

UERJ

Dissertação de Mestrado em Engenharia de Computação

**CLASSIFICAÇÃO DO USO E COBERTURA DO SOLO EM
ESCALA REGIONAL A PARTIR DE SEQUÊNCIAS TEMPORAIS
DE DADOS MODIS**

Autor: Milton Jonathan

Orientador: Margareth Simões Penello Meirelles

Programa de Pós-Graduação em Engenharia de Computação
Área de Concentração em Geomática

Setembro - 2005



Faculdade de Engenharia

CLASSIFICAÇÃO DO USO E COBERTURA DO SOLO EM ESCALA REGIONAL A PARTIR DE SEQUÊNCIAS TEMPORAIS DE DADOS MODIS

Milton Jonathan

Dissertação submetida ao corpo docente da Faculdade de Engenharia da Universidade do Estado do Rio de Janeiro – UERJ, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia de Computação.

Orientador: Margareth Simões Penello Meirelles

Programa de Pós-Graduação em Engenharia de Computação – Área de Concentração em Geomática

Rio de Janeiro
Setembro - 2005

JONATHAN, MILTON

Classificação do Uso e Cobertura do Solo em Escala Regional a partir de Sequências Temporais de Dados MODIS [Rio de Janeiro] 2005.

ix, 147 p. 29,7 cm (FEN/UERJ, M.Sc., Programa de Pós-Graduação em Engenharia de Computação – Área de Concentração em Geomática, 2005)

Dissertação - Universidade do Estado do Rio de Janeiro - UERJ

1. Geomática

2. Sensoriamento Remoto

I. FEN/UERJ II. Título (série)

FOLHA DE JULGAMENTO

Título: Classificação do Uso e Cobertura do Solo em Escala Regional a partir de Sequências Temporais de Dados MODIS

Candidato: Milton Jonathan

Programa de Pós-Graduação em Engenharia de Computação – Área de Concentração em Geomática

Data da defesa: 30 de Setembro de 2005.

Aprovada por:

Orientador: Margareth Simões Penello Meirelles, D.Sc., UERJ

Heitor Luiz da Costa Coutinho, D.Sc., Embrapa Solos

Carlo Emmanoel Tolla de Oliveira, D.Sc., UFRJ

Ubiratan Porto dos Santos, D.Sc., UFRJ

AGRADECIMENTOS

Gostaria de registrar aqui os meus agradecimentos a todas as entidades, professores, alunos, e amigos que tornaram possível a realização deste trabalho. Em especial, gostaria de agradecer:

- À minha namorada, minha amiga e companheira Gabi, que ainda por cima assumiu o posto de “psicóloga oficial” desta dissertação, me passando toda a sua experiência com teses, me acompanhando até na França, me dando colo nos momentos de estresse e me proporcionando a incomensurável doçura de seu coração, em todos os momentos
- Aos meus pais, pelo irredutível e incondicional apoio e confiança em todos as situações, por terem me dado tudo o que tenho, pelo querido ambiente de amor e carinho presente em nossa casa ao longo de tantos anos, e também pelos muitos papos, seja com respeito ao desenvolvimento deste trabalho, seja com relação à vida, à felicidade e ao amor
- Ao meu irmão Dani e aos meus grandes amigos Diego, Diogo, Bia, Szmit, Pedro e Erick, companheiros de vida, que mesmo quando afastados estão sempre comigo me ajudando a encontrar o caminho
- Ao meu amigo Sérgio, pelo ouvido amigo e pelas viajantes discussões sobre a vida, os relacionamentos, e as peripécias de um sujeito em tese
- À Margareth, minha orientadora, pela confiança e amizade, e por todas as oportunidades de crescimento profissional e pessoal
- Aos pesquisadores Heitor Luiz da Costa Coutinho e João dos Santos Vila da Silva, da Embrapa, pelo apoio material e científico neste trabalho e pela boa vontade
- A Jean-Paul Berroir, do INRIA, pela inestimável ajuda e orientação durante a minha estadia na França, e pela contribuição decisiva no desenvolvimento de grande parte deste trabalho
- A Isabelle Herlin, do INRIA, pela oportunidade e orientação, tornando possível a cooperação com o seu grupo de pesquisa
- Aos amigos Pierre, Elodie, Thierry, Elisa e Ivola, e à inesquecível Michelle do Résidence Château St. Paul, *merci les mecs!*
- À UERJ, Embrapa Solos, INRIA, CAPES, e ALBAN, por tornarem materialmente viável o desenvolvimento deste trabalho
- À guerreira Beth, pela incansável dedicação ao curso de Geomática

Resumo da Dissertação ou Monografia apresentada à FEN/UERJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia de Computação.

Classificação do Uso e Cobertura do Solo em Escala Regional a partir de Sequências Temporais de Dados MODIS

Milton Jonathan

Setembro/2005

Orientador: Margareth Simões Penello Meirelles, D.Sc., UERJ.

Programa de Pós-Graduação em Engenharia de Computação – Área de Concentração em Geomática.

O conhecimento do uso e cobertura do solo e de sua dinâmica corresponde a um dado essencial para a compreensão de nosso território e para o dimensionamento do impacto das atividades humanas em nosso ambiente. Neste sentido, esta dissertação descreve uma metodologia para a classificação sistemática do uso e cobertura do solo em escala regional, com ênfase em procedimentos baratos e altamente automatizados. Esta metodologia está fundamentada na análise multitemporal de seqüências de imagens do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*), o qual se encontra a bordo dos satélites Terra e Aqua da NASA e apresenta alta frequência temporal, extensa cobertura, e baixíssimo custo para aquisição de dados. Uma seqüência de procedimentos automatizados foi desenvolvida para o pré-processamento de dados deste sensor e para o treinamento e execução de um algoritmo de classificação supervisionada. Neste algoritmo, ajustam-se curvas polinomiais aos dados temporais MODIS, e então se computam atributos descritivos dos padrões temporais de cada ponto, reduzindo-se assim a dimensionalidade dos dados e aumentando a sua interpretabilidade. Um estudo de caso foi realizado para a Bacia do Alto Taquari, uma região de mais de 25.000km² nos estados de Mato Grosso do Sul e Mato Grosso, demonstrando-se a capacidade da metodologia para a discriminação entre áreas de agricultura, pastagem e cerrado para toda a região de estudos, além de seu grande potencial para a identificação de áreas de desflorestamento de uma forma rápida, barata, e acessível.

Palavras-chave: sensoriamento remoto, processamento de imagens multitemporais, classificação de uso e cobertura do solo, detecção de mudanças de uso e cobertura do solo.

Abstract of Dissertation presented to FEN/UERJ as a partial fulfillment of the requirements for the degree of Master in Computer Engineering (M.Sc.)

Regional Scale Land Use/Land Cover Classification Using Temporal Series of MODIS data

Milton Jonathan

September/2005

Advisor: Margareth Simões Penello Meirelles, D.Sc., UERJ.

Post-Graduate Programme in Computer Engineering – Geomatics

Knowledge of land use / land cover and its dynamics is essential for understanding our territory and evaluating the impact of human activities over the environment. As such, this dissertation describes a methodology for systematic land use/land cover classification on a regional scale, with emphasis on a low cost and highly automatized approach. This methodology is based on multitemporal analyses of surface reflectance data from the Moderate Resolution Imaging Spectroradiometer (MODIS), which is located on board NASA's Terra and Aqua satellites and features high temporal frequency, extensive coverage, and extremely low costs for data acquisition. A sequence of automatized procedures were developed for MODIS data pre-processing, as well as for the training and execution of a supervised classification algorithm, where temporal profiles are fitted to smooth polynomial curves and intelligent curve features are then computed in order to reduce data dimensionality and improve profile interpretability, thus providing a more robust classification approach. A case study was performed in the High Taquari Basin, in the states of Mato Grosso do Sul and Mato Grosso, Brazil, which showed that the method was indeed capable of generalizing well over the entire region of study (over 25,000km²), effectively discriminating between areas of agriculture, pasture, and savannah. The methodology was also seen to be quite successful in identifying areas of deforestation, which is of particular interest for the monitoring of land use and land use change in the region.

Key-words: remote sensing, multitemporal image processing, land use classification, land use change detection

SUMÁRIO

1	INTRODUÇÃO.....	1
1.1	CONTEXTO GERAL E MOTIVAÇÕES	1
1.2	OBJETIVO GERAL	3
1.3	OBJETIVOS ESPECÍFICOS.....	4
1.4	PROJETOS RELACIONADOS	5
1.5	ORGANIZAÇÃO DA DISSERTAÇÃO.....	6
2	FUNDAMENTAÇÃO TEÓRICA	8
2.1	O USO E COBERTURA DO SOLO E SUA IMPORTÂNCIA	8
2.1.1	<i>Conceitos gerais</i>	<i>8</i>
2.1.2	<i>Importância e aplicações.....</i>	<i>9</i>
2.2	PRINCÍPIOS DE SENSORIAMENTO REMOTO	12
2.2.1	<i>Conceitos gerais</i>	<i>12</i>
2.2.2	<i>Sensores de energia eletromagnética</i>	<i>13</i>
2.2.3	<i>Interações da energia eletromagnética</i>	<i>15</i>
2.2.4	<i>Resposta espectral dos alvos</i>	<i>19</i>
2.3	INTRODUÇÃO À CLASSIFICAÇÃO DE IMAGENS DIGITAIS	22
2.3.1	<i>Conceitos básicos</i>	<i>22</i>
2.3.2	<i>Estratégias para classificação de padrões</i>	<i>25</i>
2.3.3	<i>Redução de dimensionalidade e extração de atributos</i>	<i>28</i>
2.3.4	<i>Avaliação de resultados.....</i>	<i>29</i>
2.4	CONSIDERAÇÕES FINAIS.....	32
3	USO E COBERTURA DO SOLO EM LARGA ESCALA.....	33
3.1	ANTECEDENTES HISTÓRICOS	33
3.2	ABORDAGENS COM DADOS NOAA/AVHRR	34
3.3	ABORDAGENS COM DADOS MODIS	36
3.4	ABORDAGENS COM DADOS DE OUTROS SENSORES	39
3.5	ABORDAGENS PARA DETECÇÃO DE DESFLORESTAMENTO	40
3.6	ANÁLISE NO NÍVEL DO SUB-PIXEL	41
3.7	CONSIDERAÇÕES FINAIS.....	44
4	MATERIAIS	45
4.1	CLASSIFICAÇÃO DETALHADA DO USO E COBERTURA DO SOLO PARA A ÁREA DE ESTUDOS	45
4.2	TRABALHO DE CAMPO.....	46
4.3	DADOS MODIS	47
4.3.1	<i>Introdução.....</i>	<i>47</i>
4.3.2	<i>Produtos MODIS: uma visão geral</i>	<i>50</i>
4.3.3	<i>Produto MOD09GQK: reflectância diária da superfície a 250m.....</i>	<i>54</i>
4.3.4	<i>Produto MOD09GST: qualidade da reflectância diária da superfície a 1km</i>	<i>55</i>
4.3.5	<i>Produto MOD13Q1: composição 16 dias de índices de vegetação a 250m</i>	<i>57</i>
4.3.6	<i>Aquisição de dados</i>	<i>59</i>
4.4	IMAGENS LANDSAT	59
4.5	SISTEMAS E PROGRAMAS	60
5	METODOLOGIA	62
5.1	PRÉ-PROCESSAMENTO DE DADOS MODIS	63
5.1.1	<i>Recorte/mosaicagem, reprojeção e conversão de dados usando MRT</i>	<i>63</i>

5.1.2	<i>Filtragem de dados para o produto MOD13Q1</i>	64
5.1.2.1	Considerações iniciais	64
5.1.2.2	Procedimento	64
5.1.3	<i>Filtragem de dados para os produtos MOD09GQK / MOD09GST</i>	65
5.1.3.1	Considerações iniciais	65
5.1.3.2	Processamento de dados MOD09GST	66
5.1.3.3	Processamento de dados MOD09GQK	67
5.2	ADAPTAÇÃO DA CLASSIFICAÇÃO DE REFERÊNCIA PARA DADOS MODIS	68
5.2.1	<i>Agrupamento das classes originais (merge)</i>	69
5.2.2	<i>Sub-divisão das classes originais (splitting)</i>	69
5.2.3	<i>Geração da classificação de treinamento</i>	70
5.3	ANÁLISE DE PERFIS TEMPORAIS NDVI	71
5.3.1	<i>Modelagem de perfis temporais através do ajuste de curvas polinomiais</i>	72
5.3.2	<i>Cálculo de atributos</i>	73
5.3.3	<i>Pós-processamento do cálculo de atributos</i>	75
5.4	SELEÇÃO DE ATRIBUTOS	76
5.4.1	<i>Algoritmo</i>	76
5.4.1.1	Estratégia de busca	77
5.4.1.2	Medida de aptidão	77
5.4.1.3	Observações	79
5.4.2	<i>Métodos alternativos</i>	80
5.4.2.1	Análise discriminante	80
5.4.2.2	Wrapper	81
5.5	CLASSIFICAÇÃO	81
5.5.1	<i>Algoritmo principal</i>	82
5.5.1.1	Fundamentação teórica	82
5.5.1.2	Procedimento metodológico	83
5.5.2	<i>Extensão: classificação de pixels problemáticos e/ou misturados</i>	84
5.5.2.1	Motivação	84
5.5.2.2	Procedimento metodológico	86
5.5.2.3	Detalhamento do procedimento	86
5.6	CONSIDERAÇÕES FINAIS	88
6	ESTUDO DE CASO	90
6.1	ÁREA DE ESTUDOS	90
6.2	AQUISIÇÃO DE DADOS	92
6.2.1	<i>Classificação detalhada do uso e cobertura do solo</i>	92
6.2.2	<i>Dados MODIS</i>	94
6.3	APLICAÇÃO DA METODOLOGIA	94
6.3.1	<i>Pré-processamento dos dados MODIS</i>	94
6.3.1.1	Recorte, reprojeção e conversão de dados	94
6.3.1.2	Filtragem de dados	95
6.3.2	<i>Análise preliminar de dados</i>	97
6.3.3	<i>Geração da classificação de treinamento adaptada para os dados MODIS</i>	98
6.3.4	<i>Análise dos perfis temporais NDVI</i>	102
6.3.5	<i>Seleção de atributos</i>	104
6.3.6	<i>Classificação</i>	106
6.4	RESULTADOS E DISCUSSÃO	107
6.4.1	<i>Classificação</i>	107
6.4.1.1	Avaliações preliminares	108
6.4.1.2	Avaliação do impacto de pixels misturados	109
6.4.1.3	Avaliação do critério de confiabilidade da classificação	109

6.4.1.4	Avaliação do algoritmo complementar de classificação.....	112
6.4.1.5	Avaliações finais.....	113
6.4.2	<i>Detecção de desflorestamento</i>	118
6.4.2.1	Metodologia de avaliação	118
6.4.2.2	Avaliação dos resultados	120
6.5	CONSIDERAÇÕES FINAIS.....	123
7	CONCLUSÕES.....	125
7.1	CONSIDERAÇÕES GERAIS	125
7.2	TRABALHOS FUTUROS	127
7.3	CONSIDERAÇÕES FINAIS.....	130
	APÊNDICE A: ESPECIFICAÇÕES DE SENSORES.....	131
A.1.	MODIS.....	131
A.2.	NOAA/AVHRR.....	131
A.3.	CBERS/WFI	132
A.4.	SPOT/VEGETATION	132
A.5.	SÉRIE LANDSAT.....	133
	REFERÊNCIAS.....	135

ÍNDICE DE FIGURAS

FIGURA 2.1 INFLUÊNCIA DO USO E COBERTURA DO SOLO.....	11
FIGURA 2.2 O ESPECTRO ELETROMAGNÉTICO E SUAS DIFERENTES FAIXAS DE FREQUÊNCIA	12
FIGURA 2.3 RESOLUÇÃO ESPACIAL OU CAMPO DE VISADA INSTANTÂNEO (IFOV)	14
FIGURA 2.4 INTERAÇÕES ENTRE A ENERGIA ELETROMAGNÉTICA E A SUPERFÍCIE	16
FIGURA 2.5 MODELOS DE REFLEXÃO	17
FIGURA 2.6 EXEMPLO DE FUNÇÃO BRDF	17
FIGURA 2.7 ABSORÇÃO ATMOSFÉRICA DA RADIAÇÃO AO LONGO DO ESPECTRO	18
FIGURA 2.8 RESPOSTAS ESPECTRAIS TÍPICAS PARA DIVERSOS TIPOS DE COBERTURA DO SOLO...	19
FIGURA 2.9 IMAGEM DA SUPERFÍCIE TERRESTRE E RESULTADO DE CLASSIFICAÇÃO.....	22
FIGURA 2.10 ESPAÇO DOS ATRIBUTOS PARA UMA IMAGEM COM DUAS BANDAS	23
FIGURA 2.11 SEPARABILIDADE ENTRE CLASSES NO ESPAÇO DE ATRIBUTOS.....	24
FIGURA 2.12 EXEMPLO DE UMA CLASSE COM DISTRIBUIÇÃO MULTIMODAL.....	25
FIGURA 4.1 TRECHO DE RIO EXTREMAMENTE ASSOREADO	46
FIGURA 4.2 VOÇOROCA DE GRANDES DIMENSÕES	47
FIGURA 4.3 COMPARAÇÃO ENTRE BANDAS PARA MODIS, AVHRR E LANDSAT/ETM+.....	50
FIGURA 4.4 GRADE FIXA UTILIZADA PARA DIVIDIR O MUNDO EM GRANDES LADRILHOS	53
FIGURA 5.1 VISÃO GERAL DA METODOLOGIA	63
FIGURA 5.2 UTILIZAÇÃO DE INTERPOLAÇÃO LINEAR NO DOMÍNIO TEMPORAL	65
FIGURA 5.3 MODELAGEM DE PERFIS TEMPORAIS A PARTIR DE CURVAS POLINOMIAIS	72
FIGURA 5.4 CÁLCULO DE ATRIBUTOS OU MÉTRICAS A PARTIR DE UM PERFIL TEMPORAL	74
FIGURA 5.5 VISÃO GERAL DO PROCEDIMENTO PRINCIPAL DE CLASSIFICAÇÃO.	84
FIGURA 5.6 O PROBLEMA DO <i>PIXEL</i> “MISTURADO”	85
FIGURA 5.7 PROCEDIMENTO DE EXTENSÃO DO ALGORITMO PRINCIPAL DE CLASSIFICAÇÃO.....	88
FIGURA 6.1 LOCALIZAÇÃO DA REGIÃO DA BACIA DO ALTO TAQUARI.....	90
FIGURA 6.2 BACIA DO ALTO TAQUARI E SUAS SUBDIVISÕES	91
FIGURA 6.3 CLASSIFICAÇÃO LANDSAT DO USO E COBERTURA DO SOLO PARA TODA A BAT ..	93
FIGURA 6.4 RECORTE DOS LADRILHOS ORIGINAIS MODIS	95
FIGURA 6.5 IDENTIFICAÇÃO DE <i>PIXELS</i> DE ALTA E BAIXA QUALIDADE	96
FIGURA 6.6 RESULTADO DA FILTRAGEM DE DADOS PARA UM <i>PIXEL</i> DA ÁREA DE ESTUDOS.....	96
FIGURA 6.7 PERFIS TEMPORAIS DE NDVI PARA DIFERENTES CLASSES DE VEGETAÇÃO	99
FIGURA 6.8 ANÁLISE DOS PERFIS TEMPORAIS DE NDVI PARA PASTAGEM	99
FIGURA 6.9 ANÁLISE DOS PERFIS TEMPORAIS DE NDVI PARA AGRICULTURA.....	100
FIGURA 6.10 ANÁLISE DOS PERFIS TEMPORAIS DE NDVI PARA CERRADO	101
FIGURA 6.11 PERFIS TEMPORAIS DE NDVI DAS 7 CLASSES MODIS.....	102
FIGURA 6.12 <i>PIXELS</i> MISTURADOS E <i>PIXELS</i> COM BAIXO NÍVEL DE CONFIABILIDADE	111
FIGURA 6.13 EXEMPLO DE PERFIL TEMPORAL COM ALTO NÍVEL DE RUÍDO	112
FIGURA 6.14 COMPARAÇÃO ENTRE DADOS DE REFERÊNCIA E CLASSIFICAÇÃO	114
FIGURA 6.15 DISCREPÂNCIAS EM REGIÕES DE AGRICULTURA EM REPOUSO	116
FIGURA 6.16 PERFIL TEMPORAL EM TRANSIÇÃO ENTRE AGRICULTURA E VEGETAÇÃO CILIAR .	117
FIGURA 6.17 DETALHE DO RESULTADO DA DETECÇÃO DE DESFLORESTAMENTO	120
FIGURA 6.18 INSPEÇÃO DE ÁREA IDENTIFICADA COMO DESFLORESTAMENTO	121
FIGURA 6.19 VISÃO GERAL DAS ÁREAS EFETIVAS DE DESFLORESTAMENTO DETECTADAS	122
FIGURA 6.20 CLASSIFICAÇÃO FINAL DO USO E COBERTURA DO SOLO PARA TODA A BAT	124

ÍNDICE DE TABELAS

TABELA 2.1 EXEMPLO DE MATRIZ DE CONFUSÃO	30
TABELA 4.1 ESPECIFICAÇÕES DO SENSOR MODIS.	48
TABELA 4.2 ESPECIFICAÇÕES DA CAMADA DE QUALIDADE DO PRODUTO MOD09GQK.....	55
TABELA 4.3 ESPECIFICAÇÕES DA CAMADA DE ESTADO DO PRODUTO MOD09GST	56
TABELA 4.4 ESPECIFICAÇÕES DA CAMADA DE QUALIDADE DO PRODUTO MOD13Q1.....	58
TABELA 4.5 ÓRBITAS/PONTO E DATAS DAS IMAGENS LANDSAT DO ANO 2000	59
TABELA 4.6 ÓRBITAS/PONTO E DATAS DAS IMAGENS LANDSAT DO ANO 2002	60
TABELA 5.1 CRITÉRIOS PARA FILTRAR DADOS DO PRODUTO MOD13Q1	65
TABELA 5.2 CRITÉRIOS PARA FILTRAR DADOS DO PRODUTO MOD09GST	66
TABELA 5.3 CRITÉRIOS PARA FILTRAR DADOS DO PRODUTO MOD09GQK	67
TABELA 5.4 PASSOS DO ALGORITMO DE AGRUPAMENTO <i>K-MEANS</i>	70
TABELA 6.1 DISTRIBUIÇÕES DO USO E COBERTURA DO SOLO NAS DUAS METADES DA BAT	108
TABELA 6.2 RESULTADO PARCIAL NA ÁREA DE VALIDAÇÃO.....	108
TABELA 6.3 RESULTADO PARCIAL NA ÁREA DE VALIDAÇÃO PARA <i>PIXELS</i> PUROS	109
TABELA 6.4 RESULTADO PARCIAL NA ÁREA DE VALIDAÇÃO PARA <i>PIXELS</i> CONFIÁVEIS.....	110
TABELA 6.5 RESULTADO FINAL NA ÁREA DE TREINAMENTO COM MOD09GQK	113
TABELA 6.6 RESULTADO FINAL NA ÁREA DE VALIDAÇÃO COM MOD09GQK	114
TABELA 6.7 RESULTADO FINAL NA ÁREA DE VALIDAÇÃO COM MOD13Q1	118
TABELA A.1 ESPECIFICAÇÕES DO SENSOR NOAA/AVHRR.....	132
TABELA A.2 ESPECIFICAÇÕES DO SENSOR CBERS/WFI	132
TABELA A.3 ESPECIFICAÇÕES DO SENSOR SPOT/VEGETATION	133
TABELA A.4 ESPECIFICAÇÕES DOS SENSORES TM (LANDSAT 5) E ETM+ (LANDSAT 7).....	134

1 Introdução

1.1 Contexto geral e motivações

Nos tempos atuais, um dos maiores desafios enfrentados pela nossa sociedade consiste na manutenção de condições que sejam apropriadas à sobrevivência do ser humano e das demais espécies do planeta. De fato, nestes últimos anos, a crescente influência das atividades humanas no funcionamento e equilíbrio dos ecossistemas tem merecido cada vez mais atenção por parte da comunidade científica. Assim, por diversas vezes já se estabeleceram relações entre as ações do Homem e degradações intensivas do solo em diversas regiões, além de perda de biodiversidade, mudanças em regimes hidrológicos e mesmo alterações climáticas [111]. Neste contexto, o uso e cobertura do solo (*land use/land cover*, ou LULC), assim como as suas mudanças de natureza tanto antrópica quanto natural, vem sendo reconhecido já há algum tempo como um fator preponderante para o controle dos ciclos biogeoquímicos de nosso planeta (tais como os ciclos de carbono e de água), e conseqüentemente do próprio funcionamento dos ecossistemas [69] (ver seção 2.1).

Entretanto, apesar desta importância, o monitoramento contínuo e detalhado do uso e cobertura do solo em escalas regionais, continentais e globais ainda constitui um desafio para a comunidade científica nos dias de hoje. Ao longo das últimas décadas, inúmeros trabalhos demonstraram a eficiência da utilização de imagens de sensoriamento remoto de alta resolução para a classificação do uso e cobertura a nível local. Entretanto, tornou-se claro também que o emprego destas técnicas para levantamentos freqüentes sobre grandes áreas termina por exigir custos proibitivos tanto do ponto de vista financeiro quanto computacional, especialmente se considerarmos os limitados recursos disponíveis em regiões menos desenvolvidas do Brasil e do mundo.

Por estas razões, ao longo dos anos também se exploraram as possibilidades de levantamento do uso e cobertura do solo a partir de imagens de baixo custo, alta resolução temporal, e baixa ou moderada resolução espacial. De fato, seqüências de imagens do sensor NOAA/AVHRR (*Advanced Very High Resolution Radiometer*, ver especificações no apêndice A.2) têm sido utilizadas já há mais de uma década com relativo sucesso num número significativo de estudos [103][97][22][64][43]. Entretanto, apesar deste sucesso, constataram-se também importantes limitações com relação à aplicabilidade deste tipo de abordagem para a realização de levantamentos regionais e até mesmo globais [95][101], o que pode ser justificado pelo fato deste sensor ter sido lançado originalmente com fins meteorológicos, apresentando assim

uma resolução espacial demasiadamente baixa (apenas 1,1km) e um padrão de qualidade de dados insuficiente para este tipo de aplicação (ver seção 3.2).

Por outro lado, nos dias de hoje também se encontram disponíveis dados provenientes do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*), um sensor concebido especificamente para este tipo de aplicação e que se encontra a bordo dos satélites *Terra* e *Aqua* da NASA (*National Aeronautics and Space Administration*, a agência espacial dos EUA). De fato, quando comparado ao seu predecessor, verifica-se que este novo sensor apresenta uma maior resolução espacial (250m nas faixas do vermelho e infra-vermelho próximo) e padrões superiores de calibração, georreferenciamento e correção atmosférica, além de informações detalhadas a respeito da qualidade de seus dados (ver seções 3.3 e 4.3). Por tudo isto, considerando-se a disponibilidade gratuita de seus dados e sua cobertura quase que diária de todos os pontos da superfície terrestre, o sensor MODIS se mostra como uma alternativa de enorme interesse para o aprimoramento do levantamento do uso e cobertura do solo sobre grandes regiões, e conseqüentemente para o melhoramento do entendimento das relações ecossistêmicas de nosso planeta. Assim, o emprego de seus dados para este tipo de monitoramento tem sido explorado crescentemente nos últimos anos, tendo-se alcançado resultados muito interessantes para levantamentos globais [95][34], e mais recentemente também para aplicações de caráter regional [112][8][5] (ver seção 3.3). Entretanto, o atual estágio de desenvolvimento destas técnicas ainda não permite uma fácil disseminação e utilização deste tipo de abordagem para levantamentos regionais rotineiros, especialmente considerando os poucos recursos financeiros, computacionais e tecnológicos de muitas regiões de nosso país.

Com relação a aplicações no Brasil e na América do Sul, observa-se de fato que um melhor entendimento das interdependências entre os sistemas naturais e humanos destas regiões constitui uma necessidade urgente de pesquisa, uma vez que a acelerada expansão das fronteiras agrícolas e a intensificação da influência antrópica já começa a produzir efeitos significativos e claramente perceptíveis tanto para a população humana quanto para o meio-ambiente em si. Infelizmente, no entanto, o levantamento do uso e cobertura do solo para estas regiões ainda se encontra insuficiente para viabilizar um entendimento apropriado das relações ecossistêmicas e assim estabelecer a forma e a magnitude dos efeitos causados pela ação do Homem [78]. De fato, as classificações mais abrangentes e confiáveis disponíveis no momento para estas regiões correspondem a produtos de cobertura global, os quais apresentam uma baixa resolução espacial (1km no melhor dos casos), e assim não se mostram capazes de capturar a complexidade do uso e cobertura do solo com o necessário

detalhamento [98][100][95]. Além disso, a utilização deste tipo de dado também torna muito difícil uma boa avaliação de aspectos regionais de cunho específico [112], o que em muitos casos pode impossibilitar uma modelagem adequada dos processos ecossistêmicos destas regiões.

Sob uma outra perspectiva, é também de particular importância que se consiga realizar um melhor monitoramento do uso e cobertura do solo em áreas que sejam críticas para o funcionamento dos ecossistemas de nosso país, e que ao mesmo tempo se encontrem em acentuado processo de degradação. Com efeito, este tipo de situação pode ser verificado com assombrosa frequência no Brasil, onde processos descontrolados de expansão das terras ocupadas pelo Homem vêm causando significativos impactos em grandes áreas por todo o país, e particularmente nas regiões Centro-Oeste e Norte. Infelizmente, no entanto, a grande extensão territorial das áreas afetadas (com dezenas ou mesmo centenas de milhares de km²), a dificuldade de acesso a muitos pontos, e principalmente as restrições de recursos financeiros e computacionais fazem com que hoje em dia esse tipo de monitoramento não seja efetivamente viável de uma forma operacional.

1.2 Objetivo geral

A hipótese levantada neste trabalho é a de que dados do sensor MODIS podem ser utilizados para levantamentos rotineiros do uso e cobertura do solo em escala regional, permitindo realizar monitoramentos de baixo custo que sejam ao mesmo tempo acessíveis a organismos locais e adaptáveis para objetivos particulares e questões específicas de cada região.

Neste sentido, esta dissertação teve como objetivo geral o desenvolvimento e avaliação de uma metodologia para a classificação sistemática do uso e cobertura do solo sobre grandes regiões, fundamentada na análise de seqüências temporais de dados do sensor MODIS. Uma ênfase especial foi dada na utilização de processos com altos níveis de automação, de modo a minimizar a necessidade de intervenção humana e assim facilitar ao máximo a aplicação da metodologia para regiões de grande extensão territorial. Assim, através deste trabalho se almeja desenvolver uma alternativa acessível e barata que permita que mesmo órgãos locais de governo consigam realizar um levantamento do uso e cobertura do solo para suas respectivas regiões, viabilizando assim o monitoramento contínuo e em larga escala de extensas áreas de nosso país. Desta forma, espera-se contribuir para que medidas de prevenção e mitigação possam ser implementadas e também acompanhadas, de modo a proporcionar uma melhor gerência dos recursos naturais e humanos indispensáveis para a manutenção de um desenvolvimento sustentável no Brasil.

1.3 Objetivos específicos

Para atingir o objetivo geral estabelecido, este trabalho adotou uma série de metas específicas, as quais se encontram descritas a seguir:

- a. Desenvolver uma cadeia automatizada de programas para o processamento de dados do sensor MODIS, de modo a permitir que esta metodologia fosse implementada com pouca ou nenhuma dependência de *softwares* de cunho comercial. Desta forma, pretendeu-se minimizar o custo operacional de execução do procedimento como um todo, tornando-o mais acessível a administrações governamentais locais, institutos de pesquisa e organizações não-governamentais.
- b. Desenvolver uma metodologia de análise de dados que fosse tão flexível quanto possível. Neste sentido, teve-se como objetivo facilitar a adaptação destes procedimentos para problemas específicos ou características regionais particulares, de maneira a se obter uma plataforma de operações para aplicações das mais diversas naturezas, tais como planejamento regional, preservação ambiental, ou estimativas de produção agrícola.
- c. Avaliar o potencial do sensor MODIS para a realização de classificações do uso e cobertura do solo em escala regional. Para isto, utilizaram-se seqüências temporais de dados nas faixas do vermelho e infra-vermelho próximo, de forma a cobrir um período de 1 ano com uma resolução espacial de 250m. Estes dados foram então analisados de maneira a comprovar se a sua resolução e sua qualidade geral são realmente suficientes para este tipo de tarefa. Assim, investigou-se o seu potencial para a discriminação entre classes de uso e cobertura do solo, além de se avaliarem questões de precisão de georreferenciamento, coerência radiométrica ao longo do tempo, e robustez com relação a interferências atmosféricas e presença de cobertura de nuvens.
- d. Explorar as possibilidades da utilização de dados MODIS para o monitoramento de mudanças no uso e cobertura do solo. Neste ponto, procurou-se estender as avaliações anteriores de modo a investigar o potencial desta metodologia para detectar alterações significativas ao longo do período de análise de 1 ano. Em particular, uma ênfase especial foi dada na avaliação da capacidade de identificação de áreas de desflorestamento, visto ser esse um dos mais impactantes processos de mudança de uso e cobertura do solo observados em território brasileiro.
- e. Aplicar a metodologia num estudo de caso para a região da Bacia do Alto Taquari, nos estados do Mato Grosso do Sul e Mato Grosso, de maneira a avaliar a viabilidade da

utilização desta estratégia em casos reais. Além disso, como detalhado no capítulo 6, há um particular interesse e urgência no monitoramento contínuo do uso e cobertura do solo nesta região, uma vez que ela possui enorme importância dentro do contexto do Pantanal Matogrossense, ao mesmo tempo em que vem sofrendo um processo acelerado de expansão de áreas antropizadas, com graves consequências tanto ambientais quanto sócio-econômicas.

- f. Adquirir conhecimentos e experiência de modo a subsidiar um projeto muito mais amplo, com o objetivo de analisar e modelar a dinâmica do uso e cobertura do solo para toda a Bacia do Rio da Prata (veja seção 1.4, a seguir). Assim, o estudo de caso realizado teve a função de proporcionar um primeiro passo neste sentido, havendo uma preocupação específica com relação aos efeitos das variações dos padrões de uso e cobertura do solo observados em áreas geograficamente distantes entre si.

1.4 Projetos relacionados

O trabalho desenvolvido nesta dissertação esteve inserido no contexto de diversos projetos de pesquisa, resultantes de parcerias estabelecidas entre o Programa de Pós-graduação em Geomática da Universidade do Estado do Rio de Janeiro e outros departamentos da UERJ, outras instituições de ensino e pesquisa no Brasil, e também instituições no exterior.

Em primeiro lugar, esta dissertação fez parte do desenvolvimento do projeto “ECOAIR – Tecnologia de Processamento de Imagens para Detecção de Mudanças e Extração de Informações Ambientais”, resultado do acordo de cooperação franco-brasileiro PROTEM-CC/INRIA 02/1999 envolvendo o CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) e o INRIA (Institut National de Recherche en Informatique et en Automatique, da França). Este projeto contou com a participação de pesquisadores e alunos da UERJ (Departamento de Engenharia de Sistemas e Computação, Programa de Pós-Graduação em Geomática), da Embrapa Solos (Empresa Brasileira de Pesquisa Agropecuária – Centro Nacional de Pesquisa de Solos), da PUC-Rio (Pontifícia Universidade Católica do Rio de Janeiro – Departamento de Engenharia Elétrica), da UFRJ (Universidade Federal do Rio de Janeiro – Núcleo de Computação Eletrônica), e do INRIA (Unidade Rocquencourt - Grupo de Pesquisa Air/Clime), e teve como objetivo desenvolver técnicas e ferramentas para apoiar administrações locais na identificação e monitoramento de processos de degradação ambiental através da análise de dados de sensoriamento remoto. Com foco específico nos problemas ambientais da região do Pantanal Matogrossense, o Projeto ECOAIR corresponde na realidade a um desdobramento do Projeto SOS-Taquari, uma iniciativa apoiada pelo

Programa de Apoio ao Desenvolvimento de Tecnologias Agropecuárias para o Brasil (PRODETAB), realizado com recursos oriundos do Banco Mundial e do governo brasileiro, coordenado pela Embrapa Solos, e tendo o Programa de Pós-Graduação em Geomática da UERJ como parceiro.

Além disso, esta dissertação também esteve inserida no contexto de um esforço internacional para o desenvolvimento de uma modelagem das interações entre os sistemas naturais e humanos para toda a Bacia do Rio da Prata, uma região que cobre áreas tanto do Brasil quanto de outros países da América do Sul, como Argentina, Paraguai, Uruguai, e Bolívia. Denominado “Land use change in the Rio de la Plata Basin: Linking biophysical and human factors to predict trends, assess impacts, and support viable strategies for the future”, este esforço tem como objetivo específico uma melhor compreensão acerca do impacto exercido sobre estes sistemas pelas mudanças do uso e cobertura do solo na região, e conta com a participação de diversas instituições do Brasil, da Argentina e dos Estados Unidos, dentre outros países [53]. Assim, como explicado na seção 1.3 acima, esta dissertação tem como meta específica servir como uma abordagem preliminar para este projeto de maior escopo, de modo que ela possa ser posteriormente estendida e aplicada para regiões mais amplas e de características diferentes, tanto no Brasil quanto em outros países sul-americanos.

Finalmente, deve-se dizer ainda que este trabalho contou com a cooperação direta do Grupo de Pesquisa Air/Clima do INRIA, em cujas dependências foi desenvolvida grande parte da metodologia descrita neste documento. Para tanto, este trabalho contou com o apoio do Programa ALBAN, Programa de bolsas de alto nível da União Européia para a América Latina, bolsa nº E04M045790BR.

1.5 Organização da dissertação

No capítulo 2 desta dissertação são descritas as bases teóricas nas quais este trabalho está fundamentado, fornecendo-se uma introdução aos conceitos de uso e de cobertura do solo, além de serem explicados os princípios básicos do sensoriamento remoto e da teoria de classificação de padrões em imagens. Em seguida, no capítulo 3, é fornecida uma revisão bibliográfica das abordagens realizadas no passado e do estado da arte do levantamento do uso e cobertura do solo para regiões de grande extensão territorial. Por sua vez, o capítulo 4 tem por objetivo descrever todos os dados utilizados para o desenvolvimento desta dissertação, com especial ênfase nas características e propriedades dos dados do sensor MODIS. Depois disto, no capítulo 5, descreve-se em detalhe a metodologia desenvolvida neste trabalho, compreendendo todos os passos necessários para a sua aplicação numa área

qualquer de interesse. Um estudo de caso para a região da Bacia do Alto Taquari (MS/MT) é então apresentado no capítulo 6, incluindo-se uma discussão minuciosa acerca dos resultados encontrados e de suas implicações com relação à avaliação da metodologia como um todo. Finalmente, no capítulo 7, são apresentadas as conclusões finais deste trabalho, aliadas a reflexões e recomendações para a realização de trabalhos futuros e aperfeiçoamentos da metodologia aqui descrita.

2 Fundamentação Teórica

Como introduzido no capítulo 1, esta dissertação tem como tema o processamento digital de imagens de sensoriamento remoto, com o propósito específico de realizar uma classificação do uso e cobertura do solo em escala regional. Assim, para esclarecer alguns tópicos fundamentais e facilitar o entendimento da metodologia proposta neste trabalho, são descritos neste capítulo alguns conceitos básicos com relação aos principais assuntos abordados. Desta forma, primeiramente é apresentada a definição do próprio conceito de uso e cobertura do solo, juntamente com algumas considerações com relação à importância de seu estudo (seção 2.1). Em seguida, é fornecida também uma introdução aos princípios fundamentais do sensoriamento remoto, explicando-se suas bases físicas e seu enorme potencial para a observação sistemática da superfície terrestre (seção 2.2). Por fim, na seção 2.3, apresenta-se ainda uma visão geral do processo de classificação de imagens digitais, de forma a introduzir conceitos teóricos básicos sobre classificação de padrões e destacar pontos particularmente relevantes para o entendimento da metodologia descrita mais adiante.

2.1 O uso e cobertura do solo e sua importância

2.1.1 Conceitos gerais

A observação da superfície terrestre é indispensável para o entendimento de processos de natureza espacial que são de fundamental importância para diversos campos do conhecimento científico, dentre os quais podemos citar hidrologia, geologia, biologia, climatologia, sociologia, economia e atividades militares, além de muitos outros. Com efeito, esta observação compreende o estudo de aspectos dos mais diversos, como a temperatura de superfície ou a sua umidade, porém uma das informações mais importantes a serem analisadas corresponde sem dúvida ao *uso* e à *cobertura* verificados em cada ponto da superfície de nosso planeta.

Especificamente, o conceito de *cobertura* da terra se refere ao tipo de elemento que é efetivamente observado na superfície terrestre. Assim, dentre os tipos de cobertura possíveis podemos incluir feições como lagos, rios, campos, vegetações arbustivas, florestas tropicais, estradas, ou desertos. Em contraste, o conceito de *uso da terra* ou *uso do solo* propriamente dito faz referência à atividade humana ou função econômica desempenhada por cada região [61]. Neste caso, os tipos de elementos categorizados poderiam incluir entidades como propriedades rurais, pastagens, áreas industriais, reservas florestais, etc.

Em tese, estes dois conceitos poderiam ser dispostos de forma independente, produzindo-se mapas separados para o uso e para a cobertura do solo. Na prática, entretanto, a diferenciação entre estes dois conceitos nem sempre se faz desejável. Em primeiro lugar, a distinção entre uso e cobertura do solo pode ter um caráter um pouco duvidoso em alguns casos, como por exemplo para áreas de cultivo agrícola. Além disso, esta diferenciação pode ser mesmo completamente irrelevante em certos casos, dependendo do fenômeno em estudo. Para completar, enquanto a cobertura do solo pode em geral ser estimada simplesmente a partir de observações adequadas da superfície (*e.g.*, imagens de sensoriamento remoto de resolução espacial suficientemente grande), a caracterização de certas atividades de uso da terra podem exigir a aquisição e análise de dados adicionais, tais como o conhecimento de fronteiras políticas ou do contexto sócio-econômico de cada região. Assim, por todas estas razões, levantamentos baseados em imagens de sensoriamento remoto quase sempre consideram estes dois conceitos de forma simultânea, adotando-se sistemas de classificação que integram classes de uso e de cobertura do solo em um único mapeamento. Desta maneira, em casos práticos, procura-se criar uma legenda de classificação de uso e cobertura que seja efetivamente capaz de expressar todas as informações relevantes ao estudo em questão, ao mesmo tempo em que se mantém viável a realização de seu levantamento a partir de imagens de sensoriamento remoto.

2.1.2 Importância e aplicações

O conhecimento do uso e cobertura do solo constitui um dado essencial para o entendimento do território e da própria vida cotidiana em inúmeros sentidos, podendo ser considerado como uma ferramenta básica indispensável a qualquer processo de tomada de decisão do ponto de vista governamental a níveis tanto locais quanto regionais, nacionais, e globais. Com efeito, a diversidade das diferentes aplicações deste tipo de informação abrange aspectos dos mais diversos, incluindo questões econômicas, administrativas, ecológicas, comerciais e urbanísticas, dentre muitas outras. Do ponto de vista estritamente econômico, por exemplo, este tipo de conhecimento pode contribuir decisivamente para estimativas do volume de recursos naturais disponíveis numa dada região (*e.g.*, através de dados de cobertura do solo como a área ocupada por florestas), além de poder proporcionar insumos para políticas de planejamento econômico e manejo da terra através de preciosas informações sobre a extensão das áreas sendo usadas para diferentes atividades. Neste sentido, dados como o cálculo da área plantada de diferentes cultivos agrícolas podem permitir, por exemplo, que se façam estimativas da magnitude da safra agrícola e de seus conseqüentes impactos econômicos, tais como variações de preços dos produtos, pressão inflacionária, capacidade de geração de

empregos, e crescimento econômico. Com relação a questões administrativas, o monitoramento da dinâmica do uso e cobertura do solo permite, por exemplo, a observação dos fenômenos de expansão das fronteiras agrícolas e da ocupação urbana, correspondendo assim a um dado fundamental para a tomada de decisões com relação a investimentos em infra-estrutura ou logística. Por sua vez, informações relativas à localização e extensão de áreas industriais, comerciais, recreativas e residenciais são também importantes para orientar estratégias de atuação comercial e urbanística, possibilitando um direcionamento mais inteligente de suas atividades a partir da espacialização de medidas de demanda e de potencial de crescimento.

Sob outro ponto de vista, a dinâmica do uso e cobertura do solo também possui enorme relevância para processos de natureza ambiental e ecossistêmica, podendo ser relacionada a processos tão diversos quanto erosão dos solos, ciclos de carbono ou comportamento de espécies biológicas. Com efeito, a observação de variações da cobertura do solo, como desflorestamento e diminuições de cobertura vegetal em campos e pastos, é indispensável para a elaboração e fiscalização de ações de conservação florestal e biológica, além de auxiliar no entendimento dos processos erosivos e de seus conseqüentes impactos ambientais, sociais e econômicos, tais como o surgimento de voçorocas, assoreamento de rios e enchentes. Além disso, em conjunto com informações advindos da pedologia, geologia e climatologia, os dados de uso do solo também podem ser utilizados para estimar o nível de sustentabilidade das atividades econômicas exercidas em cada região, permitindo desta forma que se identifiquem áreas com alto risco de degradação ambiental.

Numa visão mais global, deve-se dizer que a dinâmica do uso e cobertura do solo e suas conseqüências para as características físicas da superfície (como topografia, albedo e cobertura vegetal) exercem uma influência direta sobre o próprio funcionamento dos ecossistemas, afetando assim as relações de troca de matéria e energia entre a superfície e a atmosfera, bem como entre a biota (plantas, animais e microorganismos) e o meio-ambiente [53][69]. Neste sentido, um extenso levantamento do uso e cobertura do solo permite, por exemplo, que se diferenciem regiões nas quais há manutenção de biomassa acima do solo (*e.g.* florestas, campos arbustivos) daquelas em que há períodos de pouca ou nenhuma atividade de crescimento acima do solo (*e.g.* áreas agrícolas), tornando possível a inferência de atributos fisiológicos críticos das plantas tais como a taxa de troca de gases [56][95]. Da mesma forma, uma diferenciação entre classes de vegetações decíduas e sempre-verdes permite que se estime a longevidade das folhas (isto é, o quanto as copas são repostas todo ano), o que, por sua vez, corresponde a uma variável crítica para a dinâmica do ciclo de

carbono da vegetação, além de ser importante, dentre outros, para a determinação de características de transferência de energia da superfície [95].

