abs(((b4 - b3) / (b4 + b3)) + 0.5)) *
(sqrt(abs(((b4 - b3) / (b4 + b3)) + 0.5))));
}
```

APÊNDICE 4 – Rotina de determinação do GEMI

```
{  
//Declaração  
Imagem b3 ("CCD");  
Imagem b4 ("CCD");  
Imagem etaa ("CCD");  
Imagem novabanda ("CCD");  
//Instanciação  
b3 = Recuperar (Nome = "B3_corr_atm");  
b4 = Recuperar (Nome = "B4_corr_atm");  
etaa = Novo (Nome = "etaa_pg", ResX=20, ResY=20);  
novabanda = Novo (Nome = "GEMI", ResX=20, ResY=20);  
//Operação  
etaa = ((2 * (b4^2 - b3^2)) + (1.5 * b4) + (0.5 * b3)) / (b4 + b3 + 0.5);  
novabanda = 0.0125 * (etaa * (1 - (0.25 * etaa)) * ((b3 - 0.125) / (1 - b3)));  
}
```

APÊNDICE 5 – Rotina de determinação do SAVI

```
{  
//Declaração  
Imagem b3 ("CCD");  
Imagem b4 ("CCD");  
Imagem novabanda ("CCD");  
//Instanciação  
b3 = Recuperere (Nome = "B3_corr_atm");  
b4 = Recuperere (Nome = "B4_corr_atm");  
novabanda = Novo (Nome = "SAVI", ResX=20, ResY=20);  
L = 0.5;  
//Operação  
novabanda = ((b4 - b3) / ( b4 + b3 + L)) * (1 + L);  
}
```


APÊNDICE 6 – Rotina de determinação do TVI

```
{  
//Declaração  
Imagem b3 ("CCD");  
Imagem b4 ("CCD");  
Imagem novabanda ("CCD");  
//Instanciação  
b3 = Recuperere (Nome = "B3_corr_atm");  
b4 = Recuperere (Nome = "B4_corr_atm");  
novabanda = Novo (Nome = "TVI", ResX=20, ResY=20);  
//Operação  
novabanda = sqrt(((b4 - b3) / ( b4 + b3)) + 0.5);  
}
```

APÊNDICE 7 – Rotina de classificação por árvore de decisão (cena 157/128)

```

{
//Declaração
Imagem b1 ("CCD");
Imagem b2 ("CCD");
Imagem b4 ("CCD");
Imagem cp1 ("CCD");
Imagem cp2 ("CCD");
Imagem dvi ("CCD");
Imagem gemi ("CCD");
Imagem mmeagua ("CCD");
Imagem ndvi ("CCD");
Imagem novabanda ("CCD");
//Instanciação
b1 = Recuperar (Nome = "B1_corr_atm");
b2 = Recuperar (Nome = "B2_corr_atm");
b4 = Recuperar (Nome = "B4_corr_atm");
cp1 = Recuperar (Nome = "CP1");
cp2 = Recuperar (Nome = "CP2");
dvi = Recuperar (Nome = "DVI");
gemi = Recuperar (Nome = "GEMI");
mmeagua = Recuperar (Nome = "MMEag");
ndvi = Recuperar (Nome = "NDVI");
novabanda = Novo (Nome = "ClassAD", ResX=20, ResY=20);
//Operação
novabanda = ndvi<=90 ? (cp1<=26 ? 6 : (mmeagua<=150 ? 10 : 9)) : (mmeagua>139 ? (b2>19
? 5 : (b4<=103 ? (b1>=9 ? 2 : 1) : (gemi>117 ? 8 : (cp2<=123 ? 2 : 8)))) : (b4>204 ? 4 :
(mmeagua<=125 ? 3 : (b1>50 ? 3 : (gemi>153 ? 7 : (dvi<=85 ? 7 : 3))))));
}

```

APÊNDICE 8 – Rotina de classificação por árvore de decisão (cena 158/127)

```

{
//Declaração
Imagem b1 ("CCD");
Imagem b2 ("CCD");
Imagem b3 ("CCD");
Imagem b4 ("CCD");
Imagem cp1 ("CCD");
Imagem ctvi ("CCD");
Imagem mixag ("CCD");
Imagem mixso ("CCD");
Imagem mixve ("CCD");
Imagem sr ("CCD");
Imagem tvi ("CCD");
Imagem novabanda ("CCD");
//Instanciação
b1 = Recuperar (Nome = "B1_corr_atm");
b2 = Recuperar (Nome = "B2_corr_atm");
b3 = Recuperar (Nome = "B3_corr_atm");
b4 = Recuperar (Nome = "B4_corr_atm");
cp1 = Recuperar (Nome = "CP1");
ctvi = Recuperar (Nome = "CTVI");
mixag = Recuperar (Nome = "MMEag");
mixso = Recuperar (Nome = "MMEso");
mixve = Recuperar (Nome = "MMEve");
sr = Recuperar (Nome = "SR");
tvi = Recuperar (Nome = "TVI");
novabanda = Novo (Nome = "ClassAD", ResX=20, ResY=20);
//Operação

```

```

novabanda = tvi>175 ? (b2<=20 ? (mixso<=79 ? 5 : (mixve<=223 ? 4 : (b4<=60 ? 5 : 4))) :
(b4>66 ? (mixso<=142 ? (b3<=30 ? 2 : 8) : (mixve<=227 ? 1 : 2)) : (b2>23 ? 8 : (b3>25 ? 1 :
(b1<=22 ? 4 : 6)))) : (cp1<=96 ? 10 : (ctvi<=161 ? 3 : (mixag<=64 ? 7 : (b2<=27 ? 7 :
(cp1<=121 ? 9 : (sr<=14 ? 7 : 9))))));
}

```

APÊNDICE 9 – Rotina de geração do mapa temático (cena 157/128)

```
{
//Declaração
Imagem imclassAD ("CCD");
Tematico classes ("MapaVerão");
//Instanciação
imclassAD = Recuperar (Nome = "ClassAD");
classes = Novo (Nome = "ClassAD_T", ResX=20, ResY=20);
classes = Atribua
{
"Pinus" : (imclassAD == 1),
"Eucalipto" : (imclassAD == 2),
"Pasto" : (imclassAD == 3),
"Soja" : (imclassAD == 4),
"Feijão" : (imclassAD == 5),
"Água" : (imclassAD == 6),
"Sorgo_milho" : (imclassAD == 7),
"Mata" : (imclassAD == 8),
"Solo" : (imclassAD == 9),
"Área_urbana" : (imclassAD == 10)};
}
```

APÊNDICE 10 – Rotina de geração do mapa temático (cena 158/127)

```
{
//Declaração
Imagem imclassAD ("CCD");
Tematico classes ("MapaInverno");
//Instanciação
imclassAD = Recuperar (Nome = "ClassAD");
classes = Novo (Nome = "ClassAD_T", ResX=20, ResY=20);
classes = Atribua
{
"Aveia" : (imclassAD == 1),
"Trigo" : (imclassAD == 2),
"Eucalipto" : (imclassAD == 3),
"Pinus" : (imclassAD == 4),
"Araucária" : (imclassAD == 5),
"Mata" : (imclassAD == 6),
"Solo" : (imclassAD == 7),
"Pasto" : (imclassAD == 8),
"ÁreaUrbana" : (imclassAD == 9),
"Água" : (imclassAD == 10)};
}
```