

TATIANE ASSIS VILELA

**AVALIAÇÃO DO DESMATAMENTO E SEUS POSSÍVEIS
IMPACTOS NAS MUDANÇAS CLIMÁTICAS DA BACIA DO
RIO TURVO SUJO - MG**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Civil, para obtenção do título de *Magister Scientiae*.

VIÇOSA
MINAS GERAIS – BRASIL
2009

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

TATIANE ASSIS VILELA

**AVALIAÇÃO DO DESMATAMENTO E SEUS POSSÍVEIS
IMPACTOS NAS MUDANÇAS CLIMÁTICAS DA BACIA DO
RIO TURVO SUJO - MG**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Civil, para obtenção do título de Magister Scientiae.

Orientador: Prof. Carlos Antônio Oliveira Vieira

VIÇOSA
MINAS GERAIS – BRASIL
2009

TATIANE ASSIS VILELA

**AVALIAÇÃO DO DESMATAMENTO E SEUS POSSÍVEIS
IMPACTOS NAS MUDANÇAS CLIMÁTICAS DA BACIA DO
RIO TURVO SUJO - MG**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia, para obtenção do título de *Magister Scientiae*.

Prof. Antônio Simões Silva
(Co-Orientador)

Prof. Dalto Domingos Rodrigues
(Co-Orientador)

Prof. Gutemberg B. França

Prof. Vicente Paulo Soares

Prof. Carlos Antônio Oliveira Vieira
(Orientador)

*Aos meus queridos pais, Virgilio e Ione (in memoriam),
ao meu querido irmão Rodrigo e ao meu
amado noivo Junior,
dedico.*

AGRADECIMENTOS

Primeiramente a Deus por me abençoar a cada dia me dando força, saúde, alegria e disposição para alcançar os meus objetivos e realizar os meus sonhos.

À FAPEMIG pelo incentivo financeiro em forma de bolsa de estudos, que me permitiu dedicação exclusiva à pesquisa.

Ao PSA pela concessão das imagens e ortoimagens Ikonos e ao INPE pelas imagens Landsat gentilmente cedidas;

Ao Prof. Carlos Vieira, pela orientação, apoio, estímulo e dedicação.

Aos professores Dalto Rodrigues, Simões, Liu pela contribuição cedida durante a realização desta dissertação.

Aos meus pais, Virgílio e Ione, por serem o presente mais doce que Deus me proporcionou, a presença mais constante, por me apoiarem em minhas decisões, por me ensinarem a caminhar com meus próprios pés, por me oferecerem amor incondicional e principalmente por fazerem parte da minha vida. Obrigada. E ao meu irmão Rodrigo, pelo carinho, pela amizade e pelos momentos felizes.

Aos meus tios, Neila e Pedro por me acolherem e por me acompanharem durante toda essa jornada, também pelo carinho e compreensão. E aos primos Fábio, Bruno e Mateus pela amizade.

Aos colegas e amigos, Leandro Poletto, Carlos H. Crespo, Edneya Gomes, Julierme Wagner e Leonardo Campos de Assis, Juliana Mendes Gomes, Keyla Cristina Francisco, Josie Oliveira, Kelly Cristina Francisco, Ricardo Cabral, Joaquim Junior pela ajuda, presença, apoio e incentivo, nos momentos difíceis e também nos momentos alegres.

Principalmente ao meu noivo Junior, por me incentivar, por estar ao meu lado, por ser meu apoio, meu companheiro nos momentos felizes e tristes.

BIOGRAFIA

TATIANE ASSIS VILELA, nascida em 20 de novembro de 1981 é filha de Virgílio Vilela de Lima Neto e Ione Assis Lima, e natural da cidade de Jataí, Goiás.

Em 1995 iniciou o curso Técnico em Edificações em nível de ensino médio/profissionalizante na Escola Técnica Federal de Goiás (ETFG), atual CEFET–Jataí - GO, concluindo o curso em 1998.

No ano de 2001 ingressou no Curso de Engenharia de Agrimensura na Universidade Federal de Viçosa (UFV), Viçosa – MG, concluindo a graduação em 2006.