Com efeito, a influência do uso e cobertura do solo nestas relações de troca de matéria e energia em nosso planeta é tão importante que ela exerce um papel preponderante na determinação da natureza e qualidade dos chamados *serviços ecossistêmicos*, os quais incluem mecanismos vitais para a sobrevivência humana tais como a regulação dos gases atmosféricos responsáveis pelo efeito estufa (*greenhouse gases*) e a regulação hídrica, assim como o crescimento vegetal e o controle da erosão e da qualidade do solo. Por sua vez, os impactos causados por estes serviços acabam por se fazer sentir em variados sistemas naturais ao redor do planeta, sendo possível identificar, por exemplo, impactos locais com relação às condições do solo e à vegetação potencial, além de impactos globais com relação ao próprio sistema climático do planeta. Adicionalmente, as condições impostas pelos serviços ecossistêmicos também exercem uma influência decisiva em muitos sistemas humanos, tais como migrações ou políticas governamentais a nível local, regional, nacional e internacional, dentre as quais podemos citar programas de colonização de novas terras, determinação de áreas de proteção ambiental, e muitos outros. Finalmente, analisando este cenário, observa-se que todos estes sistemas afetados, tanto humanos quanto biofísicos, são por sua vez responsáveis diretos pelas condições que determinam novamente o uso e cobertura do solo de cada área. Portanto, trata-se na realidade de um complexo processo cíclico de retroalimentação (*feedback*) entre o uso e cobertura do solo, os mecanismos ecossistêmicos, e as variáveis biofísicas e humanas [53], conforme ilustrado pela Figura 2.1 abaixo.

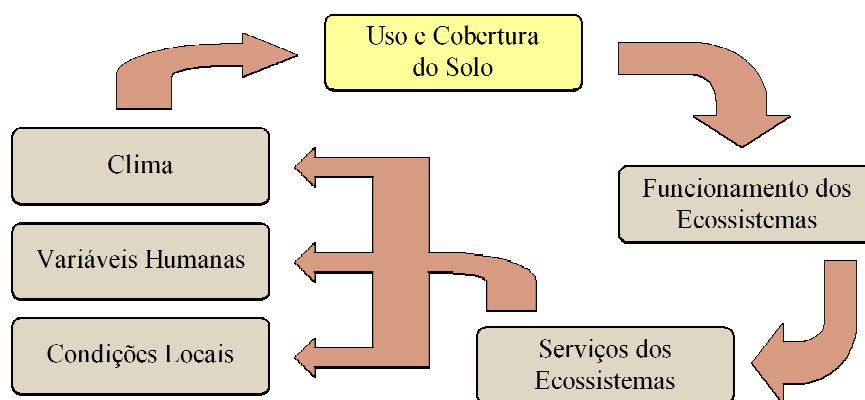


Figura 2.1 Influência do uso e cobertura do solo no processo cíclico de retroalimentação (*feedback*) existente entre os ecossistemas e os sistemas naturais e humanos

2.2 Princípios de sensoriamento remoto

2.2.1 Conceitos gerais

Segundo a definição de Lillesand e Kiefer [61], o termo “sensoriamento remoto” se refere à ciência e arte de se obterem informações sobre um objeto, área ou fenômeno através da análise de dados adquiridos por instrumentos localizados a alguma distância destes alvos (isto é, instrumentos que não estão em contato com o referido objeto, área ou fenômeno em estudo). Em particular, este termo é empregado com maior frequência quando os dados obtidos estão de alguma forma relacionados a atividades de mapeamento, aos recursos naturais e ao ambiente da Terra ou de outros planetas.

O sensoriamento remoto pode fazer uso de informações de natureza bastante diversa, tais como aquelas relacionadas a variações de campos gravitacionais, distribuições de ondas acústicas, ou propagações de energia eletromagnética. Na prática, entretanto, a grande maioria das aplicações de sensoriamento remoto faz uso exclusivamente desta última alternativa, uma vez que as ondas eletromagnéticas se propagam no vácuo a altíssimas velocidades e transportam uma diversidade extremamente rica de informações a respeito dos alvos. Desta forma, convém lembrar que esta radiação eletromagnética pode ser caracterizada pela *frequência* f de suas ondas, ou, inversamente, pelo seu *comprimento de onda* λ , de uma maneira tal que $c = \lambda f$ (onde c corresponde à velocidade da luz no vácuo, aproximadamente 300.000 km/s). Além disso, as diferentes frequências ou comprimentos de onda podem ser divididas em intervalos, também conhecidos como *faixas* ou *bandas*, conforme as suas propriedades especiais e/ou as diferentes finalidades para as quais elas podem ser utilizadas. Desta forma, ao conjunto de todas as possíveis frequências ou comprimentos de onda é atribuído o termo *espectro eletromagnético*, que pode então ser dividido em faixas ou bandas conforme a Figura 2.2 abaixo.




Figura 2.2 O espectro eletromagnético e suas diferentes faixas de frequência
Fonte: Santos [86]

2.2.2 Sensores de energia eletromagnética

Os sensores correspondem a instrumentos responsáveis por captar e medir as ondas eletromagnéticas, e em geral operam apenas em um determinado intervalo ou faixa do espectro. Desta forma, sensores que trabalham no espectro da luz visível, tais como os olhos humanos, são capazes de medir a intensidade de propagações eletromagnéticas cujos comprimentos de onda se encontram entre 380 e 750 nanômetros (sendo que 1nm corresponde a 10^{-9} m). Da mesma maneira, estes instrumentos podem ser sensíveis apenas a faixas mais estreitas do espectro, podendo agir como detectores exclusivamente de luz vermelha (comprimentos de onda aproximadamente entre 600 e 700nm, ou 0,6 e 0,7 μ m).

Sob outro ponto de vista, estes sensores também podem ser divididos em duas categorias principais. Os chamados *sensores passivos* se referem àqueles instrumentos que, desprovidos de fonte própria de propagação de energia, simplesmente captam as radiações eletromagnéticas emitidas por outra fonte. Assim, no caso geral, estes sensores terminam por medir a energia solar refletida ou, alternativamente, a radiação termal efetivamente emitida pelos próprios alvos. Por sua vez, os *sensores ativos* operam através da emissão própria de ondas eletromagnéticas, de forma a detectar, em seguida, como esta energia foi refletida pelos alvos. O exemplo mais conhecido deste tipo de sensor corresponde ao *radar* (sigla para *radio detection and ranging*), um instrumento que emite e capta ondas eletromagnéticas na faixa das micro-ondas, isto é, aquelas com comprimentos de onda aproximadamente entre 1mm e 1m.

Outras características importantes dos sensores dizem respeito ao grau de precisão com a qual eles medem a energia eletromagnética, o que tem papel preponderante na determinação dos tipos de objetos que podem ser detectados por cada sensor. Em primeiro lugar, a chamada *resolução espacial* estabelece a área de superfície mínima possível de ser discriminada pelo sensor, estando dependente das propriedades óticas ou eletrônicas do instrumento de detecção, bem como da sua posição com relação ao alvo. Na literatura de sensoriamento remoto, esta propriedade do instrumento também é conhecida como “campo de visada instantâneo” (IFOV, ou *instantaneous field of view*), numa referência à área ou ângulo para o qual a energia eletromagnética incidente é focada no detector. Na Figura 2.3, disposta abaixo, encontra-se uma visualização destes conceitos para pontos localizados imediatamente abaixo de um sensor ótico a nível orbital ou aerotransportado, sendo esta linha vertical conhecida como *linha de nadir*. Na realidade, deve-se ter em mente também que, para os demais pontos do terreno (*i.e.*, aqueles localizados “fora do nadir”), a resolução espacial observada pelo sensor será efetivamente menor ou mais pobre do que aquela mostrada na Figura 2.3, uma vez que o

IFOV observado pelo sensor corresponderá a áreas maiores ao nível do solo. Como última observação, convém ainda lembrar que, do ponto de vista de imagens digitais geradas a partir de sensores remotos, a resolução espacial do instrumento permite de fato a estimativa das dimensões reais dos *pixels* quadrados das imagens produzidas. Desta forma, também é bastante comum quantificar esta propriedade através da simples especificação da largura de cada *pixel* da imagem digital medido no nadir, num procedimento adotado nas descrições de sensores apresentadas neste trabalho (*e.g.*, Tabela 4.1, Tabela A.1, Tabela A.2). Portanto, neste caso, deve-se ter em mente que resoluções melhores corresponderão a *pixels* com dimensões *menores* (*i.e.*, uma resolução espacial de 10m é considerada superior a uma resolução de 20m).




Figura 2.3 Resolução espacial ou campo de visada instantâneo (IFOV) de um sensor ótico, para pontos no nadir. H corresponde à distância entre o sensor e o alvo, d ao tamanho do detector, e f à distância focal do sistema ótico, sendo que tipicamente $f \ll H$. Nestas condições, a resolução espacial efetiva pode ser computada a partir da relação $IFOV = Hd / f$

Fonte: adaptado de Santos [86]

Adicionalmente, além do aspecto espacial, a capacidade de discriminação de um sensor também depende de uma série de outros fatores, tal como o seu grau de sensibilidade com relação aos diferentes níveis de intensidade da energia eletromagnética captada. Esta sensibilidade, denominada *resolução radiométrica*, é dada simplesmente pelo número de níveis distintos de energia detectáveis pelo sensor, sendo comumente descrita a partir do número de bits necessários para codificar estes níveis digitalmente. Desta forma, uma resolução radiométrica de 8 bits equivale a uma capacidade de discriminação de 256 diferentes níveis de energia.

Por sua vez, a chamada *resolução espectral* de um sensor corresponde à precisão com a qual ele consegue medir propagações eletromagnéticas de comprimentos de onda muito específicos. Assim, instrumentos de detecção sensíveis apenas a faixas muito estreitas do espectro eletromagnético são considerados como sendo dotados de uma maior resolução espectral. Similarmente, o *número de bandas espectrais* captadas pelo sensor também pode ser considerado como uma medida de sua capacidade de detecção. Neste sentido, instrumentos sensíveis a mais de uma banda são costumeiramente denominados de sensores *multiespectrais*, enquanto que aqueles capazes de medir até centenas de bandas simultaneamente são conhecidos como sensores *hiperespectrais*. É importante se notar ainda que, via de regra, um maior número de bandas normalmente implica em faixas mais estreitas de sensoriamento, e conseqüentemente numa maior resolução espectral do sensor, porém deve-se ter sempre em mente que estas duas propriedades não são necessariamente perfeitamente correlacionadas entre si.

Finalmente, outro fator importante para definir a capacidade de discriminação de um sensor corresponde à frequência com a qual ele é capaz de realizar as suas medições. Esta capacidade, conhecida como *resolução temporal* ou *período de revisita* do sensor, é em geral dependente da forma como o instrumento é transportado para realizar a detecção dos alvos. Assim, para os chamados sensores orbitais, localizados a bordo de satélites espaciais, este período de revisita corresponde simplesmente ao tempo médio transcorrido entre dois imageamentos subseqüentes de um mesmo ponto da superfície, o qual é normalmente medido em dias. Com efeito, de forma geral, este período depende basicamente do regime orbital do satélite (*e.g.*, altitude, velocidade e ângulo de inclinação com relação ao equador), e da largura de faixa do terreno imageada pelo sensor a cada passagem. Entretanto, outros fatores externos, tais como falhas instrumentais ou obstruções de visão devido a cobertura de nuvens, podem prejudicar ou mesmo impossibilitar a frequência prevista de revisita em determinadas condições. Assim, por estas razões, a resolução temporal efetiva de um sensor orbital pode na prática ser inferior àquela considerada em teoria.

2.2.3 Interações da energia eletromagnética

Com efeito, a capacidade apresentada por um sensor para detectar um determinado tipo de alvo, e assim diferenciá-lo dos demais, depende não apenas das características do instrumento de detecção, mas obviamente das próprias propriedades físicas dos alvos em questão, de como elas se relacionam com a energia eletromagnética e da natureza e magnitude das interferências sofridas pelo sinal antes de chegar aos detectores do sensor.

De forma geral, como apresentado na Figura 2.4, a energia eletromagnética incidente (seja originada por um sensor ativo, seja de outra fonte, tal como o sol) atinge o alvo em questão e, dependendo de suas características, parcelas específicas desta energia serão respectivamente absorvidas, transmitidas, e refletidas de volta. Em particular, esse comportamento será normalmente diferente para cada tipo de alvo e cada comprimento de onda da energia incidente. Além disso, é interessante notar ainda que a energia absorvida por este alvo será geralmente re-emitida em algum momento posterior, porém em diferentes comprimentos de onda.




Figura 2.4 Interações entre a energia eletromagnética e a superfície. Dependendo do comprimento de onda e das características físicas da superfície, parcelas diferentes da energia incidente E_i serão absorvidas (E_A), transmitidas (E_T) ou refletidas (E_R) pelo alvo.

Fonte: adaptado de Santos [86] e Lillesand e Kiefer [61]

Por sua vez, a parcela da energia refletida pelos alvos pode ser redirecionada de volta de maneiras bastante diversas, dependendo das propriedades de rugosidade destes alvos. Neste contexto, os chamados *refletores especulares* ideais corresponderiam a superfícies planas capazes de refletir perfeitamente a energia incidente como se fossem espelhos, com o ângulo de reflexão equivalendo sempre ao ângulo de incidência. De forma inversa, os *refletores difusos* ou *lambertianos* ideais corresponderiam a superfícies “perfeitamente rugosas”, de maneira que a energia incidente terminasse sendo uniformemente refletida em todas as direções. Na prática, como as superfícies reais não se comportam desta forma ideal, é comum que se modelem as superfícies dos alvos como tendo uma característica majoritariamente especular, ou então majoritariamente difusa (Figura 2.5).




Figura 2.5 Da esquerda para a direita: modelos de reflexão especular ideal (a) e reflexão difusa ideal (b), seguidos de exemplos mais realistas de refletores especulares quase perfeitos (c) e refletores difusos quase perfeitos (d).

Fonte: adaptado de Santos [86] e Lillesand e Kiefer [61]

Entretanto, em certas situações, torna-se conveniente descrever em maior nível de detalhe as propriedades de reflexão características de cada tipo de alvo, o que pode ser realizado através da especificação de funções de distribuição bidirecional de reflexão (BRDFs, *bidirectional reflectance distribution functions*). Assim, estas funções descrevem, para uma condição específica de iluminação e um determinado comprimento de onda, o comportamento verificado para todos os ângulos possíveis de observação, tal como disposto na Figura 2.6.




Figura 2.6 Exemplo de função BRDF, descrevendo detalhadamente as características de reflectância de um tipo específico de cobertura do solo, dadas as condições de iluminação e o comprimento de onda.

Fonte: adaptado de Caron [18] e Bittner [13]

Um outro tipo de interação da energia eletromagnética, que tem fundamental importância para o sensoriamento remoto, corresponde às interferências introduzidas pela atmosfera terrestre, capazes de alterar significativamente o sinal emitido em determinadas situações. Em primeiro lugar, o *espalhamento* ou *scattering* atmosférico é causado pela presença de partículas ou moléculas no ar, levando assim a uma difusão aleatória da energia em propagação. O principal fenômeno deste tipo corresponde ao chamado *espalhamento Rayleigh*, que é causado por moléculas e partículas minúsculas muito menores do que o comprimento de onda da radiação incidente. Efetivamente, este espalhamento afeta mais significativamente aquelas propagações eletromagnéticas com menores comprimentos de onda, fazendo com que, por exemplo, a luz azul seja mais espalhada na atmosfera do que qualquer outra luz visível, sendo esta a principal razão da coloração do céu de nosso planeta. Por outro lado, nos casos de

partículas atmosféricas maiores, como vapor d'água, poeira e outros tipos de aerossóis, o fenômeno de difusão da energia eletromagnética ocorre quando o comprimento de onda da radiação se assemelha ao diâmetro destas partículas, levando ao fenômeno conhecido como *espalhamento Mie*. Finalmente, o chamado *espalhamento não-seletivo* se verifica em situações onde o diâmetro das partículas suspensas são muito maiores do que o comprimento de onda da energia propagada, tal como ocorre com gotas d'água. Este tipo de espalhamento constitui um problema mais sério para aplicações de sensoriamento remoto, uma vez que são afetados todos os comprimentos de onda na faixa do visível, infra-vermelho próximo, e infra-vermelho médio, dificultando qualquer procedimento de correção.

De outra forma, uma segunda interferência fundamental causada pela atmosfera terrestre consiste nos efeitos de *absorção atmosférica*, os quais levam a uma perda de energia e a uma conseqüente deterioração do sinal eletromagnético. De fato, hoje em dia sabe-se que os principais responsáveis pela ocorrência deste tipo de fenômeno são o vapor d'água, o dióxido de carbono (CO_2), e o ozônio (O_3), gases estes que estão presentes em razoável quantidade na maior parte da atmosfera terrestre. Além deles, o oxigênio (O_2) e o óxido nitroso (N_2O) também podem causar interferências. Felizmente, no entanto, a perda de energia causada por estes efeitos de absorção tende a ocorrer apenas em faixas bastante específicas do espectro eletromagnético. Desta forma, os sensores a nível orbital são normalmente projetados de modo a captar radiação apenas daquelas faixas de comprimentos de onda que não sofrem interferências significativas destes efeitos atmosféricos. Configuram-se, assim, autênticas “janelas espectrais”, correspondendo às regiões do espectro eletromagnético que são efetivamente propícias para o sensoriamento remoto através da atmosfera (Figura 2.7).




Figura 2.7 Absorção atmosférica da radiação ao longo do espectro eletromagnético, quantificada pela taxa de transmissão de energia ao longo de um caminho de 1km. Áreas majoritariamente azuis indicam faixas de comprimentos de onda muito absorvidas pela atmosfera, ao passo que as áreas mais brancas correspondem a “janelas espectrais” onde a interferência atmosférica não é tão significativa, correspondendo assim a faixas mais apropriadas para aplicações de sensoriamento remoto.

Fonte: adaptado de Short [93]

De fato, observando esta figura, percebe-se claramente que os comprimentos de onda nas faixas do visível e das micro-ondas se mostram como regiões de níveis de absorção atmosférica relativamente baixa, justificando assim o uso de sensores óticos e de radar como

alternativas mais interessantes para o sensoriamento remoto da superfície terrestre. Por sua vez, pode-se ver também que na faixa do infra-vermelho se faz necessária uma alta precisão radiométrica do sensor, de modo a tentar evitar que os níveis de energia medidos incluam radiações de faixas do espectro demasiadamente afetadas pela interferência da atmosfera.

2.2.4 Resposta espectral dos alvos

Apesar das diversas fontes de ruídos e interferências e da grande variabilidade da resposta espectral dos alvos, pode-se constatar que o uso de sensoriamento remoto permanece sendo uma abordagem perfeitamente viável para a identificação de tipos distintos de coberturas da superfície terrestre. De fato, observando o comportamento típico da resposta espectral de diferentes tipos de alvos naturais (Figura 2.8), é possível observar que superfícies como água, solo exposto e vegetação saudável apresentam propriedades bastante características ao longo do espectro eletromagnético.




Figura 2.8 Respostas espectrais típicas para diversos tipos de cobertura do solo, de acordo com o comprimento de onda da energia eletromagnética.

Fonte: adaptado de Santos [86]

De fato, observando esta figura, percebe-se, por exemplo, que a água límpida apresenta um comportamento de forte absorção da energia eletromagnética em quase todos os comprimentos de onda, configurando-se um nível razoável de reflectância apenas na faixa do azul. Por sua vez, corpos d'água com material em suspensão (*e.g.*, rios turvos) apresentam respostas espectrais um pouco distintas, observando-se índices maiores de reflectância em

todas as faixas da luz visível, e também em uma parcela da região do infra-vermelho próximo. Já os solos expostos apresentam comportamentos totalmente diferentes, com os maiores níveis de reflectância sendo verificados na região do infra-vermelho médio. Além disso, neste caso também se verifica a possibilidade de diferenciação entre solos expostos de características predominantemente arenosas (cujas reflectâncias são muito altas nas faixas do vermelho, infra-vermelho próximo e infra-vermelho médio) daqueles solos mais argilosos (com respostas de intensidades bem mais baixas).

Finalmente, deve-se observar também que as áreas cobertas por vegetação apresentam um comportamento espectral de características muito peculiares, num conjunto de fenômenos relacionados aos processos bioquímicos e à própria estrutura física das plantas. Em primeiro lugar, verifica-se a existência de um alto nível de absorção de energia eletromagnética na faixa da luz visível, num processo decorrente da atividade de fotossíntese costumeiramente realizada pela vegetação saudável. Entretanto, se observarmos esta região do espectro com maior atenção, poderemos notar também um pequeno pico de reflectância na faixa da luz verde, o que é responsável pela coloração assumida pelos vegetais. Além disso, observa-se que a absorção de energia pela vegetação para a realização de fotossíntese se dá exatamente numa faixa do espectro de baixa absorção atmosférica, como visto na Figura 2.7, o que maximiza a quantidade de radiação passível de ser absorvida.

Dando prosseguimento à análise do comportamento espectral das plantas, podemos observar também que há uma característica bastante peculiar na faixa do infra-vermelho próximo. Nesta região do espectro, são de forma geral verificados altíssimos níveis de reflectância, num fenômeno associado à própria estrutura das folhas dos vegetais, e causado especificamente pela descontinuidade dos índices de refração do ar e das paredes celulósicas hidratadas [55][70]. Além disso, verifica-se que o índice de reflectância nesta faixa também aumenta de acordo com o número de camadas de folhas presentes no dossel vegetativo, uma vez que nestes casos parte da energia transmitida através da primeira camada de folhas é refletida pelas camadas subseqüentes [55][61][70]. Por fim, a água líquida presente nas folhas das plantas também provoca uma absorção significativa em determinadas faixas da região do infra-vermelho médio, levando assim aos “vales” observados para estes comprimentos de onda na parte direita da curva de resposta espectral da vegetação (Figura 2.8).

Com efeito, o comportamento espectral peculiar deste tipo de cobertura torna possível uma efetiva caracterização da densidade de vegetação na superfície a partir da combinação de informações de diferentes faixas do espectro eletromagnético. Desta forma, ao longo dos anos, diversos *índices de vegetação* foram estabelecidos com base nos valores de reflectância

medidos por diferentes bandas de sensores remotos, de modo a tentar sintetizar a informação colhida de uma maneira prática e informativa. De um modo geral, estes índices fazem uso principalmente das respostas captadas nas faixas do vermelho (ou alternativamente de toda a região do visível) e do infra-vermelho próximo, podendo às vezes incluir informações em outras faixas, como no azul e no infra-vermelho médio. Na realidade, embora existam muitas dezenas de índices de vegetação na literatura, com diferentes peculiaridades, vantagens e desvantagens, o mais conhecido e utilizado na prática corresponde ao chamado *índice de vegetação por diferenças normalizadas* (NDVI, *normalized differential vegetation index*), o qual é definido pela seguinte relação (equação (2.1)):

$$NDVI = \frac{IVP - V}{IVP + V} \quad (2.1)$$

sendo:

- IVP : reflectância medida na faixa do infra-vermelho próximo
- V : reflectância medida na faixa do vermelho

Ao longo dos anos, diversos estudos comprovaram que o NDVI consiste de fato numa medida bastante robusta, sendo capaz de minimizar a interferência de diversos fatores externos à cobertura do solo propriamente dita e que afetam ambas as bandas de forma similar, tais como condições variantes de iluminação, declividade do terreno, orientação de vertentes, e certos efeitos atmosféricos [61]. Além disso, verificou-se também que este índice está correlacionado com diversos fenômenos biofísicos da vegetação, podendo-se utilizá-lo para estimar grandezas como a biomassa, o índice de área foliar (LAI, *leaf area index*), a fração de radiação fotossinteticamente ativa absorvida (fPAR, *fraction of photosynthetically-active radiation absorbed*) e a produtividade primária líquida (NPP, *net primary production*) [113][61][70]. Desta forma, sendo um termo de cálculo computacional extremamente simples, exigindo pouca informação de entrada (apenas duas bandas) e não requerendo qualquer tipo de calibração, este índice se mostra bastante interessante para a discriminação de tipos diferentes de cobertura do solo e sua relação com processos ecossistêmicos tais como os ciclos de carbono e de água. Deve-se notar, entretanto, que certos tipos de interferência ainda podem induzir a variações de NDVI que não estão de modo algum relacionadas à cobertura vegetal, dentre os quais podemos destacar alguns efeitos atmosféricos (especialmente aqueles causados pela presença de aerossóis), ângulos de visada demasiadamente grandes (*i.e.*, pontos muito distantes do nadir), características particulares dos sensores remotos, e variações no ângulo de incidência da radiação solar [61].

2.3 Introdução à classificação de imagens digitais

2.3.1 Conceitos básicos

De forma simplificada, o processo de classificação de uma imagem digital pode ser definido como o ato de se atribuir uma determinada *classe* para cada ponto ou cada *pixel* desta imagem. Desta forma, na verdade este processo corresponde a uma análise dos dados originais de uma imagem, transformando-os então em *informação* dotada de um maior nível de abstração e maior utilidade prática. Assim, pode-se afirmar que, no caso geral, a atribuição de classes realizada a partir da imagem original tem como consequência a produção de um *mapa temático*. Além disso, em particular, a análise de imagens aéreas ou orbitais da superfície terrestre pode ser realizada de forma a se produzir um mapa de *uso e cobertura do solo*, tal como exemplificado na Figura 2.9.



Figura 2.9 Imagem da superfície terrestre (à esquerda) e o resultado de um processo de classificação (à direita). Os dados originais são transformados em informação pelo processo classificatório, gerando-se como resultado um mapa temático de uso e cobertura do solo. Neste caso, áreas em azul correspondem a água, verde a áreas cobertas por vegetação, e rosa/alaranjado a áreas de solo exposto.

Sob um outro ponto de vista, o processo de classificação também pode ser entendido como um meio de *simplificar* ou *condensar* os dados originais, facilitando assim quaisquer procedimentos subseqüentes de processamento. Efetivamente, uma imagem de sensoriamento remoto tal como a disposta na Figura 2.9 normalmente compreende diversas bandas de dados (*e.g.*, medições nas faixas do verde, vermelho, infra-vermelho próximo, etc), de modo que cada *pixel* pode apresentar níveis quaisquer de intensidade de energia refletida em cada uma destas bandas. Assim, a título de ilustração, uma imagem como esta pode apresentar 3 bandas e 256 possíveis níveis de reflectância para cada banda, o que representa um total de $256^3 = 16.777.216$ variantes possíveis para cada *pixel* da imagem. Entretanto, se a informação relevante para o usuário corresponder simplesmente a uma discriminação entre áreas de vegetação, solo exposto e água, este volume de dados poderia ser drasticamente reduzido

através de um processo de classificação da imagem, resultando, assim, em apenas 3 variantes possíveis para cada *pixel*.

O processo de classificação de qualquer imagem digital está baseado no *agrupamento* de elementos que são considerados semelhantes entre si, a partir de algum critério bem definido. Na realidade, esta medida de similaridade não precisa estar restrita apenas aos níveis de reflectância medidos em cada ponto, podendo-se efetivamente levar em consideração uma vasta gama de *atributos* que de uma forma ou outra contribuam para a caracterização destes pontos. Desta forma, por exemplo, podem-se incluir no processo classificatório dados como a altitude de cada ponto, a sua declividade, a temperatura na superfície ou a velocidade do vento, sejam estes dados provenientes de sensoriamento remoto ou de outras fontes de informação. Outra possibilidade consiste na utilização de dados de reflectância captados em vários momentos ao longo do tempo, sendo a reflectância de cada data interpretada como um atributo diferente. Assim, no caso geral, cada “banda” da imagem final a ser classificada corresponde simplesmente a uma matriz, a qual informa, para cada *pixel*, os valores medidos ou obtidos para o atributo em questão. Desta maneira, em qualquer situação o grau de similaridade ou discrepância entre dois pontos distintos pode ser visualizado e medido naquilo que se define como o *espaço dos atributos*, isto é, o espaço formado por todos os valores possíveis de serem assumidos pelos *pixels* de cada uma destas bandas (Figura 2.10).




Figura 2.10 Espaço dos atributos para uma imagem com duas bandas. Pontos com respostas similares em ambos os atributos estarão necessariamente próximos entre si.

Neste contexto, o processo de classificação consiste simplesmente num agrupamento de pontos similares ou próximos entre si neste espaço de atributos. Com efeito, a medida de similaridade a ser utilizada na prática é de caráter arbitrário, podendo ser definida, por exemplo, como a simples distância euclidiana entre dois pontos no espaço de atributos, isto é:

$$d = \sqrt{\sum_{i=1}^n (a_i - b_i)^2} \quad (2.2)$$

sendo:

- n : o número total de atributos ou bandas na imagem
- a_i : o valor medido ou obtido para o i -ésimo atributo num ponto a
- b_i : o valor medido ou obtido para o i -ésimo atributo num ponto b

Sob um outro ponto de vista, o processo classificatório pode ser entendido como uma *partição* do espaço dos atributos, definindo-se assim *fronteiras de decisão* responsáveis pela escolha da classe a ser atribuída a cada ponto deste espaço. Portanto, é de fundamental importância ter em mente que uma discriminação satisfatória entre duas classes será possível *apenas* quando os elementos de cada classe ocuparem regiões nitidamente distintas deste espaço. De outro modo, os dados fornecidos para a classificação devem ser considerados como sendo insuficientes para a realização desta discriminação, sendo as referidas classes qualificadas como *não-separáveis* a partir dos atributos disponíveis (Figura 2.11).




Figura 2.11 Separabilidade entre classes no espaço de atributos. A distinção entre as diferentes classes é realizada a partir da partição deste espaço e da definição de fronteiras de decisão. Caso duas classes ocupem a mesma região no espaço de atributos (pontos amarelos e vermelhos), elas não poderão ser adequadamente discriminadas entre si a partir da informação utilizada.

Como últimas observações, deve-se ter em mente também que, em certos casos, pontos pertencentes a uma determinada classe não irão ocupar regiões necessariamente contínuas dentro do espaço de atributos. Nesta situação, diz-se então que a classe em questão apresenta uma *distribuição multimodal*, num fenômeno que pode impossibilitar sua correta classificação a partir de partições simples deste espaço, exigindo portanto a aplicação de procedimentos mais complexos de classificação (Figura 2.12).




Figura 2.12 Exemplo de uma classe com distribuição multimodal no espaço de atributos (pontos verdes). Métodos simples de classificação podem ser inadequados para tratar casos como este de forma satisfatória e diferenciar corretamente as classes de interesse.

Finalmente, é importante lembrar também que, em algumas situações, os atributos utilizados para a classificação podem na verdade não ser de natureza numérica contínua, havendo a possibilidade de se empregarem dados binários (*e.g.*, uma máscara oceano/terra firme), ou mesmo variáveis discretas ou nominais de ordem genérica, tais como o resultado de outras classificações (*e.g.*, a classificação do uso e cobertura do solo 10 anos antes, ou o tipo de feição geológica levantado para cada ponto da imagem).

2.3.2 Estratégias para classificação de padrões

Numa visão mais geral, as diferentes abordagens de classificação existentes na literatura são divididas em dois grandes grupos principais: as *classificações não-supervisionadas*, e as *classificações supervisionadas*.

A primeira dessas duas categorias, também chamada na literatura de “clusterização” ou *clustering*, se refere a técnicas que procuram discriminar grupos ou classes de elementos exclusivamente a partir dos próprios dados fornecidos, isto é, requerendo pouca ou nenhuma informação adicional a respeito da natureza ou da distribuição destas classes no espaço de atributos. Desta forma, algoritmos deste tipo procuram simplesmente criar aglomerações ou *clusters* de pontos que estejam próximos entre si no espaço de atributos, o que é realizado através de alguma medida qualquer de similaridade (*e.g.*, distância euclidiana com relação ao centróide de cada classe, como descrito na equação (2.2)). Sob um certo ponto de vista, este tipo de estratégia pode ser entendido como uma partição de dados em aglomerações “naturais”, isto é, em grupos que de alguma forma obedecem à própria estrutura da informação e assim independem de questões de interpretação ou critérios subjetivos de discriminação. Desta maneira, este tipo de técnica tem como objetivo fundamental minimizar

ao extremo a necessidade de intervenção humana, tornando o procedimento tão automatizado quanto possível.

Em contrapartida, os métodos supervisionados de classificação têm como característica principal o fornecimento de algum tipo de informação adicional ao algoritmo, de modo que a natureza e distribuição de cada classe possa ser definida ou estimada *a priori*, isto é, anteriormente à categorização efetiva dos dados de interesse. Em outras palavras, o algoritmo é executado sob a *supervisão* de uma informação externa, de modo a se computarem antecipadamente as fronteiras de decisão necessárias para a partição do espaço de atributos. Por esta razão, estes métodos apresentam na realidade duas etapas bastante distintas durante o processo de classificação. Em primeiro lugar, executa-se uma fase de *treinamento* ou *aprendizado*, onde na maioria dos casos são fornecidas ao algoritmo amostras de dados pertencentes a cada uma das classes de interesse. Então, através da observação destas amostras, estimam-se as distribuições das classes no espaço de atributos, demarcando-se por conseguinte as fronteiras de decisão entre cada uma delas. Em seguida, executa-se finalmente a etapa de classificação propriamente dita, na qual estas fronteiras de decisão são efetivamente utilizadas para decidir a que classe cada ponto avaliado deve pertencer.

É importante se ter em mente que, via de regra, o desempenho dos métodos supervisionados de classificação é significativamente melhor do que aquele verificado para os métodos não-supervisionados [102]. Tal fato é na realidade bastante compreensível, uma vez que os métodos supervisionados dispõem de uma maior riqueza de informações graças ao seu período de treinamento. Assim, estes métodos freqüentemente conseguem detectar diferenças entre as classes que dificilmente seriam percebidas a partir da simples análise não-supervisionada da distribuição geral dos dados no espaço de atributos. Por esta razão, na prática, as técnicas não-supervisionadas são muitas vezes utilizadas como um primeiro passo de análise, de modo a fornecer insumos para a aplicação de um método supervisionado, chegando-se assim à classificação final dos dados [27]. Neste sentido, esses algoritmos de “clusterização” são úteis para proporcionar uma medição preliminar e bastante imparcial acerca do potencial de separabilidade entre as classes, identificando-se assim o nível de adequação da legenda de classificação adotada com relação aos dados disponíveis. Além disso, estes métodos também podem ser empregados como uma base para facilitar a escolha de amostras representativas de cada classe, uma vez que ela permite identificar as regiões do espaço inconfundivelmente associadas a cada um dos agrupamentos, em contraste com aquelas regiões próximas às prováveis fronteiras de decisão entre classes distintas.

Por outro lado, apesar de seu desempenho superior, é importante se enfatizar também que os métodos supervisionados, por necessitarem de amostras de treinamento, exigem um maior nível de intervenção humana e assim levam a maiores custos para a execução do processo de classificação como um todo. Com efeito, a aquisição de um conhecimento externo, necessário ao aprendizado do algoritmo, freqüentemente exige que se adotem procedimentos bastante custosos de levantamento de informações, tais como cuidadosas interpretações visuais das imagens por meio de especialistas ou consultas a outras mapas e bases de dados. Desta forma, não apenas se configura um maior custo do ponto de vista financeiro (*e.g.*, contratação de serviços de especialistas), como também se expõem os procedimentos de classificação às potenciais incoerências e subjetividades inerentes às fontes destas informações de treinamento, o que acaba tornando o procedimento classificatório como um todo relativamente lento e complexo.

Por fim, uma outra distinção importante a ser notada entre as diferentes estratégias de classificação diz respeito às eventuais suposições realizadas pelos algoritmos com relação às distribuições das classes no espaço de atributos. Neste sentido, os chamados *métodos paramétricos*, geralmente mais simples, fazem uso de algumas destas hipóteses de maneira a tentar minimizar a complexidade das medidas de similaridade entre dois pontos neste espaço. Como exemplo deste tipo de suposição, podemos retornar ao caso de algoritmos que fazem uso da distância euclidiana (equação (2.2)) para este fim. Neste caso, a hipótese adotada estabelece que discrepâncias entre valores de um atributo i são sempre diretamente comparáveis a discrepâncias de mesma magnitude para um segundo atributo j , o que não se verifica necessariamente na prática. Assim, para que técnicas deste tipo possam ser adequadamente usadas na prática, torna-se evidente a necessidade de algum tipo de *normalização* dos valores de todos os atributos, de modo que se consiga colocá-los numa mesma base de comparação. Alternativamente, outros métodos paramétricos de classificação consistem nos chamados *métodos estatísticos*, os quais supõem que as diferentes classes de interesse apresentam distribuições normais ou gaussianas de probabilidade ao longo do espaço de atributos. Na prática, esta suposição costuma ser razoavelmente simples e robusta, porém ela apresenta também importantes limitações, particularmente com relação à correta estimativa das distribuições de probabilidade a partir dos dados de treinamento. Em contrapartida, os chamados *métodos não-paramétricos*, tais como as redes neurais e as árvores de decisão, possuem uma natureza mais complexa de implementação, porém não realizam em princípio qualquer tipo de suposição com relação aos dados de entrada, sendo assim em tese mais adequados e adaptáveis a qualquer tipo de problema.

2.3.3 Redução de dimensionalidade e extração de atributos

Um dos principais empecilhos com relação à aplicação de algoritmos de classificação em problemas de ordem genérica consiste na chamada “maldição da dimensionalidade” [27]. Este problema, de fato, está relacionado à utilização de um número excessivo de atributos para a análise dos dados, o que acaba prejudicando severamente o processo classificatório de diversas maneiras diferentes. Em primeiro lugar, a caracterização dos dados através de dezenas ou centenas de atributos leva invariavelmente a níveis muito maiores de redundância de informações, o que por sua vez dificulta a correta interpretação do seu significado. Desta forma, os algoritmos de classificação terminam tendo grandes dificuldades para conseguir analisar estes dados e identificar corretamente as fronteiras de decisão entre as classes de interesse. Como consequência, os resultados finais encontrados pelos algoritmos acabam sendo significativamente prejudicados, ao mesmo tempo em que se provoca um aumento extraordinário dos custos computacionais de processamento. Adicionalmente, no caso de métodos supervisionados de classificação, este número excessivo de atributos também torna necessária a utilização de quantidades muito maiores de amostras, de forma a se poder viabilizar o aprendizado das distribuições das diferentes classes durante a fase de treinamento. Portanto, nestes casos tem-se como resultado adicional um aumento significativo dos custos financeiros, além de um maior nível de complexidade para o processo como um todo.

Assim, com o intuito de reduzir o impacto deste problema, podem-se utilizar diversas estratégias de maneira a compactar estes dados de entrada e assim diminuir a sua dimensionalidade. Mais especificamente, estas abordagens têm como objetivo proporcionar uma forma de *extrair* destes dados apenas aquelas características que podem ser consideradas úteis ou relevantes para o processo de classificação. Desta forma, uma estratégia possível consiste na *transformação* destes dados, combinando-os de forma a se atingir um conjunto de informações mais enxuto e significativo. Neste sentido, o cálculo do índice de vegetação NDVI, por exemplo (equação (2.2), seção 2.2.4), permite compactar os dados provenientes de duas bandas (no caso, vermelho e infra-vermelho próximo), proporcionando ao mesmo tempo uma medida mais clara e informativa a respeito da presença de vegetação fotossinteticamente ativa em cada ponto analisado. Alternativamente, outras abordagens de redução de dimensionalidade realizam simplesmente uma *seleção* daqueles atributos considerados mais importantes para a discriminação entre as classes de interesse. Neste caso, as medidas obtidas para cada ponto não sofrem nenhum processo de transformação, evitando assim que se perca o sentido original destes atributos, numa estratégia que também pode ser interessante do ponto de vista da interpretabilidade do resultado final. De todo modo, qualquer que seja a estratégia,

estes algoritmos de redução de dimensionalidade terão sempre como objetivo final a definição de um conjunto que reduza ao extremo o número de atributos utilizados para a classificação, ao mesmo tempo em que consegue capturar ao máximo a informação relevante contida nos dados disponíveis.

2.3.4 Avaliação de resultados

Após o processo de classificação propriamente dito, é também importante confrontar os resultados computados para os dados de interesse com a realidade efetivamente verificada para cada ponto. Nesse sentido, esta abordagem torna possível avaliar a capacidade e propriedade do algoritmo de classificação, e, se for o caso, até mesmo validar o seu uso como ferramenta confiável de análise. Entretanto, para que isto possa ser feito, configura-se antes de mais nada a necessidade de se adquirir uma classificação “correta” dos pontos a partir de alguma fonte alternativa e totalmente confiável, sendo estes dados de referência conhecidos na literatura como a “verdade terrestre” da região em análise.

De fato, uma vez obtidos os dados, o procedimento de avaliação dos resultados é bastante simples, consistindo basicamente em verificar, para cada ponto analisado, se a classe atribuída pelo algoritmo equivale efetivamente àquela observada pela verdade terrestre. Entretanto, é importante notar que uma avaliação quantitativa da acurácia do resultado deve na verdade levar em conta dois aspectos diferentes, podendo portanto ser realizada de duas maneiras distintas e ao mesmo tempo complementares. Neste sentido, uma primeira abordagem de avaliação toma por base a atribuição de classes especificada pela verdade terrestre, para então calcular qual percentagem destes pontos é efetivamente classificada da mesma forma pelo algoritmo executado. Portanto, neste caso, tem-se uma avaliação cujo objetivo consiste em indicar o quanto da realidade consegue ser apreendida corretamente pelo algoritmo, o que resulta numa medida conhecida na literatura como *acurácia do produtor*. De maneira inversa, uma segunda abordagem de avaliação consiste em tomar como referência o resultado da classificação e, então, verificar para cada classe a percentagem de pontos que foram corretamente classificados segundo a verdade terrestre disponível. Assim, neste caso, obtém-se a chamada *acurácia do usuário*, o que consiste numa medida da confiabilidade das atribuições de classes realizadas pelo algoritmo de classificação executado.

Além disso, com o intuito de facilitar a compreensão dos resultados e permitir uma visualização dos erros cometidos, utiliza-se freqüentemente na literatura um recurso denominado *matriz de confusão*. Esta matriz, cujo exemplo se encontra disposto na Tabela 2.1, consiste simplesmente numa tabela que apresenta, classe a classe, todas as comparações

possíveis entre a verdade terrestre e os resultados alcançados após a execução do algoritmo de classificação.

	<i>Dados de Referência</i>				
	Água	Pastagem	Floresta	Urbano	Total
<i>Resultados</i>					
Água	480	0	0	10	490
Pastagem	0	240	30	15	285
Floresta	0	5	305	10	320
Urbano	0	0	0	105	105
Total	480	245	335	140	1200

Tabela 2.1 Exemplo de matriz de confusão, utilizando dados fictícios para 4 classes: água, pastagem, floresta e áreas urbanas.

Observando esta matriz, temos que a verdade terrestre (*i.e.*, os dados de referência) pode ser lida coluna a coluna, enquanto que os resultados da classificação são dispostos linha a linha. Desta forma, os valores na diagonal da matriz indicam os pontos classificados corretamente pelo algoritmo em avaliação, sendo todos os demais elementos representativos de erros de classificação. Portanto, uma classificação perfeita seria representada por uma matriz de confusão contendo valores diferentes de zero apenas ao longo de sua diagonal. Além disso, se tomarmos a coluna “Pastagem” neste exemplo, poderemos observar todas as classificações realizadas para as áreas pertencentes a esta classe segundo a verdade terrestre. Assim, neste caso, demonstra-se que, de um total de 245 pontos de pastagem, 240 deles foram classificados corretamente pelo algoritmo sendo avaliado, enquanto outros 5 pontos foram erroneamente classificados como floresta.

Em seguida, a partir destes dados, podem também ser facilmente computadas as diversas acurácias do usuário e do produtor, discutidas mais acima. Assim, se enumerarmos as linhas i e colunas j de 1 a n segundo a classe à qual elas se referem, podemos obter as seguintes relações (equações (2.3) e (2.4)):

$$Acur. Usr._i = \frac{x_{ii}}{\sum_{j=1}^n x_{ij}} \quad (2.3)$$

$$Acur. Prod._j = \frac{x_{jj}}{\sum_{i=1}^n x_{ij}} \quad (2.4)$$

sendo:

- n : o número de classes
- x_{ij} : o elemento da matriz de confusão de linha i e coluna j
- $Acur. Usr._i$: a acurácia do usuário para a classe descrita na linha i
- $Acur. Prod._j$: a acurácia do produtor para a classe descrita na coluna j

Portanto, seguindo no exemplo da classe “Pastagem” a partir da Tabela 2.1, podemos computar uma acurácia do produtor de $240/245 = 97,96\%$, ao passo que a acurácia do usuário para esta mesma classe corresponde a apenas $240/285 = 84,21\%$. Estes resultados indicariam então que, embora a maioria das áreas de pastagem tivesse sido corretamente classificada (*i.e.*, poucos erros de omissão para esta classe), certas áreas identificadas como tal seriam na realidade pertencentes a outras classes. No caso, 30 pontos seriam áreas de floresta, e 15 outros pontos seriam correspondentes a áreas urbanas, o que indicaria assim uma maior quantidade de erros de comissão com relação a esta classe.

Entretanto, além destas medidas de acurácia por cada classe, é também de suma importância uma avaliação global da classificação como um todo, de modo a permitir uma comparação simples e direta entre diferentes algoritmos e/ou diferentes regiões de análise. Assim, com esta finalidade, utiliza-se comumente uma medida de *acurácia global* da classificação, correspondendo simplesmente à razão entre a soma dos pontos corretamente classificados (*i.e.*, o traço da matriz de confusão) e o total de pontos avaliados, isto é:

$$\text{Acur.Global} = \frac{\sum_{i=1}^n x_{ii}}{N} \quad (2.5)$$

sendo:

- n : o número de classes
- x_{ii} : o i -ésimo elemento na diagonal da matriz de confusão (*i.e.*, linha i e coluna i)
- N : o número total de pontos avaliados (*i.e.*, soma de todos os elementos da matriz)

Assim, no exemplo disposto na Tabela 2.1, teríamos uma acurácia global de $480+240+305+105 / 1200 = 1130/1200 = 94,17\%$, indicando um ótimo nível de concordância geral entre os resultados da classificação e a verdade terrestre neste caso.

Entretanto, ao se interpretar uma medida como essa, é importante que se leve em consideração também que mesmo uma classificação totalmente aleatória levará inevitavelmente a algum nível de acerto dos resultados. Além disso, dependendo da distribuição das classes (*e.g.*, maioria dos pontos pertencentes a uma mesma classe), é possível até mesmo que esta atribuição aleatória forneça uma acurácia global bastante boa. Assim, para minimizar este tipo de problema, utiliza-se alternativamente uma outra medida de avaliação dos resultados, conhecido na literatura como *coeficiente kappa* ou “KHAT” [21][61]. Conceitualmente, esta estatística procura medir a diferença existente entre a acurácia do resultado e aquela acurácia verificada para uma atribuição aleatória de classes para cada ponto, ou seja:

$$kappa = \frac{acurácia\ global - acurácia\ aleatória}{1 - acurácia\ aleatória} \quad (2.6)$$

Desta forma, um valor *kappa* equivalente a 0 indicaria um resultado tão ruim quanto uma atribuição aleatória de classes, ao passo que um resultado de 1 indicaria uma classificação perfeita. Além disso, um coeficiente de *kappa* de 0,50 poderia ser interpretado como um indicador de que o algoritmo executado alcançou uma acurácia 50% superior a esta atribuição aleatória de classes. Em tese, este coeficiente poderia até mesmo ser negativo, em casos extremos onde os resultados alcançados são efetivamente inferiores a uma classificação aleatória dos pontos. Objetivamente, o coeficiente *kappa* é calculado da seguinte forma (equação (2.7) [61]):

$$kappa = \frac{\frac{\sum_{i=1}^n x_{ii}}{N} - \frac{\sum_{i=1}^n (x_{i+} \cdot x_{+i})}{N^2}}{1 - \frac{\sum_{i=1}^n (x_{i+} \cdot x_{+i})}{N^2}} \quad (2.7)$$

sendo:

- n : o número de classes
- x_{ii} : o i -ésimo elemento na diagonal da matriz de confusão (*i.e.*, linha i e coluna i)
- x_{i+} : total de pontos classificados como sendo da classe i (*i.e.*, total da linha i)
- x_{+i} : total de pontos pertencentes à classe i (*i.e.*, total da coluna i)
- N : o número total de pontos avaliados (*i.e.*, soma de todos os elementos da matriz)

Portanto, no exemplo utilizado anteriormente (Tabela 2.1), obter-se-ia como resultado um valor de *kappa* equivalente a 0,9171. Finalmente, é importante notar ainda que, via de regra, o valor de *kappa* deverá ser sempre inferior àquele encontrado para a acurácia global (neste caso 0,9417), uma vez que se está desconsiderando a parcela de acerto do resultado que seria obtido aleatoriamente.

2.4 Considerações finais

Neste capítulo foram delineados os fundamentos teóricos relativos aos principais assuntos abordados neste trabalho. Assim, apresentaram-se os conceitos gerais de uso e cobertura do solo, bem como das técnicas de sensoriamento remoto e de classificação de padrões. Em seguida, no capítulo 3, será fornecida uma visão geral acerca das principais abordagens do passado e do presente com relação ao mapeamento do uso e cobertura do solo sobre grandes regiões, de modo a servir de base para a compreensão da metodologia descrita mais adiante.

3 Uso e Cobertura do Solo em Larga Escala

Este capítulo tem como objetivo apresentar uma revisão bibliográfica, descrevendo as abordagens utilizadas no passado e o estado da arte do mapeamento do uso e cobertura do solo em escalas regionais, continentais e globais. Além disso, também se incluirá aqui uma breve discussão acerca das limitações, vantagens e aplicabilidade de cada uma destas abordagens.

3.1 Antecedentes históricos

Até meados da década de 1980, os esforços de levantamento do uso e cobertura do solo em larga escala se concentraram na tarefa de analisar e combinar dados provenientes de uma vasta gama de mapas e atlas pré-existent, de forma a desenvolver uma base de dados coesa e abrangente. Desta forma, diversos trabalhos emergiram como as primeiras estimativas sólidas de uso e cobertura do solo em escala global (*e.g.*, Olson e Watts [77], Mathews [66], Wilson e Henderson-Sellers [114]), sendo estas estimativas ainda hoje largamente utilizadas para a parametrização de modelos climáticos globais.

Infelizmente, no entanto, este tipo de abordagem, dita convencional, possui uma série de limitações. Em primeiro lugar, as diferentes fontes de dados utilizadas sempre apresentam uma grande variabilidade de escalas e datas, o que faz com que uma combinação destes dados leve inevitavelmente a grandes níveis de imprecisão no produto final. Além disso, o fato destes produtos serem baseados em fontes muito diversas de dados faz com que haja uma grande dificuldade para que as diferentes legendas de classificação sejam apropriadamente comparadas e mescladas numa legenda única, o que freqüentemente não é possível sob um ponto de vista de rigor científico [95].

De fato, segundo Townshend *et al.* [99] e Strahler *et al.* [95], a realização de uma comparação entre os resultados fornecidos por cada um destes produtos deixa bastante claro o fato de que há significativa discordância entre eles. Em outras palavras, estes dados são simplesmente inconsistentes entre si, sendo possível verificar discrepâncias não só na distribuição espacial de cada classe de cobertura do solo, como também nos próprios percentuais totais de ocupação de cada classe. Finalmente, uma última limitação importante deste tipo de abordagem diz respeito ao caráter estático do produto final, o que torna inviável a sua utilização para monitoramentos contínuos do uso e cobertura do solo e de suas alterações ao longo do tempo.

Assim, por todas estes fatores, tornou-se necessário o desenvolvimento de outras metodologias e abordagens de forma a viabilizar a produção destes levantamentos de uso e cobertura. Em particular, estabeleceu-se um consenso na comunidade científica no sentido de procurar aproveitar ao máximo as potencialidades dos dados provenientes de sensoriamento remoto, dada a vasta quantidade de informações a serem levantadas para a realização deste tipo de tarefa.

3.2 Abordagens com dados NOAA/AVHRR

A primeira e mais popular estratégia adotada para o levantamento sistemático do uso e cobertura do solo em larga escala através do sensoriamento remoto corresponde sem dúvida alguma ao emprego de dados do sensor AVHRR (*Advanced Very High Resolution Radiometer*) fornecido pela agência norte-americana NOAA (*National Oceanic and Atmospheric Administration*). Um sensor originalmente concebido para observações meteorológicas, o NOAA/AVHRR começou a ser utilizado para fins de monitoramento da cobertura da superfície terrestre a partir de meados da década de 1980. De fato, apesar de sua baixa resolução espacial não permitir muitas vezes a identificação de áreas homogêneas de uso e cobertura do solo (resolução de 1,1km no máximo, ver especificações no apêndice A.2), a extensa área de cobertura espacial deste sensor fez com que ele rapidamente se tornasse uma alternativa natural para qualquer tipo de levantamento em larga escala. Mais do que isso, entretanto, a sua altíssima resolução temporal, com visitas diárias a todos os pontos do planeta, aliada a um custo muito baixo de aquisição e processamento (os dados estão disponíveis gratuitamente na Internet, veja apêndice A.2), fizeram com que este sensor se tornasse extremamente atraente para a realização de classificações da superfície terrestre a nível continental e global. Finalmente, outro fator muito interessante diz respeito à longa sequência histórica proporcionada pelo NOAA/AVHRR, com dados sendo coletados desde 1978.

Realmente, a utilização de dados multitemporais provenientes das bandas 1 (visível) e 2 (infra-vermelho próximo) do NOAA/AVHRR demonstrou ser desde cedo uma alternativa muito útil para descrever o comportamento fenológico da vegetação ao longo do ano, e assim permitir a classificação da cobertura do solo sobre áreas de grande extensão territorial. Desta forma, estimativas para a cobertura do solo em escala continental foram realizadas ainda na década de 1980 para a África (por Tucker *et al.* [103]) e América do Sul (por Townshend *et al.* [97]). Em particular, o emprego de índices de vegetação como o NDVI (índice de vegetação por diferenças normalizadas, veja seção 2.2.4) foi logo identificado como uma

forma especialmente prática e eficiente de abordar o problema, o que facilitou a realização de análises multitemporais utilizando todo o histórico existente de dados AVHRR desde 1981 [110].

O sucesso inicial deste tipo de abordagem fez com que um grande número de pesquisadores passasse a produzir classificações de cobertura do solo utilizando seqüências multitemporais de NDVI calculadas a partir de dados do NOAA/AVHRR. Deste modo, uma classificação global com resolução de 1 grau foi produzida por DeFries e Townshend [22], sendo por sua vez utilizada como fundamento para uma base de dados global de parâmetros biofísicos para análises climáticas, descrita por Sellers *et al.* [87]. Subseqüentemente, DeFries *et al.* [23] demonstraram também que os resultados de uma classificação deste tipo podem ser significativamente melhorados a partir da utilização de *métricas temporais*, tais como taxas de crescimento e senescência ou valor máximo de NDVI para todo o ano, de maneira a se proporcionarem dados mais úteis e uma abordagem geral mais robusta. Em seguida, outros pesquisadores também realizaram classificações a partir de dados AVHRR que chegaram a 1km de resolução e que fizeram uso não apenas do NDVI mas também de dados auxiliares, tais como elevação (em Loveland *et al.* [64]). Além disso, dados provenientes dos demais canais (3, 4 e 5) do sensor NOAA/AVHRR também demonstraram ser úteis para a produção de classificações deste tipo [101][43].

Entretanto, apesar do grande sucesso alcançado por este tipo de abordagem, é importante que se tenha sempre em mente que o NOAA/AVHRR é um sensor originalmente concebido para aplicações meteorológicas. Assim, observa-se que a utilização de seus dados para procedimentos de classificação do uso e cobertura do solo apresenta de fato um conjunto de desvantagens e complicações que devem ser levadas em consideração [95][101]. Em primeiro lugar, o reduzido número de bandas disponíveis para a caracterização do uso e cobertura do solo (basicamente apenas um canal para o visível e outro para o infra-vermelho) torna os dados do NOAA/AVHRR relativamente pobres para a execução deste tipo de tarefa. Além disso, o fato destas bandas possuírem uma largura de espectro muito ampla faz com que o sinal capturado muitas vezes inclua um nível de interferência atmosférica bastante alto e de difícil correção, o que reduz bastante a confiabilidade do dado final. Outro problema semelhante corresponde à grande dificuldade encontrada para a identificação de certos tipos de nuvem a partir de dados do NOAA/AVHRR, fazendo com que *pixels* contaminados sejam freqüentemente levados em consideração pelos algoritmos de classificação. Na prática, muitos destes efeitos atmosféricos e de contaminação por nuvens podem ser minimizados através de procedimentos como composição de imagens por valor máximo (MVC, *maximum value*

compositing) [45]. Ainda assim, no entanto, demonstrou-se que mesmo com a utilização destes procedimentos os dados NOAA/AVHRR continuam apresentando níveis significativos de distorções [95].

Finalmente, deve ser observado também que o NOAA/AVHRR apresenta uma capacidade muito limitada para o registro (*i.e.*, georreferência) e a calibração tanto espectral quanto radiométrica de seus dados [95]. Em particular, deve-se ressaltar que as incertezas envolvidas no registro das imagens deste sensor fazem com que haja muitas dificuldades para que dados obtidos em datas diferentes sejam superpostos de forma adequada. Desta forma, é importante que se tenha consciência da confiabilidade limitada das seqüências multitemporais de dados provenientes do NOAA/AVHRR, especialmente com relação àquelas de maior resolução espacial (*i.e.*, 1,1km).

3.3 Abordagens com dados MODIS

Lançado em dezembro de 1999 pela NASA (*National Aeronautics and Space Administration*) a bordo do satélite Terra e desde 2002 também presente no satélite Aqua, o sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) logo se apresentou como uma solução natural para muitos dos problemas encontrados na utilização de dados do NOAA/AVHRR para fins de levantamento do uso e cobertura do solo.

De fato, o MODIS, cujos dados também são distribuídos gratuitamente (veja seção 4.3), possui um grande número de vantagens quando comparado ao seu predecessor. Em primeiro lugar, ele apresenta uma maior resolução espacial (250m para as bandas do vermelho e infravermelho próximo, ver especificações na Tabela 4.1), o que é especialmente importante se lembrarmos que a resolução de 1,1km proporcionada pelo NOAA/AVHRR é muitas vezes insuficiente para capturar a complexidade do uso e cobertura do solo [98][100][95]. Ademais, o MODIS também proporciona informações em outras 34 bandas do espectro eletromagnético, 5 das quais foram concebidas especificamente para o levantamento do uso e cobertura do solo baseado na experiência obtida com os sensores da série LANDSAT [95]. Além disso, se por um lado a maior resolução e o maior número de bandas constituem vantagens bastante óbvias deste sensor, é importante observar também que o MODIS apresenta uma série de características adicionais que, juntas, conferem a seus dados um grau de confiabilidade e precisão sem precedentes para a observação da superfície terrestre em larga escala, como discutido em maior detalhe na seção 4.3.

Dentre os esforços empreendidos para o levantamento de uso e cobertura do solo a partir de dados MODIS, um primeiro trabalho a destacar corresponde ao produto oficial MOD12 de

cobertura do solo (*MODIS Land Cover Product*) gerado pela equipe de cientistas do próprio programa MODIS [95][34]. Um produto que procurou aproveitar ao máximo as informações fornecidas pelas 36 bandas do sensor, este levantamento realizou uma classificação com base em dados de reflectâncias corrigidas para o nadir pelas funções BRDF (NBARS, *nadir BRDF-adjusted reflectances*, sub-produto MOD43B4 do MODIS), além de dados de textura (sub-produto MODAGTEX do MODIS), índices de vegetação (EVI, *enhanced vegetation index*, sub-produto MOD13), informação direcional (extraído de MOD43B1), temperatura de superfície (MOD11) e modelos digitais de terreno (MOD03), entre outros. Além disso, os dados analisados ainda levaram em conta uma medida de qualidade, sendo dados considerados não-confiáveis tratados como dados ausentes. Finalmente, uma estratégia de partição de dados por meio de árvores de decisão foi utilizada para selecionar um subconjunto de informações a serem analisadas por uma rede neural do tipo *fuzzy ARTMAP* [19] de modo a realizar a classificação final [15]. Assim, como resultado deste esforço, já se tornou publicamente disponível uma classificação global da cobertura do solo, com 1km de resolução espacial, para o ano de 2001 (os dados podem ser obtidos através do EOS Data Gateway, em <http://edcimswww.cr.usgs.gov/pub/imswelcome>).

Entretanto, apesar da alta qualidade do produto final, algumas limitações com relação a esta abordagem devem ser destacadas. Em primeiro lugar, a resolução final do produto teve que ficar limitada a apenas 1km, dado que quase todos os dados auxiliares coletados pelo MODIS e utilizados para esta classificação só se encontram disponíveis nesta resolução (ver especificações na seção 4.3, Tabela 4.1). Assim, como discutido anteriormente, este nível de resolução termina por ser insuficiente para capturar corretamente os padrões de uso e cobertura do solo em certos casos [98][100][95]. Adicionalmente, segundo Wessels *et al.* [112], a aplicabilidade de produtos globais MODIS para análises regionais ainda precisa ser melhor explorada, uma vez que elas dificultam a incorporação de aspectos biofísicos e sócio-econômicos particulares de cada região. Desta forma, diversos autores chegaram à conclusão de que resoluções maiores de 250m ou 500m seriam mais interessantes para mapeamentos regionais de uso e cobertura do solo, permitindo inclusive a adoção de legendas de classificação mais apropriadas a problemas regionais específicos [98][112].

Neste sentido, Wessels *et al.* [112] utilizaram uma imagem MODIS para uma única data, com 7 bandas e 500m de resolução, para mapear com sucesso áreas de floresta e não-floresta na região amazônica do estado do Pará. Embora incapaz de detectar nuances diferentes de cobertura vegetal (tais como florestas em regeneração, pastagens e agricultura), este experimento demonstrou que dados na faixa espectral do infra-vermelho médio podem

contribuir para a classificação do uso e cobertura do solo. Adicionalmente, os mesmos autores utilizaram também imagens MODIS de três datas diferentes, a 250m de resolução (vermelho e infra-vermelho próximo), para realizar uma classificação na região do *Greater Yellowstone Ecosystem*, nos EUA. Os autores constataram ser de fato possível o uso destes dados para o mapeamento das principais classes de uso e cobertura do solo na região com base no comportamento temporal dos alvos, muito embora a mesma eficiência não tenha sido verificada para classes menos abrangentes que ocorrem tipicamente em fragmentos menores do que o tamanho de um *pixel* do MODIS. Desta forma, os autores sugeriram que o uso de seqüências temporais de imagens MODIS a 250m de resolução teria um grande potencial para mapear pastagens, agricultura, e nuances de cobertura vegetal tais como florestas em crescimento secundário.

No Brasil, a aplicação de dados MODIS de 250m de resolução para mapeamentos regionais de uso e cobertura do solo vem recebendo uma maior atenção nos últimos anos, com especial destaque para os mapeamentos na região da Amazônia Legal realizados dentro do contexto do Experimento de Grande Escala da Biosfera-Atmosfera na Amazônia (LBA, *Large Scale Biosphere-Atmosphere Experiment in Amazonia*). Estes trabalhos demonstraram claramente o grande potencial do sensor MODIS para este tipo de tarefa [5][8][71][92][108]. Em particular, segundo Morton *et al.* [71], demonstrou-se que os dados MODIS aumentam a possibilidade de se conseguirem imagens livres de cobertura de nuvens na bacia amazônica, ao mesmo tempo em que se diminui drasticamente o volume de dados processados e os custos financeiros.

No contexto específico do cerrado brasileiro, a análise da utilidade de dados MODIS para o levantamento do uso e cobertura do solo tem começado a se intensificar nos últimos 2 anos. De fato, estudos realizados por Mesquita Jr. e Bitencourt [68] e Ferreira *et al.* [31] demonstraram que seqüências temporais NDVI do MODIS com 250m de resolução seriam de fato capazes de capturar corretamente os diferentes comportamentos fenológicos da vegetação neste bioma. Assim, estudos independentes foram desenvolvidos concomitantemente a esta dissertação, com o intuito de tentar aplicar estes dados MODIS para classificações em regiões de cerrado: Oliveira Jr. e Shimabukuro [76] realizaram uma classificação preliminar para os estados de Goiás e Tocantins, enquanto que em Aguiar *et al.* [5] relata-se o desenvolvimento de um projeto para o mapeamento da região do cerrado brasileiro como um todo. De fato, embora nenhum destes esforços tenha produzido resultados validados até o momento, pode-se de todo modo constatar que existe atualmente um consenso na comunidade científica brasileira com relação à grande utilidade de dados MODIS para o mapeamento desta região.

3.4 Abordagens com dados de outros sensores

Além do NOAA/AVHRR e do MODIS, um número de outros sensores já foram também empregados para fins de levantamento do uso e cobertura do solo em escalas regionais, continentais e globais. Com efeito, de forma geral, qualquer sensor dotado de uma larga faixa de imageamento do terreno e alta resolução temporal poderia ser utilizado para este tipo de tarefa, como ocorre por exemplo com o sensor WFI, a bordo do satélite sino-brasileiro CBERS, ou com o sensor VEGETATION, a bordo dos satélites SPOT-4 e SPOT-5 (ver apêndices A.3 e A.4, respectivamente).

Dentre os trabalhos realizados com estes sensores, um destaque especial pode ser dado ao projeto *Global Land Cover 2000*, realizado basicamente a partir de dados do sensor SPOT VEGETATION com 1km de resolução [29][35]. Embora um trabalho extremamente meticuloso, com participação ativa de representantes regionais como a Embrapa-CNPq no Brasil [29], este trabalho utilizou uma metodologia de difícil replicação, tornando complexa a sua aplicação para monitoramentos contínuos das mudanças de uso e cobertura do solo [38]. Além disso, como já discutido anteriormente, a baixa resolução de 1km deste sensor o torna menos interessante com vistas a mapeamentos regionais, uma vez que ela é algumas vezes insuficiente para capturar a complexidade do uso e cobertura do solo [98][100][95].

Por sua vez, o sensor CBERS/WFI apresenta características bastante interessantes. Como descrito no apêndice A.3, trata-se de um sensor de fabricação nacional e portanto de interesse estratégico para o País, ao mesmo tempo em que sua resolução espacial de 260m o torna particularmente apto para mapeamentos regionais. Realmente, se comparado ao sensor MODIS, o WFI possui praticamente a mesma resolução espacial, porém com uma largura de faixa de imageamento menor, um período de revisita um pouco mais longo, e capacidades reduzidas de calibração dos dados, o que na realidade não compromete de forma alguma o seu potencial para este tipo de aplicação. Entretanto, até o presente momento, a georreferência das imagens WFI ainda se encontra em níveis insatisfatórios, o que termina exigindo um laborioso processo de correção imagem a imagem de modo que se possam obter seqüências temporais coesas de dados. Desta forma, com a devida disponibilidade de mão-de-obra para a correção da georreferência das imagens, já é possível hoje o aproveitamento destes dados para importantes levantamentos regionais de uso e cobertura do solo, tais como aquele realizado pelo projeto DETER [92][108]. Espera-se, assim, que, com as melhorias previstas no futuro próximo para o processo de georreferência destas imagens, seja possível um melhor aproveitamento dos dados CBERS/WFI para o mapeamento do território brasileiro, o que seria extremamente interessante para o nosso país.

3.5 Abordagens para detecção de desflorestamento

Como discutido anteriormente, na seção 2.1, o levantamento do uso e cobertura do solo constitui um passo fundamental para a compreensão das inter-relações entre a superfície terrestre e os ecossistemas. Desta forma, configura-se também uma necessidade de se acompanharem as *mudanças* deste uso e cobertura do solo ao longo do tempo, particularmente com relação àquelas de causa antrópica. Neste contexto, o monitoramento de processos de desflorestamento se destaca como um dos mais urgentes desafios a serem enfrentados nos dias de hoje, uma vez que seu ritmo acelerado vem colocando em risco ecossistemas inteiros, com importantes conseqüências para o balanço energético e para os ciclos de carbono e de água [60][108]. Além disso, sabe-se também que o desflorestamento afeta a diversidade biológica através da destruição e fragmentação de *habitats* naturais [112].

Na prática, convém lembrar que a ocorrência deste tipo de fenômeno implica necessariamente numa forte diminuição da atividade fotossintética das áreas afetadas, e que esta atividade fotossintética pode ser relacionada diretamente com valores de índices de vegetação, tais como o NDVI (ver seção 2.2.4). Assim, torna-se teoricamente possível realizar a identificação de eventos de desflorestamento através do uso de técnicas de sensoriamento remoto, bastando para isso que se observem aqueles pontos que apresentam sensível declínio em suas respostas de NDVI medidas ao longo do tempo. Por conta disto, e dadas as grandes áreas a serem monitoradas, o sensoriamento remoto passou a ser visto nos últimos anos como uma alternativa cada vez mais promissora e importante para o mapeamento sistemático de eventos de desflorestamento, particularmente com relação a problemas de monitoramento em regiões tropicais do planeta.

Na realidade, segundo Nepstad *et al.* [74], o mapeamento do desflorestamento através de sensoriamento remoto não é capaz de capturar a magnitude total da influência humana, o que pode ocorrer em casos onde o fogo ou a exploração madeireira reduz a cobertura florestal sem removê-la por completo. Ainda assim, o uso deste tipo de técnica continua sendo indispensável e insubstituível para o monitoramento das formas mais extremas de mudança da cobertura terrestre sobre grandes áreas e com baixo custo [74][112]. Neste sentido, o sensoriamento remoto pode ser empregado em tarefas deste tipo de duas formas bastante distintas. Numa primeira abordagem, imagens de alta resolução podem ser meticulosamente analisadas de forma a se obter um mapeamento detalhado do desflorestamento com o maior nível de precisão possível, tendo como melhor exemplo o Programa de Avaliação do Desflorestamento na Amazônia Legal (PRODES) [26].

Por outro lado, imagens de sensores de resolução moderada, tais como o MODIS (ver seção 4.3) ou o CBERS/WFI (ver apêndice A.3), também podem ser empregadas com o intuito de se obter uma visão mais geral das mudanças ocorridas, e com um custo final muito mais baixo tanto do ponto de vista computacional quanto financeiro. Segundo Anderson [8], Morton *et al.* [71] e Valeriano *et al.* [108], abordagens deste tipo apresentam uma tendência a subestimar a área total desmatada, mas ainda assim apresentam-se extremamente eficientes para detectar a grande maioria das áreas de desflorestamento. Assim, somando-se a isso a característica de revisita quase que diária destes sensores, concluiu-se que este tipo de abordagem se apresenta ideal para a implementação de sistemas de alerta de desmatamento em larga escala. Em particular, das abordagens que seguem esta linha, é possível destacar o Projeto de Detecção de Áreas Desflorestadas em Tempo Real (DETER), implementado recentemente para a região da Amazônia Legal e que se baseia no uso de dados diários MODIS com 250m de resolução [92][108]. Com efeito, resultados recentes e comparações com estimativas feitas com imagens de alta resolução têm demonstrado o sucesso deste tipo de metodologia, tendo sido verificadas taxas de erros de comissão extremamente baixas [71]. Deve ser notado, no entanto, que erros significativos de omissão ainda podem ser observados em certos casos, particularmente com relação a regiões pequenas próximas às bordas das florestas [71].

3.6 Análise no nível do sub-pixel

Um importante aspecto no processamento de imagens de baixa e média resolução é que deve ser melhor detalhado aqui diz respeito ao processamento destes dados a um nível de *sub-pixel*. Neste tipo de abordagem, as metodologias de classificação ou detecção de mudanças não agem diretamente sobre as informações coletadas pelo sensor na sua resolução original (*i.e.*, os níveis de reflectância detectados, ou ainda transformações destas reflectâncias tais como NDVI e componentes principais). Ao invés disto, busca-se de alguma forma “quebrar” cada *pixel* destas imagens em sub-grupos menores, estimando-se as *proporções* ou *frações* destes grupos em seu interior de forma a capturar um maior nível de detalhamento da superfície terrestre e aproveitar melhor a informação captada pelo sensor.

Dentro desta filosofia, diversas abordagens foram propostas ao longo dos anos de modo que se conseguisse realizar este tipo de processamento. Dentre estas abordagens, uma das mais intuitivas e populares corresponde aos métodos de análise de mistura espectral (SMA, *spectral mixture analysis* [47][4][89]), uma técnica que parte do pressuposto de que a reflectância observada em cada *pixel* pode ser modelada a partir das reflectâncias de cada classe de interesse (*endmembers*) e de suas proporções no interior deste *pixel*, num processo

conhecido como “desmistura” ou “*unmixing*”. Desta forma, uma modelagem linear de mistura espectral (LSMA, *linear spectral mixture analysis*) sugere que uma combinação linear das respostas espectrais características de cada classe seja suficiente para explicar a reflectância final observada em cada *pixel* de forma bastante satisfatória. Assim, sob esta ótica, temos a seguinte relação:

$$R_i^k = \sum_{j=1}^{N_c} \rho_{ij} R_j^k \quad (3.1)$$

$$\text{sujeito às restrições: } \sum_{j=1}^{N_c} \rho_{ij} = 1 \quad e \quad 0 \leq \rho_{ij} \leq 1$$

sendo:

- R_i^k : reflectância do pixel i na banda k
- R_j^k : reflectância do *endmember* j na banda k
- ρ_{ij} : proporção do *endmember* j contido no pixel i
- N_c : número de *endmembers*

Assim, uma vez conhecidas as reflectâncias das classes de interesse (por exemplo, através de observação de *pixels* “puros”, inteiramente formados por um único *endmember*), torna-se possível estimar as proporções destas classes no interior de todos os demais *pixels*. De fato, é importante que se note que a aplicação de técnicas deste tipo está condicionada ao fato do número N_c de classes de interesse ou *endmembers* ter de ser obrigatoriamente menor ou igual ao número k de bandas de informação disponíveis mais 1, pois do contrário o sistema de equações descrito na equação (3.1) não teria solução. Assim, se considerarmos apenas a presença de 2 bandas de reflectância (*e.g.*, vermelho e infra-vermelho próximo), teremos a possibilidade de escolher apenas um máximo de 3 *endmembers*.

Portanto, no contexto deste tipo de modelagem, difundiu-se bastante a idéia de escolher apenas alguns poucos *endmembers* (em geral 3) para a análise de uma imagem no nível do *sub-pixel*, mas que ainda assim fossem capazes de capturar as componentes físicas fundamentais presentes na cena. Em particular, Shimabukuro e Smith [90] propuseram a utilização dos componentes “solo”, “vegetação” e “água/sombra”, de forma a extrair o máximo de informações físicas a partir das diferenças entre as respostas espectrais dos alvos. Sob esta ótica, *imagens fração* de cada componente são estimadas a partir dos dados iniciais de reflectância, de forma a facilitar a interpretação dos dados e melhorar os resultados alcançados pela classificação ou detecção de mudanças, levando a um procedimento adotado em um grande número de trabalhos [8][46][76][91][92].

Alternativamente, a utilização de um número maior de classes de interesse dentro do modelo de mistura está restrita à condição de se empregarem dados com um número maior de canais de informação. Neste sentido, embora estes canais estejam tradicionalmente associados a bandas espectrais, é também possível fazer uso de uma seqüência de dados multitemporais de modo a se obterem equações de mistura para cada banda e para cada data, contanto que as proporções de cada *endmember* no interior dos *pixels* não se altere no decorrer do período analisado [80][24][63]. Desta forma, viabiliza-se a utilização de um número muito maior de *endmembers*, condicionada apenas à restrição de seus perfis temporais serem linearmente independentes entre si. De fato, este tipo de abordagem já foi explorado com sucesso em diversos trabalhos, servindo por exemplo para a realização de estimativas mais precisas da extensão de áreas de cultivo em larga escala [63], uma vez que estas áreas freqüentemente ocupam fragmentos de tamanhos pequenos, menores até do que um *pixel* MODIS de 250m. Além disso, a utilização deste tipo de abordagem também se mostrou bem-sucedida em levantamentos regionais de uso e cobertura do solo de caráter geral, como demonstrado por Bouzidi *et al.* [16] e Lahoche [59] utilizando dados NOAA/AVHRR.

Finalmente, apesar de sua relativa simplicidade e de seus resultados bastante interessantes, deve-se dizer ainda que as limitações dos modelos lineares de mistura espectral fizeram com que diversos outros métodos alternativos fossem também explorados ao longo dos anos para permitir análises não-lineares no nível do *sub-pixel*. Dentre estes outros métodos, podemos destacar as abordagens por regressão propostas por Iverson *et al.* [51][52][41], e aquelas baseadas em árvores de regressão ou *regression trees* [109], estas últimas tendo se tornado a base para o produto oficial de estimativa global de cobertura vegetal a partir de dados MODIS (produto MOD44B, *MODIS Vegetation Continuous Fields* [44]). Além disso, deve-se mencionar ainda a utilização de lógica nebulosa (*fuzzy logic* [115]) e de diversos tipos de redes neurais para análises no nível do *sub-pixel*. No primeiro caso, as propostas mais conhecidas estão baseadas no método de classificação nebuloso conhecido como *fuzzy c-means* [11][12], segundo o qual a cada *pixel* é dado um *grau de pertinência* a cada classe. Experimentos baseados neste tipo de abordagem foram realizados por Foody [32] e Atkinson [9], dentre outros, atingindo-se resultados semelhantes àqueles obtidos pelos métodos de análise de mistura espectral. Com relação às técnicas baseadas em redes neurais, a abordagem mais tradicional empregada corresponde à utilização de redes diretas (*feedforward*) de múltiplas camadas utilizando algoritmo de treinamento de retro-alimentação (*back-propagation* [58]), o que foi mais uma vez explorado tanto por Foody [33] quanto por Atkinson [9]. Mais recentemente, vários pesquisadores passaram a defender o emprego de outros tipos mais sofisticados de redes neurais para análise de imagens no nível do *sub-pixel*,

como por exemplo aqueles baseados na teoria de ressonância adaptativa (ART, ARTMAP e *fuzzy* ARTMAP [19]) descritos em Carpenter *et al.* [20] e em Liu *et al.* [62], além daqueles baseados em mapas auto-organizáveis de Kohonen (*Kohonen self-organizing maps* [57]), como demonstrado em Houet *et al.* [48].

3.7 Considerações finais

Neste capítulo procurou-se fornecer uma visão geral das técnicas existentes para o mapeamento do uso e cobertura do solo em larga escala, com particular destaque para abordagens de sensoriamento remoto baseadas nos sensores NOAA/AVHRR e MODIS.

A seguir, no capítulo 4, serão apresentados todos os materiais utilizados ao longo do desenvolvimento deste trabalho, o que inclui os dados de satélite e trabalhos de campo, além dos sistemas de *software* utilizados.

4 Materiais

A metodologia apresentada nesta dissertação fez uso de materiais de diversas naturezas. Primeiramente, foi necessário adquirir uma classificação detalhada da área de estudos (seção 4.1; veja também estudo de caso no capítulo 6), de modo a servir como base para os treinamentos e testes da metodologia em conjunto com o conhecimento obtido num trabalho de campo (seção 4.2). Fora isso, a quase totalidade dos procedimentos de classificação de uso e cobertura do solo foi desenvolvida através da análise de dados do sensor MODIS, cujas características são descritas em detalhe na seção 4.3. Além disso, imagens LANDSAT foram também utilizadas nesta dissertação para a avaliação dos procedimentos de detecção de desflorestamento (seção 4.4). Finalmente, deve-se notar ainda que o desenvolvimento deste trabalho fez uso de diversos sistemas de processamento e pacotes de *software* computacional, que estão especificados na seção 4.5.

4.1 Classificação detalhada do uso e cobertura do solo para a área de estudos

Para que a metodologia descrita nesta dissertação pudesse ser apropriadamente desenvolvida, treinada e avaliada na área de estudos (a Bacia do Alto Taquari, ver seção 6.1), seria necessário, em condições ideais, que se tivesse acesso a dados de verdade terrestre obtidos em campo para toda a região. Infelizmente, no entanto, a grande área ocupada (28.046 km²), aliada ao difícil acesso à região e a restrições de ordem orçamentária, tornam virtualmente impossível a obtenção de dados de campo com a densidade necessária para uma validação rigorosa.

Neste contexto, decidiu-se por admitir que o desenvolvimento e avaliação desta metodologia fossem realizados tomando por base uma classificação do uso e cobertura do solo previamente disponibilizada. Obviamente, a classificação a ser utilizada teria necessariamente que ser detalhada, acurada e baseada em dados de média/alta resolução, de modo que se pudesse tomá-la como fundamento para a avaliação da técnica aqui desenvolvida. Assim, após algumas avaliações, concluiu-se que as classificações de uso da terra e cobertura vegetal realizadas por Silva [94] para toda a Bacia do Alto Taquari seriam apropriadas para a tarefa em questão. Estas classificações foram realizadas a partir de dados LANDSAT/TM de julho de 2000, além de diversas viagens a campo aliadas a um conhecimento profundo da região por parte do autor, o que proporcionou uma visão bastante completa e consistente da bacia como um todo.

4.2 Trabalho de campo

Em agosto de 2004, realizou-se uma visita à área referente ao estudo de caso, localizada na Bacia do Alto Taquari, no estado do Mato Grosso do Sul (ver seção 6.1). Esta visita foi realizada dentro do escopo dos projetos ECOAIR e SOS-Taquari (ver seção 1.4), de modo a dar seqüência a outros trabalhos de campo realizados em 1998, 2001 e março de 2004. A equipe de trabalho desta última visita foi formada pelo autor deste trabalho, por membros da UERJ (Universidade do Estado do Rio de Janeiro), especialistas da Embrapa (Empresa Brasileira de Pesquisa Agropecuária) e representantes de entidades locais.

Neste trabalho de campo, atravessou-se a região de estudos a partir do município de Camapuã, ao sul da bacia, até o município de Alcinópolis, na porção mais central. Ao longo de todo o trajeto, foram utilizados equipamentos GPS (*Global Positioning System*) e computadores portáteis munidos de Sistemas de Informação Geográfica (SIG), de modo a tornar possível uma confrontação entre a realidade observada visualmente e imagens recentes dos sensores LANDSAT e MODIS. Desta forma, foi possível se obter um melhor entendimento acerca das possíveis variabilidades e nuances dos diferentes tipos de uso e cobertura do solo existentes na região, ao mesmo tempo em que se proporcionou uma maior compreensão acerca das possibilidades e limitações de levantamentos a partir de imagens de sensoriamento remoto de diferentes escalas.

Além disso, sob um outro aspecto totalmente diferente, também pode-se considerar esta ida ao campo como tendo sido extremamente importante para permitir a observação em primeira mão das desastrosas conseqüências do mau uso da terra na região. Neste sentido, puderam-se visitar áreas de drástico assoreamento dos rios (Figura 4.1), ao passo que, em outros pontos, observaram-se as conseqüências do processo intensivo de erosão verificado na bacia, tendo como resultado o surgimento de voçorocas de extraordinárias dimensões (Figura 4.2).



Figura 4.1 Trecho de rio extremamente assoreado, observado em agosto de 2004 durante o trabalho de campo na Bacia do Alto Taquari



Figura 4.2 Voçoroca de grandes dimensões, observada em agosto de 2004 durante o trabalho de campo na Bacia do Alto Taquari

4.3 Dados MODIS

4.3.1 Introdução

O *Moderate Resolution Imaging Spectroradiometer* (MODIS) corresponde a um sensor que se encontra a bordo de dois satélites diferentes do programa EOS (*Earth Observing System*) da agência espacial norte-americana NASA (*National Aeronautics and Space Administration*): o satélite Terra, lançado em 1999, e o Aqua, lançado em 2002. Informações de caráter geral sobre o MODIS podem ser obtidas no endereço <http://modis.gsfc.nasa.gov>

O MODIS tem como objetivo fornecer dados abrangentes e de forma simultânea acerca da superfície terrestre, dos oceanos e da atmosfera. Desta maneira, este sensor procura satisfazer um amplo leque de necessidades em vários campos de pesquisa científica, fornecendo insumos para avanços importantes no entendimento do funcionamento e interações dos sistemas terrestres. Assim, o MODIS foi concebido de forma a, por um lado, realizar amplos imageamentos sobre grandes áreas e com alta frequência, apresentando uma largura de faixa de 2330km com coberturas quase que diárias em 36 bandas do espectro eletromagnético (ver especificações na Tabela 4.1). Por outro lado, procurou-se ao mesmo tempo dotar o sensor de uma resolução espacial capaz de captar as informações com o nível necessário de detalhe, resolução esta que chega a 250m nas faixas do vermelho e do infra-vermelho próximo. As especificações detalhadas do sensor MODIS estão dispostas na Tabela 4.1.

Período de revisita	1 a 2 dias
Altitude	705km
Largura de faixa	2330km
Resolução no nadir	250m (bandas 1-2) 500m (bandas 3-7) 1km (bandas 8-36)

<i>Canais</i>	<i>Bandas Espectrais</i>	<i>Principais Usos</i>
1. Vermelho	0,620 – 0,670 μm	Propriedades da superfície, das nuvens e dos aerossóis
2. IV próximo	0,841 – 0,876 μm	
3. Azul	0,459 – 0,479 μm	Propriedades da superfície, das nuvens e dos aerossóis
4. Verde	0,545 – 0,565 μm	
5. IV próximo	1,230 – 1,250 μm	
6. IV médio	1,628 – 1,652 μm	
7. IV médio	2,105 – 2,155 μm	
8.	0,405 – 0,420 μm	Cor oceânica Fitoplâncton Biogeoquímica
9.	0,438 – 0,448 μm	
10.	0,483 – 0,493 μm	
11.	0,526 – 0,536 μm	
12.	0,546 – 0,556 μm	
13.	0,662 – 0,672 μm	
14.	0,673 – 0,683 μm	
15.	0,743 – 0,753 μm	
16.	0,862 – 0,877 μm	Vapor d'água na atmosfera
17.	0,890 – 0,920 μm	
18.	0,931 – 0,941 μm	
19.	0,915 – 0,965 μm	Temperatura de superfície Temperatura das nuvens
20.	3,660 – 3,840 μm	
21.	3,929 – 3,989 μm	
22.	3,929 – 3,989 μm	
23.	4,020 – 4,080 μm	Temperatura atmosférica
24.	4,433 – 4,498 μm	
25.	4,482 – 4,549 μm	Nuvens cirrus
26.	1,360 – 1,390 μm	
27.	6,535 – 6,895 μm	Vapor d'água
28.	7,175 – 7,475 μm	
29.	8,400 – 8,700 μm	Ozônio
30.	9,580 – 9,880 μm	
31.	10,780 – 11,280 μm	Temperatura de superfície Temperatura das nuvens
32.	11,770 – 12,270 μm	
33.	13,185 – 13,485 μm	Altitude de topo de nuvens
34.	13,485 – 13,785 μm	
35.	13,785 – 14,085 μm	
36.	14,085 – 14,385 μm	

Tabela 4.1 Especificações do sensor MODIS.

Fonte: Lillesand e Kiefer [61]

A concepção do MODIS procurou fazer uso de diversos avanços científicos e tecnológicos recentes, de modo que se pudesse garantir um alto grau de qualidade e confiabilidade aos seus dados. Em primeiro lugar, foram especificadas faixas espectrais de imageamento bastante estreitas e bem definidas, com o intuito de maximizar a precisão radiométrica e evitar efeitos de absorção atmosférica (ver seção 2.2.3). Além disso, também dotou-se o sensor de uma série de equipamentos de bordo, os quais lhe conferem uma capacidade sofisticada de calibragem tanto radiométrica quanto espectral, além de viabilizarem ainda uma qualidade superior de geolocalização.

Especificamente com relação à observação da superfície terrestre, um outro aspecto interessante do MODIS diz respeito ao aproveitamento da informação obtida por todas as suas 36 bandas de sensoriamento. De fato, apesar de 29 destas bandas não fornecerem dados diretamente aplicáveis ao levantamento do uso e cobertura do solo, estas medições se mostram bastante úteis para que, por exemplo, nuvens de todos os tipos possam ser eficientemente detectadas (*i.e.*, mesmo nuvens de difícil identificação tais como aquelas de tipo *cirrus*). Além disso, esta riqueza de informações também viabiliza a realização de uma correção atmosférica dinâmica dos seus dados, utilizando-se para isso bandas de imageamento definidas especificamente para o sensoriamento da atmosfera. Por fim, informações adicionais como as funções bidirecionais de distribuição de reflectância (BRDFs, *bidirectional reflectance distribution functions*, ver seção 2.2.3) permitem ainda que os dados sejam corrigidos com relação ao ângulo de visada e efeitos de iluminação [95].

Sob outra perspectiva, é importante notar também que a NASA adotou uma abordagem de controle de qualidade totalmente inédita para o projeto do sensor MODIS. Neste sentido, para cada *pixel* de uma imagem MODIS são também disponibilizados *metadados* que permitem ao usuário tomar conhecimento das condições nas quais o *pixel* foi processado, se a presença de nuvens foi detectada, ou quais os algoritmos de correção atmosférica utilizados, dentre outras informações. Na prática, estes metadados conseguem proporcionar um alto grau de flexibilidade com relação ao aproveitamento e interpretação dos produtos MODIS, muito embora, em contrapartida, eles também terminem por aumentar a complexidade destes produtos, tornando mais laborioso o seu processamento.

Outro ponto importante corresponde à preocupação da agência espacial norte-americana em prover uma continuidade com relação aos dados de outros sensores. Neste sentido, pretende-se que os dados do MODIS sirvam para dar seqüência às medições de mais de duas décadas realizadas pela série de sensores NOAA/AVHRR (ver apêndice A.2), tanto no tocante a medições meteorológicas quanto para o monitoramento da vegetação, gelo, e temperaturas da superfície do mar [7]. Além disso, buscou-se também aproveitar a experiência adquirida após muitos anos de estudos com a série LANDSAT, de modo que foram escolhidas faixas semelhantes do espectro eletromagnético para as bandas destinadas ao imageamento da superfície terrestre (Figura 4.3). Deve-se dizer ainda que o sensor MODIS, de caráter experimental, servirá de base para uma nova série de sensores que deverá funcionar futuramente em caráter operacional. Esta nova série, denominada NPOESS (*National Polar-orbiting Operational Environmental Satellite System*), será administrada pela agência NOAA

e substituirá de forma definitiva a antiga série AVHRR. Maiores informações sobre esta futura série podem ser encontradas no endereço: <http://www.ipo.noaa.gov>

Finalmente, um outro fator que confere uma grande atratividade aos dados do MODIS decorre de sua política de distribuição de dados. A NASA, buscando estimular ao máximo a difusão destes dados e a sua utilização para pesquisas e testes, adotou uma estratégia de distribuição bastante aberta e transparente, disponibilizando os produtos MODIS de forma gratuita e tornando públicas as documentações dos mesmos. Desta forma, os dados provenientes deste sensor podem ser obtidos diretamente pela Internet através do portal de dados do EOS (EDG, *EOS Data Gateway*), mantido pela agência norte-americana USGS (*United States Geological Survey*) no seguinte endereço: <http://edcimswww.cr.usgs.gov/pub/imswelcome>.




Figura 4.3 Comparação entre as bandas na faixa do vermelho e infravermelho próximo para os sensores MODIS, NOAA/AVHRR e LANDSAT/ETM+
Fonte: Anderson *et al.* [7], adaptado de Justice *et al.* [54]

4.3.2 Produtos MODIS: uma visão geral

Diferentemente do que ocorre com outros sensores, a distribuição de dados do MODIS não se limita simplesmente à disponibilização dos valores de radiância captados pelo sensor. Em vez disso, a NASA decidiu adotar uma complexa abordagem de padronização e validação de procedimentos, de forma que foram estudados e desenvolvidos algoritmos para cada passo de processamento destes dados, da georreferência e calibração radiométrica até o próprio cálculo de variáveis biofísicas. Desta forma, é possível se obter os chamados *produtos* MODIS em diferentes *níveis de processamento* de acordo com a necessidade, de modo que cada usuário possa focar o seu trabalho no ponto exato de seu interesse, aproveitando ao máximo o conhecimento da NASA nas etapas preliminares de processamento. Entretanto, deve-se notar também que, por um outro lado, a adoção desta política torna um pouco mais complicado para

o usuário leigo compreender qual produto será mais adequado para a sua necessidade particular, uma vez que existem dezenas destes produtos (44 no total), e em diferentes versões. Além disso, a documentação detalhada de cada produto ainda não se encontra disponível de forma centralizada, de forma que é necessário obtê-la diretamente do grupo de pesquisa responsável pelo seu desenvolvimento, em geral localizado em um departamento de alguma universidade dos EUA.