Em março de 2007 iniciou o curso de pós-graduação pelo Programa de Pós-Graduação em Engenharia Civil – Área de Concentração em Informações Espaciais, Linha de Pesquisa em Geoprocessamento com ênfase em Sensoriamento Remoto, nível mestrado, na Universidade Federal de Viçosa (UFV). Submeteu-se à defesa da dissertação em 18 de fevereiro de 2009.

SUMÁRIO

LISTA DE ABREVIATURAS E SIGLAS.....	vi
LISTA DE FIGURAS	vii
LISTA DE TABELAS.....	ix
RESUMO	x
ABSTRACT	xi
1. INTRODUÇÃO.....	1
1.1 Caracterização do problema.....	2
1.2 Justificativa	3
1.3 Hipótese.....	4
1.4 Objetivos.....	4
1.5 Estruturação da dissertação.....	5
2. FUNDAMENTAÇÃO TEÓRICA.....	6
2.1 Influência do Desmatamento nas Mudanças Climáticas	6
2.2 Reflorestamento	7
2.3 O uso de Geotecnologias no estudo de Bacias Hidrográficas	8
2.4 Sensoriamento Remoto (SR).....	9
2.5 Comportamento espectral do uso e ocupação do solo	10
2.5.1 Comportamento espectral da Vegetação	10
2.5.2 Comportamento espectral da Água	11
2.5.3 Comportamento espectral dos Solos	11
2.6 Resolução das Imagens.....	12
2.6.1 Resolução Espacial.....	12
2.6.2 Resolução Espectral	13
2.6.3 Resolução Radiométrica	13
2.6.4 Resolução Temporal.....	13
2.7 Sistemas Sensores	13
2.7.1 NOAA	14
2.7.2 Landsat	15
2.7.3 IKONOS	19
2.8 Processamento digital de imagens.....	21
2.8.1 Pré-Processamento	21
2.8.2 Classificação Digital de Imagens	23
2.8.3 Validação da Classificação	25
2.9 Técnicas de análise temporal do uso do solo - LCM.....	29
2.10 Índices de Vegetação.....	31
3. METODOLOGIA	34
3.1 Caracterização da Área de Estudo.....	35
3.2 Usos do solo e cobertura vegetal.....	38
3.3 Geração do mapa de referência	38
3.4 Coleta dos dados Meteorológicos e de Satélites	42
3.5 Registro das Imagens TM/Landsat.....	43
3.6 Classificação do uso do solo pelo método RNA empregando as imagens digitais do satélite Landsat.....	44

3.7	Obtenção do Mapa de Mudanças	45
3.8	Evolução temporal da taxa de desmatamento	46
3.9	Investigação dos Impactos do Desmatamento nas Mudanças Climáticas	46
4.	RESULTADOS.....	48
4.1	Classificação do uso do solo pelo método RNA empregando as imagens digitais do satélite Landsat/TM.....	48
4.2	Obtenção do mapa de Mudanças.....	51
4.3	Monitoramento da evolução temporal da taxa de desmatamento	53
4.4	Investigação dos Impactos do Desmatamento nas Mudanças Climáticas	54
5.	CONCLUSÕES E RECOMENDAÇÕES.....	56
	REFERÊNCIAS BIBLIOGRÁFICAS	58
	APÊNDICE A.....	64
	APÊNDICE B.....	66
	APÊNDICE C.....	90

LISTA DE ABREVIATURAS E SIGLAS

ANA	Agência Nacional de Águas
AVHRR	<i>Advanced Very High Resolution Radiometer</i>
CCD	<i>Charge Coupled Device</i>
CEMIG	Companhia Energética de Minas Gerais
DCS	<i>Data Collection System</i>
ETM	<i>Enhanced Thematic Mapper</i>
ERTS	<i>Earth Resource Technology Satellit</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
IGBP	<i>International Geosphere-Biosphere Program</i>
INMET	Instituto Nacional de Meteorologia
ITOS-1	<i>Improved TIROS Operational System</i>
LCM	<i>Land Change Modeler</i>
MLP	<i>Multi-Layer Perceptron Classifier</i>
MSS	<i>Multispectral Scanner System</i>
NASA	<i>National Aeronautics and Space Administration</i>
NESDIS	<i>National Environmental Satellite Data and Information Service</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NOAA	<i>National Oceanic and Atmospheric Administration</i>
NRC	<i>National Research Council</i>
RBV	<i>Return Beam Vidicon</i>
REM	Radiação Eletromagnética
RMS	<i>Root Mean Square</i>
RNA	Redes Neurais Artificiais
SEM	<i>Solar Environment Monitor</i>
SIG	Sistema de Informações Geográficas
SR	Sensoriamento Remoto
TIROS	<i>Television and Infrared Observation Satellite</i>
TOVS	<i>Tiros Operational Vertical Sounder</i>
TM	<i>Thematic Mapper</i>
VHRR	Very High Resolution Radiometer