Não obstante estas complicações, os diferentes produtos MODIS seguem regras gerais de padronização razoavelmente rígidas, de modo que eles se encontram distribuídos em formatos bastante homogêneos, podendo assim ser tratados de forma semelhante. Em primeiro lugar, todos estes produtos são distribuídos em arquivos num único formato, denominado HDF-EOS (*Hierarchical Data Format – Earth Observing System*). De fato, embora a própria NASA reconheça que este formato hierárquico de dados não é ainda largamente difundido entre os programas comerciais de geoprocessamento, esta escolha permitiu a fácil inclusão de metadados de todos os tipos e se mostrou adequada para que se conseguisse representar os diferentes produtos disponibilizados de forma uniforme. Além disso, a agência norte-americana e diversas outras instituições também providenciaram a distribuição gratuita de diversos *softwares* de modo a permitir a manipulação deste tipo de arquivo, assim como a sua conversão para demais formatos mais populares. Dentre estes programas, aquele que merece maior destaque no contexto desta dissertação corresponde ao *MODIS Reprojection Tool* (MRT), que permite a reprojeção e mosaicagem de dados MODIS, além da sua conversão para formato GeoTIFF [104]. Este e outros programas podem ser adquiridos diretamente via Internet, juntamente com suas respectivas documentações, no seguinte endereço da agência USGS: <http://edcdaac.usgs.gov/dataproducts.asp>

Um dos fatores mais importantes para auxiliar na orientação dos usuários de dados MODIS corresponde à categorização destes produtos nos seus diferentes *níveis de processamento*. Esta divisão permite, na realidade, que se tenha uma noção das características gerais de um produto qualquer, uma vez que todos os produtos MODIS de um mesmo nível compartilham características semelhantes entre si, independentemente dos detalhes específicos de cada um. Desta forma, o conjunto de produtos disponíveis é dividido em 5 níveis principais, enumerados de 0 a 4 segundo os critérios abaixo:

Nível 0: dados brutos, não disponibilizados para o usuário

Nível 1A: dados brutos, resolvidos todos os problemas de comunicação/sincronização.

Produtos deste nível já vêm acompanhados de metadados indicando aqueles

pixels onde algum tipo de problema foi detectado (*e.g.*, falha ou mal funcionamento no sensor). Exemplos de produtos deste nível são:

- valores brutos de radiância no sensor, para cada uma das 36 bandas
- dados de *geolocalização*, o que inclui, para cada pixel, latitude e longitude geodésicas, altitude geoidal, ângulos solares de azimute e zênite, ângulos satelitais de azimute e zênite, e uma máscara informando áreas sobre terra e áreas sobre mar

Nível 1B: dados de nível 1A que sofreram um processo de correção radiométrica, acompanhados de informação de geolocalização. Assim, neste nível se encontram imagens com valores calibrados e georreferenciados de radiância para cada uma das 36 bandas do sensor

Nível 2: variáveis geofísicas derivadas dos dados de nível 1B. Estes dados possuem a mesma resolução e georreferência dos dados de nível 1, porém deve-se notar que, dependendo do produto, a informação de geolocalização pode não estar incluída no arquivo HDF. Neste caso, informações de geolocalização de nível 1 devem ser obtidas separadamente de forma a georreferenciar os dados. Exemplos de produtos neste nível são:

- temperatura na superfície do mar
- estimativa de conteúdo de vapor d'água na coluna de ar
- valores de reflectância da superfície terrestre

Nível 2G: dados de nível 2 para um único dia que foram reorganizados em uma grade fixa, também conhecidos como dados de nível 2 *gridded* (L2G). Assim, diferentemente dos produtos de nível mais baixo, as imagens L2G são distribuídas em grandes ladrilhos ou *tiles* de dimensões 1200km x 1200km (Figura 4.4). Além disso, estes ladrilhos apresentam georreferência sempre idêntica, de modo que seus *pixels* ocupam sempre a mesma posição geográfica. Em contraste, imagens de nível 1 e 2 são distribuídas da forma original como foram captadas pelo sensor, de modo que *pixels* de duas imagens diferentes dificilmente possuem a mesma localização geográfica. Desta forma, na nomenclatura utilizada pela NASA, diz-se que estas imagens L1 e L2 são distribuídas em grânulos ou *granules*, ao invés de ladrilhos ou *tiles*.

Nível 3: dados de nível 2 que foram mapeados para escalas uniformes de tempo e espaço, e que além disso sofreram um processamento adicional de forma a

garantir algum nível de consistência e completude. Exemplos de produtos deste nível são:

- médias mensais da temperatura na superfície do mar
- composições de 16 dias de índices de vegetação

Nível 4: dados resultantes de modelos ou análises mais complexas, incluindo o processamento de dados diversos de níveis mais baixos. Produtos deste nível são destinados aos usuários que não estão necessariamente focados em sensoriamento remoto propriamente dito, pretendendo simplesmente incorporar estes dados diretamente em modelos biogeoquímicos tais como os de circulação de carbono e de água, ou modelos climáticos. Exemplos de produtos deste nível são:

- dados semanais de índice de área foliar (LAI, *leaf area index*)
- dados semanais de produtividade primária líquida sobre os oceanos




Figura 4.4 Grade fixa utilizada para dividir o mundo em grandes ladrilhos ou *tiles*, numa projeção sinusoidal. Esses ladrilhos, de 1200km de lado, são utilizados para a distribuição de produtos MODIS de nível 2G, 3 e 4.
Fonte: MODIS Reprojection Tool User's Manual [104]

Finalmente, cabe dizer ainda que a grande maioria dos produtos MODIS são distribuídos numa resolução de 1km, haja vista ser esta a resolução da maioria de suas bandas de imageamento (ver Tabela 4.1). Entretanto, produtos que fazem uso apenas das bandas 1 a 7, em geral voltados para o imageamento da superfície terrestre, podem estar disponíveis em resoluções de 500m ou até mesmo 250m, caso se utilizem apenas informações das bandas do vermelho e infra-vermelho próximo. Além disso, produtos com resoluções mais baixas (*e.g.*, 4km, 36km, 0,05 graus ou 1 grau) também são produzidos rotineiramente, muitas vezes com o intuito de facilitar a integração destes dados com modelos globais de circulação e afins.

4.3.3 Produto MOD09GQK: reflectância diária da superfície a 250m

Dentre os produtos MODIS disponíveis, o MOD09GQK apresenta-se como um dos mais interessantes para aplicações relacionadas ao levantamento do uso e cobertura do solo. Este produto, de nível de processamento 2G, apresenta estimativas de valores de reflectância espectral na superfície, tais como elas seriam medidas no nível do solo (*i.e.*, procurando eliminar ou minimizar distorções causadas por influências atmosféricas). Desta forma, algoritmos de correção são aplicados de forma a compensar os efeitos de absorção ou dispersão causados por aerossóis, gases atmosféricos, ou nuvens finas do tipo *cirrus*.

O MOD09GQK inclui valores de reflectâncias de superfície apenas para as bandas do vermelho e do infra-vermelho próximo, o que permite que ele seja disponibilizado a uma resolução de 250m. Desta forma, a sua boa resolução e o seu caráter diário de imageamento fazem deste produto uma alternativa especialmente interessante para a observação da evolução do uso e cobertura do solo em tempo real.

Com relação aos seus metadados, este produto inclui as seguintes camadas de informação:

- *Qualidade* – corresponde ao controle de qualidade *pixel a pixel* do produto, indicando por exemplo se foi detectado algum tipo de problema ou condição especial no momento da aplicação dos algoritmos de correção atmosférica. Como ocorre com muitas camadas de metadados, para cada *pixel* é dado um valor inteiro de 16 bits, onde cada bit corresponde a um tipo de informação, conforme especificado na Tabela 4.2 abaixo. Deve-se notar ainda que os dados desta camada sobre cobertura de nuvens em cada *pixel* referem-se a um algoritmo interno de detecção que utiliza apenas as bandas do vermelho e infra-vermelho próximo (bandas 1 e 2, as únicas incluídas no produto).
- *Órbita e cobertura* – indica, para cada *pixel*, a órbita do satélite no momento da sua observação (deve-se lembrar que, sendo um produto de nível 2G, cada imagem representa um ladrilho ou *tile* de grandes dimensões composto pela reorganização de diferentes passagens do satélite em um único dia). Além disso, também está contida nesta camada uma informação denominada cobertura de observação (*observation coverage*), que corresponde à percentagem de superposição entre a observação realizada pelo sensor e a célula da grade fixa (*pixel* da imagem). Assim, quanto maior esta superposição, mais fiel será o produto L2G com relação à superfície original. Em particular, deve-se notar que, quanto maior o ângulo de visada, menos informação é coletada pela observação do sensor, tornando-a percentualmente menos significativa com relação à célula da grade fixa.

BIT	DESCRIÇÃO
0-1	Bits de QA (quality assurance); correções do produto efetuados em: 00 - condições ideais para todas as bandas 01 - condições aquém das ideais para algumas ou todas as bandas correções não efetuadas devido a: 10 - efeitos de nuvens em todas as bandas 11 - outras razões
2-3	cobertura de nuvens; 00 - sem nuvens 01 - com nuvens 10 - misturado 11 - não definido, assume-se ausência de nuvens
4-7	dados de qualidade para a banda 1; 0000 - qualidade máxima 1000 - detector inoperante; dados interpolados no nível L1B 1001 - ângulo de zênite solar ≥ 86 graus 1010 - ângulo de zênite solar ≥ 85 e < 86 graus 1011 - dados de entrada não encontrados 1100 - pelo menos uma constante atmosférica fez uso de um valor interno, no lugar de dados climatológicos 1101 - valor corrigido do <i>pixel</i> fora dos limites: restringido para o valor extremo permitido 1110 - dados de nível L1B com falhas 1111 - <i>pixel</i> não processado devido a oceano profundo ou nuvens
8-11	dados de qualidade para a banda 2; IDÊNTICO AO ACIMA
12	correção atmosférica realizada; 1 - sim 0 - não
13	correção de adjacência realizada; 1 - sim 0 - não
14-15	bit não utilizado;

Tabela 4.2 Especificações da camada de metadados de qualidade, para o produto MOD09GQK. Bits são numerados da direita (menos significativo) para a esquerda (mais significativo).

Fonte: adaptado de USGS [105]

- *Número de observações* – indica o número de observações do sensor que interceptam a célula da grade fixa utilizada pelo produto L2G. De forma geral, a imagem fornecida irá conter a melhor dessas observações, considerando-se os critérios de qualidade e cobertura de observação (veja itens anteriores).

4.3.4 Produto MOD09GST: qualidade da reflectância diária da superfície a 1km

Este produto, embora de caráter auxiliar, possui extrema importância para o bom aproveitamento e correto processamento de seqüências temporais de dados MOD09GQK. De fato, embora o produto de reflectância descrito anteriormente possua indicadores de qualidade bastante úteis para o seu processamento, deve-se ter sempre em mente que estes indicadores foram gerados exclusivamente a partir das bandas de 250m de resolução (*i.e.*, somente vermelho e infra-vermelho próximo). Em particular, deve ser ressaltado que uma detecção de nuvens apenas com estas duas bandas é conhecidamente insuficiente para a grande maioria das aplicações, fazendo com que um grande número de *pixels* contaminados não sejam devidamente detectados. Desta forma, o produto MOD09GST utiliza na verdade informações provenientes de um grande número de bandas do MODIS, o que lhe permite fornecer

informações muito mais confiáveis e completas acerca de cada *pixel*. Assim, além de uma detecção mais confiável da presença de nuvens, este produto também inclui informações sobre níveis de concentração de aerossóis, detecção de áreas de sombra, e presença de nuvens altas do tipo *cirrus*, entre outras indicações. Em contrapartida, devido ao uso de tantas bandas MODIS, a resolução espacial deste produto está restrita a 1km.

BIT	DESCRIÇÃO
0-1	cobertura de nuvens; 00 - sem nuvens 01 - com nuvens 10 - misturado 11 - não definido
2	presença de sombra de nuvens; 1 - sim 0 - não
3-5	indicador terra/água; 000 - oceano raso 001 - terra 010 - costa oceânica ou costa de lagos 011 - águas fechadas rasas 100 - águas temporárias 101 - águas fechadas profundas 110 - oceano continental/moderado 111 - oceano profundo
6-7	quantidade de aerossóis; 00 - utilizando dados climatológicos 01 - baixa 10 - média 11 - alta
8-9	detecção de nuvens <i>cirrus</i> ; 00 - nenhum 01 - pouco 10 - médio 11 - muito
10	algoritmo interno de detecção de nuvens; 1 - com nuvens 0 - sem nuvens
11	algoritmo interno de detecção de fogo; 1 - com fogo 0 - sem fogo
12	indicador de presença de neve/gelo (advindo do produto MOD35); 1 - sim 0 - não
13-14	correção BRDF realizada; 00 - nenhuma 01 - utilização de metodologia de Montana 10 - utilização de metodologia de Boston
15	algoritmo interno de detecção de neve; 1 - com neve 0 - sem neve

Tabela 4.3 Especificações da camada de metadados de estado dos dados de reflectância a 1km de resolução, no produto MOD09GST. Bits são numerados da direita (menos significativo) para a esquerda (mais significativo).

Fonte: adaptado de USGS [106]

As principais camadas de informação incluídas neste produto são as seguintes:

- *Estado dos dados de reflectância (state)* – corresponde à camada principal de informações de qualidade. Aqui, indica-se para cada *pixel* de 1km se foi detectada alguma contaminação por nuvens, assim como a presença de sombras de alguma

nuvem. Além disso, inclui-se também a quantidade estimada de aerossóis no *pixel*, juntamente com um indicador da presença de nuvens *cirrus*. Outras informações desta camada incluem a detecção de neve ou gelo, e um indicador do tipo de superfície no *pixel* em questão (*i.e.*, terra, ambiente costeiro, oceano raso ou profundo, etc.). A especificação completa desta camada pode ser vista na Tabela 4.3 acima.

- *Órbita e cobertura* – semelhante à camada homônima do produto MOD09GQK.
- *Número de observações* – semelhante à camada homônima do produto MOD09GQK.

4.3.5 Produto MOD13Q1: composição 16 dias de índices de vegetação a 250m

O produto MOD13Q1 corresponde a uma opção muito interessante para aplicações de levantamento e/ou monitoramento do uso e cobertura do solo. Diferentemente do MOD09GQK, este produto corresponde a uma informação de nível 3 de processamento, de modo a procurar garantir um maior nível de consistência temporal dos dados e assim fornecer uma informação mais acessível e prática para o usuário final.

Com efeito, o MOD13Q1 toma por base os dados diários de reflectância da superfície, e então os processa de modo a identificar a medição mais representativa e confiável obtida para cada *pixel* durante um período de 16 dias. Para tanto, são consideradas tanto as condições atmosféricas (*i.e.*, presença de nuvens, fumaça, sombras, aerossóis, etc.) quanto a qualidade angular da observação (*i.e.*, ângulos de visada elevados são considerados de baixa qualidade). Então, uma vez selecionada a melhor medição de reflectância para o período, são também calculados dois tipos diferentes de índice de vegetação. Em primeiro lugar, computa-se o índice NDVI, já bastante conhecido da literatura (ver seção 2.2.4), a partir dos valores medidos nas faixas do vermelho e infra-vermelho próximo (canais 1 e 2, ver Tabela 4.1). Além disso, calcula-se também o *Enhanced Vegetation Index* (EVI), um índice específico do MODIS que utiliza informações adicionais das faixas do azul e do infra-vermelho médio (canais 3 e 7 do sensor). Este segundo índice foi desenvolvido com o intuito de minimizar efeitos de interferência atmosférica e de diferentes tipos de solo, bem como para evitar a saturação de valores do índice em pontos de cobertura vegetal extremamente densa.

As camadas de metadados incluídas no produto MOD13Q1 são as seguintes:

- *Qualidade NDVI* – corresponde ao controle de qualidade *pixel a pixel* para os dados de NDVI computados. Esta camada inclui medidas globais de qualidade e “usabilidade” para cada valor calculado, servindo assim como uma orientação básica para que o usuário final possa filtrar os dados mais confiáveis daqueles sujeitos a condições não-ideais de medição. Além disso, esta camada também contém informações mais

específicas acerca do nível de concentração de aerossóis, presença de nuvens, e detalhes do tipo de algoritmo de processamento executado, entre outros indicadores, conforme especificado na Tabela 4.4 abaixo.

BIT	DESCRIÇÃO
0-1	qualidade; 00 NDVI produzido, qualidade perfeita; 01 NDVI produzido, checar demais campos de QA 10 NDVI produzido, com provável contaminação por nuvens 11 não produzido por razões além da presença de nuvens
2-5	índice de usabilidade; 0000 qualidade perfeita ... 0111 qualidade média ... 1100 qualidade baixa 1101 nenhuma correção atmosférica realizada 1110 qualidade baixa demais para ser útil 1111 não utilizável por outras razões
6-7	quantidade de aerossóis; 00 - utilizando dados climatológicos 01 - baixa 10 - média 11 - alta
8	correção de adjacência realizada; 1 - sim 0 - não
9	correção BRDF realizada; 1 - sim 0 - não
10	nuvens misturadas; 1 - sim, possibilidade de existência de nuvens misturadas 0 - não, sem nuvens misturadas
11-12	indicador terra/água; 00 - oceano ou águas fechadas profundas 01 - área de costa ou águas fechadas rasas 10 - áreas alagadas ou temporárias 11 - terra
13	presença de neve/gelo; 1 - sim 0 - não
14	presença de sombra de nuvens; 1 - sim 0 - não
15	método de composição para cálculo de NDVI 0 - valor equivalente no nadir usando modelo BRDF 1 - CV-MVC (constraint view angle maximum value composite)

Tabela 4.4 Especificações da camada de metadados de qualidade dos valores NDVI, para o produto MOD13Q1. Bits são numerados da direita (menos significativo) para a esquerda (mais significativo).

Fonte: adaptado de USGS [107]

- *Qualidade EVI* – idêntica à camada *Qualidade NDVI* acima, porém referente aos valores de EVI calculados em cada *pixel*.
- *Ângulo de visada* – indica o ângulo de visada referente à medição selecionada dentro do período de 16 dias.
- *Ângulo solar* – indica o ângulo solar referente à medição selecionada dentro do período de 16 dias.

- *Azimute relativo* – indica o ângulo de azimute relativo entre a direção do satélite e a direção do sol, referente à medição selecionada dentro do período de 16 dias

4.3.6 Aquisição de dados

Através do portal EOS Data Gateway, mantido pela agência norte-americana USGS (ver seção 4.3.1), foram encomendados e adquiridos gratuitamente seqüências de imagens MODIS cobrindo o período de um ano, do dia 1º de agosto de 2000 ao dia 31 de julho de 2001.

Para este trabalho, foram encomendadas tanto imagens de NDVI e reflectância resultantes da composição de 16 dias de dados (produto MOD13Q1, ver seção 4.3.5), quanto imagens de reflectância diária da superfície (produto MOD09GQK, ver seção 4.3.3) acompanhadas dos metadados também diários de qualidade da reflectância a 1km de resolução (produto MOD09GST, ver seção 4.3.4). Desta forma, de modo a cobrir todo o período estabelecido, foi obtido um total de 24 imagens MOD13Q1, 315 imagens MOD09GQK, e outras 315 imagens de qualidade MOD09GST.

4.4 Imagens LANDSAT

Conforme mencionado na introdução deste capítulo, além dos dados provenientes do sensor MODIS e das informações de classificação do uso e cobertura do solo, nesta dissertação se utilizaram também imagens da série LANDSAT, com o objetivo de permitir avaliar melhor as técnicas de detecção de desflorestamento investigadas neste trabalho. Estas imagens apresentam uma resolução espacial de 30m (em contraste com os 250m dos produtos MODIS de maior resolução), permitindo assim uma melhor avaliação dos resultados alcançados pela metodologia. Uma visão geral do programa LANDSAT, assim como suas especificações, encontra-se descrito no apêndice A.5.

Especificamente, ao longo deste trabalho foram utilizados os seguintes conjuntos de imagens:

- Ano 2000

Mosaico de imagens LANDSAT/TM (LANDSAT 5), composição 5-4-3. Corresponde ao mesmo conjunto de dados utilizado por Silva [94] em sua classificação (seção 4.1).

Este mosaico foi produzido a partir das seguintes imagens originais LANDSAT:

Órbita/ Ponto	Data
224/72	30/07/2000
224/73	30/07/2000
225/72	05/07/2000
225/73	05/07/2000

Tabela 4.5 Órbitas/ponto e datas das imagens LANDSAT adquiridas para o ano 2000

- Ano 2002

Imagens LANDSAT/ETM+ (LANDSAT 7):

Órbita/ Ponto	Data
224/72	26/06/2002
224/73	26/06/2002
225/72	17/06/2002
225/73	17/06/2002
225/74	17/06/2002

Tabela 4.6 Órbitas/ponto e datas das imagens LANDSAT adquiridas para o ano 2002

4.5 Sistemas e programas

A realização do trabalho descrito nesta dissertação envolveu a utilização de uma série de sistemas de computação, tais como bibliotecas de *software*, programas acadêmicos, programas gratuitos de uso público, e também alguns programas de cunho comercial.

Em primeiro lugar, deve-se dizer que a metodologia em si, descrita no capítulo 5, foi quase que totalmente implementada em linguagem ANSI C, de modo a garantir o máximo de simplicidade, eficiência e portabilidade dos programas desenvolvidos. Esta implementação foi de fato realizada e testada tanto em sistemas operacionais Microsoft Windows (98/Me/2000/XP) quanto em ambiente Linux, sendo desta forma facilmente portátil para outras plataformas. Em ambiente Windows, utilizou-se o ambiente de programação Dev-Cpp versão 5, um sistema IDE (*Integrated Development Environment*) disponibilizado gratuitamente pela Bloodshed Software (<http://www.bloodshed.net/devcpp.html>). Por sua vez, o desenvolvimento em ambiente Linux foi realizado com o auxílio do sistema Eclipse CDT (*C++ Development Tools*) versão 2, o qual também é gratuito e é baseado na plataforma Eclipse 3.0 (<http://www.eclipse.org/cdt>). Em todas os ambientes, os procedimentos implementados em C fizeram uso da biblioteca de processamento de imagens INRIMAGE, produzida e distribuída gratuitamente pelo INRIA (<http://www-rocq.inria.fr/inrimage>).

Adicionalmente, utilizou-se o *software* comercial ENVI (*Environment for Visualizing Images*, produzido pela Research Systems Inc.), nas versões 3.5 e 4.0, para a realização de avaliações visuais e para alguns procedimentos de manipulação de formatos e conversão de dados (<http://www.rsinc.com/envi>). Além disso, certos procedimentos de processamento foram implementados no sistema MATLAB, também comercial e produzido pela MathWorks, nas versões 6.5 e 7.0 (<http://www.mathworks.com/products/matlab>). Outros procedimentos experimentais foram ainda implementados com o auxílio do pacote estatístico gratuito “R”, o qual pode ser obtido em <http://www.r-project.org>. Finalmente, deve-se mencionar ainda a utilização do pacote acadêmico de mineração de dados WEKA, disponibilizado gratuitamente

pela Universidade de Waikato, Nova Zelândia (<http://www.cs.waikato.ac.nz/~ml/weka/>), e que permitiu a experimentação e teste de diversos algoritmos de seleção de atributos, além de proporcionar uma ferramenta para a visualização das distribuições de probabilidade dos dados utilizados para a classificação.

5 Metodologia

Neste capítulo são descritos em detalhe todos os passos propostos para a realização de um levantamento do uso e cobertura do solo em escala regional, a partir de dados MODIS e de forma quase que totalmente automatizada.

Esta metodologia toma como base dois conjuntos de dados:

- Uma seqüência temporal de dados MODIS para a região em estudo, com informações nas bandas do vermelho e infra-vermelho próximo cobrindo um período de 1 ano com uma resolução espacial de 250m. A metodologia pode fazer uso tanto de dados de reflectância diária da superfície (produto MOD09GQK, acompanhado dos metadados do produto MOD09GST a 1km de resolução, ver seções 4.3.3 e 4.3.4) quanto dados de reflectância e de NDVI resultantes de uma composição de 16 dias (produto MOD13Q1, ver seção 4.3.5).
- Uma classificação confiável do uso e cobertura do solo para o mesmo ano, para servir de dado de referência na fase de treinamento da metodologia. Esta classificação deve cobrir uma parcela da região em estudo, devendo descrever as classes de interesse de maneira representativa.

A partir destes dados iniciais, propõe-se então uma série de passos bem-definidos de forma a se atingir o objetivo final. Em resumo, o processo como um todo pode ser descrito pelas seguintes etapas:

- a. Pré-processamento dos dados MODIS, de modo a se obterem perfis temporais livres de interferências e ruídos excessivos (seção 5.1).
- b. Adaptação da classificação original de referência, de modo a se determinarem quais classes são efetivamente discrimináveis utilizando dados MODIS, gerando por fim uma classificação de treinamento (seção 5.2).
- c. Análise dos perfis temporais NDVI obtidos no item *a*, de modo a se calcularem métricas ou atributos que forneçam informações mais inteligentes e úteis para a caracterização das classes (seção 5.3).
- d. Seleção dos atributos computados no item *c*, de modo a se definir um sub-conjunto de métricas que maximize a capacidade de discernimento entre as classes de interesse (seção 5.4).

- e. Classificação do uso e cobertura do solo a partir dos atributos selecionados no item *d*. Esta etapa pode ainda ser subdividida em uma fase de treinamento (que faz uso da classificação adaptada no item *b*) e de uma fase de execução, seguida de um processamento adicional de refino dos resultados da classificação (seção 5.5).

Todas estas etapas de processamento podem ser visualizadas graficamente na Figura 5.1 abaixo.

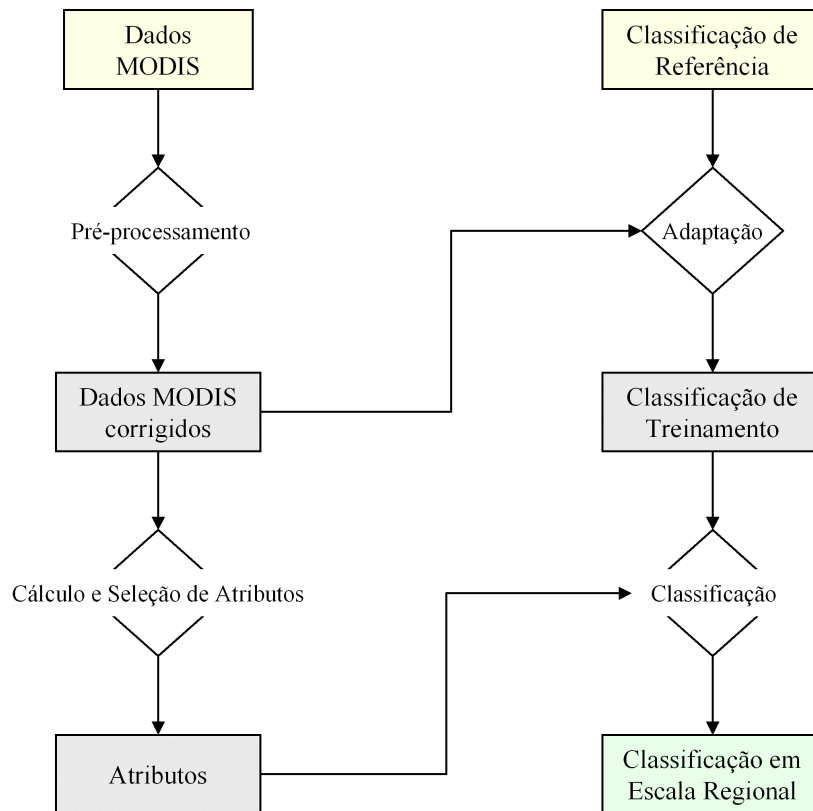


Figura 5.1 Visão geral da metodologia de classificação do uso e cobertura do solo em escala regional a partir de seqüências temporais de dados MODIS

5.1 Pré-processamento de dados MODIS

5.1.1 Recorte/mosaicagem, reprojeção e conversão de dados usando MRT

O primeiro passo a ser tomado nesta fase de pré-processamento de dados diz respeito à assimilação dos arquivos de produtos MODIS a serem trabalhados. Para tanto, recomenda-se a utilização do programa *MODIS Reprojection Tool* (MRT) disponibilizado gratuitamente pela NASA (veja seção 4.3.2).

Em primeiro lugar, o MRT deve ser utilizado para uma operação de recorte e/ou mosaicagem dos arquivos originais, de forma a se poder trabalhar exclusivamente com os dados que cobrem a região de interesse. Esta etapa é importante para facilitar o processamento de uma forma geral, particularmente com relação à exclusão de dados externos à região de interesse.

Em seguida, é também importante que se realize uma reprojeção destes dados, passando-os da projeção sinusoidal de origem (Figura 4.4, na seção 4.3.2) para uma outra projeção mais fácil de se trabalhar e compatível com os dados da classificação original de entrada. Em especial, deve-se enfatizar que a projeção utilizada nos produtos MODIS é bastante particular, não utilizando parâmetros e especificações comumente empregadas no meio cartográfico e nos programas comerciais de geoprocessamento. Desta forma, a própria NASA sugere que a conversão de projeções seja realizada exclusivamente através do programa MRT.

Finalmente, deve-se notar ainda que todos os produtos MODIS são distribuídos no formato HDF-EOS, o que, como discutido na seção 4.3.2, não corresponde a um formato muito intercambiável, além de apresentar um nível razoável de complexidade. Desta forma, o programa MRT também pode ser utilizado para converter os dados destes produtos para formato HDF-RAW (formato binário cru), de modo a simplificar o seu processamento, ou para GeoTIFF, de forma a facilitar a sua visualização em programas comerciais de geoprocessamento.

Todos os detalhes da utilização do programa MRT podem ser encontrados em USGS [104].

5.1.2 Filtragem de dados para o produto MOD13Q1

5.1.2.1 Considerações iniciais

Como discutido na seção 4.3, os arquivos de produtos MODIS necessariamente incluem, além dos dados principais, um conjunto de informações auxiliares ou *metadados* cujo objetivo principal consiste em fornecer para cada *pixel* uma medida do grau de sua qualidade e das peculiaridades envolvidas no seu processamento. Desta forma, ao se construir uma sequência temporal com dados desta natureza, é de extrema importância levar em consideração estas medidas de qualidade, de forma que se possa filtrar dados de baixa confiabilidade e assim minimizar ruídos e interferências devidos a efeitos atmosféricos, falhas de sensor ou outra origem qualquer [54].

5.1.2.2 Procedimento

Especificamente com relação ao produto MOD13Q1 (dados de reflectância e de NDVI resultantes de uma composição de 16 dias, ver seção 4.3.5), uma sequência temporal de dados para o período de 1 ano inclui 24 imagens, e a principal informação a ser utilizada na avaliação de cada imagem corresponde à camada de metadados *Qualidade NDVI*. Assim, observando-se a especificação dada na Tabela 4.4, foi estabelecido que um *pixel* qualquer de uma imagem deve ser considerado como confiável e útil para a metodologia apenas se ele satisfizer os seguintes critérios:

1. Bit 1	deve ser '0'	(NDVI produzido, provavelmente sem nuvens)
2. Bit 5	deve ser '0'	(utilidade de NDVI média ou superior)
3. Bits 6-7	não podem ser '11'	(alta quantidade de aerossóis)
4. Bit 10	deve ser '0'	(sem nuvens misturadas)
5. Bit 14	deve ser '0'	(sem possibilidade de sombra)

Tabela 5.1 Critérios estabelecidos para filtrar dados do produto MOD13Q1, com base nas especificações da camada de metadados *Qualidade NDVI* (Tabela 4.4)

Portanto, os *pixels* que não satisfazem estas condições são filtrados da sequência temporal, sendo os seus dados ignorados e substituídos através de uma interpolação linear no tempo, conforme ilustrado na Figura 5.2 abaixo.




Figura 5.2 Utilização de interpolação linear no domínio temporal para substituir *pixels* que não satisfaçam os critérios de qualidade estabelecidos na Tabela 5.1. Operação permite a obtenção de perfis temporais mais suaves e consistentes.

Deve-se notar ainda que, conforme a necessidade, outros critérios mais ou menos rígidos podem também ser adotados com vistas a este processo de filtragem. Assim, ao final do processo, obtêm-se como resultado perfis temporais mais consistentes e suaves, sendo agora confiáveis o suficiente para serem utilizados como base para um algoritmo de classificação.

5.1.3 Filtragem de dados para os produtos MOD09GQK / MOD09GST

5.1.3.1 Considerações iniciais

Alternativamente à utilização da composição de 16 dias MOD13Q1, os produtos de reflectância diária da superfície também podem ser utilizados para o levantamento do uso e cobertura do solo em escala regional. Neste caso, o volume de dados a ser analisado é evidentemente muito maior, uma vez que, para um período de um ano, em vez de 24 imagens se trabalha com um potencial de mais de 300 imagens (considerando-se um único ladrilho MODIS). Conseqüentemente, a complexidade para o processamento destes dados também aumenta, ao mesmo tempo em que deixa-se de aproveitar o conhecimento e experiência dos pesquisadores da NASA ao desenvolver o produto MOD13Q1.

Em contrapartida, a utilização destes produtos diários pode ser atraente por alguns outros aspectos. O processamento de dados de nível mais básico permite na realidade um controle maior sobre o processo como um todo, evitando eventuais interferências indesejáveis de suposições e escolhas feitas na produção dos dados mais avançados. Desta forma, permite-se uma maior flexibilidade na definição dos critérios de qualidade e na construção da sequência

temporal como um todo, particularmente com relação ao controle mais fino acerca das datas exatas de cada dado.

5.1.3.2 Processamento de dados MOD09GST

A metodologia proposta para o pré-processamento dos dados diários de reflectância consiste primeiramente numa etapa de análise do produto de qualidade MOD09GST (descrito na seção 4.3.4). Esta análise é realizada com o intuito de avaliar quais datas apresentam melhores condições de observação, de forma a se eliminarem todas as imagens de baixa utilidade ou qualidade (*e.g.*, imagens altamente contaminadas pela presença de nuvens).

De fato, a escolha desta abordagem se justifica por duas razões. Primeiramente, o produto MOD09GST possui informações mais detalhadas do que qualquer outro no tocante a possíveis causadores de ruído e interferência nos dados, concentrando dados sobre cobertura de nuvens, presença de sombras, nível de concentração de aerossóis e detecção de nuvens finas do tipo *cirrus*. Em segundo lugar, por apresentar uma resolução espacial de 1km, a aquisição e manipulação deste produto se mostra bem mais viável do que para as imagens de reflectância com 250m de resolução.

Desta forma, analisam-se duas camadas de metadados do produto (*Estado e Órbita e cobertura*), estabelecendo-se os seguintes critérios para admitir uma imagem como sendo de qualidade suficientemente boa:

- a. Um mínimo de 40% de *pixels* não contaminados pela presença de nuvens, sombras, *cirrus* ou altas concentrações de aerossóis (critério explicitado na Tabela 5.2).
- b. Uma média de cobertura (*observation coverage*) para toda a imagem de no mínimo 20%. Este valor foi obtido através de observações empíricas da qualidade visual das imagens e está de acordo com observações feitas por outros pesquisadores [82].

1.	Bits 0-1	devem ser '00'	(sem nuvens)
2.	Bit 2	deve ser '0'	(sem sombra de nuvens)
3.	Bits 6-7	não podem ser '11'	(alta quantidade de aerossóis)
4.	Bits 8-9	devem ser '00'	(sem nuvens do tipo <i>cirrus</i>)
5.	Bit 10	deve ser '0'	(sem nuvens - algoritmo interno)

Tabela 5.2 Critérios estabelecidos para considerar *pixels* do produto MOD09GST como livres de contaminação atmosférica e interferências similares, com base nas especificações da camada de metadados *Estado* (Tabela 4.3)

Portanto, ao final deste processo, apenas um pequeno sub-conjunto de datas é selecionado para o período de análise em questão, restringindo-se drasticamente a quantidade de imagens de reflectância (produto MOD09GQK) a serem adquiridas e processadas.

5.1.3.3 Processamento de dados MOD09GQK

Uma vez adquiridas as imagens MOD09GQK apenas para as datas de maior qualidade, é necessário então que se realize uma filtragem dos *pixels* que porventura apresentem algum problema ou falha de processamento. Desta maneira, de forma semelhante ao que foi descrito para o produto MOD13Q1 (seção 5.1.2.2), utiliza-se um critério para a identificação de *pixels* considerados de baixa qualidade. Os dados destes *pixels* são então desconsiderados, aplicando-se uma interpolação linear temporal para substituir os valores suprimidos.

Os critérios estabelecidos para determinar *pixels* de qualidade aceitável são os seguintes:

- a. O *pixel* não deve estar contaminado pela presença de nuvens, sombras, *cirrus* ou altas concentrações de aerossóis, conforme determinado pela camada *Estado* do produto MOD09GST (critério explicitado na Tabela 5.2).
- b. O *pixel* deve possuir bons níveis de qualidade com relação aos processos de correção atmosférica e determinação dos valores de reflectância, conforme determinado pela camada *Qualidade* do produto MOD09GQK (critério explicitado na Tabela 5.3).
- c. O *pixel* deve apresentar um mínimo de 20% de cobertura (*observation coverage*), conforme estabelecido pela camada *Órbita e cobertura* do produto MOD09GQK.

1.	Bits 0-1	devem ser '00'	(qualidade ideal em todas as bandas)
2.	Bits 2-3	devem ser '00'	(sem nuvens)
3.	Bits 4-7	devem ser '0000'	(qualidade máxima para banda 1)
4.	Bits 8-11	devem ser '0000'	(qualidade máxima para banda 2)
5.	Bit 12	deve ser '1'	(correção atmosférica realizada)

Tabela 5.3 Critérios estabelecidos para considerar *pixels* do produto MOD09GQK como sendo de boa qualidade, com base nas especificações da camada de metadados *Qualidade* (Tabela 4.2)

Na realidade, apesar de toda a rigidez na execução destes critérios, deve-se ter em mente ainda que as detecções de nuvens e demais avaliações informadas nos metadados dos produtos MODIS estão sempre sujeitas a falhas e imperfeições. Em particular, é especialmente reconhecida a deficiência dos algoritmos utilizados pela NASA com relação à detecção de sombras de nuvem a partir de dados MODIS [3], o que pode introduzir diversos ruídos indesejáveis nos perfis temporais de cada *pixel*.

Por estas razões, além do processo de interpolação dos valores suprimidos, aplica-se subsequentemente um algoritmo de filtragem no domínio temporal, de modo a suavizar o perfil resultante e minimizar o ruído causado pela presença não detectada de nuvens ou sombras. Neste sentido, por exemplo, pode-se utilizar um *filtro de mediana* com uma janela móvel de determinado tamanho (*e.g.*, três elementos, ou datas). Neste caso, para cada ponto são avaliados também os valores observados em sua vizinhança temporal, sendo o valor do ponto então substituído pelo valor mediano encontrado (*i.e.*, no caso de 3 valores, o valor

mediano corresponderia ao segundo maior valor observado). Desta forma, evitam-se as ondulações excessivas, tornando o perfil como um todo muito mais suave. Alternativamente, um filtro de *variância local* também poderia ser aplicado, utilizando o mesmo conceito de janela móvel. Neste caso, em cada ponto são calculados a média μ e o desvio padrão σ da vizinhança local. Então, verifica-se se o valor observado no ponto encontra-se contido no intervalo $[\mu - 2\sigma, \mu + 2\sigma]$. Caso não esteja, este valor é então substituído pela média μ . Como resultado final, obtém-se então um perfil livre de picos ou vales súbitos e extremos, eliminando-se, portanto, medidas tipicamente decorrentes de algum tipo de interferência não-detectada.

5.2 Adaptação da classificação de referência para dados MODIS

Neste ponto, ao se obterem perfis temporais confiáveis para cada *pixel* da região de estudos, torna-se possível utilizá-los para analisar a informação fornecida *a priori* acerca do uso e cobertura do solo, com o objetivo de se gerar, por fim, dados de treinamento que possam ser utilizados por um algoritmo de classificação a partir de dados MODIS.

De fato, estes dados de referência de uso e cobertura, que, a princípio, são considerados como corretos e confiáveis, são de forma geral provenientes de um esforço detalhado de levantamento, incluindo-se aí o apoio de viagens ao campo e imagens de alta resolução, dentre outros recursos. Desta forma, é natural admitir a possibilidade de que os dados provenientes do sensor MODIS, com 250m de resolução espacial e apenas duas bandas de informação, possam não ser capazes de capturar este mesmo nível de detalhamento de forma confiável. Portanto, torna-se necessário realizar uma análise de forma a determinar quais das classes originais são efetivamente discerníveis a partir dos perfis temporais de dados MODIS, considerando-se as bandas do vermelho e infra-vermelho próximo e o índice NDVI.

Em contrapartida, também se deve levar em consideração a possibilidade de se observarem, a partir dos dados MODIS, diversos comportamentos temporais distintos para cada uma destas classes originalmente estipuladas. Neste caso, diversas coberturas distintas do solo (*e.g.*, diferentes cultivos agrícolas) podem estar agrupadas em uma única classe segundo os dados de referência (no exemplo, *agricultura*), muito embora espectralmente se verifiquem respostas temporais bastante diferenciadas, com padrões de crescimento e senescência característicos de cada cultivo. Portanto, para que se realize uma classificação a partir de dados temporais MODIS, é importante também que sejam identificadas, para cada classe original, quais as possíveis sub-classes existentes no seu interior.

Finalmente, deve-se notar ainda que, a partir das observações feitas por diversos pesquisadores [98][100][95], pode-se assumir também que a resolução espacial de 250m apresentada pelo MODIS é suficiente para que se encontre um número bastante significativo de *pixels* inteiramente cobertos por uma única classe de uso e cobertura do solo (*i.e.*, *pixels* “puros”). Assim, valendo-se desta hipótese, todos os procedimentos de adaptação da classificação original de referência para a geração de uma classificação de treinamento serão baseados na análise de *pixels* puros. Portanto, deve-se enfatizar que a metodologia descrita aqui não se aplica para casos de classes cujas ocorrências se dêem majoritariamente em áreas de superfícies menores do que a de um *pixel* MODIS.

5.2.1 Agrupamento das classes originais (*merge*)

Neste primeiro ponto, inicia-se o processo ao se superporem os dados MODIS com a imagem de classificação de referência, para então identificar, para cada classe, todos aqueles *pixels* que podem ser considerados como puros a 250m de resolução (*i.e.*, 100% cobertos pela classe em questão). Uma vez feito isso, observam-se então os dados temporais NDVI correspondentes a estes *pixels*, de modo a se calcular, para cada classe, um perfil temporal médio juntamente com o seu desvio padrão em cada data da seqüência sob análise.

Desta forma, estes perfis calculados podem ser então exibidos em forma de gráfico, juntamente com seus respectivos desvios-padrão, de modo que se possa realizar uma avaliação visual do potencial do sensor MODIS para identificar diferenças entre as classes existentes. Como regra geral, classes cujos perfis médios se encontram afastados o suficiente um do outro em alguma data do período podem ser considerados como potencialmente separáveis a partir de observações do MODIS. Entretanto, caso haja uma superposição significativa entre os perfis durante todo o período de análise (*e.g.*, considerando-se o intervalo $[\mu - \sigma, \mu + \sigma]$), as classes em questão deverão ser agrupadas em uma única classe considerada como sendo discernível a partir de dados MODIS.

5.2.2 Sub-divisão das classes originais (*splitting*)

Para avaliar os possíveis sub-grupos existentes no interior de cada classe original, adota-se uma abordagem de agrupamento ou *clusterização* não-supervisionada de dados, tomando como base as seqüências temporais de índices NDVI para cada *pixel*.

Especificamente, existe uma grande quantidade de algoritmos deste tipo disponíveis na literatura, podendo-se utilizar, por exemplo, o método clássico *k-means* (uma descrição pode ser encontrada em [65]). Em resumo, este método corresponde a um algoritmo iterativo, que

aprimora progressivamente o agrupamento realizado até que o resultado convirja para uma divisão estável dos dados, como explicado na Tabela 5.4 abaixo.

1. É estabelecido o número k de grupos a serem considerados
2. Inicializam-se aleatoriamente k centróides, correspondentes aos perfis temporais médios dos k grupos
3. Para cada *pixel*, atribui-se o grupo cujo centróide esteja mais próximo. Para tanto, utiliza-se como medida a *distância euclidiana*, correspondente à simples raiz da soma dos quadrados das diferenças entre os valores do *pixel* e os valores do centróide, para cada data
4. Recalculam-se os centróides (*i.e.*, os perfis temporais médios) de cada grupo com base na atribuição realizada
5. Retorna-se ao passo 2 até que o agrupamento se estabilize

Tabela 5.4 Passos do algoritmo de agrupamento ou *clusterização* conhecido como *k-means*.

Assim, para cada classe, observa-se novamente o conjunto de *pixels* puros existentes com relação à classificação de referência e aos dados MODIS com 250m de resolução. Então, selecionam-se as seqüências temporais NDVI correspondentes a estes *pixels*, e aplica-se o algoritmo de agrupamento com $k = 3, 6$, ou 10 grupos, onde o número de grupos pode ser estimado com auxílio de conhecimento específico da área (*e.g.*, conhecimento do número de cultivos importantes existentes na região).

Desta forma, obtém-se como resultado um conjunto de k perfis temporais médios, cada um correspondente a um agrupamento encontrado pelo algoritmo. Então, uma inspeção visual dos centróides resultantes se faz mais uma vez necessária, de modo a se concluir se há diferenças significativas entre os diferentes grupos estabelecidos:

- a. Grupos cujos perfis temporais médios possuem forma similar são considerados como um único grupo
- b. Grupos cujos perfis temporais médios são identificados como sendo combinações de perfis de outros grupos são ignorados
- c. Grupos resultantes são considerados como sub-classes significativas com relação a uma classificação a partir de dados MODIS

5.2.3 Geração da classificação de treinamento

Uma vez realizados os procedimentos de agrupamento e sub-divisão das classes originais (*merge/splitting*), os grupos resultantes podem então ser utilizados para estabelecer uma nova classificação, a partir dos dados originais. Essa nova classificação apresentará potencialmente um número diferente de classes, e deverá estar especificada com uma resolução espacial de 250m. Assim, com estas características, ela pode finalmente ser considerada como sendo compatível com dados temporais MODIS, sendo mais adiante considerada como uma

classificação de treinamento com vistas ao algoritmo de classificação supervisionada em escala regional (seção 5.5).

Adicionalmente, é importante que se tenha em mente que não é de forma alguma necessário que esta classificação de treinamento cubra todos os pontos incluídos na classificação de referência adquirida originalmente. De fato, como o seu objetivo é simplesmente especificar pontos que sirvam de exemplo para cada classe, nesta classificação de treinamento podem ser omitidos quaisquer *pixels* que apresentem comportamento fora do comum ou indesejável, contanto que os demais *pixels* consigam descrever de forma representativa a variabilidade inerente a cada uma destas classes de uso e cobertura do solo.

5.3 Análise de perfis temporais NDVI

Apesar de já apresentarem um bom nível de qualidade após o pré-processamento descrito na seção 5.1, os dados temporais MODIS computados ainda correspondem, neste ponto, a uma informação de características impróprias para um processo automatizado de classificação.

De fato, se considerarmos estes dados da maneira como se encontram, com um valor especificado para cada data da seqüência, veremos que a dimensionalidade d destes dados atinge patamares muito elevados para o período de 1 ano. Assim, para o produto MOD13Q1 de 16 dias, teremos $d = 24$ imagens na seqüência, com este número sendo potencialmente muito maior para o caso de se usar o produto MOD09GQK (ver seção 5.1.3). Mais grave ainda do que isso, os dados provenientes destas d dimensões serão necessariamente extremamente redundantes entre si, uma vez que haverá sempre um altíssimo grau de correlação entre valores de datas próximas de uma seqüência temporal.

Portanto, feitas estas considerações, percebe-se que é necessário realizar um processamento adicional dos perfis temporais, de modo a transformar estes dados em informações mais explícitas e úteis para a caracterização das diferentes classes de uso e cobertura do solo. Neste sentido, algoritmos tradicionais de redução de dimensionalidade de dados, tais como Análise de Componentes Principais (PCA, *Principal Components Analysis* [27][65][102]), não oferecem a capacidade de explicitar adequadamente a informação temporal contida na seqüência de dados, além de muitas vezes levar à perda de sua interpretabilidade.

Devido a estas questões, diversos autores propuseram que, no lugar dos dados originais da seqüência temporal, fossem utilizadas *métricas* de forma a quantificar a dinâmica destes dados ao longo do tempo, fornecendo assim um conjunto de informações mais compacto e pertinente [23][95][101]. Em particular, muitos destes estudos verificaram que métricas

computadas a partir de perfis temporais de NDVI, tais como amplitude do perfil e taxas de crescimento e senescência, se mostraram extremamente propícias para a classificação do uso e cobertura do solo, sendo capazes de capturar os diferentes comportamentos fenológicos das classes ao longo do tempo.

Sob esta ótica, nesta seção será descrito em detalhe o procedimento para o cálculo de diversas métricas ou *atributos* para perfis temporais, de modo a minimizar efeitos de ruídos residuais, reduzir a dimensionalidade e redundância dos dados, e aumentar a sua interpretabilidade. Este procedimento está dividido em 3 etapas, como discutido a seguir.

5.3.1 Modelagem de perfis temporais através do ajuste de curvas polinomiais

Apesar do bom nível de qualidade dos dados temporais MODIS após o pré-processamento descrito na seção 5.1, o uso destes dados diretamente para o cálculo de atributos ainda pode esbarrar em alguns inconvenientes. De fato, é importante notar que um perfil composto por amostras discretas apresentará em geral um formato bastante irregular (ver Figura 5.3 abaixo), o que trará dificuldades para a estimativa de taxas de crescimento e senescência, bem como das datas de início e fim do ciclo de crescimento vegetativo, dentre outros atributos. Além disso, a ocorrência de casos isolados de pontos contaminados pela presença de nuvens ou sombras não detectadas ainda pode prejudicar seriamente o cálculo de algumas métricas temporais, dentre as quais podemos notar a amplitude do perfil (*i.e.*, a diferença entre os valores máximo e mínimo ao longo da curva).




Figura 5.3 Modelagem de perfis temporais a partir de curvas polinomiais, de forma a minimizar o ruído residual e facilitar o cálculo de métricas mais apropriadas para a caracterização da dinâmica temporal dos dados.

Por estas razões, antes do cálculo dos atributos propriamente ditos, executa-se uma primeira etapa de *suavização dos perfis temporais*, de forma a reduzir o seu ruído residual e facilitar a sua interpretabilidade. Para tanto, realiza-se um ajuste de curvas polinomiais de grau n aos

dados da cada seqüência temporal NDVI, de forma a se obter o resultado desejado. A escolha de curvas do tipo polinomial se dá pelo fato delas corresponderem a curvas matematicamente simples e cujo ajuste não consome recursos computacionais em demasia, podendo ainda se escolher o grau n de acordo com o nível de variabilidade dos dados temporais sob análise.

Mais especificamente, o processo de ajuste das curvas se dá pela minimização do erro quadrático entre a curva polinomial descrita pela função f e os dados temporais y_1, y_2, \dots, y_d , tal como explicitado na equação (5.1) abaixo:

$$f(x, a) = a_0 + a_1x + \dots + a_nx^n$$

$$e^2 = \sum_{i=0}^d (y_i - f(x_i, a))^2 \quad (5.1)$$

sendo:

- x_i : a data correspondente ao i -ésimo valor da seqüência temporal
- y_i : o i -ésimo valor da seqüência temporal
- d : o número de valores ou número de datas na seqüência temporal
- a : o vetor de coeficientes da curva polinomial
- n : o grau da curva polinomial

De fato, esta minimização do erro quadrático e^2 pode ser computada até mesmo de forma analítica, obtendo-se o vetor de coeficientes a da função polinomial através de uma simples inversão de matriz, como descrito na equação (5.2):

$$\begin{bmatrix} d & \sum x_i & \dots & \sum x_i^n \\ \sum x_i & \sum x_i^2 & \dots & \sum x_i^{n+1} \\ \dots & \dots & \dots & \dots \\ \sum x_i^n & \sum x_i^{n+1} & \dots & \sum x_i^{2n} \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ \dots \\ a_n \end{bmatrix} = \begin{bmatrix} \sum y_i \\ \sum x_i y_i \\ \dots \\ \sum x_i^n y_i \end{bmatrix} \quad (5.2)$$

Para esta metodologia, após experimentos empíricos, foi constatado que o uso de curvas polinomiais de grau 8 se mostra apropriado para a modelagem de perfis temporais para o período de 1 ano, tal como ilustrado pela Figura 5.3 acima.

5.3.2 Cálculo de atributos

Uma vez modelados os perfis temporais, uma série de atributos pode ser computada de forma a capturar da melhor maneira possível as propriedades características de cada um destes perfis. Neste sentido, um certo número de métricas já foram exploradas e avaliadas em trabalhos existentes na literatura (*e.g.*, [23][95][101]), e servem assim de base para a escolha dos atributos a serem utilizados. Entretanto, também é importante que se tenha em mente que a enorme diversidade disponível para a criação destas métricas permite ainda uma grande

flexibilidade de escolhas, de modo que atributos específicos podem ser desenvolvidos com o intuito de facilitar a identificação de classes ou processos temporais particulares.

Neste sentido, por exemplo, dado o interesse em se aplicar esta metodologia no nível regional e em áreas com presença de atividades agrícolas, decidiu-se por incorporar o conceito de um *modo* de curva temporal, correspondendo a um movimento significativo de crescimento da curva, seguido de uma queda posterior. Desta forma, um modo caracterizaria, no caso de dados NDVI, os momentos de crescimento vegetativo e senescência verificados no ponto em questão, de maneira que se passaria a poder quantificar as ocorrências de culturas diferentes de uma maneira mais inteligente. Obviamente, a forma exata de se definir um modo deve depender do caso específico de aplicação. Nesta metodologia, após testes empíricos, determinou-se que um modo poderia ser admitido como tal desde que houvesse uma diferença de 0.3 NDVI entre a sua base e o seu pico. Entretanto, deve-se ter sempre em mente que outras restrições também poderiam ser adicionadas conforme a necessidade, como por exemplo a consideração de uma largura mínima ou máxima como requisito para admitir a caracterização de um modo.

Uma visão geral do cálculo de atributos pode ser vista na Figura 5.4 abaixo:




Figura 5.4 Cálculo de atributos ou métricas a partir de um perfil temporal, de modo a se obterem informações mais inteligentes, robustas e úteis para a caracterização de diferentes classes de interesse

Além disso, nesta metodologia também se utilizou uma abordagem de se definir uma grande variedade de atributos, com grande redundância entre si, incluindo-se por exemplo tanto os valores extremos de NDVI (*i.e.*, valores mínimo e máximo) quanto a amplitude do perfil (*i.e.*, diferença entre o mínimo e o máximo). Desta forma, o objetivo pretendido é o de se extrair a maior quantidade de informações possíveis, para posteriormente filtrá-las selecionando apenas aqueles atributos que se mostrarem mais adequados para discriminar entre as classes de interesse (seção 5.4, mais adiante).

Os atributos computados nesta etapa podem ser divididos em 2 grupos básicos:

- a. Atributos gerais da curva (descrevem o perfil temporal como um todo)
 - Exemplos: *média dos valores, valor mínimo, valor máximo, amplitude global (máximo – mínimo), data de máximo valor, valor inicial, ganho global (valor final – valor inicial), número de modos*
- b. Atributos de cada modo da curva
 - Exemplos: *data do pico do modo, valor no pico do modo, largura do modo (em dias), ganho do modo (valor no pico – valor antes do crescimento), perda do modo (valor no pico – valor depois da senescência), inclinações máximas do modo no crescimento e na senescência, integral sob o modo*

5.3.3 Pós-processamento do cálculo de atributos

Após o cálculo propriamente dito dos atributos, uma última etapa de pós-processamento ainda se faz necessária. Primeiramente, é importante que se note que as diferentes métricas computadas apresentam domínios de valores bastante distintos, podendo corresponder a um valor de NDVI (entre -1 e 1), uma data (*e.g.*, número de dias a partir do começo do perfil), ou ainda quantidades mais complexas como a derivada de um ponto da curva.

Desta forma, torna-se importante que todos estes atributos sejam ainda *normalizados*, de modo a permitir a comparação direta de seus valores e facilitar as tarefas posteriores de seleção de atributos (seção 5.4) e de classificação (seção 5.5). Assim, calculam-se as médias e variâncias para cada atributo sobre toda a região de interesse, e então realiza-se a normalização para cada um deles, de maneira que ao final do processo seus valores apresentem uma média $\mu = 0$ e uma variância $\sigma = 1$.

Além desta questão, também se faz necessário um segundo tipo de pós-processamento destes dados, de natureza mais complexa. Devido ao fato dos perfis temporais poderem apresentar um número variável de modos (nenhum, um, ou vários), verifica-se também que o número total de atributos para um perfil pode também variar, uma vez que são incluídas métricas para quantificar cada modo separadamente. Entretanto, a existência de um número variável de atributos pode ser bastante problemática para a maioria dos algoritmos de tratamento de dados, de modo que se torna necessário atribuir algum tipo de valor para as métricas de modos, inclusive na ausência dos mesmos.

Sob esta ótica, a solução trivial de atribuir valores constantes (*e.g.*, zero, -9999) aos atributos não disponíveis (N/D) não deve ser recomendada, uma vez que isto provocará uma confusão entre dados válidos e não-válidos, além de comprometer a normalização dos dados. Deste

modo, um atributo freqüentemente N/D para uma dada classe poderá ser equivocadamente considerado como sendo de grande importância para caracterizá-la, o que deve ser evitado (deve-se lembrar ainda que mesmo o fato do atributo estar N/D não constitui informação relevante, visto que isto decorre diretamente do atributo *número de modos*). Finalmente, o uso de um valor constante também pode provocar problemas para processos de natureza estatística, uma vez que esta ação corresponde à introdução de um fator discreto de informação. Em particular, este fato pode fazer com que a matriz de covariância de classes seja nula caso o atributo esteja N/D para todos os seus pontos, o que levará a problemas ainda mais sérios, impossibilitando por exemplo o uso de algoritmos de classificação estatística tais como o de *máxima verossimilhança* (seção 5.5).

Desta forma, a solução utilizada nesta metodologia consiste em atribuir valores aleatórios, com média 0 e variância 1, para todos os atributos considerados N/D. Com esta abordagem, será obtida como consequência uma diminuição do poder de discriminação de atributos freqüentemente não disponíveis, o que corresponde de fato a um efeito desejável. Portanto, desta maneira, uma métrica só poderá se tornar relevante para discriminar entre aquelas classes que tenham uma proporção significativa de valores válidos para este atributo.

5.4 Seleção de atributos

Conforme discutido na seção anterior, a etapa de cálculo de atributos emprega uma estratégia de se definir um número bastante grande e diversificado de métricas, possivelmente com grande redundância entre si, de modo a tentar extrair o máximo de informações possíveis a partir dos perfis temporais. Neste sentido, configura-se então a necessidade de se realizar um processo de seleção de atributos ou *feature selection* (ver seção 2.3.3), de forma a se escolher o sub-conjunto de informações mais apropriado para a discriminação entre as classes de interesse. Assim, pretende-se desta maneira que, ao final do processo, tenha-se em mãos um grupo enxuto de métricas capaz de caracterizar os perfis temporais da forma mais completa e com o mínimo de redundância possível.

5.4.1 Algoritmo

Com este objetivo em mente, foram exploradas diversas alternativas de seleção de atributos existentes na literatura. Dentre elas, foi escolhido o algoritmo intitulado “seleção de atributos baseada em correlação” (CFS, *Correlation-based Feature Selection* [42]), que faz uso de conceitos de teoria da informação. Este algoritmo, assim como muitos outros, está baseado

em dois passos principais: uma *estratégia de busca*, e uma *medida de aptidão*, os quais são descritos em detalhe a seguir.

5.4.1.1 Estratégia de busca

Nesta etapa, estabelece-se a forma e ordem pela qual será percorrido o *espaço de busca* do problema, ou seja, o universo de possíveis sub-conjuntos de atributos. Em resumo, estas estratégias consideram avaliações do mérito ou aptidão de cada sub-conjunto (item 5.4.1.2), e, baseado nelas, buscam de alguma forma explorar as variantes de sub-conjuntos consideradas mais “promissoras” segundo algum critério pré-estabelecido.

De fato, existe uma grande variedade de estratégias passíveis de serem utilizadas nesta etapa, dentre as quais podemos citar os algoritmos *best first search* [85][42] e os *algoritmos genéticos* [40][42]. Nesta metodologia, adotou-se a estratégia de busca *best first search*, principalmente em virtude de sua rapidez e simplicidade. Esta estratégia corresponde a um algoritmo clássico de inteligência artificial, na qual o espaço de busca é explorado através de mudanças locais nos sub-conjuntos de atributos. Basicamente, à medida em que as mudanças locais geram avaliações superiores, o processo continua em frente; entretanto, caso nenhuma melhora seja verificada após algum tempo (*i.e.*, um número de avaliações pré-estabelecido), o algoritmo retorna à melhor avaliação encontrada anteriormente e então experimenta outras variantes possíveis (*i.e.*, outros ramos da árvore de busca).

5.4.1.2 Medida de aptidão

Nesta segunda etapa do algoritmo de seleção de atributos, define-se um critério para que se possa realizar uma avaliação quantitativa do grau de mérito ou aptidão de um determinado sub-conjunto de atributos. O algoritmo CFS baseia-se na suposição de que um sub-conjunto apropriado deve conter atributos não-correlacionados entre si, ao mesmo tempo em que eles devem estar altamente correlacionados com a classificação de cada ponto (*i.e.*, devem permitir a discriminação entre as classes de interesse). Desta forma, é definida uma medida heurística de mérito baseada em inter-correlações entre pares de atributos (variáveis independentes), assim como entre cada um destes atributos e a classificação (variável dependente), tal como explicitada na equação (5.3):

$$M_S = \frac{k\bar{r}_{cf}}{\sqrt{k + k(k-1)\bar{r}_{ff}}} \quad (5.3)$$

sendo:

- M_S : medida final de mérito para um sub-conjunto de atributos S
- k : número de atributos no sub-conjunto
- \bar{r}_{cf} : correlação média entre cada atributo f e a classificação
- \bar{r}_{ff} : inter-correlação média entre pares de atributos pertencentes ao sub-conjunto

Na realidade, é fundamental especificar também que as correlações \bar{r}_{cf} e \bar{r}_{ff} utilizadas pelo algoritmo não correspondem às medidas de correlações clássicas, definidas no campo da estatística para variáveis de natureza contínua. De fato, o algoritmo CFS subentende a possibilidade de existirem atributos de característica tanto contínua quanto discreta, ordinal ou binária, numa mistura de tipos de dados que realmente pode ocorrer no caso desta metodologia, uma vez que o atributo *número de modos* (seção 5.3.2, Figura 5.4) possui natureza discreta.

Assim, um primeiro passo a ser tomado corresponde à homogeneização dos tipos de dados, e para isso o algoritmo CFS realiza um processo denominado *discretização*, de maneira que todos os valores dos atributos contínuos são convertidos para variáveis *nominais* ou *discretas* [42]. A discretização tem como meta produzir intervalos significativos de valores, tanto com relação aos dados quanto com relação à variável dependente sendo considerada (*i.e.*, a classificação). Assim, o processo utilizado pelo CFS, que segue o modelo proposto por Fayyad e Irani [30][42], toma como ponto de partida um único intervalo, englobando todo o conjunto de valores observado para o atributo, e então procede para uma divisão recursiva de cada intervalo em dois. Cada divisão de intervalos é realizada selecionando-se um ponto de corte ótimo com relação aos dados, definida com o auxílio de uma medida de *entropia* para um intervalo qualquer. A subdivisão de intervalos é então realizada recursivamente até ser interrompida segundo um critério de parada baseado no princípio MDL (*minimum description length* [83][27][42]), segundo o qual a descrição de um conjunto de dados deve ser tão compacta quanto possível.

Uma vez realizada a discretização, é necessário então definir de que forma serão computados os valores de correlação para variáveis discretas, de maneira que se possa enfim calcular os termos \bar{r}_{cf} e \bar{r}_{ff} na equação (5.3). Neste trabalho, será adotada a versão do algoritmo CFS que faz mais uma vez uso de medidas de entropia para atingir este objetivo, num processo denominado “incerteza simétrica” (*symmetric uncertainty* [79][42]). Especificamente, primeiro se define a medida de entropia $H(Y)$ para uma variável qualquer Y , o que permite quantificar até onde os pontos estão homogeneamente divididos entre os valores desta variável:

$$H(Y) = - \sum_{y \in Y} P(y) \log_2(P(y)) \quad (5.4)$$

sendo $P(y)$ a probabilidade observada para cada valor y assumido pela variável Y .

Em seguida, pode-se definir uma medida de *entropia condicional* $H(Y|X)$, correspondente à entropia da variável Y uma vez conhecido o valor de uma outra variável X (*i.e.*, a entropia de Y após o seu espaço de valores ser *particionado* pela variável X):

$$H(Y|X) = - \sum_{x \in X} \left[P(x) \sum_{y \in Y} P(y|x) \log_2(P(y|x)) \right] \quad (5.5)$$

sendo $P(x)$ a probabilidade observada para cada valor x assumido pela variável X , e $P(y|x)$ a probabilidade condicional observada para cada valor y assumido pela variável Y , uma vez conhecido x .

Desta forma, se as variáveis forem bem correlacionadas, os valores de Y assumirão distribuições muito concentradas (*i.e.*, haverá uma entropia muito baixa) para cada valor dado de X . Portanto, pode-se definir o *ganho de informação* obtido pelo conhecimento da variável X como a diferença $H(Y) - H(Y|X)$. Assim, finalmente, é definido o coeficiente de correlação normalizado r como sendo:

$$r = 2 \left(\frac{H(Y) - H(Y|X)}{H(Y) + H(X)} \right) \quad (5.6)$$

5.4.1.3 Observações

Comparativamente aos demais algoritmos de seleção de atributos, o método CFS apresenta dois aspectos bastante importantes. Em primeiro lugar, este método possui uma grande vantagem de apresentar um custo computacional relativamente baixo, sendo assim extremamente veloz quando comparado com os demais algoritmos. Esta característica permite, na prática, que ele seja utilizado em casos onde o número de atributos a serem analisados é muito grande, ou quando o número de amostras de pontos considerados é também elevado.

Por outro lado, uma importante limitação deste algoritmo consiste no fato de que ele considera inter-correlações apenas entre pares de variáveis. Desta forma, este método é simplesmente incapaz de analisar relações complexas entre atributos, como quando uma variável pode ser inferida a partir de uma função de 2 ou mais outras. Na prática, este fator limitante pode acabar levando a resultados inferiores em situações onde este tipo de fenômeno ocorre.

Maiores detalhes com relação ao algoritmo CFS e à sua fundamentação teórica podem ser obtidos no trabalho de Hall [42].

5.4.2 Métodos alternativos

Obviamente, muitos outros métodos de seleção de atributos podem ser alternativamente empregados nesta etapa da metodologia, sendo este tópico por si só uma grande e importante área de pesquisa. Em particular, dentre estas outras técnicas, duas abordagens clássicas foram também investigadas no decorrer do desenvolvimento deste trabalho, estando descritas nesta seção de uma forma mais superficial.

5.4.2.1 *Análise discriminante*

Este método clássico de cunho estatístico está baseado numa modelagem linear dos dados, o que é usado de forma a relacionar os atributos (variáveis independentes) com a classificação (variáveis dependentes) [96]. Como estratégia de seleção de atributos, a análise discriminante é realizada passo a passo, podendo-se empregar para isso as formas *ascendente* ou *descendente* de busca. Em particular, a forma ascendente consiste nos seguintes passos:

- a. Escolher um primeiro atributo possuindo o maior poder de discriminação entre classes, sendo este poder medido pela estatística F global (razão entre o espalhamento inter-classes e o espalhamento intra-classes, ponderados pelos seus respectivos graus de liberdade)
- b. A cada passo, adicionar o atributo que mais contribui com informação ao modelo, o que é medido pela estatística F parcial (razão entre o aumento de capacidade descritiva do modelo e a capacidade adicional necessária para explicar toda a variabilidade dos dados)
- c. O novo atributo é adicionado apenas se for considerado estatisticamente significativo (valor p superior a um limiar α pré-definido)
- d. Ao se adicionar um atributo, deve-se checar se todos os outros atributos incluídos até então continuam sendo estatisticamente significativos (*i.e.*, verificar se a sua retirada constitui em perda acentuada na capacidade descritiva do modelo)

Desta maneira, a principal característica da abordagem de análise discriminante consiste na suposição de um modelo linear para o processo de classificação, fazendo com que muitos atributos possam ser selecionados desde que eles contribuam com algum tipo de informação estatisticamente relevante. Entretanto, na prática, a grande maioria dos algoritmos de classificação se beneficia de um conjunto mais reduzido de atributos [27][42], de modo a se descrever a informação de forma mais compacta e menos redundante, o que sugere que esta abordagem não seja a ideal para o caso particular deste trabalho.

5.4.2.2 Wrapper

Este algoritmo consiste numa estratégia extremamente simples e direta para a realização de uma seleção de atributos [42]. Assim como o algoritmo CFS e muitos outros métodos, ele se baseia numa estratégia de busca, tal como o *best first search* ou algoritmos genéticos (ver seção 5.4.1.1), combinada com uma medida de mérito ou aptidão dado um sub-conjunto de atributos. Entretanto, diferentemente do algoritmo CFS, o método *wrapper* avalia cada sub-conjunto de atributos através da execução do próprio algoritmo de classificação, de modo que a medida de mérito empregada corresponde pura e simplesmente à acurácia encontrada para a classificação.

Obviamente, pode-se perceber de imediato que esta estratégia está certamente mais adaptada para a tarefa de seleção de atributos. Diferentemente das demais abordagens, o método *wrapper* não consiste num procedimento heurístico e nem faz suposições estatísticas. Ao contrário, ele efetivamente avalia a *performance* real esperada, e assim leva em consideração todas as relações especiais entre os tipos de dados a serem analisados e o algoritmo específico de classificação a ser usado. Entretanto, este tipo de estratégia também possui a grave desvantagem de ser uma abordagem extremamente lenta e custosa computacionalmente, visto que ela envolve a execução de um grande número de avaliações de classificações. Portanto, o uso deste método, embora em tese ideal, se torna na prática inviável em casos de dados com muitos atributos, uma vez que isto leva a uma combinação explosiva de possibilidades de sub-conjuntos a serem avaliados.

5.5 Classificação

Uma vez computados e selecionados os atributos descritivos dos perfis temporais, torna-se finalmente possível realizar a *classificação em escala regional* propriamente dita. Neste sentido, como os *pixels* MODIS de 250m de resolução são em geral capazes de capturar os diferentes tipos de uso e cobertura do solo [98][100][95], pode-se argumentar que a atribuição de uma única classe para cada *pixel* será em geral apropriada para caracterizar a maior parte da região de interesse, numa abordagem conhecida como classificação “dura” ou “*hard*” *classification*.

O processo de classificação adotado nesta metodologia é realizado de forma *supervisionada*, utilizando a classificação de treinamento gerada na seção 5.2 para uma fase inicial de *aprendizagem* do algoritmo de classificação, de modo a se caracterizar o comportamento de cada classe com relação aos atributos dos perfis temporais. Então, uma vez treinado, o algoritmo é executado para toda a região de interesse, obtendo-se assim a classe de uso e

cobertura do solo em cada ponto desta região. Por fim, efetua-se ainda um último procedimento de forma a refinar a classificação e tentar minimizar problemas decorrentes de *pixels* contendo mais de um tipo de uso e cobertura do solo.

Com relação ao algoritmo de classificação propriamente dito, é possível, em princípio, fazer uso de uma grande diversidade de estratégias de classificação de natureza supervisionada, podendo-se escolher uma dentre as várias alternativas disponíveis na literatura. De fato, como os dados de entrada já se encontram bem tratados após sofrerem o elaborado processo de produção, normalização e seleção de atributos, espera-se que qualquer método bem estabelecido de classificação seja capaz de fornecer resultados bastante satisfatórios para esta tarefa. Assim, nesta metodologia, decidiu-se por adotar o método estatístico clássico de classificação conhecido como *máxima verossimilhança* ou MAXVER [27][65], uma vez que se trata de um algoritmo bastante simples de ser implementado, mas que ao mesmo tempo é largamente conhecido e aplicado com sucesso em problemas de sensoriamento remoto. Além disso, esta estratégia também apresenta a característica interessante de prover uma medida de confiabilidade da classificação resultante em cada ponto avaliado, o que será explorado na seção 5.5.2 para estender a metodologia de modo a mitigar os efeitos de mistura de diferentes classes de uso e cobertura do solo no interior de um único *pixel*.

5.5.1 Algoritmo principal

5.5.1.1 Fundamentação teórica

O algoritmo básico de máxima verossimilhança corresponde a uma abordagem puramente estatística, assumindo que as variáveis (*i.e.*, os atributos) sejam todos de natureza contínua. Além disso, este algoritmo também pressupõe que todas estas variáveis apresentem uma distribuição de probabilidades normal ou *gaussiana* multi-dimensional.

Este método se baseia na fórmula de Bayes, que pode ser descrita pela equação (5.7) abaixo:

$$P(w_j | x) = \frac{p(x | w_j)P(w_j)}{\sum_i p(x | w_i)P(w_i)} \quad (5.7)$$

sendo:

- $P(w_j)$: probabilidade *a priori* para a classe w_j
- $P(w_j|x)$: probabilidade *a posteriori* para a classe w_j dadas as variáveis x de entrada
- $p(x|w_j)$: função densidade de probabilidade das variáveis x , dada a classe w_j

Adicionalmente, a suposição de normalidade realizada pelo algoritmo significa que as funções de densidade de probabilidade de cada classe w_j podem ser modeladas simplesmente através da especificação de suas médias $\mu(x|w_j)$ e de suas matrizes de covariância $\Sigma(x|w_j)$. Desta

forma, considerando-se a dimensionalidade d dos dados (equivalente ao número de atributos), temos que:

$$p(x | w_j) \sim N(\mu_j(x | w_j), \Sigma(x | w_j))$$

sendo:

$$N(\mu, \Sigma) = \frac{1}{(2\pi)^{d/2} \det(\Sigma)^{1/2}} e^{-\frac{1}{2}(x-\mu)^T \Sigma^{-1}(x-\mu)} \quad (5.8)$$

No caso particular deste trabalho, deve-se considerar ainda que alguns destes atributos considerados como variáveis de entrada podem não ser, na realidade, de natureza contínua. Desta forma, estes dados não poderiam ser tratados de forma apropriada através desta abordagem básica, numa situação que de fato se verifica para o caso do atributo *número de modos* (seção 5.3.2, Figura 5.4), que, conforme já discutido anteriormente, possui natureza discreta.

Portanto, torna-se importante modificar o algoritmo básico de modo que se possam processar variáveis discretas da forma correta. Assim, estas alterações permitem não apenas garantir uma maior consistência teórica no processamento, como também admitir a existência de classes com variância zero para atributos desta natureza (*e.g.*, classes cujos perfis temporais nunca apresentam um modo), o que normalmente traria problemas devido a matrizes de covariância não-inversíveis.

Feitas estas considerações, na equação (5.9) abaixo encontra-se a extensão do modelo de máxima verossimilhança de maneira a admitir a existência de uma variável discreta:

$$P(w_j | x) = \frac{p(x_{cont} | w_j, x_{disc}) P(x_{disc} | w_j) P(w_j)}{\sum_i p(x_{cont} | w_i, x_{disc}) P(x_{disc} | w_i) P(w_i)} \quad (5.9)$$

sendo:

- x_{cont} : todas as variáveis contínuas existentes no conjunto de dados
- x_{disc} : a variável de natureza discreta (*e.g.*, atributo *número de modos*)
- $P(x_{disc}|w_j)$: função condicional de massa de probabilidade da variável discreta, dada uma classe w_j

5.5.1.2 Procedimento metodológico

Utilizando-se o novo modelo descrito pela equação (5.9), são observados todos os atributos dos perfis temporais de NDVI para cada um dos *pixels* da classificação de treinamento, de modo a se estimarem todas as variáveis necessárias. Neste sentido, em primeiro lugar, nenhuma suposição é feita com relação às probabilidades *a priori*, de modo que todos os valores $P(w_j)$ são definidos como sendo idênticos. Os valores $P(x_{disc}|w_j)$ são então computados para cada

valor observado da variável discreta x_{disc} , refletindo a estimativa da probabilidade de se observar, para cada classe w_j , cada um destes valores. Finalmente, as médias e matrizes de covariância de todas as variáveis contínuas são então calculadas para cada classe e cada valor observado de x_{disc} , de modo a se estimarem as distribuições de probabilidade $p(x_{cont}|w_j, x_{disc})$.

Uma vez realizado o treinamento do algoritmo, a sua execução de forma a generalizar a classificação para toda a região de interesse torna-se bastante simples e direta. Para isso, em cada *pixel* a ser avaliado são observados os valores dos atributos calculados a partir dos perfis temporais de NDVI. Então, dado o valor de x_{disc} , consultam-se os valores das probabilidades estimadas $P(x_{disc}|w_j)$ para cada classe, e calculam-se também as densidades de probabilidade $p(x_{cont}|w_j, x_{disc})$, utilizando-se para isto as médias e matrizes de covariância adequadas conjuntamente com a equação (5.8). Assim, através da equação (5.9), torna-se possível estimar a probabilidade *a posteriori* para cada classe w_j , dados os atributos observados no *pixel* em questão. Como último passo, a classe de maior probabilidade *a posteriori* é finalmente escolhida para ser atribuída ao *pixel*, completando assim o processo principal de classificação.

Uma visão geral deste procedimento pode ser visualizada graficamente na Figura 5.5 abaixo.

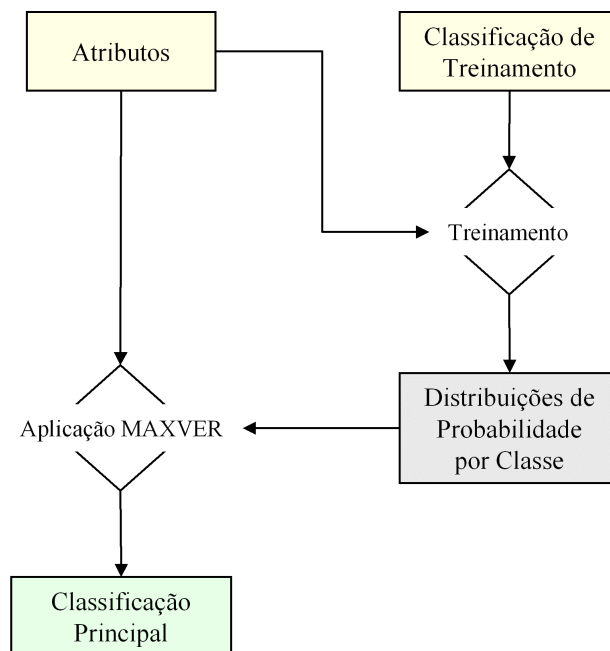


Figura 5.5 Visão geral do procedimento principal de classificação.

5.5.2 Extensão: classificação de *pixels* problemáticos e/ou misturados

5.5.2.1 Motivação

Como discutido anteriormente, diversos estudos já apontaram para o fato de que uma resolução espacial de 250m é adequada para a caracterização do uso e cobertura do solo na maioria dos casos. Além disso, se considerarmos que as classes discrimináveis pelo sensor

MODIS devem ser de uma natureza um pouco mais genérica (ver seção 5.2), podemos supor também que, de forma geral, uma região de uso e cobertura homogênea do solo terá dimensões frequentemente superiores às de um *pixel*, justificando portanto o uso de abordagens de classificação “dura”, conforme descrito na seção anterior.

Entretanto, apesar disso, pode-se notar ainda que, em determinadas situações, um *pixel* MODIS com este nível de resolução pode cobrir mais do que apenas um tipo de cobertura do solo [63][112]. Efetivamente, este fenômeno é quase que obrigatoriamente verificado nas áreas de transição entre regiões cobertas por classes diferentes de uso e cobertura. Em certos casos, transições graduais entre regiões de coberturas distintas levam à existência de áreas de comportamento intermediário (*e.g.*, transições entre áreas de cerrado aberto e áreas de cerrado denso). Em outras situações, fronteiras bastante abruptas entre regiões de classes distintas (*e.g.*, fronteiras entre áreas de agricultura com diferentes cultivos) podem levar à ocorrência de *pixels* parcialmente cobertos por cada tipo de cobertura, o que também terá como consequência a observação de um comportamento temporal distinto.

Em qualquer um dos casos, o problema do *pixel* “misturado” (*i.e.*, contendo mais de um tipo de cobertura do solo no seu interior) levará forçosamente a situações onde algoritmos de classificação “dura” terão grandes dificuldades para identificar corretamente a realidade observada. Em particular, no contexto da metodologia aqui proposta, os atributos computados a partir dos perfis temporais (seção 5.3) serão totalmente incapazes de representar corretamente a mistura de comportamento verificada, podendo inclusive, no caso geral, apresentar características totalmente distintas de ambas as classes presentes no *pixel* (Figura 5.6).




Figura 5.6 O problema do *pixel* “misturado”. À esquerda, o perfil temporal de NDVI para duas classes hipotéticas de uso e cobertura do solo (*e.g.*, dois tipos diferentes de cultivo agrícola). À direita, o comportamento observado para uma área 50% coberta por cada uma destas classes, assumindo-se um modelo linear de mistura espectral. O perfil observado não se assemelha a nenhuma das duas classes presentes na área, dificultando a tarefa do algoritmo de classificação

5.5.2.2 Procedimento metodológico

Assim, para abordar este problema, será admitido como hipótese que, nos pontos de *pixels* misturados, o perfil temporal observado apresentará um comportamento distinto da maioria dos *pixels* “puros”, de modo que os atributos computados não poderão ser seguramente associados a nenhuma classe particular de uso e cobertura do solo. Neste sentido, o valor calculado para a probabilidade *a posteriori* de cada classe (equação (5.9)) pode ser interpretado como uma medida do grau de confiabilidade para a atribuição desta classe a cada *pixel*. Assim, dado um ponto, se para nenhuma classe for verificada uma probabilidade *a posteriori* muito elevada, pode-se supor então que o perfil temporal observado não se assemelha a nenhuma classe em particular, devendo o *pixel* em questão cobrir uma área de mistura de classes, ou do contrário uma área cujo comportamento espectral foi contaminado por interferências externas.

Com base nestas suposições, propõe-se então que, uma vez executado o algoritmo descrito na seção 5.5.1, sejam aceitas apenas as atribuições de classes cuja probabilidade *a posteriori* excede um determinado limiar (*e.g.*, superior a 95%). Do contrário, a classificação é avaliada como sendo de *baixa confiabilidade*, sendo o *pixel* em questão considerado como potencialmente misturado. Neste caso, é então realizado um procedimento de análise linear de mistura espectral para o ponto, de modo a analisá-lo no nível do *sub-pixel* e tentar extrair as proporções das classes de uso e cobertura do solo presentes no seu interior (ver seção 3.6). Assim, é finalmente atribuído ao *pixel* em questão a classe estimada como tendo a maior proporção no seu interior.

5.5.2.3 Detalhamento do procedimento

Especificamente, o procedimento está baseado num modelo linear similar ao descrito em Bouzidi *et al.* [16] e Lahoche [59]. Desta forma, estende-se o modelo descrito pela equação (3.1) de maneira a considerar cada data da seqüência multitemporal como uma banda de informação. A partir daí, busca-se então uma solução na forma de um problema de otimização, estimando-se o conjunto de proporções das classes que minimiza a diferença entre a reflectância observada e aquela resultante da aplicação do modelo linear de mistura espectral. Assim, a estimativa das proporções das classes no interior do *pixel* é computada através da minimização de uma função objetivo f , para todas as bandas k (neste caso, vermelho e infra-vermelho próximo) e tempos t (*i.e.*, as datas da seqüência temporal), como descrito na equação (5.10) a seguir:

$$f = \left| R_i^k(t) - \sum_{j=1}^{N_c} \rho_{ij} R_j^k(t) \right| \quad (k = 1, 2) \quad (t = 1, \dots, d) \quad (5.10)$$

$$\text{sujeito às restrições: } \sum_{j=1}^{N_c} \rho_{ij} = 1 \quad e \quad 0 \leq \rho_{ij} \leq 1$$

sendo:

- $R_i^k(t)$: reflectância do *pixel* i na banda k , para a data t da sequência temporal
- $R_j^k(t)$: reflectância característica da classe j na banda k , para a mesma data t
- ρ_{ij} : proporção da classe j no interior do *pixel* i
- N_c : número de classes

Nesta situação, as reflectâncias $R_i^k(t)$ são observadas diretamente para cada *pixel* i . Por sua vez, as reflectâncias características $R_j^k(t)$ para cada classe j devem ser estimadas a partir dos dados de treinamento. Desta forma, observam-se as seqüências temporais de imagens MODIS nas bandas do vermelho e infra-vermelho próximo (seção 5.1) e então, para cada data t , calculam-se as médias das reflectâncias para cada classe j com base na classificação de treinamento (seção 5.2).

Adicionalmente, para facilitar a tarefa de estimativa de proporções, nem todas as classes de uso e cobertura do solo são necessariamente levadas em consideração para cada *pixel* a ser reavaliado. Em contraste, esta abordagem, aqui intitulada “estimativa local de proporções” (*local proportions estimation*), utiliza para cada *pixel* de baixa confiabilidade detectado uma janela local de tamanho restrito (*e.g.*, 3×3 *pixels*). Desta forma, considerando-se apenas os pontos classificados com alto grau de confiabilidade, somente as classes presentes no interior desta janela local são então incluídas no modelo de mistura espectral. Adicionalmente, estes pontos de alta confiabilidade podem também ser utilizados como base para o cálculo dos perfis temporais $R_j^k(t)$, numa alternativa à metodologia de estimar estes perfis a partir de dados de treinamento. Esta segunda opção poderia garantir, em certos casos, uma maior adaptabilidade à estimativa de proporções quando aplicada sobre grandes regiões, uma vez que os perfis temporais utilizados seriam capazes de refletir mais fielmente o comportamento local específico das classes presentes na área.

Finalmente, deve-se mencionar ainda que o processo de otimização em si, responsável por minimizar a função objetivo descrita na equação (5.10), pode ser implementado de inúmeras maneiras diferentes, dada a vastidão de trabalhos publicados na literatura a este respeito. Nesta metodologia, foi utilizada a abordagem proposta por Zhou e Tits [116], que realiza uma busca linear não-monotônica baseada em um algoritmo de programação quadrática seqüencial.

Na Figura 5.7 abaixo, é disposta uma visão geral deste procedimento de re-classificação de *pixels* de baixa confiabilidade a partir da estimativa de proporções através de análises lineares de mistura espectral.

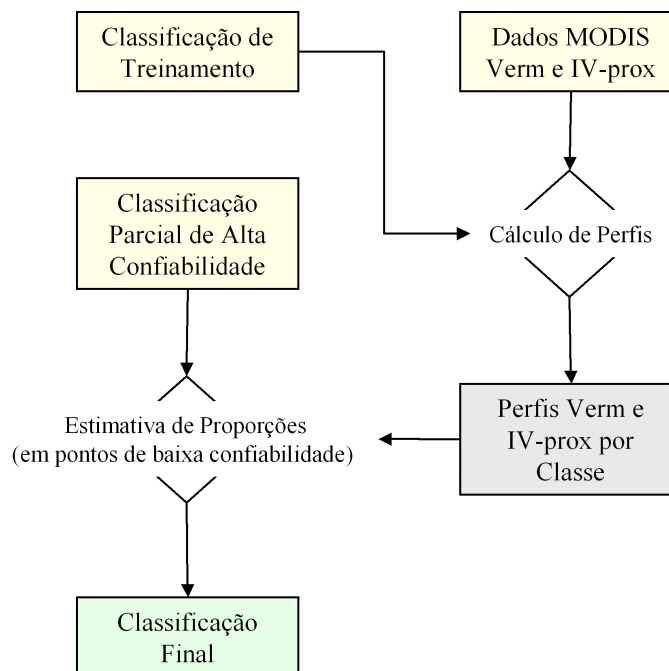


Figura 5.7 Visão geral do procedimento de extensão do algoritmo principal de classificação, de maneira a minimizar problemas de misturas de classes no interior dos *pixels*

5.6 Considerações finais

Neste capítulo foram detalhados todos os procedimentos da metodologia proposta para o mapeamento sistemático do uso e cobertura do solo a partir de seqüências temporais de dados MODIS. Assim, foram descritos todos os passos envolvidos na aplicação deste procedimento, desde o pré-processamento das imagens de sensoriamento remoto até a obtenção do resultado final, passando pelas etapas de análise de perfis temporais de NDVI e de classificação supervisionada de dados temporais.

A bem da verdade, deve ser observado aqui que o procedimento de treinamento do algoritmo de classificação, descrito na seção 5.5.1, procura levar em consideração o caso geral de uma região de interesse arbitrária no Brasil ou em qualquer outra parte do mundo, não se conhecendo em princípio o comportamento temporal característico de cada classe de uso e cobertura do solo. Entretanto, em casos práticos, é possível fazer uso de análises anteriores ou conhecimento específico da região, de modo a se estabelecerem *a priori* estes perfis temporais característicos de cada uma das classes. Desta forma, nestes casos, tornaria-se possível eliminar a necessidade de se adquirir uma classificação de referência confiável e

representativa da realidade, evitando-se assim as tarefas de processamento e adaptação desta informação (seção 5.2) e barateando-se ainda mais o processo de mapeamento como um todo.

Enfim, com o objetivo de proporcionar uma visão mais aprofundada destes procedimentos, será apresentado no capítulo 6, a seguir, um estudo de caso descrevendo em detalhe todos os passos da aplicação prática desta metodologia para uma região de interesse específica de nosso país.

6 Estudo de Caso

Neste capítulo é apresentada a aplicação da metodologia proposta no capítulo 5 para uma área específica de estudos, localizada numa região de cerrado do Centro-Oeste brasileiro. Assim, são descritas aqui todas as etapas do processo de aquisição, análise e processamento de dados dentro do contexto de um caso prático, sendo discutidos não apenas o resultado final obtido como também todos os resultados intermediários verificados em cada etapa. Além disso, é importante notar também que este estudo inclui a aplicação da metodologia tanto para dados diários de reflectância (produtos MOD09GQK e MOD09GST) quanto para dados de índice de vegetação compostos a cada 16 dias (produto MOD13Q1).

Desta forma, neste capítulo é inicialmente fornecido uma descrição geral das características e peculiaridades da área de estudos considerada (seção 6.1), seguida pela definição das características específicas dos dados utilizados neste experimento prático (seção 6.2). Subseqüentemente, é apresentada toda a evolução da aplicação da metodologia para o caso em questão, observando-se e discutindo-se os resultados atingidos após cada passo (seção 6.3). Finalmente, os resultados finais alcançados são dispostos na seção 6.4, discutindo-se em maior detalhe o nível de rendimento verificado para a metodologia, assim como os problemas encontrados na sua execução.

6.1 Área de estudos

A área de estudos abordada neste estudo de caso corresponde à Bacia do Alto Taquari (BAT), localizada quase que inteiramente no estado de Mato Grosso do Sul, na região Centro-Oeste do Brasil (Figura 6.1). Uma pequena parcela ao norte da bacia está localizada no estado de Mato Grosso. Segundo a definição adotada por Silva [94], a BAT está limitada pelos pontos de coordenadas ($17^{\circ}10'$ S, $53^{\circ}10'$ W) e ($19^{\circ}45'$ S, $55^{\circ}10'$ W).

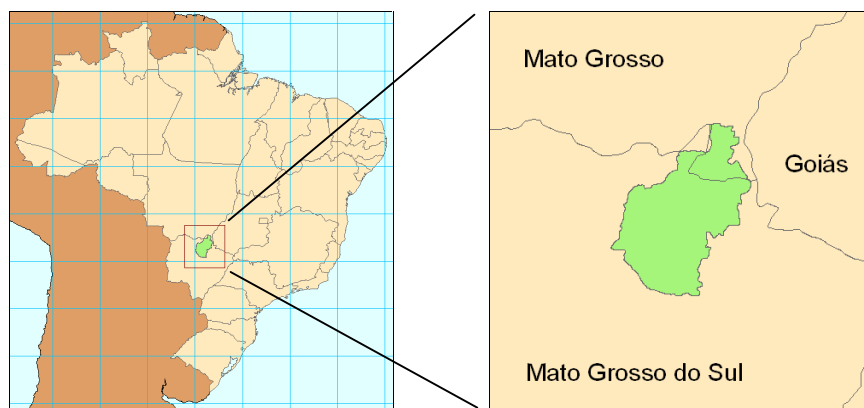


Figura 6.1 Localização da região da Bacia do Alto Taquari, nos estados do Mato Grosso do Sul e Mato Grosso

Segundo Galdino [37], a bacia do rio Taquari como um todo pode ser dividida em três seções distintas, de acordo com o comportamento do rio. Sob esta ótica, a Bacia do Alto Taquari corresponde à primeira seção, sendo limitada pela escarpa cuestiforme da bacia sedimentar do Paraná, perto da cidade de Coxim, MS. Desta forma, a BAT corresponde a uma região de planalto com altitude variando entre 300m e 800m, ocupando em sua totalidade uma área de 28.046 km², segundo os cálculos de Silva [94]. Por fim, deve-se dizer que a própria BAT pode ainda ser subdividida em 4 sub-bacias. São elas, em ordem de área ocupada: sub-bacia do Alto Taquari, sub-bacia do rio Coxim, sub-bacia do rio Jauru (todas visíveis na Figura 6.2 abaixo), e finalmente a pequena sub-bacia do rio Taquari-Mirim [36].




Figura 6.2 Bacia do Alto Taquari e suas subdivisões na sub-bacia do Alto Taquari (acima), sub-bacia do rio Jauru (ao centro), e sub-bacia do rio Coxim (abaixo).

Fonte: adaptado de Abdon *et al.* [2]

Sob o ponto de vista deste trabalho, a Bacia do Alto Taquari corresponde a uma área de especial interesse para ser estudada. O rio Taquari constitui um importante afluente do rio Paraguai, exercendo um papel preponderante no ecossistema do Pantanal Matogrossense. De fato, o assoreamento deste rio já é considerado como o principal problema de ordem ambiental e sócio-econômico na região pantaneira [37], com desdobramentos importantes como enchentes, redução da área disponível para pecuária, e impactos sobre a vida animal e vegetal. Este assoreamento, na verdade, está intimamente associado aos processos erosivos que ocorrem na região do Alto Taquari, e que terminam por levar a um grande aporte de sedimentos à região baixa do rio. Além disso, mesmo na própria região da BAT, já se verificam muitos impactos negativos devido ao assoreamento extremo dos rios, com graves prejuízos para a pesca e navegabilidade, entre outros efeitos.

Na realidade, os processos de erosão e aporte de sedimentos correspondem a um fenômeno natural da região, fenômeno este que vem ocorrendo a milhares de anos e é inclusive responsável pela própria formação da planície pantaneira [37]. Entretanto, a partir da década de 1970, e em particular nos últimos anos, verificou-se uma ocupação de terras cada vez mais intensa na região do Alto Taquari, impulsionada pela expansão da fronteira agrícola e pela conversão de áreas naturais em pasto através do desmatamento. De fato, esta expansão se deu de forma completamente descontrolada, inclusive com o desmatamento indiscriminado de áreas ribeirinhas, de modo que os processos naturais de erosão se intensificaram de forma quase exponencial [39]. Desta forma, do início da década de 1980 até meados da década em 1990, pôde-se verificar que o aporte de sedimentos provenientes da BAT para o Pantanal aumentou em 46% [84].

Por todas estas razões, a relevância desta região e de seus problemas fez com que a Bacia do Alto Taquari já tenha sido objeto de numerosos estudos, além daqueles já mencionados ([1][17], entre outros). Desta forma, dentro do contexto do trabalho descrito nesta dissertação, tornou-se possível tirar proveito de um conhecimento relativamente avançado acerca das características e peculiaridades do uso e cobertura do solo nesta região, fazendo com que ela se tornasse particularmente apropriada como área piloto para o desenvolvimento desta pesquisa.

6.2 Aquisição de dados

Para este estudo, foi necessária a aquisição de dois conjuntos principais de dados, conforme especificado na introdução do capítulo 5: uma classificação minuciosa do uso e cobertura do solo, para servir como referência para treinamentos e testes (seção 6.2.1), e um conjunto de dados provenientes do sensor MODIS, a serem usados para a análise propriamente dita do uso e cobertura do solo em escala regional (seção 6.2.2).

6.2.1 Classificação detalhada do uso e cobertura do solo

Conforme mencionado na seção 4.1, para o desenvolvimento deste trabalho foi obtida a classificação de uso e cobertura do solo realizada por Silva [94], feita a partir de imagens LANDSAT/TM do mês de julho de 2000 e cobrindo toda a extensão da Bacia do Alto Taquari.

Em seu formato original, este levantamento está na realidade dividido em duas porções complementares. Primeiramente, a classificação de *uso da terra* ([94], pág. 147) discrimina as áreas naturais da bacia daquelas de uso antrópico, detalhando em seguida as diferentes formas

deste uso antrópico da terra: atividade pecuária em pastagem cultivada, agricultura, e áreas urbanas. Por sua vez, a classificação de *cobertura vegetal* ([94], pág. 120) realiza um minucioso detalhamento das áreas naturais existentes na bacia, separando-as em 9 classes de floresta, cerrado, e vegetações mistas. Assim, após unificar ambos os levantamentos em uma única classificação, obteve-se um mapeamento do uso e cobertura do solo para a Bacia do Alto Taquari com 14 classes distintas, referentes a julho de 2000, tal como ilustrado na Figura 6.3 abaixo.

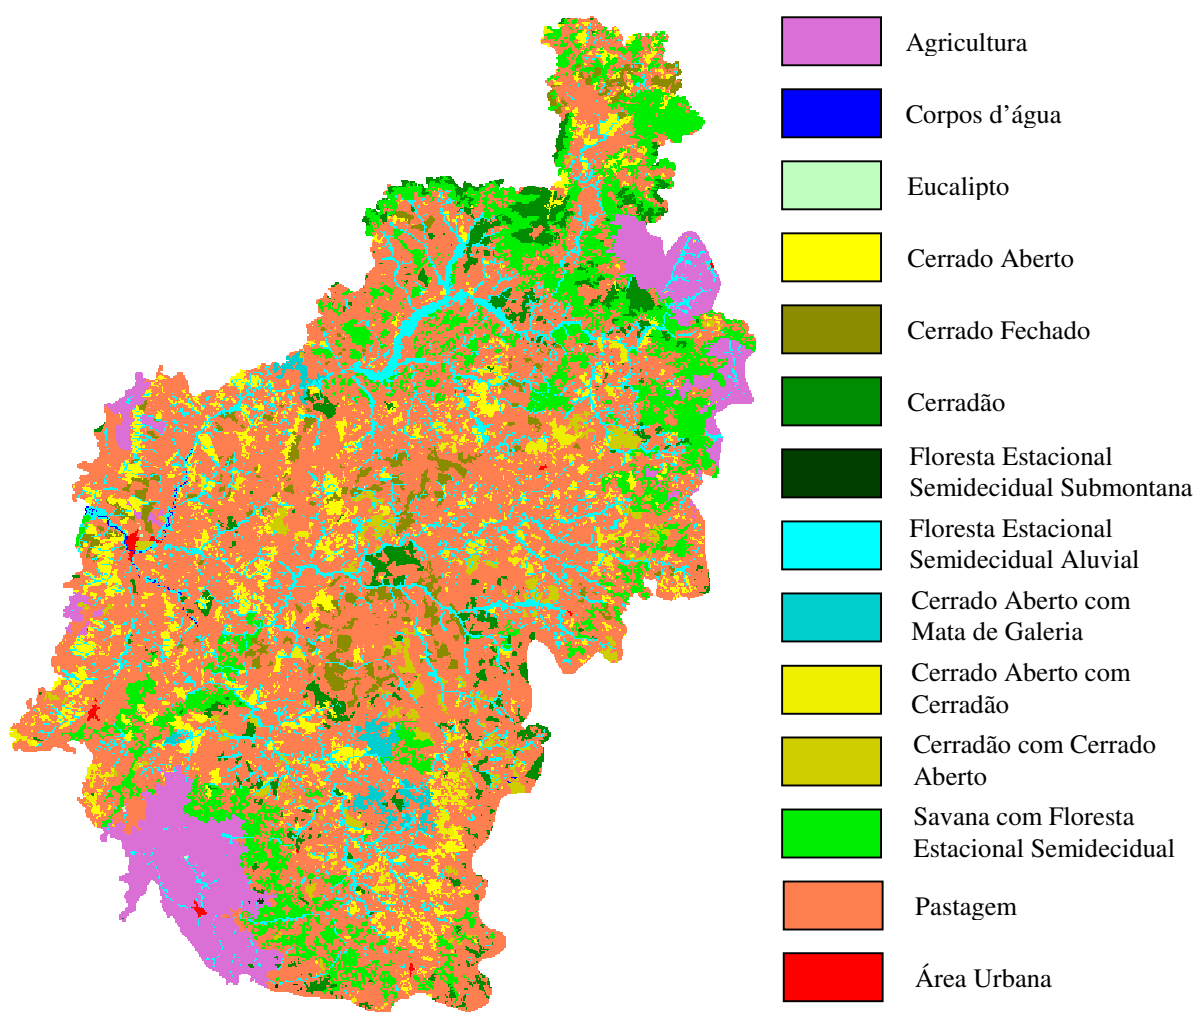


Figura 6.3 Classificação do uso e cobertura do solo para toda a Bacia do Alto Taquari, a partir dos resultados obtidos por Silva [94]. Esta classificação se refere ao mês de julho de 2000 e foi baseada em imagens LANDSAT/TM e viagens de campo.

No tocante à definição precisa das classes utilizadas, uma descrição detalhada de cada uma, incluindo as espécies vegetais encontradas, pode ser encontrada em [1] ou em [94]. Em particular, cabe aqui especificar melhor os diferentes tipos de cerrado considerados:

- *Cerrado Aberto* e *Cerrado Fechado* – ambos correspondem a formações de savana arborizada, devendo ser entendidos como cerrado senso restrito. A diferenciação entre as duas classes se dá por diferenças na cobertura arbórea, conforme interpretado a

partir das imagens de satélite. Foi avaliado, a partir de inspeções em campo, que a altura das árvores em áreas de cerrado fechado pode chegar a até 12m.

- *Cerradão* – corresponde a uma formação de savana florestada, com cobertura vegetal mais densa (fisionomia florestal).
- *Cerrado Aberto com Cerradão* – corresponde a uma formação composta de savana, com predomínio de cerrado aberto.
- *Cerradão com Cerrado Aberto* – corresponde a uma formação composta de savana, com predomínio de cerradão.

6.2.2 Dados MODIS

Conforme descrito na seção 4.3.6, adquiriram-se seqüências de imagens MODIS a partir do portal EOS Data Gateway, de forma a cobrir o período de um ano entre 1º de agosto de 2000 e 31 de julho de 2001. Este período foi estabelecido de modo a acompanhar o ciclo vegetativo da região (que se inicia normalmente em meados para fins de agosto), ao mesmo tempo em que permite sincronizar o início do perfil temporal de dados com a informação disponível de classificação de uso e cobertura do solo. Desta forma, será pressuposto neste experimento que as classes de uso e cobertura do solo descritas em [94] são válidas para todos os pontos, no início do período de análise (*i.e.*, 1º de agosto de 2000).

6.3 Aplicação da metodologia

6.3.1 Pré-processamento dos dados MODIS

6.3.1.1 Recorte, reprojeção e conversão de dados

Conforme descrito na seção 5.1, o pré-processamento dos dados MODIS adquiridos foi realizado, numa primeira etapa, utilizando-se o programa *MODIS Reprojection Tool* (MRT). Desta forma, realizou-se o recorte de cada um dos ladrilhos originais de dimensões 1200km x 1200km, excluindo-se assim todos os dados externos à área de estudos. A área de corte especificada consistiu na região delimitada pelos pontos de coordenadas (17°30' S, 55°30' W) e (20°00' S, 52°30' W). Além disso, os dados, originalmente em formato HDF-EOS e em projeção sinusoidal, foram convertidos para o formato cru de dados HDF-RAW, em projeção geográfica (*i.e.*, não projetado). Em seguida, estes dados processados pelo MRT foram então convertidos para o formato de imagens INRIMAGE, de modo a facilitar o seu processamento e visualização (ver seção 4.5). Por fim, a delimitação propriamente dita da bacia foi então utilizada para recortar apenas os dados correspondentes à região de interesse (Figura 6.4).




Figura 6.4 Recorte dos ladrilhos originais, extraindo-se apenas os dados referentes à área de estudos. À esquerda, um ladrilho original MODIS de dimensões 1200km x 1200km, na faixa do infra-vermelho próximo. Ao centro, a extração apenas do retângulo envolvente à região de interesse, feito através do programa MRT. À direita, o recorte final contendo apenas os dados referentes à área de estudos propriamente dita.

6.3.1.2 Filtragem de dados

Para os dados de composição de 16 dias MOD13Q1, aplicou-se o procedimento descrito na seção 5.1.2, de modo a filtrar os dados de cada uma das 24 imagens da sequência temporal. Desta forma, para cada imagem, foram identificados todos aqueles *pixels* considerados como sendo pouco confiáveis ou de baixa qualidade, sendo estes pontos então suprimidos e substituídos através da aplicação de um algoritmo de interpolação temporal.

De forma alternativa, conforme descrito na seção 5.1.3, também se analisaram os dados de qualidade de reflectância diária MOD09GST, com o intuito de avaliar quais das 315 datas ao longo do ano continham imagens de qualidade suficientemente boa para serem admitidas na sequência temporal para o período de análise. Desta forma, seguindo os critérios especificados na seção 5.1.3.2, verificou-se que 202 das imagens não se apresentavam satisfatórias por terem menos de 40% de seus *pixels* livres de contaminação por nuvens, sombras, *cirrus*, ou altos níveis de aerossóis. Similarmente, 154 imagens foram avaliadas negativamente por apresentarem uma média de cobertura de observação inferior a 20%. Assim, ao final, apenas 71 destas imagens satisfizeram efetivamente todos os critérios estabelecidos, tendo-se verificado também uma maior quantidade de imagens de boa qualidade em 2001 do que em 2000, devido às condições meteorológicas.

Em seguida, a partir desta seleção, construiu-se uma sequência temporal de 71 imagens de reflectância diária MOD09GQK. Então, conforme os critérios definidos na seção 5.1.3.3, cada uma destas imagens foi analisada em conjunto com seus *metadados*, de modo a se computar uma *máscara* identificando todos os *pixels* contaminados pela presença de nuvens, sombras, *cirrus* e altos níveis de aerossóis, ou que tivessem sofrido qualquer outro tipo de interferência devido a defeitos no sensor ou condições não-ideais para a aplicação dos algoritmos de correção atmosférica dos dados (Figura 6.5).




Figura 6.5 Identificação de *pixels* de alta e baixa qualidade em imagens de reflectância. À esquerda, dados originais na banda do vermelho provenientes de um produto MOD09GQK. À direita, máscara computada indicando, em preto, *pixels* a serem suprimidos devido à presença de nuvens, sombras e outros efeitos de contaminação atmosférica, bem como pontos onde foram identificadas falhas no sensor ou problemas na execução dos algoritmos de correção atmosférica.

A partir deste ponto, utilizando-se as máscaras computadas, suprimiram-se então todos os *pixels* considerados como sendo não confiáveis, sendo estes pontos substituídos através da execução de um algoritmo de interpolação temporal, seguida da aplicação de uma filtragem adicional, conforme descrito na seção 5.1.3.3. Em particular, deve-se notar que para os dados NDVI foi aplicado um filtro de mediana com janela móvel de tamanho 3, enquanto que para os dados de reflectância foram utilizados filtros de variância local com janela móvel de tamanho 5. Como resultado final, pôde-se observar claramente como os dados temporais, antes extremamente ruidosos, foram corrigidos de forma bem satisfatória, suprimindo-se a grande maioria dos dados contaminados por interferências externas e atingindo-se por fim perfis temporais bastante interessantes, como pode ser visto na Figura 6.6 abaixo.




Figura 6.6 Resultado da filtragem de dados para um *pixel* da área de estudos. Pode-se notar terem sido suprimidas a maioria das datas em que o dado de reflectância sofreu interferência, atingindo-se como resultado final um perfil temporal muito mais interpretável e útil para análises posteriores.

Finalmente, é importante enfatizar ainda que, a partir desta etapa, todas os demais passos da metodologia são totalmente idênticos para ambos os tipos de dados MODIS sendo utilizados

(i.e., produtos diários ou composições de 16 dias). Desta forma, por questões de brevidade, serão apresentados subseqüentemente apenas aqueles resultados intermediários obtidos a partir dos dados diários de reflectância de superfície, sendo ambos os casos novamente comparados mais adiante, com relação aos resultados finais (seção 6.4).

6.3.2 Análise preliminar de dados

Na verdade, antes de se fazer qualquer tipo de processamento dos dados MODIS em conjunto com a informação de classificação de referência, foi realizada uma fase de pré-análise de dados, de forma que se pudesse realizar uma avaliação preliminar das condições verificadas no caso em estudo, e assim corroborar algumas das hipóteses assumidas na metodologia.

Desta forma, antes de mais nada, foi observado que, com uma resolução espacial de 250m, aproximadamente 70% dos *pixels* da área de estudos podiam realmente ser considerados como *pixels* “puros” com relação à classificação original de referência realizada por Silva [94]. Em outras palavras, em 70% dos casos foi verificado que um *pixel* MODIS efetivamente cobria somente um único tipo de uso/cobertura do solo, justificando portanto a estratégia de se trabalhar apenas com *pixels* puros para a maior parte do processo de análise destes dados. Desta maneira, pôde-se considerar como válida a hipótese de que uma resolução de 250m é em geral suficiente para caracterizar o uso e cobertura do solo, conforme afirmado em Townshend e Justice [98], Townshend *et al.* [100] e Strahler *et al.* [95].

Além disto, neste ponto foi também realizada uma *divisão arbitrária* da área de estudos em duas metades. Deste modo, estabeleceu-se que a metade sul da bacia seria utilizada para todo tipo de análise preliminar, servindo assim como área de treinamento e teste. Por sua vez, a parcela ao norte da bacia foi reservada de modo a ser utilizada exclusivamente para fins de validação da metodologia, ao final do processo (seção 6.4). Efetivamente, esta separação também apresentou a propriedade interessante de permitir que as classes de uso e cobertura do solo estivessem bem representadas em ambas as partes. Por fim, deve-se dizer ainda que a adoção de uma divisão abrupta como esta também pode ser considerada como sendo bem mais interessante do que uma seleção aleatória de pontos ao longo da bacia, uma vez que ela permitiu reforçar a condição de que as áreas de treinamento e de aplicação podem apresentar um certo nível de variabilidade devido a diferenças geográficas. Assim, com esta estratégia, procurou-se testar a capacidade da metodologia em lidar com variações dos perfis temporais decorrentes de leves diferenças no comportamento do clima, tipos de solo, e demais condições de características mais locais, num fenômeno que certamente ocorrerá com ainda mais intensidade no caso da análise e classificação de regiões maiores.

6.3.3 Geração da classificação de treinamento adaptada para os dados MODIS

Uma vez realizado o pré-processamento dos dados, a etapa seguinte consistiu na análise da classificação original de referência realizada por Silva [94], de modo a se identificar quais classes de uso e cobertura do solo eram efetivamente discerníveis a partir dos perfis temporais de dados MODIS, conforme descrito na seção 5.2.

Assim, antes de mais nada, verificou-se que algumas das classes originais de uso e cobertura do solo apresentavam efetivamente uma representatividade muito baixa na região de estudos. Deste modo, a uma resolução espacial de 250m, puderam-se observar pouquíssimos *pixels* para estas classes, levando a uma amostragem pequena demais para uma caracterização adequada de seu comportamento temporal. Portanto, sob este ponto de vista, foi decidido que todas as classes com menos de 30 *pixels* puros MODIS na área de análise e testes (*i.e.*, a metade sul da bacia) seriam desconsideradas com vistas a definição de uma classificação de treinamento. Assim, foram eliminadas as classes originais *corpos d'água* (equivalente a 0,068% da área total da bacia), *eucalipto* (0,009% da área total da bacia), e *floresta estacional semidecidual submontana* (0,015% da área total da bacia).

Em seguida, conforme descrito na seção 5.2.1, observaram-se os perfis temporais médios de NDVI para cada uma das classes restantes, juntamente com os seus respectivos desvios-padrão, levando-se em conta para isso apenas os dados da metade sul da bacia (*i.e.*, a área de treinamento e testes). Deste modo, foi logo observado que todas as diferentes classes de vegetação natural apresentavam um comportamento temporal muito semelhante, incluindo-se aí as diferentes classes de cerrado, a classe *floresta estacional semidecidual aluvial* e todas as classes de misturas de vegetação natural. De fato, considerando-se os desvios-padrão, pôde-se perceber que até mesmo as classes *cerrado aberto* e *cerradão* apresentavam uma superposição significativa durante todo o período de análise, tornando difícil a sua discriminação a partir de dados NDVI do MODIS (Figura 6.7). Portanto, como resultado, decidiu-se pelo *agrupamento* de todas estas classes em uma única classe de treinamento, que aqui recebeu o nome genérico de “cerrado”.




Figura 6.7 Perfis temporais médios de NDVI observados pelo sensor MODIS para diferentes classes de vegetação natural na metade sul da BAT. A grande superposição observada evidencia ser muito pequena a separabilidade destas classes a partir deste tipo de dados, mesmo nos casos das classes *cerrado aberto* e *cerradão* (à direita).

Assim, ao final deste processo de agrupamento, as 14 classes originais de uso e cobertura do solo foram separadas em 4 grandes grupos: agricultura, cerrado, pastagem, e áreas urbanas. Então, a partir deste ponto, realizou-se um processo para verificar quais destes grupos poderiam ser ainda sub-divididos com base em comportamentos temporais distintos (ver seção 5.2.2). Neste sentido, ao se aplicar o algoritmo de agrupamento *k-means* para os pontos de pastagem e de áreas urbanas, verificou-se que nenhum dos agrupamentos ou *clusters* encontrados pelo algoritmo apresentavam qualquer diferenciação com relação ao seu comportamento temporal, de modo que nenhuma sub-divisão pudesse ser identificada nestes casos (Figura 6.8).




Figura 6.8 Análise dos perfis temporais de NDVI para *pixels* do grupo de pastagem. À esquerda, perfil médio verificado para todos os pontos na área de treinamento e testes. À direita, perfis temporais para os diferentes *clusters* identificados a partir da aplicação do algoritmo *k-means*, com $k=6$. Pode-se observar que nenhum destes *clusters* apresenta comportamento temporal diferenciado, o que indica não haver qualquer razão para a sub-divisão do grupo.

Em contrapartida, ao se realizar o mesmo procedimento para o grupo de agricultura, verificou-se prontamente a existência de sub-grupos com comportamentos temporais bastante particulares, que poderiam assim ser relacionados a diferentes práticas agrícolas. De fato, após

a interpretação dos perfis resultantes (conforme descrito na seção 5.2.2), pôde-se dividir este grupo em 4 sub-classes distintas, como apresentado na Figura 6.9 abaixo. Infelizmente, no entanto, estas sub-classes encontradas não puderam ser comprovadamente relacionadas a práticas reais de plantio agrícola, uma vez que não havia disponibilidade de informações de campo a este respeito. De todo modo, observando-se o calendário agrícola comumente empregado na região, foi possível relacionar 3 destas sub-classes à ocorrência de plantios de: **a) soja;** **b) soja seguida de milho de safrinha, em sistema de plantio direto;** e **c) trigo.**




Figura 6.9 Análise dos perfis temporais de NDVI para *pixels* do grupo de agricultura. À esquerda, perfil médio verificado para todos os pontos na área de treinamento e testes. À direita, perfis temporais para as diferentes sub-classes identificadas após a interpretação dos *clusters* resultantes (algoritmo *k-means* com $k=6$). Ao final, pôde-se observar a existência de três sub-classes de agricultura (associadas respectivamente a *soja*, *soja com milho de safrinha* e *trigo*), sendo o quarto agrupamento identificado como áreas agrícolas em repouso, apresentando perfil semelhante ao da classe *pastagem* (ver Figura 6.8).

Com relação à quarta sub-classe identificada, uma análise um pouco mais cuidadosa nos permitiu perceber que este *cluster* apresentava, na realidade, um comportamento temporal praticamente idêntico àquele verificado para áreas de classe *pastagem* (Figura 6.8). Com efeito, esta constatação é realmente plausível, uma vez que, dentro do sistema de rodízio de culturas, é bastante comum que áreas de plantio sejam deixadas em repouso (*i.e.*, sem cultivo) durante um ano qualquer, servindo efetivamente como pastagem durante este período. Desta forma, entendeu-se por fim existirem apenas 3 sub-classes diferentes de agricultura na região de análise, sub-classes estas a serem portanto utilizadas mais adiante para fins de treinamento do algoritmo de classificação. Além disso, deve-se enfatizar ainda que, no caso do quarto sub-grupo, será tecnicamente impossível reconhecê-lo como agricultura apenas a partir deste comportamento temporal ao longo de um ano, uma vez que nestes pontos não se verifica qualquer prática agrícola durante o período de análise. Assim, considerando-se que este sub-grupo representou aproximadamente 17% do total de pontos considerados, é possível também estimar um nível razoável de discrepância entre a informação original de “verdade terrestre” e o resultado da classificação a ser realizada posteriormente (seção 6.4.1).

Finalmente, a aplicação da mesma metodologia para o grupo de cerrado fez com que mais uma vez se pudessem identificar sub-classes com distintos comportamentos temporais. Desta vez, a interpretação dos *clusters* encontrados pelo algoritmo *k-means* permitiu observar a ocorrência de um sub-grupo minoritário cujo comportamento temporal indicava um decréscimo nos valores de NDVI ao longo do período de análise, destoando significativamente do comportamento mais estável observado para as demais áreas de vegetação natural da região (Figura 6.10). Por esta razão, definiram-se por fim duas classes distintas com vistas à classificação de treinamento: uma classe *cerrado*, correspondente ao grupo majoritário, e outra classe intitulada de *desflorestamento*, uma vez que o decréscimo de NDVI verificado para este sub-grupo pode ser relacionado a uma diminuição da atividade fotossintética nas áreas em questão.




Figura 6.10 Análise dos perfis temporais de NDVI para *pixels* do grupo de cerrado. O algoritmo de agrupamento permitiu observar a existência de uma sub-classe distinta, aqui nomeada *desflorestamento*, cujo perfil temporal apresenta um decréscimo nos valores de NDVI ao longo do período de análise.

Desta forma, ao final do processo de agrupamento e subdivisão das classes originais, obtiveram-se então 7 classes consideradas como sendo discrimináveis a partir de dados temporais MODIS com 250m de resolução espacial: *agricultura tipo 1*, *agricultura tipo 2*, *agricultura tipo 3*, *cerrado*, *pastagem*, *áreas urbanas* e *desflorestamento* (Figura 6.11). Desta forma, a partir dos *pixels* puros da metade sul da bacia, foi gerada uma *classificação de treinamento* contendo estas 7 classes, de modo a poder alimentar o algoritmo de classificação a ser aplicado na metade norte da bacia (*i.e.*, a área de validação).




Figura 6.11 Perfis temporais de NDVI das 7 classes consideradas discrimináveis a partir de dados temporais MODIS com 250m de resolução espacial.

De forma similar, foi também gerada uma *classificação para fins de validação*, correspondendo à informação a ser usada para comprovar quantitativamente os resultados finais da metodologia de classificação. Neste caso, como o processo de sub-divisão é realizado sem qualquer comprovação de verdade de campo, esta classificação de validação foi produzida simplesmente a partir do resultado do processo de agrupamento das classes originais, sem levar em consideração os sub-grupos posteriormente identificados. Portanto, temos para este fim apenas a discriminação dos 4 grandes grupos: *agricultura*, *cerrado*, *pastagem* e *áreas urbanas*.

6.3.4 Análise dos perfis temporais NDVI

Nesta etapa, os dados MODIS de NDVI, pré-processados na seção 6.3.1, foram analisados em maior detalhe, de modo a se obter um conjunto de informações de menor dimensionalidade, menos redundante, e mais apropriado para a tarefa de classificação. Conforme a descrição apresentada na seção 5.3, este procedimento envolveu primeiramente a suavização dos perfis temporais através de ajustes de curvas polinomiais aos dados, seguido do cálculo de uma série de métricas criadas para prover uma descrição de maior qualidade acerca do comportamento temporal de cada ponto.

Desta forma, foi calculado um total de 14 métricas diferentes para caracterizar o perfil como um todo, somadas a mais 10 métricas destinadas à caracterização de cada modo identificado nos perfis. Como discutido na seção 5.3, um modo foi definido aqui como um segmento de perfil temporal tal que as suas bases (*i.e.*, o início e o fim do segmento) correspondessem a pontos de mínimo local ou início/fim do perfil, sendo o seu pico necessariamente um ponto de

máximo local. Ademais, é imposta também uma restrição de existir uma diferença mínima de 0.3 NDVI entre o pico e as bases. Finalmente, deve-se dizer ainda que estas métricas foram deliberadamente criadas com uma grande redundância entre si, estando todas elas listadas a seguir:

- a. Atributos gerais da curva (descrevem o perfil temporal como um todo)
 - *média de NDVI*
 - *NDVI mínimo*
 - *NDVI máximo*
 - *data de máximo NDVI*
 - *NDVI inicial*
 - *amplitude global: (NDVI máximo) – (NDVI mínimo)*
 - *ganho global: (NDVI final) – (NDVI inicial)*
 - *número de modos*
 - *ganho 150 dias: (média de NDVI para os últimos 215 dias) – (média de NDVI para os primeiros 150 dias)*
 - *derivada mínima da curva (i.e., derivada negativa de maior intensidade)*
 - *média dos valores absolutos das derivadas da curva*
 - *desvio-padrão dos dados originais (i.e., antes do ajuste de curvas)*
 - *derivada mínima computada a partir dos dados originais*
- b. Atributos de cada modo da curva
 - *data do pico do modo*
 - *valor NDVI no pico do modo*
 - *largura do modo (em dias): (data do fim do modo) – (data do início do modo)*
 - *largura do crescimento do modo (em dias): (data do pico) – (data do início)*
 - *largura da senescência do modo (em dias): (data do fim) – (data do pico)*
 - *ganho do modo no crescimento: (NDVI no pico) – (NDVI no início)*
 - *perda do modo na senescência: (NDVI no pico) – (NDVI no fim)*
 - *derivada no crescimento: média das derivadas de todos os pontos anteriores ao pico do modo e de derivada segunda igual a zero*
 - *derivada na senescência: média das derivadas de todos os pontos posteriores ao pico do modo e de derivada segunda igual a zero*
 - *integral sob o modo: soma dos valores NDVI de todos os pontos entre o início e o fim do modo*

Uma vez calculados os atributos, verificou-se a ocorrência de um máximo de 3 modos para os perfis temporais da área de treinamento. Desta forma, para cada ponto MODIS foi atribuído um número variável de métricas temporais, apresentando portanto um mínimo de 14 atributos (no caso de um perfil sem modo algum), e um máximo de 44 atributos (no caso de existência de 3 modos). Por fim, aplicou-se o procedimento de pós-processamento descrito na seção 5.3.3, de modo a normalizar todos os dados computados e prepará-los para as tarefas de seleção de atributos e classificação.

6.3.5 Seleção de atributos

Uma vez computadas todas as métricas descritivas dos perfis temporais, implementou-se finalmente o procedimento discutido na seção 5.4, com o intuito de analisar o conjunto de informações coletadas e selecionar um sub-conjunto conciso de atributos de modo a maximizar o poder de discriminação entre as classes de interesse (*i.e.*, as 7 classes definidas na seção 6.3.3). Assim, com este objetivo, executou-se tanto o algoritmo CFS selecionado nesta metodologia (ver seção 5.4.1), quanto os algoritmos alternativos descritos na seção 5.4.2, de modo a se poderem avaliar os seus desempenhos de forma quantitativa e assim corroborar as hipóteses levantadas anteriormente.

Do ponto de vista prático, a realização desta tarefa para toda a região da classificação de treinamento (definida na seção 6.3.3) se mostrou inviável por limitações de capacidade de processamento computacional, uma vez que se tratavam de muitas dezenas de milhares de *pixels*. Por estas razões, as análises realizadas nesta etapa foram todas efetuadas com base num procedimento de amostragem aleatória de pontos, selecionando-se para avaliação um total de 500 amostras por classe a partir dos dados de treinamento. Entretanto, deve-se notar ainda que, no caso específico das classes *áreas urbanas* e *desflorestamento*, a totalidade dos pontos disponíveis foram empregadas nesta análise, visto que nestes casos existiam menos de 500 *pixels* para cada classe em toda a área de treinamento.

Desta maneira, num primeiro momento, tentou-se aplicar o algoritmo *wrapper* (ver seção 5.4.2.2) para realizar a seleção de atributos da forma mais direta e confiável possível. Esta aplicação consistiu na utilização do ambiente WEKA para análise de dados (ver seção 4.5), tomando como parâmetros uma busca do tipo *best first search* (busca em sentido progressivo, tolerância de 5 avaliações sem melhora de desempenho), e o método de classificação “*Naive Bayes*” (de características semelhantes ao classificador de máxima verossimilhança a ser utilizado posteriormente). Infelizmente, no entanto, a grande quantidade de atributos (44) e a conseqüente enorme quantidade de possibilidades a serem avaliadas fez com que o custo computacional para a execução da busca fosse demasiadamente elevado, o que terminou por inviabilizar o uso desta estratégia nestas circunstâncias.

Assim, experimentou-se então uma segunda técnica de seleção de atributos, o algoritmo estatístico de *análise discriminante* (seção 5.4.2.1). Desta vez, esperava-se que se pudesse realmente encontrar uma solução em tempo hábil, para assim poder avaliar o desempenho desta estratégia no caso particular desta aplicação. Para isso, aplicou-se então a versão passo a passo do algoritmo, com busca ascendente, utilizando-se um valor de α equivalente a 0,05.

Como resultado da aplicação da análise discriminante, verificou-se primeiramente que o sub-conjunto final de fato excluía a presença de atributos perfeitamente correlacionados entre si, tal como ocorre com o trio *NDVI máximo*, *NDVI mínimo*, e *amplitude global* (i.e., diferença entre o máximo e mínimo). Neste caso específico, a métrica *NDVI máximo* foi considerada pelo algoritmo como sendo a que adicionava menos informação ao modelo, apresentando um poder discriminatório menos significativo e sendo assim eliminada do sub-conjunto. Todavia, por outro lado, verificou-se também que o sub-conjunto final encontrado pela estratégia ainda continha um número total de 30 atributos, o que foi considerado ainda exageradamente elevado. Além disso, esta seleção final também incluía métricas razoavelmente correlacionadas entre si (e.g., *derivada mínima da curva* e *derivada mínima computada a partir dos dados originais*), de modo que o resultado pôde ser visto como sendo ainda insatisfatório para fins de classificação. Desta forma, chegou-se à conclusão de que a modelagem linear realizada por esta técnica não se adequava suficientemente bem ao problema em questão.

Finalmente, aplicou-se então o algoritmo CFS (descrito em detalhe na seção 5.4.1) ao conjunto de 44 atributos, utilizando mais uma vez para isso o ambiente WEKA. De fato, pôde-se verificar imediatamente a extrema rapidez proporcionada pelo algoritmo, que em poucos segundos percorreu o espaço de busca utilizando a mesma estratégia *best first search* descrita anteriormente. Adicionalmente, observou-se terem sido selecionadas apenas 13 métricas para o sub-conjunto de atributos encontrado, o que configurava uma importante e interessante redução da dimensionalidade dos dados.

Entretanto, apesar destas características interessantes, foi também percebido que o sub-conjunto final escolhido incluía tanto os atributos *NDVI mínimo* e *NDVI máximo* quanto o atributo *amplitude global* (i.e., diferença entre o máximo e mínimo). Esta configuração, indesejável devido à presença de dados redundantes, de fato levaria à existência de matrizes de covariância não-inversíveis para os atributos das classes, impossibilitando a aplicação do algoritmo de classificação de máxima verossimilhança a ser empregado em seguida (ver seções 5.5 e 6.3.6). Na realidade, este problema pôde ser imediatamente relacionado às características da estratégia adotada pelo algoritmo, segundo a qual são avaliadas apenas inter-correlações entre pares de atributos (ver equação (5.3)). Por esta razão, a redundância entre estas três métricas, de um maior grau de complexidade, não pôde ser inteiramente percebida pelo algoritmo, explicando assim o resultado encontrado.

Para solucionar esta questão, adotou-se uma abordagem de aproveitamento dos resultados encontrados pela análise discriminante, onde a métrica *NDVI máximo* foi considerada como

sendo a menos importante dos três atributos em questão. Desta forma, decidiu-se pela eliminação desta métrica, resultando num conjunto final de 12 atributos. Alternativamente, estes mesmos 12 atributos também puderam ser encontrados ao se executar o algoritmo CFS a partir do sub-conjunto de 30 atributos anteriormente selecionado pela análise discriminante, mostrando serem coerentes os resultados encontrados pelas duas estratégias.

Os 12 atributos finalmente selecionados para a classificação dos perfis temporais foram os seguintes: *média de NDVI*, *NDVI mínimo*, *data de máximo NDVI*, *NDVI inicial*, *amplitude global*, *ganho global*, *número de modos*, *ganho 150 dias*, *média dos valores absolutos das derivadas da curva*, *desvio-padrão dos dados originais*, *data do pico do modo 1*, e *largura do modo 1*. Pôde-se notar, assim, que a maioria das métricas selecionadas se refere a atributos gerais da curva, tendo sido selecionadas apenas duas métricas designadas para a caracterização de modos: *data de pico do modo 1* e *largura do modo 1*.

Desta forma, ao final de todo este processo de cálculo e seleção de atributos, foi demonstrado ser efetivamente possível reduzir drasticamente a dimensionalidade dos dados de entrada, de 71 (o número de datas na sequência temporal original produzida com dados diários de reflectância) para apenas 12. Assim, obteve-se uma importante minimização da redundância destes dados, ao mesmo tempo em que se buscou proporcionar informações mais inteligentes e também mais robustas com relação a pequenas variações dos perfis temporais (*e.g.*, devido a ruídos e variabilidades intra-classe), facilitando portanto o processo classificatório como um todo.

6.3.6 Classificação

Por fim, processados todos os dados de entrada, empregou-se a metodologia de classificação descrita na seção 5.5, de forma que as propriedades características de cada classe pudessem ser apreendidas a partir dos dados de treinamento (gerados na seção 6.3.3).

Desta maneira, os *pixels* de cada uma das 7 classes MODIS foram avaliados, extraindo-se, para cada classe, a sua distribuição de probabilidades com relação aos 12 atributos selecionados anteriormente. Com efeito, deve-se lembrar aqui que a variável discreta *número de modos* apresentou 4 valores distintos, variando de 0 (nenhum modo) até 3 modos. Desta maneira, como definido pelas equações (5.8) e (5.9) (seção 5.5.1), as médias $\mu(x_{cont}|w_j, x_{disc})$ e as matrizes de covariância $\Sigma(x_{cont}|w_j, x_{disc})$ tiveram que ser calculadas para o conjunto de 11 atributos contínuos, para cada classe e para cada valor discreto do atributo *número do modos*. Adicionalmente, para permitir a aplicação da extensão do processo de classificação (baseada em análises de mistura espectral, como descrito na seção 5.5.2), calcularam-se ainda, para

cada classe, os valores médios das reflectâncias observadas nas faixas do vermelho e infravermelho próximo em todas as datas da sequência temporal obtida na seção 6.3.1. Assim, obtiveram-se *perfis temporais característicos* $R_j^k(t)$, para cada classe j e cada banda k , a serem usados posteriormente no processo de modelagem linear de mistura espectral nos *pixels*.

Desta forma, após esta fase de treinamento, executou-se finalmente o procedimento de classificação para toda a área de estudos. Para tanto, num primeiro passo, aplicou-se o algoritmo principal baseado em máxima verossimilhança para a bacia, sendo atribuídos aos pontos a classe de maior probabilidade *a posteriori*, desde que esta probabilidade fosse superior a 95%. Então, numa segunda passagem, utilizou-se essa classificação preliminar em conjunto com o algoritmo complementar de estimativa local de proporções, de maneira a se avaliarem todos os pontos não classificados na primeira passagem e lhes atribuir a classe estimada como sendo a de maior proporção no seu interior. Assim, utilizou-se uma janela local de tamanho 3x3 *pixels*, considerando-se deste modo apenas misturas espectrais de classes detectadas pelo algoritmo principal nas proximidades de cada ponto não classificado. Adicionalmente, executou-se o mesmo algoritmo utilizando-se, no lugar dos perfis $R_j^k(t)$ computados a partir de dados de treinamento, estimativas geradas localmente a partir dos próprios *pixels* classificados pelo algoritmo principal no interior da janela local (ver seção 5.5.2.3). A avaliação da aplicação destas diferentes estratégias se encontra na seção 6.4.1, a seguir.

6.4 Resultados e discussão

6.4.1 Classificação

Para realizar uma avaliação do procedimento de classificação, compararam-se os resultados alcançados através da metodologia com aqueles provenientes da classificação de referência, processada na seção 6.3.3 para fins de validação com 4 classes (*agricultura, cerrado, pastagem e áreas urbanas*). Neste sentido, avaliaram-se as diferentes etapas do algoritmo (classificação principal, medida de confiabilidade *pixel a pixel*, e estimativa local de proporções em pontos de baixa confiabilidade), observando-se assim o desempenho de cada passo de modo a verificar as hipóteses assumidas anteriormente. Além disso, foram realizadas avaliações da *performance* final do algoritmo tanto para a área de validação (norte da bacia) quanto para a área de treinamento (sul da bacia), de modo a averiguar a capacidade da metodologia em generalizar os perfis temporais sobre grandes regiões, conseguindo assim discriminar os diferentes tipos de uso e cobertura do solo apesar das variações de caráter local.

6.4.1.1 Avaliações preliminares

Antes de mais nada, avaliaram-se as características gerais da distribuição do uso e cobertura do solo nas duas metades da área de estudos, após o procedimento de agrupamento de classes realizado na seção 6.3.3. De fato, pôde-se perceber que as condições em ambas as porções eram bastante semelhantes (Tabela 6.1), inclusive com relação à percentagem de *pixels* misturados, o que nos permite, em princípio, realizar comparações diretas entre os resultados obtidos para cada região.

	Sul	Norte
Agricultura	7,90%	5,60%
Cerrado	34,40%	42,30%
Pastagem	57,50%	52,00%
Áreas urbanas	0,20%	0,10%
<i>Pixels puros</i>	73,66%	73,52%

Tabela 6.1 Distribuições do uso e cobertura do solo nas metades sul e norte da Bacia do Alto Taquari

Então, como primeiro passo para a avaliação da metodologia, quantificou-se o nível de acurácia proporcionado pelo algoritmo principal de classificação (*i.e.*, utilizando os atributos temporais), medindo-se o seu desempenho para a área de validação. Desta forma, desconsiderando-se qualquer critério de confiabilidade da classificação (*i.e.*, limiar mínimo de probabilidade *a posteriori*), comparou-se a classe atribuída pelo algoritmo com a classe majoritária identificada na classificação de referência. Com esta abordagem, computou-se então uma *matriz de confusão*, uma ferramenta comumente utilizada na literatura com o objetivo de quantificar as disparidades ou concordâncias entre duas classificações (ver seção 2.3.4). Além disso, a partir desta matriz, calculou-se também a acurácia global e o coeficiente kappa, obtendo-se assim uma medida do desempenho geral do algoritmo. Desta forma, obteve-se ao final uma acurácia global de 83% para a classificação baseada apenas na etapa principal da classificação, demonstrando que, de forma geral, as diferentes classes de uso e cobertura do solo puderam ser razoavelmente bem apreendidas pelo algoritmo (Tabela 6.2).

	<i>Dados de Referência</i>					
	Agricultura	Cerrado	Pastagem	Urbano	Total	Acur. Usr.
<i>Resultados</i>						
Agricultura	10.713	858	1.480	6	13.057	82,05%
Cerrado	236	85.320	20.475	9	106.040	80,46%
Pastagem	2.351	15.459	102.931	165	120.906	85,13%
Urbano	0	1	33	7	41	17,07%
Total	13.300	101.638	124.919	187	240.044	
Acur. Prod.	80,55%	83,94%	82,40%	3,74%		

Acurácia Global: 82,89%

Coeficiente Kappa: 0,6877

Tabela 6.2 Matriz de confusão e acurácias verificadas ao se aplicar o algoritmo principal de classificação na área de validação. Deve-se notar que nenhum critério de confiabilidade de classificação foi utilizado de modo a minimizar os problemas decorrentes de *pixels* misturados e/ou problemáticos.

6.4.1.2 Avaliação do impacto de pixels misturados

Então, neste ponto, realizou-se uma análise um pouco mais minuciosa com relação à origem dos erros encontrados, de forma a verificar, em especial, a influência do fenômeno de *pixels* misturados neste aspecto, ou seja, *pixels* no interior dos quais, segundo a classificação de referência, podia se encontrar na realidade mais de uma classe de uso e cobertura do solo. Com este objetivo, observou-se então que, caso se avaliassem apenas *pixels* puros (*i.e.*, excluindo-se todos os *pixels* misturados), os resultados alcançados pelo algoritmo seriam de fato bastante superiores, como demonstrado na Tabela 6.3 abaixo.

	Dados de Referência					
	Agricultura	Cerrado	Pastagem	Urbano	Total	Acur. Usr.
Resultados						
Agricultura	9.666	320	1.143	3	11.132	86,83%
Cerrado	63	65.120	8.813	2	73.998	88,00%
Pastagem	1.664	5.311	84.239	109	91.323	92,24%
Urbano	0	0	30	6	36	16,67%
Total	11.393	70.751	94.225	120	176.489	
Acur. Prod.	84,84%	92,04%	89,40%	5,00%		

Pixels Classificados: 73,52% do total

Acurácia Global: 90,11%

Coeficiente Kappa: 0,8207

Tabela 6.3 Matriz de confusão e acurácias verificadas ao se aplicar o algoritmo principal de classificação na área de validação, levando em consideração apenas os *pixels* puros. Novamente, nenhum critério de confiabilidade de classificação foi utilizado de modo a minimizar os problemas decorrentes de *pixels* problemáticos.

Analisando este resultado, foi possível constatar então que, de fato, mais da metade dos erros de classificação (58%) cometidos pelo algoritmo principal estavam relacionados a *pixels* misturados, significando que na maioria desses casos o algoritmo não foi capaz de identificar corretamente a classe majoritária existente em cada um destes pontos. Ademais, observou-se também que, do total destes *pixels* misturados, aproximadamente 37% deles não foram classificados corretamente, ou seja, o fato de existirem diversas classes no interior de um *pixel* poderia realmente ser visto como um indicador de risco de erros de classificação. Desta maneira, pôde ser comprovada experimentalmente a influência e importância do problema de mistura de classes em levantamentos de uso e cobertura do solo realizados a partir de dados MODIS, corroborando resultados encontrados por outros pesquisadores [63][112], e também justificando o emprego de alguma medida complementar de modo a auxiliar o processo de classificação e minimizar este tipo de efeito.

6.4.1.3 Avaliação do critério de confiabilidade da classificação

Neste ponto, realizou-se então uma avaliação do critério de confiabilidade da classificação principal, segundo o qual o limiar de 95% de probabilidade *a posteriori* é utilizado para indicar a ocorrência de *pixels* misturados e/ou problemáticos, e assim evitar possíveis erros de classificação. De fato, ao aplicar este limiar na área de validação da metodologia, verificou-se

primeiramente que 70% dos pontos foram de fato classificados com alto grau de confiabilidade (*i.e.*, probabilidade *a posteriori* superior ao limiar de 95%). Além disso, comparando-se os dados de referência com a classificação atribuída a estes pontos de alta confiabilidade (*i.e.*, excluindo-se todos os pontos de baixa confiabilidade), observou-se também um alto desempenho do algoritmo, como pode ser observado na Tabela 6.4 abaixo.

	<i>Dados de Referência</i>					
	Agricultura	Cerrado	Pastagem	Urbano	Total	Acur. Ushr.
<i>Resultados</i>						
Agricultura	8.807	606	876	2	10.291	85,58%
Cerrado	74	67.578	6.470	3	74.125	91,17%
Pastagem	1.831	6.094	76.480	128	84.533	90,47%
Urbano	0	1	25	5	31	16,13%
Total	10.712	74.279	83.851	138	168.980	
Acur. Prod.	82,22%	90,98%	91,21%	3,62%		

Pixels Classificados: 70,40% do total

Acurácia Global: 90,47%

Coeficiente Kappa: 0,8282

Tabela 6.4 Matriz de confusão e acurácias verificadas ao se aplicar o algoritmo principal de classificação na área de validação, levando em consideração apenas os pixels com alto grau de confiabilidade (*i.e.*, aqueles cuja classificação apresentou uma probabilidade *a posteriori* superior ao limiar de 95%).

Desta forma, foi possível chegar à conclusão de que neste caso a utilização deste critério de confiabilidade foi realmente capaz de fornecer resultados interessantes. Assim, calculou-se que, de fato, 61% dos *pixels* classificados erradamente pelo algoritmo original (Tabela 6.2) possuíam de fato probabilidades *a posteriori* inferiores ao limiar de 95%, comprovando portanto a utilidade de se empregar este tipo de critério para identificar pontos onde um outro tipo de abordagem se faz necessário.

Em seguida, realizou-se um estudo suplementar de forma a tentar quantificar a relação entre *pixels* classificados com baixa confiabilidade e aqueles que efetivamente continham mais de uma classe no seu interior. De fato, numa primeira análise, a observação da Tabela 6.3 (classificação de *pixels* puros) e da Tabela 6.4 (classificação de *pixels* com alta confiabilidade) nos permite perceber uma grande semelhança no desempenho do algoritmo nos dois casos, inclusive com relação aos percentuais totais de *pixels* classificados (73,52% e 70,40%, respectivamente), sugerindo assim a existência de algum tipo de relação entre as suas características. Então, ao se realizar uma análise mais minuciosa desta questão, observou-se que, na realidade, 50% dos *pixels* misturados efetivamente apresentavam um baixo nível de confiabilidade de classificação, calculando-se por fim um total de 71% de concordância geral entre estas duas condições. Desta forma, pôde-se perceber que estas duas medidas estavam definitivamente correlacionadas, porém não completamente, como demonstrado na Figura 6.12 abaixo.




Figura 6.12 Exemplo do relacionamento entre *pixels* misturados observados nos dados de referência (pontos pretos à esquerda) e *pixels* com baixo nível de confiabilidade na classificação realizada pela metodologia (pontos pretos à direita). Pontos laranjas correspondem a áreas de pastagem, enquanto que pontos verdes correspondem a cerrado. Pode-se observar que os *pixels* de baixa confiabilidade realmente se concentram nas áreas de mistura de classes (nas fronteiras entre regiões homogêneas), embora a correspondência entre estes dois fatores não seja perfeita.

De fato, observando esta figura, percebe-se que os *pixels* avaliados como sendo de baixa confiabilidade realmente se concentram nas regiões de fronteira entre diferentes classes de uso e cobertura do solo. Na verdade, embora não se correlacionem perfeitamente com *pixels* efetivamente misturados, as discrepâncias observadas podem ser explicadas por uma série de fatores relacionados a este fenômeno. Em primeiro lugar, pode-se supor que áreas de transição gradual entre classes distintas possam causar efeitos de mistura espectral em certos pontos teoricamente “puros”, porém próximos às bordas efetivamente observadas nos dados de referência. De forma inversa, é também bastante provável que certos *pixels* ditos misturados sejam de fato dominados pela resposta espectral de uma classe largamente majoritária, levando a perfis temporais semelhantes aos das classes propriamente ditas e assim fornecendo uma alta confiabilidade na classificação resultante. Por fim, é importante se observar também que, embora a georreferência dos dados MODIS seja de fato bastante acurada, pequenas discrepâncias entre as diferentes imagens da sequência temporal podem de fato ocorrer. Assim, nestes casos, *pixels* teoricamente puros, porém próximos às bordas das classes, podem sofrer diferentes níveis de contaminação na sua resposta espectral ao longo do período de análise, podendo levar a perfis temporais ruidosos e não característicos de sua classe. Este fenômeno torna-se de fato bastante relevante em casos de transições muito repentinas entre coberturas de respostas espectrais muito distintas, como em pontos próximos a corpos d’água ou áreas cultivadas, nos quais a contaminação espectral diferenciada ao longo do tempo é capaz de provocar níveis de ruído extremamente elevados (Figura 6.13).




Figura 6.13 Exemplo de perfil temporal com alto nível de ruído (à direita), observado numa área próxima a um cultivo agrícola (à esquerda, sendo verde correspondente a *pixels* puros de classe *cerrado*, laranja a *pastagem*, roxo a *agricultura*, e preto a *pixels* misturados). Devido a pequenas variações na georreferência dos dados MODIS, áreas próximas a pontos de transição entre classes podem apresentar respostas espectrais bastante distintas ao longo do tempo.

Feitas estas considerações, pode-se concluir que, na prática, áreas com baixa confiabilidade de classificação correspondem freqüentemente a pontos efetivamente misturados, ou com algum nível de interferência devido a efeitos de misturas de respostas espectrais provenientes de coberturas de solo distintas. Portanto, sob este ponto de vista, pode-se considerar como sendo bastante razoável o emprego de técnicas de análise de mistura espectral para buscar uma melhor interpretação destas áreas, como proposto pelo refinamento descrito na seção 5.5.2.

6.4.1.4 Avaliação do algoritmo complementar de classificação

Em seguida, avaliou-se finalmente a última etapa do procedimento, onde foram estimadas as proporções existentes em cada um dos *pixels* não classificados pelo algoritmo principal. Prontamente, verificou-se que a alternativa de se computarem localmente os perfis temporais característicos $R_j^k(t)$ de cada classe (ver seção 5.5.2.3) apresentou resultados inferiores àqueles obtidos com perfis gerados a partir dos dados de treinamento. Com efeito, este comportamento pareceu estar relacionado ao fato de que, nesta etapa complementar, a maior parte dos pontos avaliados se localizavam exatamente nas áreas de fronteira entre diferentes classes de uso e cobertura do solo. Desta forma, dentre os *pixels* próximos classificados pelo algoritmo principal, encontravam-se freqüentemente pontos contaminados por misturas de respostas espectrais, de modo que seus perfis temporais não refletissem tão bem as propriedades características de cada classe. Entretanto, mais grave ainda do que isso, as interferências freqüentemente observadas nestas áreas de fronteira parecem ter feito com que estes *pixels* fossem classificados de maneira equivocada pelo algoritmo principal, tendo como consequência um prejuízo ainda maior da qualidade e utilidade destes perfis estimados localmente.

Com relação à melhoria no desempenho geral do algoritmo, pôde ser observado que, utilizando-se os perfis temporais característicos $R_j^k(t)$ obtidos a partir dos dados de treinamento, foi realmente possível verificar um incremento na acurácia final da classificação, quando comparado àquele obtido puramente pelo algoritmo principal (c.f., Tabela 6.2). De fato, considerando-se os *pixels* classificados com baixo grau de confiabilidade, observou-se realmente um aumento significativo de 6,5% na acurácia do resultado. Entretanto, infelizmente, a acurácia final verificada para estes *pixels* “problemáticos” se manteve a níveis ainda relativamente baixos, atingindo-se por fim um valor de 71%. Este resultado nos leva à conclusão de que, embora esta estratégia tenha sido realmente útil para o aprimoramento do algoritmo como um todo, seria ainda necessário desenvolver soluções mais eficientes para lidar com estes problemas relacionados a misturas de diferentes classes de uso e cobertura do solo. Em particular, seria interessante conseguir combinar, de alguma forma, a adaptabilidade da estimativa local de perfis temporais com a confiabilidade garantida através do uso de perfis obtidos a partir de dados de treinamento.

6.4.1.5 Avaliações finais

Por fim, realizou-se uma análise do desempenho do processo de classificação como um todo, compreendendo todas as etapas descritas na seção 5.5. Desta forma, aplicou-se esta metodologia para toda a região de análise, utilizando tanto dados diários MOD09GQK quanto dados compostos de 16 dias MOD13Q1 (descritos na seção 4.3). Então, comparou-se a classificação final alcançada com os dados de referência, observando-se por fim o grau de acurácia alcançado pela metodologia tanto na área de treinamento (metade sul da bacia) quanto na área de validação (metade norte da bacia).

Assim, utilizando-se dados MOD09GQK, os resultados alcançados na própria área de treinamento da metodologia foram os seguintes (Tabela 6.5):

	<i>Dados de Referência</i>					
	Agricultura	Cerrado	Pastagem	Urbano	Total	Acur. Usr.
<i>Resultados</i>						
Agricultura	16.549	417	1.393	7	18.366	90,11%
Cerrado	254	71.878	21.770	29	93.931	76,52%
Pastagem	3.200	14.758	122.539	480	140.977	86,92%
Urbano	0	2	26	63	91	69,23%
Total	20.003	87.055	145.728	579	253.365	
Acur. Prod.	82,73%	82,57%	84,09%	10,88%		

Acurácia Global: 83,29%

Coefficiente Kappa: 0,6944

Tabela 6.5 Matriz de confusão e acurácias verificadas ao se aplicar a metodologia completa de classificação na própria área de treinamento (metade sul da bacia), a partir de dados diários MOD09GQK.

Similarmente, para a área de validação foi também construída uma matriz de confusão, disposta na Tabela 6.6 abaixo:

	<i>Dados de Referência</i>					
	Agricultura	Cerrado	Pastagem	Urbano	Total	Acur. Usr.
<i>Resultados</i>						
Agricultura	10.239	674	980	2	11.895	86,08%
Cerrado	305	87.811	18.372	10	106.498	82,45%
Pastagem	2.756	13.149	105.523	163	121.591	86,79%
Urbano	0	3	44	12	59	20,34%
Total	13.300	101.637	124.919	187	240.043	
Acur. Prod.	76,98%	86,40%	84,47%	6,42%		

Acurácia Global: 84,81%

Coeficiente Kappa: 0,7217

Tabela 6.6 Matriz de confusão e acurácias verificadas ao se aplicar a metodologia completa de classificação na área de validação (metade norte da bacia), a partir de dados diários MOD09GQK.

Assim, observando-se estas tabelas, foi possível concluir que, de forma geral, o desempenho da metodologia alcançou bons resultados, atingindo uma acurácia final de 85% na área de validação. De fato, as acurácias finais obtidas pelo algoritmo foram vistas como sendo bastante similares para as duas metades da bacia, demonstrando que o aprendizado realizado na área de treinamento foi realmente capaz de capturar os padrões temporais de cada classe de uso e cobertura do solo, e então reconhecê-los na área de validação. Adicionalmente, os resultados alcançados também puderam ser vistos como sendo satisfatórios a partir de comparações visuais realizadas entre a classificação resultante e os dados de referência, conforme disposto na Figura 6.14 abaixo.




Figura 6.14 Comparação entre os dados de referência (utilizados como “verdade terrestre”, à esquerda) e o resultado da aplicação do algoritmo de classificação (à direita). Verde corresponde à classe *cerrado*, laranja a *pastagem*, e roxo a *agricultura*.

Numa análise mais detalhada, observando o desempenho do algoritmo separadamente para cada classe de uso e cobertura do solo, foi possível chegar a algumas conclusões interessantes a respeito do comportamento, virtudes e limitações da metodologia, no contexto particular deste estudo de caso.

Em primeiro lugar, notou-se claramente a impossibilidade de se mapear corretamente a classe de *área urbana* (correspondente a 0,15% da área da bacia) a partir dos dados nas faixas do vermelho e infra-vermelho próximo. De fato, observando o perfil temporal desta classe (ver

Figura 6.11), pode-se perceber que as áreas urbanas estão em geral associadas a pontos de solo exposto, isto é, áreas com muito pouca cobertura vegetal e perfis temporais com baixos valores de NDVI durante todo o ano. Assim, pode-se entender as razões da grande confusão observada entre esta classe e áreas de pastagem degradada (Tabela 6.6), onde também se verifica a ocorrência de solo exposto. Entretanto, deve-se enfatizar aqui que a identificação de áreas urbanas não constitui uma prioridade da metodologia descrita neste trabalho, uma vez que seu foco está voltado para o impacto das mudanças do uso e cobertura do solo nos ecossistemas, especialmente com relação a questões de degradação ambiental (*e.g.*, diferenciação entre áreas naturais e antropizadas, monitoramento da expansão da fronteira agrícola, caracterização de fenômenos de desflorestamento, entre outros).

Com relação às demais classes, pode-se constatar de imediato que a classe *pastagem* realmente apresentou um bom nível de generalização. Correspondendo à classe mais significativa da bacia em termos de superfície ocupada (54,85% da área total), as regiões de pastagem foram identificadas com um nível de acurácia bastante satisfatório, atingindo valores em torno de 85% tanto na área de treinamento quanto na área de validação. Com efeito, a semelhança do desempenho do algoritmo em ambas as áreas pode ser interpretado como uma comprovação de que, neste caso, a metodologia foi capaz de efetivamente aprender o padrão de comportamento desta classe e aplicar este conhecimento com sucesso em outras regiões. Além disso, a quase totalidade dos erros verificados (95%) pode ser diretamente relacionada a confusões com a classe *cerrado*, o que é bastante compreensível uma vez que áreas de pastagem em recuperação são comumente deixadas em repouso, evitando-se nestes casos o seu uso efetivo como pasto e permitindo um certo grau de regeneração da vegetação nativa de cerrado. Similarmente, certas áreas de cerrado aberto com cobertura arbórea muito esparsa podem também ser confundidas com áreas de pasto, dificultando ainda mais a separação entre estas duas classes.

Observando-se mais uma vez o desempenho do algoritmo, pode-se afirmar ainda que o mapeamento da classe *cerrado* em si também apresentou resultados satisfatórios, com uma boa generalização de seus padrões de comportamento temporal. Mais uma vez, 95% dos erros verificados para esta classe se deveram a confusões com áreas de pastagem, porém um fato adicional interessante foi que o desempenho verificado na metade norte da bacia (Tabela 6.6) alcançou níveis ainda superiores àqueles observados na área de treinamento, na metade sul (Tabela 6.5). Os aumentos observados de 4% na acurácia do produtor, e 6% na acurácia do usuário, podem ser parcialmente explicados pelo fato de que na metade norte há uma maior concentração de áreas de vegetação mais densa (*e.g.*, cerrado denso, florestas aluviais, e

misturas de cerrado e floresta – ver seção 6.2.1), ao passo em que, no sul, observam-se mais áreas de cerrado aberto. Desta forma, a separação entre as classes MODIS de *cerrado* e de *pastagem* se torna de forma geral mais fácil na metade norte, em termos percentuais.

Por sua vez, a generalização observada para a classe *agricultura* apresentou, à primeira vista, resultados menos satisfatórios. De fato, comparando-se o desempenho alcançado nas áreas de treinamento e validação, constatou-se um decréscimo de 4% da acurácia do usuário e 6% na acurácia do produtor, este último atingindo um percentual final de apenas 76%. Como no caso da classe *cerrado*, a maior parte dos erros cometidos (90%) se deveram a confusões com a classe *pastagem*, o que pode ser em boa parte explicado por dificuldades em caracterizar o uso normalmente agrícola da terra a partir dos perfis temporais observados durante o período de análise. De fato, em diversas ocasiões, áreas agrícolas são deixadas em repouso durante um ano particular, sendo usadas temporariamente como pasto para proporcionar uma maior produtividade e sustentabilidade dentro do sistema de rotação de culturas e interação lavoura-pecuária (ILP [6]). Realmente, este tipo de fenômeno foi verificado com maior frequência na metade norte da bacia, fazendo com que, nestes casos, o comportamento verificado durante o período de análise (e captado pelas imagens de satélite) correspondesse na verdade a um padrão temporal típico da classe *pastagem*, inviabilizando portanto uma caracterização concordante com os dados de referência a partir de um único ano de dados (Figura 6.15).




Figura 6.15 Discrepâncias verificadas entre os dados de referência (à esquerda) e o resultado da classificação (centro) em certas regiões de classe *agricultura* deixadas em repouso durante o período de análise. A ausência de cultivo agrícola na área e o seu uso temporário como pasto tornam impossível a mesma caracterização de uso da terra a partir do comportamento temporal de apenas um ano de dados (à direita). *Pixels* em verde correspondem à classe *cerrado*, laranja a *pastagem*, e roxo a *agricultura*.

De forma inversa, também se observou que certas áreas, apesar de identificadas como *pastagem* pelos dados de referência, apresentaram um comportamento temporal típico de um cultivo agrícola, o que necessariamente levou a novas discrepâncias nos resultados. Pode-se concluir, portanto, que seriam necessários pelo menos 2 a 3 anos de dados para que se pudesse, em casos como este, identificar corretamente o uso geral do solo com um alto nível de confiabilidade. De todo modo, a capacidade de se caracterizar a atividade específica de cada período pode ser considerada como um aspecto positivo da metodologia implementada,

uma vez que permite um monitoramento mais detalhado da real dinâmica do uso da terra em regiões como estas.

Adicionalmente, é importante salientar ainda a existência de outras fontes de erro com relação à classe *agricultura*. Primeiramente, foi notado que certos *pixels* isolados, localizados nas fronteiras entre classes distintas e de perfis temporais ruidosos, acabaram sendo identificados erradamente como pertencentes a esta classe. Isto se deveu principalmente à ocorrência de variações bruscas nos perfis temporais destes pontos (associadas a problemas de georreferência, como discutido na seção 6.4.1.3), o que foi equivocadamente interpretado pelo algoritmo de classificação como uma propriedade característica de áreas cultivadas. Em segundo lugar, também foi possível observar que, em certos casos, a curva polinomial ajustada aos dados parece não ter sido capaz de capturar a forma efetiva do perfil temporal e assim caracterizar a existência de modos, levando a curvas mais semelhantes a perfis da classe *pastagem*. Por último, foi constatado ainda que alguns erros de classificação ocorreram em áreas de mistura das classes *agricultura* e *cerrado*, cujos perfis temporais resultantes também terminaram por ser associados a áreas de pastagem (Figura 6.16). De fato, neste último caso, estima-se que estes pontos seriam melhor avaliados a partir de técnicas de análise de mistura espectral, o que evidencia a necessidade de um aperfeiçoamento do procedimento de identificação de *pixels* misturados.




Figura 6.16 Perfil temporal (à direita) observado num ponto de transição entre áreas de agricultura e de vegetação ciliar (à esquerda). A mistura das respostas espectrais das classes resulta num comportamento temporal semelhante à resposta esperada para uma área de pastagem, dificultando o processo de classificação. Verde corresponde à classe *cerrado* (que inclui áreas de vegetação ciliar), e roxo a *agricultura*.

Por fim, o desempenho da metodologia como um todo foi avaliado novamente para a área de validação, utilizando-se desta vez os dados MOD13Q1 resultantes de composições de 16 dias. Assim, neste caso, foram alcançados os seguintes resultados (Tabela 6.7):

	<i>Dados de Referência</i>					
	Agricultura	Cerrado	Pastagem	Urbano	Total	Acur. Usr.
<i>Resultados</i>						
Agricultura	10.659	843	1.012	1	12.515	85,17%
Cerrado	350	90.537	21.787	14	112.688	80,34%
Pastagem	2.283	10.158	99.915	140	112.496	88,82%
Urbano	8	100	2.203	32	2.343	1,37%
Total	13.300	101.638	124.917	187	240.042	
Acur. Prod.	80,14%	89,08%	79,99%	17,11%		

Acurácia Global: 83,79%

Coeficiente Kappa: 0,7077

Tabela 6.7 Matriz de confusão e acurácias verificadas ao se aplicar a metodologia completa de classificação na área de validação (metade norte da bacia), a partir de dados compostos de 16 dias MOD13Q1.

Desta forma, foi possível verificar uma grande semelhança entre os resultados obtidos com dados MOD09GQK (Tabela 6.6) e com dados MOD13Q1 (Tabela 6.7), observando-se uma diferença final de apenas 1% em termos de acurácia global. Esta constatação sugere que, na prática, ambos os conjuntos de dados possam ser utilizados com sucesso para levantamentos de uso e cobertura do solo em escala regional. Assim, conclui-se que, dada uma área a ser levantada, a escolha do produto a ser utilizado deva depender de um compromisso entre uma maior riqueza e precisão temporal de dados (proporcionada pelos dados diários MOD09GQK) e uma menor complexidade de processamento, aliada a necessidades mais baixas de recursos computacionais (garantidas pelo uso de dados compostos MOD13Q1, por exigirem menos pré-processamento, levarem a seqüências temporais com menos imagens, e assim requererem o manuseio de volumes menores de dados). Portanto, de forma geral, é possível argumentar que os dados MOD13Q1 são mais interessantes para o levantamento de grandes áreas, de forma a minimizar o custo computacional de aquisição e processamento de dados. Sugere-se, assim, que dados MOD09GQK devam ser utilizados apenas em situações onde a aquisição diária de imagens se faz realmente necessária, seja por questões de precisão temporal (*e.g.*, para tarefas que exijam um acompanhamento contínuo da cobertura do solo, como sugerido por Shimabukuro *et al.* [92] e Morton *et al.* [71] para o caso de monitoramentos de desflorestamento em tempo real), seja por necessidades de uma grande riqueza de informações durante curtos períodos de tempo (*e.g.*, coberturas que se diferenciem por variações de alta frequência, ocorrendo em períodos inferiores a um mês).

6.4.2 Detecção de desflorestamento

6.4.2.1 Metodologia de avaliação

Como mencionado anteriormente (seção 6.3.3), a ausência de verdade de campo para a classe *desflorestamento* tornou impossível a realização de uma avaliação quantitativa e abrangente da acurácia desta detecção, tal como foi feito na seção anterior com relação ao processo de

classificação. Por conta disto, foi necessário adotar uma metodologia alternativa que permitisse de alguma forma julgar o mérito desta técnica a partir de dados e informações disponíveis ao longo do desenvolvimento desta dissertação.

Desta forma, em primeiro lugar, deve-se lembrar aqui que os dados de referência utilizados como “verdade terrestre” (*i.e.*, a classificação de validação gerada na seção 6.3.3) dizem respeito ao mês de julho de 2000 (seções 4.1 e 6.2.1), de modo que estas informações descrevem as condições efetivamente vigentes no momento inicial dos perfis temporais avaliados. Portanto, tornou-se possível afirmar com toda a segurança que uma detecção de desflorestamento pode ser considerada *incorreta* sempre que a área em questão estiver descrita pelos dados de referência como pertencente a uma classe que não seja *cerrado*. Entretanto, caso esta área seja realmente tida como cerrado no início do período de análise, então um segundo conjunto de dados se faz necessário de modo a comprovar a ocorrência ou não do suposto desmate detectado.

Para este fim, foram adquiridas imagens LANDSAT de forma a poder observar as condições existentes antes e depois do período de análise, e assim avaliar a propriedade da detecção. As imagens utilizadas neste estudo de caso são datadas de julho de 2000 (*i.e.*, no início do perfil temporal) e de agosto de 2002 (*i.e.*, após o fim do perfil temporal), tal como descrito na seção 4.4. Desta forma, para realizar esta avaliação, composições coloridas RGB = bandas (5,4,3) de ambas as imagens foram inspecionadas visualmente, observando-se ao mesmo tempo os perfis temporais de NDVI para os pontos supostamente desmatados. O desaparecimento ou não de áreas de floresta foi então avaliado a partir do seguinte procedimento:

- a. Caso haja sinais claros de desflorestamento tanto nas imagens LANDSAT quanto nos perfis temporais NDVI (tal como mostrado na Figura 6.18 mais adiante), então a detecção é considerada como estando seguramente correta
- b. Caso haja sinais claros de manutenção de cobertura vegetal tanto nas imagens LANDSAT quanto nos perfis temporais NDVI, então a detecção é considerada como estando seguramente incorreta
- c. Nos demais casos, nenhuma conclusão é feita

Além disso, é importante que se note que a imagem posterior ao período de análise não se refere à data mais adequada para este tipo de avaliação. De fato, em condições ideais, esta imagem deveria ser datada de julho ou agosto de 2001, ao invés da imagem de 2002 disponível para este estudo. Porém, de todo modo, deve-se ter em mente ser completamente impossível que alguma área efetivamente desmatada durante o período 2000-2001 possa ter se

regenerado em apenas 1 ano. Desta maneira, pode-se afirmar que, mesmo usando uma imagem de 2002, o procedimento proposto ainda seria capaz de verificar erros de *comissão* com segurança. Por outro lado, eventos de desflorestamento identificados a partir destas imagens LANDSAT poderiam na realidade corresponder a episódios ocorridos após o período 2000-2001, de forma que erros de *omissão* não podem ser apropriadamente averiguados. Por esta razão, a inspeção dos perfis temporais de NDVI se faz importante para confirmar a ocorrência de desmatamento durante o período de análise.

6.4.2.2 Avaliação dos resultados

Uma vez aplicada a metodologia completa de classificação (seção 6.3.6), teve-se que, para cada ponto da área de estudos, havia sido atribuída alguma das 7 classes definidas na seção 6.3.3. Assim, seguindo o procedimento descrito acima, observou-se o conjunto de *pixels* identificados como pertencentes à classe *desflorestamento* e constatou-se, primeiramente, que aproximadamente 75% deles correspondiam efetivamente a áreas de floresta ou cerrado no início do período de análise, conforme dados da classificação de referência.

Entretanto, dentre estes pontos, verificou-se a existência de um certo número de *pixels* isolados e aparentemente não relacionados a fenômenos de desflorestamento, num efeito de *salpicamento* bastante conhecido na literatura em casos de classificação *pixel a pixel* [14]. Estes pontos se encontravam sempre em áreas de transição entre diferentes classes de cobertura do solo, apresentando assim perfis temporais ruidosos devido às pequenas variações de georreferência das imagens (ver Figura 6.13 e seção 6.4.1.3). Desta forma, antes de se inspecionarem as imagens LANDSAT, aplicou-se um filtro de mediana, com janela local de tamanho 3x3 *pixels*, de forma a eliminar estes pontos isolados e proporcionar um resultado mais fácil de ser interpretado (Figura 6.17).




Figura 6.17 Detalhe do resultado da detecção de desflorestamento. A presença de um número significativo de pontos isolados (em vermelho, à esquerda, resultado de erros de interpretação devido a perfis temporais ruidosos em áreas de transição entre classes) levou à necessidade de se aplicar um filtro de mediana, de modo a tornar o resultado final mais adequado (à direita).

Em seguida, conforme o segundo passo do procedimento definido na seção 6.4.2.1, foram realizadas inspeções visuais das imagens LANDSAT em todas as regiões resultantes (*i.e.*,

para os 75% dos pontos detectados que efetivamente foram classificados como cerrado pelos dados de referência, após o processo de filtragem). Nestas condições, foi de fato verificado que praticamente *todos* os pontos detectados efetivamente correspondiam a áreas de desflorestamento, conforme visualizado na Figura 6.18 abaixo.

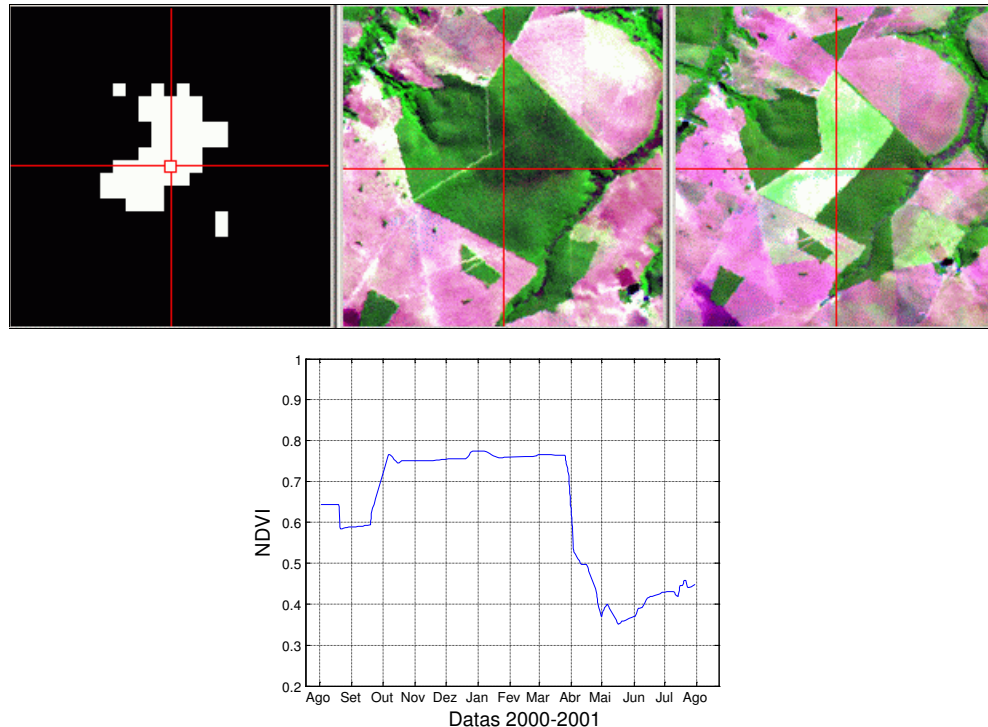


Figura 6.18 Inspeção de área identificada como desflorestamento segundo a metodologia. Observando imagens LANDSAT (composição 5-4-3), foi possível constatar que *pixels* classificados como desflorestamento (acima, à esquerda) efetivamente correspondiam a áreas que estavam anteriormente cobertas por vegetação (imagem de julho de 2000, acima, ao centro) e que foram posteriormente alteradas (imagem de agosto de 2002, acima, à direita). A data precisa da ocorrência do desflorestamento (início de abril de 2001) pode ser averiguada a partir da inspeção do perfil temporal NDVI do ponto em questão (abaixo).

A partir deste resultado, ao se observar a situação geral de desflorestamento para a área de estudos como um todo, pôde-se de fato constatar os níveis absurdos de desmate efetivamente ocorridos em um único ano na região (Figura 6.19). Então, considerando-se que cada *pixel* detectado corresponde a uma área de 6,25 hectares ou 62.500 m² (250m x 250m), foi possível estimar o total de áreas desflorestadas durante o período de análise, chegando-se desta forma a um valor final de 10.237 hectares ou 102,37 km².




Figura 6.19 Visão geral das áreas efetivas de desflorestamento (em vermelho) detectadas na Bacia do Alto Taquari durante o período de análise (Ago/2000 a Jul/2001). A superfície total desmatada foi estimada em 102,37 km², demonstrando o avanço dramático da ocupação antrópica sobre áreas naturais da região.

Adicionalmente, ao se considerar a envergadura deste desflorestamento, deve-se lembrar ainda que, em primeiro lugar, os erros de omissão da metodologia não foram levados em consideração (conforme discutido na seção 6.4.2.1), de maneira que diversas áreas podem ter sido desmatadas na região além daquelas contabilizadas aqui. Além disto, segundo diversos estudos recentes (*e.g.*, Anderson [8], Morton *et al.* [71] e Valeriano *et al.* [108]), cálculos de superfícies de desflorestamento estimadas a partir de dados MODIS são reconhecidamente inferiores aos valores reais ocorridos, uma vez que este sensor não é capaz de captar desmates de pequenas áreas, bem como atividades de extração seletiva que não eliminam completamente a cobertura vegetal. Portanto, o valor de 102,37 km² obtido acima deve ser considerado ainda como uma avaliação bastante conservadora da real dimensão do desflorestamento ocorrido na bacia, o que reforça ainda mais a gravidade da situação averiguada nesta região.

Finalmente, uma análise adicional também foi realizada com relação aos 25% dos *pixels* identificados erradamente como desflorestamento pelo algoritmo automatizado de classificação. Com efeito, foi possível verificar que, na quase totalidade dos casos (99%), estes pontos correspondiam a áreas identificadas como *pastagem* pela classificação de referência. Na realidade, pode-se considerar que esta confusão é bastante compreensível, uma vez que áreas de pasto são frequentemente deixadas em repouso, levando a respostas espectrais semelhantes àsquelas do cerrado (como já discutido na seção 6.4.1.5). Assim, nestes casos, quando o proprietário da terra realiza uma limpeza da área para reutilizá-la como pasto, o resultado observado através dos perfis temporais pode ser confundido com a ocorrência de um desflorestamento real.

Portanto, como observação final, é possível concluir que, em situações nas quais há uma disponibilidade de conhecimento prévio das áreas ocupadas por floresta ou cerrado (a

classificação de referência, neste caso), a metodologia proposta nesta dissertação pode ser efetivamente utilizada para a detecção de desflorestamento automatizado sobre grandes regiões. De outro modo, caso este conhecimento prévio não esteja disponível, é possível constatar que com um ano de dados MODIS é também possível realizar esta mesma detecção, porém nestas condições os erros de comissão podem ser significativos (25% neste estudo de caso). Adicionalmente, pode-se estimar que seja possível, com vários anos de dados MODIS, determinar com maior certeza quais áreas são efetivamente ocupadas por vegetação natural, facilitando a sua diferenciação com relação a áreas de pastagem e permitindo assim um maior nível de confiabilidade para procedimentos de detecção de desflorestamento em larga escala.

6.5 Considerações finais

Ao longo deste capítulo, foram apresentados os procedimentos e resultados alcançados para um estudo de caso na região da Bacia do Alto Taquari, nos estados do Mato Grosso do Sul e Mato Grosso. Neste estudo, foi demonstrada e analisada a aplicação da metodologia tanto para o caso de dados diários de reflectância da superfície terrestre (produtos MOD09GQK e MOD09GST) quanto para o caso de dados de índice de vegetação compostos a cada 16 dias (produto MOD13Q1). A classificação final alcançada para a área de estudos com dados diários de reflectância pode ser visualizada na Figura 6.20 abaixo.

Uma vez computados, os resultados deste estudo de caso foram então discutidos, não apenas com relação à classificação do uso e cobertura do solo de forma geral, como também para o caso específico de detecção de desflorestamento a partir de dados temporais MODIS. Finalmente, uma avaliação geral mais abrangente a respeito da metodologia como um todo será dada a seguir, no último capítulo, onde serão discutidos os pontos positivos e negativos da técnica proposta, bem como considerações gerais a respeito de sua aplicabilidade prática e sugestões de trabalhos futuros com vistas ao aprimoramento dos procedimentos propostos neste trabalho.

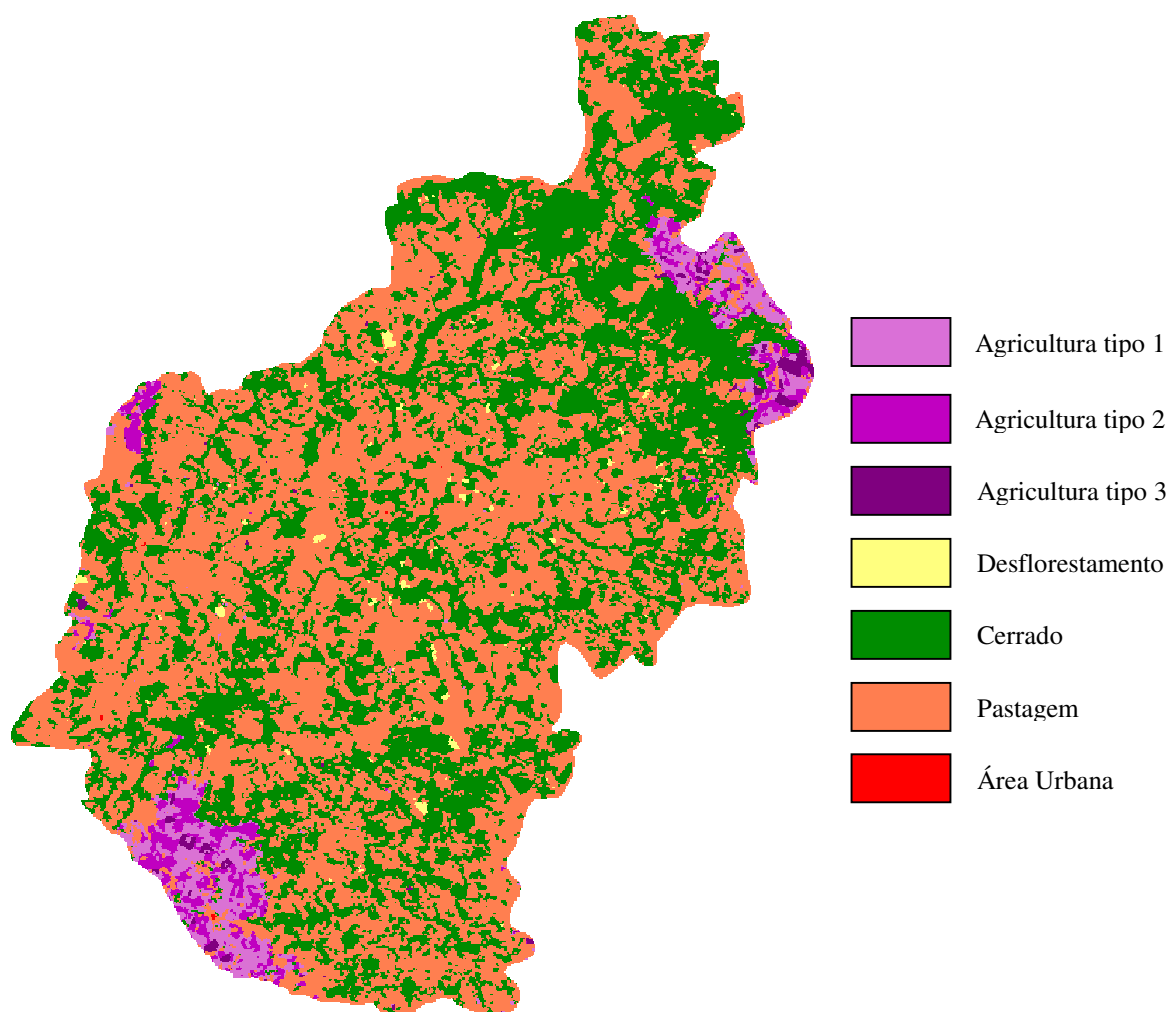


Figura 6.20 Resultado final alcançado para a classificação do uso e cobertura do solo para toda a Bacia do Alto Taquari, computado através da aplicação da metodologia para dados MODIS de reflectância diária da superfície terrestre (produtos MOD09GQK e MOD09GST). Esta classificação se refere ao período entre julho de 2000 e agosto de 2001.

7 Conclusões

Neste último capítulo, será apresentado um balanço geral a respeito desta dissertação, resumindo-se assim as principais virtudes e limitações encontradas ao se aplicar a metodologia proposta. Desta forma, primeiramente serão discutidos os principais resultados alcançados a partir da execução deste trabalho, bem como suas respectivas consequências e implicações (seção 7.1). Em seguida, serão levantadas uma série de perspectivas com relação a trabalhos futuros, de maneira a apontar possibilidades de continuidade para o desenvolvimento da metodologia descrita nesta dissertação (seção 7.2). Por fim, as considerações finais deste trabalho serão fornecidas na seção 7.3.

7.1 Considerações gerais

Nesta dissertação, foi apresentada e testada uma metodologia para o levantamento do uso e cobertura do solo sobre grandes regiões, aproveitando-se, para isso, do baixo custo, extensa cobertura, alta frequência temporal e moderada resolução espacial de dados do sensor MODIS. Esta metodologia está baseada na diferenciação entre classes de uso e cobertura do solo a partir da identificação de padrões temporais característicos de cada classe, que são definidos com o auxílio de métricas ou atributos descritivos dos perfis temporais.

Os procedimentos definidos na metodologia (capítulo 5) foram avaliados num estudo de caso na Bacia do Alto Taquari, Mato Grosso do Sul (capítulo 6), cujos resultados nos permitiram chegar a diversas conclusões interessantes com relação ao tema abordado. Em primeiro lugar, foi possível comprovar o grande potencial deste tipo de abordagem para o mapeamento de áreas extensas de cerrado do Centro-Oeste brasileiro. É possível afirmar, de fato, que este potencial se deve em grande parte à excelente qualidade geral apresentada pelos dados MODIS, tanto para os produtos diários de reflectância da superfície (*i.e.*, MOD09GQK, MOD09GST) quanto para o produto de NDVI resultante da composição de 16 dias de dados (MOD13Q1). Neste sentido, observaram-se primeiramente bons níveis de georreferência dos dados, o que permitiu a construção de seqüências temporais consistentes de forma prática e simples (seção 6.3.1), sem a necessidade de se executarem procedimentos adicionais de correção geométrica das imagens (apesar dos pequenos problemas encontrados em pontos de transição entre classes distintas de uso e cobertura do solo, como demonstrado na Figura 6.13 e seções 6.4.1.3 e 6.4.2.2). Mais do que isso, entretanto, constatou-se a extrema importância das informações de qualidade *pixel a pixel* disponibilizadas pela NASA em conjunto com os seus produtos. Esta estratégia permitiu que se efetuasse uma filtragem automatizada e bastante

razoável dos dados temporais (seção 6.3.1.2), eliminando assim a necessidade de se desenvolverem e executarem algoritmos de detecção de nuvens, sombras, ou aerossóis, dentre outros problemas.

Adicionalmente, a política de distribuição de dados MODIS em diferentes níveis de processamento (seção 4.3.2) permitiu que, de um lado, fossem incorporadas importantes etapas de pré-processamento validadas pela própria NASA, tais como o processo de correção atmosférica das imagens. Por outro lado, esta política garantiu também uma certa flexibilidade para a metodologia, de modo a permitir escolher, conforme a necessidade, entre uma maior riqueza temporal de informações (a partir de produtos diários) ou um menor volume de dados combinado com necessidades também menores de processamento (usando o produto de composição de 16 dias), tal como discutido na seção 6.4.1.5.

Deve-se dizer também que a resolução espacial de 250m dos dados MODIS também se mostrou suficiente para capturar a complexidade do uso e cobertura da terra na área estudada, conforme já afirmado por Townshend *et al.* [98], Strahler *et al.* [95] e Wessels *et al.* [112], entre outros. Com efeito, no experimento descrito nesta dissertação, foi observado ser realmente possível o uso de classificações “duras” (*i.e.*, atribuindo uma única classe a cada *pixel*), uma vez que se verificou que mais de 70% da região estudada correspondia a áreas homogêneas a 250m de resolução (seções 6.3.2 e 6.4.1.1).

Com relação ao desempenho da metodologia proposta em si, pôde-se concluir ser perfeitamente possível a sua aplicação para a classificação automatizada de áreas de agricultura, pastagem e cerrado. De fato, os resultados obtidos na área de estudos demonstraram um alto potencial a este respeito, verificando-se uma acurácia global superior a 90% na classificação de áreas homogêneas destas três classes (seção 6.4.1.2, Tabela 6.3). Além disso, o alto grau de automatização atingido, onde quase todas as etapas do processo podem ser executadas sem qualquer intervenção humana, indica ser de fato viável a aplicação desta técnica para regiões ainda muito maiores do que aquela abordada neste estudo de caso. A estas conclusões, deve-se somar ainda o fato de que a quase totalidade dos procedimentos desta metodologia foi efetivamente implementada em linguagem C no curso deste trabalho. Assim, a aplicação desta técnica para outros casos práticos está livre de maiores impedimentos financeiros associados à compra de programas de uso comercial, garantindo assim um baixo custo de utilização e uma maior liberdade para a adaptação e/ou aperfeiçoamento dos procedimentos implementados.

Sob um outro aspecto, pôde-se concluir também que a metodologia de classificação atingiu um nível interessante de flexibilidade, graças à sua abordagem baseada em atributos

descritivos dos perfis temporais (seções 5.3 e 6.3.4). Assim, conforme sugerido por outros pesquisadores [23][95][101], a estratégia de se utilizarem informações de um maior nível de abstração proporcionou dados mais concisos e pertinentes, reduzindo a sua dimensionalidade e garantindo ainda uma maior robustez com relação a ruídos, interferências e variabilidades intra-classe. De fato, o estudo de caso demonstrou ser desta forma possível diferenciar padrões temporais de natureza bastante distinta e com bastante sucesso, tornando viável tanto uma detecção de desflorestamento quanto uma discriminação de diferentes tipos de cultura agrícola, o que demonstra a variabilidade de aplicações possíveis de serem abordadas.

Especificamente com relação ao processo de detecção de desflorestamento, os resultados alcançados no estudo de caso (seção 6.4.2) corroboraram a tese de que dados temporais MODIS são capazes de capturar este tipo de alteração da cobertura do solo, conforme já sugerido por Shimabukuro *et al.* [92], Valeriano *et al.* [108] e Morton *et al.* [71], entre outros. Neste sentido, apesar da falta de dados de campo para uma validação efetiva dos resultados alcançados, a inspeção visual de dados LANDSAT de maior resolução permitiu que se comprovasse a ocorrência de desflorestamento em praticamente todos os pontos de floresta ou cerrado identificados como desmatados pelo algoritmo. Além disso, o procedimento desenvolvido neste trabalho também se mostrou capaz de, com apenas 1 ano de dados, detectar corretamente a ocorrência deste fenômeno em 75% dos casos mesmo sem o conhecimento prévio das áreas ocupadas por vegetação natural.

7.2 Trabalhos futuros

Uma vez analisados os resultados e implicações gerais do trabalho realizado, torna-se também importante realizar uma reflexão adicional de modo a apontar possibilidades interessantes de pesquisa a partir da metodologia desenvolvida nesta dissertação.

Desta forma, antes de mais nada, é preciso destacar a extrema importância de se aplicar esta metodologia com base num período de análise mais extenso, de modo a se incorporarem diversos anos de dados no estudo. De fato, a consideração de 2 a 4 anos de dados permitiria, em primeiro lugar, uma caracterização muito mais acurada do real *uso* da terra, em contraste com a cobertura verificada durante um único ano. Assim, tarefas como a diferenciação entre cerrado e pastagem (e conseqüentemente entre real desflorestamento e simples manejo do pasto) seriam muito facilitadas, uma vez que grande parte desta confusão se deve à regeneração da vegetação nativa em áreas de pastagem deixadas temporariamente em repouso (seções 6.4.1.5 e 6.4.2.2). Além disso, esta análise pluri-anual de dados também proporcionaria uma significativa melhora na compreensão da dinâmica do uso da terra em

áreas agrícolas, dada a impossibilidade, com um ano de dados, de se caracterizarem adequadamente aquelas áreas usadas temporariamente para pasto, no contexto de sistemas sustentáveis de rotação de culturas e integração lavoura-pecuária (Figura 6.15, seção 6.4.1.5).

Um outro aspecto importante de se analisarem vários anos de dados diz respeito à avaliação do potencial desta metodologia para o efetivo monitoramento do uso e cobertura do solo por longos períodos e de forma operacional. Neste sentido, poderia-se investigar a estabilidade e robustez dos atributos computados como forma de caracterização das diferentes classes ao longo de anos sucessivos. Assim, conforme os resultados alcançados, tornaria-se possível, a partir de uma classificação inicial, acompanhar as mudanças de uso e cobertura do solo ao longo dos anos exclusivamente com base nos dados MODIS, tornando o processo como um todo ainda mais interessante do ponto de vista de baixos custos e altos níveis de automação.

Outros pontos interessantes a serem ainda investigados dizem respeito ao algoritmo de classificação em si. Conforme discutido na seção 5.5, neste trabalho foi adotada a técnica clássica de *máxima verossimilhança*, devido à sua simplicidade, facilidade de implementação, e longo histórico de aplicação em problemas de sensoriamento remoto. Entretanto, atualmente se encontram disponíveis na literatura uma série de algoritmos mais sofisticados e de melhor desempenho, que poderiam ser aplicados de modo a incrementar os resultados alcançados. Em particular, poderia-se considerar o emprego de algoritmos de classificação não-paramétricos, tais como árvores de decisão construídas automaticamente (*decision-tree classifiers* [81] ou redes neurais baseadas em teoria de ressonância adaptativa e lógica nebulosa (*fuzzy ARTMAP* [19])). Assim, tornaria-se possível evitar suposições de *gaussianidade* com relação às distribuições de probabilidade dos dados de entrada, permitindo assim a análise de classes com distribuições multimodais de probabilidade, além de facilitar a interpretação final do processo de classificação realizado. Desta forma, em certos casos, poderia-se até mesmo eliminar a necessidade de subdivisão das classes originais (seções 5.2.2 e 6.3.3), uma vez que, em tese, o algoritmo de classificação seria capaz de identificar as sub-classes existentes de forma automática.

Sob um outro aspecto, a investigação de novos algoritmos para a classificação também poderia explorar as possibilidades de se tratar o problema do *pixel* misturado. Como discutido nas seções 6.4.1.3 e 6.4.1.4, os procedimentos de detecção e tratamento de *pixels* contendo mais de uma classe foram avaliados como sendo úteis, porém com desempenho aquém do ideal. Com efeito, poderia-se considerar a alternativa de se utilizarem algoritmos de classificação baseados em regiões (também conhecidos como métodos “orientados a objeto” [14]), que poderiam melhorar a classificação de regiões homogêneas e facilitar a correta

identificação da localização e natureza das áreas de transição entre classes distintas. Ao mesmo tempo, estas técnicas também seriam úteis para minimizar o efeito de salpicamento verificado em pontos isolados de perfis temporais excessivamente contaminados por algum tipo de ruído, tais como aqueles provocados pelos pequenos erros de georreferência das imagens MODIS (Figura 6.13 e seções 6.4.1.3 e 6.4.2.2). Entretanto, não obstante suas aparentes vantagens, a aplicação deste tipo de técnica em imagens de 250m de resolução espacial pode ser também bastante questionada, uma vez que áreas contíguas de dimensões relativamente pequenas (*e.g.*, menos de 4 *pixels* ou 25 hectares) podem terminar sendo ignoradas pelo algoritmo. Portanto, pode-se inferir aqui que a aplicabilidade deste tipo de algoritmo estará efetivamente dependente da região em estudo e da natureza das classes de interesse sendo investigadas.

Finalmente, com relação às possíveis aplicações da metodologia descrita nesta dissertação, deve-se enfatizar também a possibilidade de se utilizarem atributos especificamente concebidos para a detecção de padrões de particular interesse, viabilizando-se a utilização de um certo grau de *conhecimento* de forma a facilitar o processo classificatório. Assim, como observado no estudo de caso, capacita-se o algoritmo a ser aplicado em uma grande variedade de contextos, tais como detecção de desflorestamento e discriminação de cultivos agrícolas. De fato, o grande potencial para a identificação de diferentes tipos de atividade agrícola, embora levantado na seção 6.3.3 ao se realizar a subdivisão da classe original *agricultura*, foi efetivamente muito pouco explorado neste trabalho devido à ausência de dados de referência para a avaliação dos resultados computados. De todo modo, as observações realizadas naquela seção evidenciaram a possibilidade de se utilizarem atributos relativos aos modos temporais (*e.g.*, número de modos, data, largura, etc.) de forma a diferenciar áreas de cultivo de trigo, soja, e soja seguida de milho de safrinha (Figura 6.9), além da identificação da presença ou não de milheto anteriormente ao plantio de soja.

Mais do que isso, entretanto, a concepção de atributos descritivos mais elaborados permitiria que se realizasse um verdadeiro monitoramento da utilização de técnicas sustentáveis de cultivo agrícola. Neste sentido, poderia-se acompanhar a expansão da área agrícola onde são adotados sistemas de *plantio direto* (SPD, veja Mazuchowski e Derpsch [67]) e de *integração lavoura-pecuária* (ILP, veja Alves e Pelissari [6]). Especificamente, em cada área identificada como agricultura, poderia-se observar o perfil temporal, identificar o período de plantio ocorrido, e então, considerando este período, verificar a presença ou ausência de solo exposto (como por exemplo a partir de um limiar máximo de NDVI). Adicionalmente, uma vez definidos os algoritmos para identificação de diferentes culturas, poderia também ser

realizada uma avaliação do uso específico da terra em áreas agrícolas ao longo de anos subsequentes, de maneira a poder caracterizar a rotação de culturas. Assim, a identificação de áreas com integração lavoura-pecuária se tornaria possível a partir da análise de seqüências temporais de imagens cobrindo períodos de 2 a 4 anos, podendo-se caracterizá-la através da verificação de um encadeamento pastagem – lavoura – pastagem, sem revolvimento do solo e com rotação de culturas anuais.

7.3 Considerações finais

Como conclusão final deste trabalho, pode-se afirmar que a metodologia aqui apresentada permite o monitoramento de baixo custo de diversos fenômenos ligados à dinâmica do uso e cobertura do solo e importantes para o planejamento regional. Deste modo, conclui-se ser efetivamente possível utilizar procedimentos como estes para acompanhar, em larga escala, processos como o avanço do desflorestamento e a expansão da fronteira agrícola, de maneira a viabilizar a adoção de medidas de preservação ambiental e orientar políticas de desenvolvimento sustentável no Brasil.

Apêndice A: Especificações de Sensores

A.1. MODIS

As especificações do sensor MODIS estão dispostas no capítulo 4.

A.2. NOAA/AVHRR

O sensor AVHRR (*Advanced Very High Resolution Radiometer*) vem sendo enviado ao espaço há quase 25 anos a bordo de uma série de satélites construídos e operados pela agência norte-americana NOAA (*National Oceanic and Atmospheric Administration*). Este sensor foi originalmente concebido para aplicações meteorológicas, e por conta disto seus dados são distribuídos gratuitamente, podendo ser adquiridos pela Internet no endereço <http://www.saa.noaa.gov>.

Existem basicamente dois tipos de dados disponíveis: dados de cobertura local (LAC, *Local Area Coverage*) e de cobertura global (GAC, *Global Area Coverage*). O primeiro tipo de dado representa as informações coletadas pelo sensor na sua resolução máxima (aproximadamente 1,1km por *pixel*), ao passo que o segundo corresponde a uma reamostragem destas informações básicas para uma resolução mais baixa (aproximadamente 4,4km por *pixel*). A vantagem do dado GAC se deve ao fato dele ser registrado de forma contínua a bordo do satélite, enquanto que o dado LAC é enviado para bases de recepção regionais em terra. A consequência disto é que o dado LAC possui alguns problemas de continuidade temporal, além de não ser georreferenciado de forma unificada com dados de bordo do satélite, o que resulta em um dado um pouco menos confiável [101].

Além destas diferenças quanto ao formato do dado, é importante lembrar também que, ao longo dos anos, versões levemente diferentes do sensor AVHRR foram construídas. A seguir, encontram-se as especificações dos dados deste sensor em sua terceira versão (AVHRR/3), versão esta colocada a bordo dos satélites NOAA-15, NOAA-16 e NOAA-17 (cujos nomes, antes do lançamento, eram respectivamente NOAA-K, NOAA-L e NOAA-M):

Período de revisita	24h (visível), 12h (termal)
Altitude	833km
Largura de faixa	2399km
Resolução no nadir	1,09km (LAC) 4,36km (GAC)
<i>Canais</i>	<i>Bandas Espectrais</i>
1. Visível (vermelho)	0,580 – 0,680 μm
2. Infra-vermelho próximo	0,725 – 1,100 μm
3A. Infra-vermelho médio ¹	1,580 – 1,640 μm
3B. Infra-vermelho médio	3,550 – 3,930 μm
4. Infra-vermelho termal	10,300 – 11,300 μm
5. Infra-vermelho termal	11,500 – 12,500 μm

Tabela A.1 Especificações do sensor NOAA/AVHRR
Fonte: NOAA [75]

A.3. CBERS/WFI

O sensor WFI (*Wide Field Imager*) se encontra a bordo dos satélites CBERS-1 e CBERS-2 (*China-Brazil Earth Resources Satellite*). Estes satélites foram desenvolvidos pelo Brasil em parceria com a República Popular da China, tendo sido lançados ao espaço respectivamente em 1999 e 2003. Em particular, é importante destacar que o sensor WFI foi inteiramente desenvolvido no País pelo INPE (Instituto Nacional de Pesquisas Espaciais), sendo o processamento de suas imagens também realizado com tecnologia nacional. Dados deste sensor podem ser encontrados no catálogo de imagens mantido pelo INPE no endereço <http://www.dgi.inpe.br/CDSR>.

As especificações do sensor CBERS/WFI são as seguintes:

Período de revisita	5 dias
Altitude	778km
Largura de faixa	890km
Resolução no nadir	260m
<i>Canais</i>	<i>Bandas Espectrais</i>
1. Vermelho	0,63 – 0,69 μm
2. Infra-vermelho próximo	0,77 – 0,89 μm

Tabela A.2 Especificações do sensor CBERS/WFI
Fonte: INPE [50]

A.4. SPOT/VEGETATION

O sensor VEGETATION se encontra a bordo dos satélites SPOT-4 e SPOT-5, enviados ao espaço respectivamente em 1998 e 2002 pela França, dentro do programa *Système Pour l'Observation de la Terre* (SPOT), concebido e desenvolvido pelo CNES (*Centre National*

¹ Somente 5 canais são registrados de cada vez, sendo os canais 3A e 3B comutados respectivamente para passagens noturnas e diurnas do satélite (o canal 3A foi introduzido a partir do satélite NOAA-15)

d'Études Spatiales). Como ocorre com todos os dados deste programa, as imagens do VEGETATION não são em princípio distribuídas de forma gratuita, devendo assim ser adquiridas comercialmente junto à SPOT Image (<http://www.spotimage.com>). Também chamado simplesmente de “VGT”, este sensor pode ser considerado como um dos primeiros instrumentos especificamente concebidos para a tarefa de monitoramento global da vegetação.

As especificações deste sensor são as seguintes:

Período de revisita	1 dia
Altitude	832km
Largura de faixa	2250km
Resolução no nadir	1 km
<i>Canais</i>	<i>Bandas Espectrais</i>
1. Azul	0,43 – 0,47 μm
2. Vermelho	0,61 – 0,68 μm
3. Infra-vermelho próximo	0,79 – 0,89 μm
4. Infra-vermelho médio	1,58 – 1,75 μm

Tabela A.3 Especificações do sensor SPOT/VEGETATION
Fonte: Lillesand e Kiefer [61]

A.5. Série LANDSAT

O programa LANDSAT corresponde ao mais longo e bem-sucedido programa de satélites para o sensoriamento remoto de recursos terrestres, proporcionando há décadas um levantamento sistemático da superfície terrestre a médias ou altas resoluções espaciais. Iniciado ainda em 1967 pela agência norte-americana NASA (*National Aeronautics and Space Administration*), o primeiro satélite da série foi lançado ao espaço em 1972, sendo seguido por outros 6 exemplares e culminando com o lançamento do LANDSAT 7 em 1999.

Na realidade, as características dos sensores carregados por estes satélites variaram bastante ao longo da evolução do programa. O sensor RBV (*Return Beam Vidicon*) foi utilizado nas três primeiras edições da série para imageamentos na faixa do visível. Já o sensor MSS (*Multispectral Scanner*) foi empregado desde o LANDSAT 1 até o LANDSAT 5, apresentando resolução espacial de aproximadamente 80m para as faixas do visível e infra-vermelho próximo. A partir do lançamento do satélite LANDSAT 4, começou-se a empregar o sensor TM (*Thematic Mapper*), com resolução espacial de 30m em diversas bandas do visível, infra-vermelho próximo e infra-vermelho médio. Modificações e aperfeiçoamentos deste sensor levaram à produção dos sensores ETM (*Enhanced Thematic Mapper*), e ETM+ (*Enhanced Thematic Mapper Plus*), que foram respectivamente colocados a bordo nos satélites LANDSAT 6 (perdido no lançamento) e LANDSAT 7.

Apesar de todo o seu sucesso, a situação do programa LANDSAT se encontra um pouco confusa no presente momento. O satélite LANDSAT 7 (ETM+) apresentou uma falha operacional em 31 de maio de 2003, de modo que todas as imagens captadas posteriormente apresentam uma perda significativa de informações. Alternativamente, têm-se utilizado imagens do LANDSAT 5 (TM), um satélite que se encontra em órbita desde 1984 e já passou em muito a sua expectativa de vida útil de apenas 3 anos.

Dados e informações gerais acerca do programa LANDSAT podem ser obtidos no endereço <http://landsat.usgs.gov>. A aquisição de dados LANDSAT não é gratuita, e pode ser feita no Brasil junto ao INPE (Instituto Nacional de Pesquisas Espaciais), no endereço <http://www.dgi.inpe.br>.

As especificações dos sensores TM e ETM+ são as seguintes:

Período de revisita	16 dias
Altitude	705km
Largura de faixa	185km
Resolução no nadir	30m (bandas 1-5, 7)
	120m (banda 6, TM)
	60m (banda 6, ETM+)
	15m (banda 8, ETM+)

<i>Canais</i>	<i>Bandas Espectrais</i>
1. Azul	0,45 – 0,52 μm
2. Verde	0,52 – 0,60 μm
3. Vermelho	0,63 – 0,69 μm
4. Infra-vermelho próximo	0,76 – 0,90 μm
5. Infra-vermelho médio	1,55 – 1,75 μm
6. Infra-vermelho termal	10,4 – 12,5 μm
7. Infra-vermelho médio	2,08 – 2,35 μm
8. Pancromático (ETM+)	0,50 – 0,90 μm

Tabela A.4 Especificações dos sensores TM (LANDSAT 5) e ETM+ (LANDSAT 7)
Fonte: Lillesand e Kiefer [61]

Referências

- [1] Abdon, M. M. (2004). “Os impactos ambientais no meio físico - Erosão e assoreamento na bacia hidrográfica do rio Taquari, MS, em decorrência da pecuária”. Tese de Doutorado, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP, Brasil.
- [2] Abdon, M. M., Silva, J. S. V., Santos, R. F. (2004). “Mapeamento Fotográfico da Bacia Hidrográfica do Rio Taquari (BHRT) MS/MT”. ISBN 85-17-00013-7, São José dos Campos: Inpe; Campinas: CNPTIA Embrapa.
- [3] Ackerman, S., Strabala, K., Menzel, P., Frey, R., Moeller, C., Gumley, L., Baum, B., Seeman, S.W., Zhang, H. (2002). “Discriminating clear-sky from cloud with MODIS”. MOD35 Algorithm Theoretical Basis Document (ATBD), version 4.0, MODIS Cloud Mask Team, National Aeronautics and Space Administration (NASA), USA.
- [4] Adams, J. B., Smith, M. O., Johnson, P. E. (1986). “Spectral mixture modeling: A new analysis of rock and soil types at the Viking Lander 1 site”. Journal of Geophysical Research, vol. 91, no. B8, pp. 8098–8112.
- [5] Aguiar, M. C., Ferreira, L. G., Ferreira, M. E., Borges, R. O., Sano, E. E., Gomes, M. P. (2005). “Mapeamento do Uso do Solo e da Cobertura Vegetal do Bioma Cerrado a partir de dados orbitais MODIS e SRTM e dados Censitários”. In: Anais do XII Simpósio Brasileiro de Sensoriamento Remoto (SBSR), pp. 2799-2801, 16-21 abril, Goiânia, GO, Brasil.
- [6] Alves, S. J. Moraes, A., Pelissari, A. (2004). “Integração Lavoura Pecuária”. Grupo de Estudo de Nutrição de Ruminantes, Departamento de Melhoramento e Nutrição Animal, FCA-FMVZ-Unesp Botucatu, SP, Brasil.
- [7] Anderson, L. O., Latorre, M. L., Shimabukuro, Y. E., Arai, E., Carvalho Júnior, O. A. (2003). “Sensor MODIS: uma abordagem geral”. INPE-10131-RPQ/752, Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, SP, Brasil.
- [8] Anderson, L. O. (2004). “Classificação e monitoramento da cobertura vegetal de Mato Grosso utilizando dados multitemporais do sensor MODIS”. Dissertação de Mestrado em Sensoriamento Remoto, INPE-12290-TDI/986, Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, SP, Brasil.

- [9] Atkinson, P. M., Cutler, M. E. J., Lewis H. (1997). "Mapping sub-pixel proportional land cover with AVHRR imagery". *International Journal of Remote Sensing*, vol. 18, no. 4, pp. 917–935.
- [10] Belward, A. (ed.) (1996). "The IGBP-DIS Global 1-km Land Cover Data Set DISCover". IGBP-DIS Working Paper.
- [11] Bezdek, J. C. (1981). "Pattern Recognition with Fuzzy Objective Function Algorithms". ISBN 0-306-40671-3, Kluwer Academic Publishers, Norwell, MA, USA.
- [12] Bezdek, J. C., Ehrlich, R., Full, W. (1984). "FCM: The fuzzy c-means clustering algorithm". *Computers and Geosciences* 10, pp. 191-203.
- [13] Bittner, M. (acesso em 2005). "Winkelabhängige Reflexionseigenschaften: BRDF", <http://www.caf.dlr.de/caf/anwendungen/umwelt/bodenbedeckung/brdf>, Deutsches Zentrum für Luft- und Raumfahrt (DLR), Germany.
- [14] Blaschke, T., Lang, S., Lorup, E., Strobl, J. and Zeil, P. (2000). "Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications". In: *Environmental Information for Planning, Politics and the Public*, eds. Cremers, A. & Greve, K., vol. 2, pp. 555-570, Metropolis Verlag, Marburg, Germany.
- [15] Borak, J. S., Strahler, A. H. (1999). "Feature selection and land cover classification of a MODIS-like data set for a semiarid environment". *International Journal of Remote Sensing*, vol. 20, no. 5, pp. 919–938.
- [16] Bouzidi, S., Lahoche, F., Herlin, I. (2000). "Land use classification at meso-scale using remotely sensed data". In: *Proceedings of the 19th ISPRS Congress and Exhibition, geoinformation for all*, Amsterdam, Netherlands.
- [17] Bueno, M. C. D., Meirelles, M. S. P., Coutinho, H. L. da C. (2003). "Utilização de redes de dependência para a avaliação do impacto erosivo da Bacia do Alto Taquari". In: *Anais do IV Congresso Brasileiro da Sociedade Brasileira de Informática Aplicada à Agropecuária e à Agroindústria*, vol. 1, pp. 233-238, Porto Seguro, BA, Brasil.
- [18] Caron, J. (2004). "Qu'est-ce qu'une BRDF?", <http://jecaron.free.fr/brdf.html>, France.

- [19] Carpenter, G. A., Grossberg, S., Markuzon, N., Reynolds, J.H., Rosen, D. B. (1992). "Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps". *IEEE Transactions on Neural Networks* 3, pp. 698-713.
- [20] Carpenter, G. A., Gopal, S., Macomber, S., Martens, S., Woodcock, C. E. (1999). "A neural network method for mixture estimation for vegetation mapping". *Remote Sensing of Environment*, vol. 70, no. 2, pp. 138–152.
- [21] Cohen J. (1960). "A coefficient of agreement for nominal scales". *Educational and Psychological Measurement*, vol. 20, pp. 37-46.
- [22] DeFries, R. S., Townshend, J. R. G. (1994). "NDVI-derived land cover classifications at a global scale". *International Journal of Remote Sensing*, vol. 15, no. 17, pp. 3567–3586.
- [23] DeFries, R. S., Hansen M. C., Townshend, J. R. G. (1995). "Global discrimination of land cover types from metrics derived from AVHRR pathfinder data". *Remote Sensing of Environment*, vol. 54, no. 3, pp. 209–222.
- [24] DeFries, R. S., Townshend, J. R. G., Hansen, M. C. (1999). "Continuous fields of vegetation characteristics at the global scale at 1-km resolution". *Journal of Geophysical Research-Atmospheres*, vol. 104, no. D14, pp. 16911-16923.
- [25] Di Gregorio, A. (2000). "Land Cover Classification System, LCCS, Classification Concepts and User Manual". Version 1.0. Food and Agriculture Organization of the United Nations (FAO), United Nations Environment Programme (UNEP), Rome, Italy.
- [26] Duarte, V., Shimabukuro, Y. E., Santos, J. R., Mello, E. M. K., Moreira, J. C., Moreira, M. A., Souza, R. C. M., Shimabukuro, R. M. K., Freitas, U. M. (1999). "Metodologia para criação do PRODES Digital e do banco de dados digitais da Amazônia: Projeto BADDAM". INPE-7032-PUD/035, Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, SP, Brasil.
- [27] Duda, R. O., Hart, P. E., Stork, D. G. (2001). "Pattern Classification", 2nd ed. ISBN 0-471-05669-3, John Wiley & Sons, USA.
- [28] EEA – European Environment Agency (1994). "CORINE Land Cover Technical Guide". Environment series EUR 12585EN, ISBN 92-826-2578-8, Office for

- [29] Eva, H. D., Miranda, E. E., Di Bella, C. M., Gond, V., Huber, O., Sgrenzaroli, M., Jones, S., Coutinho, A., Dorado, A., Guimarães, M., Elvidge, C., Achard, F., Belward, A. S., Bartholomé, E., Baraldi, A., De Grandi, G., Vogt, P., Fritz, S., Hartley, A. (2002). "A Vegetation Map of South America". Environment series EUR 20159EN, ISBN 92-894-4449-5, Office for Official Publications of the European Communities, Luxembourg.
- [30] Fayyad, U. M., Irani, K. B. (1993). "Multi-interval discretization of continuous-valued attributes for classification learning". In: Proceedings of the 13th International Joint Conference on Artificial Intelligence IJCAi-93, Chambéry, France.
- [31] Ferreira, L. G., Silva, A. A., Jesus, E. T., Sano, E. E., Shimabukuro, Y. E. (2003). "Monitoramento sistemático da cobertura vegetal no bioma cerrado através dos índices de vegetação MODIS". In: Anais do XI Simpósio Brasileiro de Sensoriamento Remoto (SBSR), pp. 2729-2736, 05-10 abril, Belo Horizonte, MG, Brasil.
- [32] Foody, G. M., Cox, D. P. (1994). "Sub-pixel land cover composition estimation using a linear mixture model and fuzzy membership functions". International Journal of Remote Sensing, vol. 15, no. 3, pp. 619-631.
- [33] Foody, G. M., Lucas, R. M., Curran, P. J., Honzak, M. (1997). "Non-linear mixture modeling without end-members using an artificial neural network". International Journal of Remote Sensing, vol. 18, no. 4, pp. 938-953.
- [34] Friedl, M. A., McIver, D. K., Hodges, J. C. F., Zhang, X. Y., Muchoney, D., Strahler, A. H., Woodcock, C. E., Gopal, S., Schneider, A., Cooper, A., Baccini, A., Gao, F., Schaaf, C. (2002). "Global land cover mapping from MODIS: algorithms and early results". Remote Sensing of Environment, vol. 83, no. 1-2, pp. 287-302.
- [35] Fritz, S., Bartholomé, E., Belward, A. S., Hartley, A., Stibig, H-J., Eva, H., Mayaux, P., Bartalev, S., Latifovic, R., Kolmert, S., Sarathi Roy, R., Aggarwal, S., Bingfang, W., Wenting, X., Ledwith, M., Pekel, J., Giri, C., Mucher, S., De Badts, E., Tateishi, R., Champeaux, J., Defourny, P. (2003). "Harmonisation, mosaicing and production of the Global Land Cover 2000 database". Publications of the

European Communities, EUR 20849EN, ISBN 92-894-6332-5, Office for Official Publications of the European Communities, Luxembourg.

- [36] Galdino, S., Risso, A., Soriano, B. M. A., Vieira, L. M., Pott, A., Padovani, C. R., Melo, E. C., Almeida Junior, N. (2003). “Perdas de solo na bacia do alto Taquari”. Boletim de Pesquisa e Desenvolvimento 44, Embrapa Pantanal, Corumbá, MS, Brasil.
- [37] Galdino, S., Vieira, L. M., Soriano, B. M. A. (2003). “Erosão na Bacia do Alto Taquari”. Documentos 52 (ISSN 1517-1981; 52), Embrapa Pantanal, Corumbá, MS, Brasil.
- [38] Gira, C., Zhub, Z., Reeda, B. (2005). “A comparative analysis of the Global Land Cover 2000 and MODIS land cover data sets”. Remote Sensing of Environment, vol. 94, no. 1, pp. 123–132.
- [39] Godoy, J. M., Padovani, C. R., Pereira, J. C. A, Vieira, L. M., Carvalho, Z. L., Galdino, S. (1999). “Evaluation of the river Taquari, Pantanal, Brazil, silting up based on the ^{210}Pb geochronology of floodplain lakes sediments”. 3rd International Symposium Environmental Geochemistry In Tropical Countries, Nova Friburgo, RJ, Brasil.
- [40] Goldberg, D. E. (1989). “Genetic algorithms in search, optimization and machine learning”. ISBN 0-201-15767-5, Addison-Wesley Longman Publishing, Boston, MA, USA.
- [41] Hagen, S. C., Braswell, B. H., Froking, S., Salas, W. A., Xiao, X. (2002). “Determination of subpixel fractions of nonforested area in the Amazon using multiresolution satellite sensor data”. Journal of Geophysical Research, vol. 107, no. D20, pp. 8049.
- [42] Hall, M. A. (1999). “Correlation-based feature subset selection for machine learning”. PhD thesis, Department of Computer Science, University of Waikato, New Zealand.
- [43] Hansen, M. C., DeFries, R. S., Townshend, J. R. G., Sohlberg, R. A. (2000). “Global land cover classification at 1km resolution using a decision tree classifier”. International Journal of Remote Sensing, vol. 21, no. 6-7, pp. 1331-1364.
- [44] Hansen, M. C., DeFries, R. S., Townshend, J. R. G., Sohlberg, R. A., Dimiceli, C., Carroll, M. (2002). “Towards an operational MODIS continuous field of percent

- tree cover algorithm: Examples using AVHRR and MODIS data”. *Remote Sensing of Environment*, vol. 83, no. 1-2, pp. 303–319.
- [45] Holben, B. N. (1986). “Characteristics of maximum-value composite images from multitemporal AVHRR data”. *International Journal of Remote Sensing* vol. 7, pp. 1417–1434.
 - [46] Holben, B. N., Shimabukuro, Y. E. (1993). “Linear mixing applied to coarse spatial resolution data from multispectral satellite sensors”. *International Journal of Remote Sensing*, vol. 14, no. 11, pp. 2231-2240.
 - [47] Horwitz, H. M., Nalepka, R. F., Hyde, P. D., Morganstern, J. P. (1971). “Estimating the proportion of objects within a single resolution element of a multispectral scanner”. Technical Report NASA Contract NAS-9-9784, University of Michigan, Ann Arbor, MI, USA.
 - [48] Houet, T., Hubert-Moy, L., Mercier, G., Gouéry, P. (2003). “Estimation and monitoring of bare soil vegetation ratio with SPOT vegetation and HRVIR”. *IGARSS 2003: International Symposium on Geoscience and Remote Sensing*, 21-25 July, Toulouse, France.
 - [49] IGBP - International Geosphere-Biosphere Programme (1992). “Requirements for Terrestrial Biospheric Data for IGBP Core Projects”. IGBP-DIS Working Paper #2 (June 1992), IGBP-DIS, Université de Paris, Paris, France.
 - [50] INPE (2004), “As câmeras dos satélites CBERS-1 e 2”, <http://www.cbers.inpe.br>, Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, SP, Brasil.
 - [51] Iverson, L. R., Cook, E. A., Graham, R. L. (1989). “A technique for extrapolating and validating forest cover across large regions: Calibrating AVHRR with TM data”. *International Journal of Remote Sensing*, vol. 10, no. 11, pp. 1805-1812.
 - [52] Iverson, L. R., Cook, E. A., Graham, R. L. (1994). “Regional forest cover estimation via remote sensing: The calibration center concept”. *Landscape Ecology*, vol. 9, pp. 159–174.
 - [53] Jobbágy, E., Paruelo, J., Fernández, R., Oesterheld, M., Coutinho, H., Meirelles, M., Altesor, A., Panario, D., Piñeiro, D., Coronel, G., Di Bella, C., Viglizzo, E., Schlichter, T., Maceira, J., Podestá, G., Hoffmann, W., Jackson, R., Epstein, H. (2005). “Land use change in the Rio de la Plata Basin: Linking biophysical and human factors to understand trends, assess impacts, and support viable strategies for

- the future”. Research proposal, 2nd Round of the IAI Collaborative Research Network (CRN II), Inter-American Institute for Global Change Research (IAI).
- [54] Justice, C. O., Vermote, E., Townshend, J. R. G., DeFries, R. S., Roy, P. D., Hall, D. K., Salomonson, V., Privette, J. L., Riggs, G., Strahler, A., Lucht, W., Myneni, B., Knyazikhin, Y., Running, W. S., Nemani, R. R., Wan, Z., Huete, A. R., Leeuwen, W. V., Wolfe, R. E., Giglio, L., Muller, J. P., Lewis, P., Barnsley, M. (1998). “The Moderate Resolution Imaging Spectroradiometer (MODIS): land remote sensing for global change research”. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 36, no. 4, pp.1228-1247.
 - [55] Knipling, E. B. (1970). “Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation”. *Remote Sensing of Environment*, vol. 1, no. 3, pp. 155-159.
 - [56] Korner, C. (1993). “Leaf diffusive conductances in the major vegetation types of the world”. In E. D. Schulze and M. M. Caldwell (eds.), *Ecophysiology of Photosynthesis*, Springer-Verlag, Berlin, Germany, pp. 463-490.
 - [57] Kohonen, T. (2001). “Self Organizing Maps”, 3rd ed. ISBN 3-540-67921-9, Springer-Verlag, Berlin, Germany.
 - [58] Kung, S. Y. (1993). “Digital Neural Networks”. ISBN 0-136-12326-0, Prentice Hall, Englewood Cliffs, NJ, USA.
 - [59] Lahoche, F. (2002). “Suivi spatio-temporel de paramètres hydrologiques sur un bassin versant par couplage de données satellitaires”. PhD thesis, Université du Littoral, U.F.R.: Sciences, École Doctorale Lamora, France.
 - [60] Lambin, E. F., Geist, H. J., Lepers, E. (2003). “Dynamics of land-use and land-cover change in tropical regions”. *Annual Review of Environment and Resources*, vol. 28, pp. 205-241.
 - [61] Lillesand, T. M., Kiefer, R. W. (2000). “Remote sensing and image interpretation”, 4th ed. ISBN 0-471-25515-7, John Wiley & Sons, New York, NY, USA.
 - [62] Liu, W., Gopal, S., Woodcock, C. E. (2001). “ARTMAP Multisensor / resolution framework for land cover characterization”. 4th International Conference on Information Fusion, 7-10 agosto, Montreal, Canada.
 - [63] Lobell, D. B., Asner, G. P. (2004). “Cropland distributions from temporal unmixing of MODIS data”. *Remote Sensing of Environment*, vol. 93, no. 3, pp. 412-422.

- [64] Loveland, T. R., Reed, B.C., Brown, J.F., Ohlen, D.O., Zhu, Z., Yang, L., Merchant, J.W. (2000). "Development of a global land cover characteristics database and IGBP DISCover". *International Journal of Remote Sensing*, vol. 21, no. 6-7, pp. 1303-1330.
- [65] Mather, P. M. (1999). "Computer Processing of Remotely-Sensed Images: An Introduction", 2nd ed. ISBN 0-471-98550-3, John Wiley & Sons, Chichester, UK.
- [66] Matthews, E. (1983). "Global vegetation and land-use: New-high resolution data bases for climate studies". *Journal of Climate and Applied Meteorology*, vol. 22, pp. 474-487.
- [67] Mazuchowski, J. Z., Derpsch, R. (1984). "Guia de preparo do solo para culturas anuais mecanizadas". ACARPA/IAPAR/GTZ, Curitiba, Brasil.
- [68] Mesquita Jr, H. N., Bitencourt, M. D. (2003). "Análise multitemporal de fragmentos de cerrado no estado de São Paulo com sensor orbital MODIS". In: *Anais do XI Simpósio Brasileiro de Sensoriamento Remoto (SBSR)*, pp. 2815 - 2822, 05-10 abril, Belo Horizonte, MG, Brasil.
- [69] Meyer, W. B., Turner, B. L. II (1994). "Changes in land use and land cover: a global perspective". Cambridge University Press, Cambridge, UK.
- [70] Moreira, M. A. (2003). "Fundamentos do sensoriamento remoto e metodologias de aplicação", 2a ed. ISBN 85-7269-158-8, UFV, Viçosa, MG, Brasil.
- [71] Morton, D. C., Espírito-Santo, F. del B., Shimabukuro, Y. E., DeFries, R. S., Anderson, L. O. (2005). "Validation of MODIS annual deforestation monitoring with CBERS, Landsat, and field data". In: *Anais do XII Simpósio Brasileiro de Sensoriamento Remoto (SBSR)*, 16-21 abril 2005, pp. 3159-3166, Goiânia, GO, Brasil.
- [72] Myneni, R. B., Nemani, R., Running, S. W. (1997). "Estimation of global leaf area index and absorbed PAR using radiative transfer models". *IEEE Transactions on Geoscience and Remote Sensing*, vol. 35, no. 6, pp. 1380-1393.
- [73] Nemani, R., Running, S. W. (1997). "Land cover characterization using multitemporal red, near-IR, thermal-IR data from NOAA/AVHRR". *Ecological Applications*, vol. 7, pp. 79-90.
- [74] Nepstad, D. C., Verissimo, A., Alencar, A., Nobre, C., Lima, E., Lefebvre, P., Schlesinger, P., Potter, C., Moutinho, P., Mendoza, E., Cochrane, M., Brooks, V.

- (1999). “Large-scale impoverishment of Amazonian forests by logging and fire”. *Nature*, vol. 398, no. 6727, pp. 505-508.
- [75] NOAA (2000), “NOAA KLM User’s Guide”. September 2000 revision, <http://www2.ncdc.noaa.gov>, Goodrum, G., Kidwell, K. B., Winston, W. (eds.), Satellite Services Branch, Climate Services Division, National Environmental, Satellite, Data and Information Service, National Oceanic and Atmospheric Administration (NOAA), USA.
- [76] Oliveira Jr, H. J., Shimabukuro, Y. E. (2005). “Mapeamento da cobertura da terra dos Estados do Goiás e Tocantins utilizando imagens do sensor MODIS”. In: *Anais do XII Simpósio Brasileiro de Sensoriamento Remoto (SBSR)*, pp. 1641-1648., 16-21 abril, Goiânia, GO, Brasil.
- [77] Olson, J. S., Watts, J. (1982). “Major world ecosystem complexes”. In *Earth's Vegetation and Atmospheric Carbon Dioxide*, in *Carbon Dioxide Review*, D. B. Jones (ed.), Oxford University Press, Oxford, pp. 388–399.
- [78] Paruelo, J. M., Guerschman, J. P., Baldi, G., Di Bella, C. M. (2004). “La estimación de la superficie agrícola. Antecedentes y una propuesta metodológica”. *Interciencia* vol. 29, no. 8, pp. 421-427.
- [79] Press, W. H., Flannery, B. P., Teukolsky, S. A., Vetterling, W. T. (1988). “Numerical Recipes in C”. ISBN 0-521-35465-X, Cambridge University Press, Cambridge, UK.
- [80] Quarmby, N. A., Townshend, J. R. G., Settle, J. J., White, K. H., Milnes, M., Hindle, T. L., Silleos, N. (1992). “Linear mixture modeling applied to AVHRR data for crop area estimation”. *International Journal of Remote Sensing*, vol. 13, no. 3, pp. 415–425.
- [81] Quinlan, J. R. (1993). “C4.5: Programs for machine learning”. ISBN 1-55860-238-0, Morgan Kaufmann, Los Altos, CA, USA.
- [82] Riggs, G. A., Hall, D. K., Salomonson, V. V. (2003). “MODIS Snow Products User Guide for Collection 4 Data Products”. January 2003 revision, <http://modis-snow-ice.gsfc.nasa.gov/sugkc.html>. Goddard Space Flight Center, National Aeronautics and Space Administration (NASA), USA.
- [83] Rissanen, J. (1978). “Modeling by shortest data description”. *Automatica*, vol. 14, pp. 465-471.

- [84] Risso, A., Bordas, M. P., Borges, A. L. (1997). “Produção de sedimentos”. In: BRASIL. Ministério do Meio Ambiente, dos Recursos Hídricos e da Amazônia Legal. Plano de Conservação da Bacia do Alto Paraguai (Pantanal) – PCBAP: hidrossedimentologia do Alto Paraguai, vol.2, t.2-A, pp. 271-307. Brasília, DF, Brasil.
- [85] Russell, S., Norvig, P. (1995). “Artificial intelligence: a modern approach”. ISBN 0-13-103805-2, Prentice Hall, Upper Saddle River, NJ, USA.
- [86] Santos, U. P. (2003). “Notas e transparências do curso de sensoriamento remoto”, FEN-06726, Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro (UERJ), Brasil.
- [87] Sellers, P. J., Tucker, C. J., Collatz, G. J., Los, S. O., Justice, C. O., Dazlich, D. A., Randall, D. A. (1994). “A global 1 degree by 1 degree dataset for climate studies”. Part 2: The generation of global fields of terrestrial biophysical parameters from the NDVI. *International Journal of Remote Sensing*, vol. 15, no. 17, pp. 3519-3545.
- [88] Sellers, P. J., Randall, D. A., Collatz, G. J. (1996). “A revised land surface parameterization (SiB2) for atmospheric GCMs”. Part 1: Model formulation. *Journal of Climate*, vol. 9, pp. 676–705.
- [89] Settle, J. J., Drake, N. A. (1993). “Linear mixing and the estimation of ground cover proportions”. *International Journal of Remote Sensing*, vol. 14, no. 6, pp. 1159–1177.
- [90] Shimabukuro, Y. E., Smith, J. A. (1991). “The Least-Squares Mixing Models to Generate Fraction Images Derived From Remote Sensing Multispectral Data”. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 29, pp. 16-20.
- [91] Shimabukuro, Y. E., Rudorff, B. F. T. (2000). “Fraction images derived from NOAA AVHRR data for global studies”. *International Journal of Remote Sensing*, vol. 21, no. 17, pp. 3191-3194.
- [92] Shimabukuro, Y. E., Duarte, V., Moreira, M. A., Arai, E., Rudorff, B. F. T., Anderson, L. O., Espírito-Santo, F. del B., Freitas, R. M., Aulicino, L. C. M., Maurano, L. E., Aragão, J. R. L. (2005). “Detecção de áreas desflorestadas em tempo real: Conceitos básicos, desenvolvimento e aplicação do projeto DETER”. INPE-12288-RPE/796, Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, SP, Brasil.

- [93] Short, N. M. et al. (2004), “Electromagnetic Spectrum: Distribution of Radiant Energies”, The Remote Sensing Tutorial (Introduction), <http://rst.gsfc.nasa.gov>, National Aeronautics and Space Administration (NASA), USA.
- [94] Silva, J. S. V. (2003). “Análise multivariada em zoneamento para planejamento ambiental - Estudo de caso: bacia hidrográfica do alto rio Taquari, MS/MT”. Tese de Doutorado, Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, SP, Brasil.
- [95] Strahler, A. H., Muchoney, D., Borak, J. S., Friedl, M., Gopal, S., Lambin, E., Moody, A. (1999). “MODIS land cover and land cover change”. MOD12 Algorithm Theoretical Basis Document (ATBD), version 5.0, Goddard Space Flight Center, National Aeronautics and Space Administration (NASA), USA.
- [96] Tenenhaus, M. (1996). “Méthodes statistiques en gestion”. ISBN 2-100-01061-1, Dunod, Paris, France.
- [97] Townshend, J. R. G., Justice, C. O., Kalb, V. T. (1987). “Characterization and classification of South American land cover types using satellite data”. International Journal of Remote Sensing, vol. 8, pp. 1189–1207.
- [98] Townshend, J. R. G., Justice, C. O. (1988). “Selecting the spatial resolution of satellite sensors required for global monitoring of land transformations”. International Journal of Remote Sensing, vol. 9, pp. 187–236.
- [99] Townshend, J. R. G., Justice, C. O., Li, W., Gurney, C., McManus, J. (1991). “Global land cover classification by remote sensing: Present capabilities and future possibilities”. Remote Sensing of Environment, vol. 35, no. 2-3, pp. 243–255.
- [100] Townshend, J. R. G., Justice, C. O., Gurney, C., McManus, J. (1992). “The impact of misregistration on the detection of changes in land cover”. IEEE Transactions on Geoscience and Remote Sensing, vol. 30, no. 5, pp. 1054–1060.
- [101] Townshend, J. R. G., Zhan, X., DeFries, R. S., Hansen, M. C., DiMiceli, C., Sohlberg, R. A., Huang, C. (1999). “MODIS enhanced land cover and land cover change”. Algorithm Theoretical Basis Document (ATBD), version 2.0, Goddard Space Flight Center, National Aeronautics and Space Administration (NASA), USA.
- [102] Tso, B., Mather, P. M. (2001). “Classification Methods for Remotely Sensed Data”. ISBN 0-415-25908-6, Taylor and Francis, London, UK.

- [103] Tucker, C. J., Townshend, J. R. G., Goff, T. E. (1985). "African land-cover classification using satellite data". *Science*, vol. 227, pp. 369–375.
- [104] USGS (2004). "MODIS Reprojection Tool User's Manual", version 3.2a (July 2004), Department of Mathematics and Computer Science, South Dakota School of Mines and Technology, EROS Data Center, United States Geological Survey (USGS), Sioux Falls, SD, USA.
- [105] USGS (2004). "MODIS/Terra Surface Reflectance Daily L2G Global 250m SIN Grid", version 4, <http://edcdaac.usgs.gov/modis/mod09gqkv4.asp>. Land Processes Distributed Active Archive Center (LPDAAC), EROS Data Center, United States Geological Survey (USGS), Sioux Falls, SD, USA.
- [106] USGS (2004). "MODIS/Terra Surface Reflectance Quality Daily L2G Global 1km SIN Grid", version 4, <http://edcdaac.usgs.gov/modis/mod09gstv4.asp>. Land Processes Distributed Active Archive Center (LPDAAC), EROS Data Center, United States Geological Survey (USGS), Sioux Falls, SD, USA.
- [107] USGS (2004). "MODIS/Terra Vegetation Indices 16-Day L3 Global 250m SIN Grid", version 4, <http://edcdaac.usgs.gov/modis/mod13q1v4.asp>. Land Processes Distributed Active Archive Center (LPDAAC), EROS Data Center, United States Geological Survey (USGS), Sioux Falls, SD, USA.
- [108] Valeriano, D. M., Duarte, V., Anderson, L. O., Espírito-Santo, F. del B., Arai, E., Maurano, L. E., Souza, R. C., Freitas, R. M., Aulicino, L. C. M. (2005). "Detecção do desflorestamento da Amazônia Legal em tempo real - Projeto DETER". In: *Anais do XII Simpósio Brasileiro de Sensoriamento Remoto (SBSR)*, pp. 3403-3409, 16-21 abril, Goiânia, GO, Brasil.
- [109] Venables, W. N., Ripley, B. D. (1994). "Modern Applied Statistics with S-Plus". Springer-Verlag, New York, USA.
- [110] Verhoef, W., Meneti, M., Azzali, S. (1996). "A colour composite of NOAA/AVHRR NDVI based on time series analysis (1981-1992)". *International Journal of Remote Sensing*, vol. 17, pp. 231-235.
- [111] Vitousek, P. M., Mooney, H. A., Lubchenco, J., Melillo, J. M. (1997). "Human Domination of Earth's Ecosystems". *Science*, vol. 277, pp. 494-499.
- [112] Wessels, K. J., DeFries, R. S., Dempewolf, J., Anderson, L. O., Hansen, A. J., Powell, S. L., Moran, E. F. (2004). "Mapping regional land cover with MODIS data

for biological conservation: examples from the Greater Yellowstone Ecosystem, USA and Pará State, Brazil”. *Remote Sensing of Environment*, vol. 92, no. 1, pp. 67-83.

- [113] Wiegand, C. L., Richardson, A. J., Escobar, D. E., Gerbermann, A. H. (1991). “Vegetation indices in crop assessments”. *Remote Sensing of Environment*, vol. 35, no. 2-3, pp. 105-119.
- [114] Wilson, M., Henderson-Sellers, A. (1985). “A global archive of land cover and soils data for use in general circulation climate models”. *Journal of Climatology*, vol. 5, pp. 119-143.
- [115] Zadeh, L. A. (1965). “Fuzzy sets”. *Information Control*, vol. 8, no. 3, pp. 338-353.
- [116] Zhou, J. L., Tits, A. L. (1993). “Nonmonotone line search for minimax problems”, *Journal of Optimization Theory and Applications*, vol. 76, no. 3, pp. 455-476.