LISTA DE FIGURAS

Figura 1 – O espectro eletromagnético (Lillesand & Kiefer, 1987, adaptado)..	10
Figura 2 – Diagrama referente às etapas realizadas durante o Processamento Digital de Imagens.	21
Figura 3 – Matriz de Erro	27
Figura 4 – Diagrama contendo os ambientes e a hierarquia do módulo LCM	31
Figura 5 – Diagrama contendo as etapas realizadas no estudo	35
Figura 6 – Área de estudo: bacia do Rio Turvo Sujo e os municípios localizados nesta bacia.	36
Figura 7 – Imagem composta do Landsat R/G/B bandas 3/4/5 do ano 1984 da bacia do Rio Turvo Sujo	36
Figura 8 – Imagem composta do Landsat R/G/B bandas 3/4/5 do ano 1989 da bacia do Rio Turvo Sujo	37
Figura 9 – Imagem composta do Landsat R/G/B bandas 3/4/5 do ano 2000 da bacia do Rio Turvo Sujo	37
Figura 10 - Imagem composta do Landsat R/G/B bandas 3/4/5 do ano 2008 da bacia do Rio Turvo Sujo	38
Figura 11 – Modelo de plotagem do mosaico formado a partir da imagem IKONOS do ano de 2008, referente à bacia do Ribeirão São Bartolomeu..	39
Figura 12 – Modelo do recorte de cada quadrícula, no formato A4, formada a partir do mosaico de imagens IKONOS, do ano de 2008, da sub-bacia do Ribeirão São Bartolomeu, utilizada nas visitas a campo...	40
Figura 13 – Mapa de uso e cobertura do solo gerado para a bacia do Ribeirão São Bartolomeu..	41
Figura 14 – Mapa de referência gerado contendo as duas classes de interesse: áreas com cobertura vegetal e áreas sem cobertura vegetal.	42
Figura 15 - Imagem temática contendo as classes de interesse referentes ao ano 1984 da bacia do Rio Turvo Sujo.	48
Figura 16 – Imagem temática contendo as classes de interesse referentes ao ano 1989 da bacia do Rio Turvo Sujo	49
Figura 17 – Imagem temática contendo as classes de interesse referentes ao ano 2000 da bacia do Rio Turvo Sujo	49
Figura 18 – Imagem temática contendo as classes de interesse referentes ao ano 2008 da bacia do Rio Turvo Sujo	50
Figura 19 – Imagem temática obtida a partir da classificação de uma imagem Landsat, de 2008 (a esquerda) e imagem temática obtida a partir da digitalização de uma imagem Ikonos, de 2008 (a direita) ambas contendo as classes de interesse referentes ao ano de 2008 da sub-bacia do bacia do Ribeirão São Bartolomeu.	51

Figura 20 – Gráfico de ganhos e perdas das classes entre 1984 e 2008.	52
Figura 21 – Mapa de tendência de mudanças gerado para classe área com cobertura vegetal (a esquerda) e a imagem formada a partir da composição R/G/B da imagem Landsat do ano de 2008 (a direita).	52
Figura 22 – Mapa de mudanças gerado para as classes área com cobertura vegetal e área sem cobertura vegetal, durante o período de 1984 a 2008.	53
Figura 23 – Comparação das tendências das evoluções temporais de NDVI anual (a), Temperatura media anual (b) e Precipitação total anual (c) para a bacia do Rio Turvo Sujo –MG durante o período de 1984 a 2007.....	55

LISTA DE TABELAS

Tabela 1 – Resolução Espacial dos Sensores.	12
Tabela 2 – Data de lançamento dos satélites da serie Landsat.....	16
Tabela 3 – Características dos satélites Landsat.....	17
Tabela 4 – Sensor RBV a bordo dos satélites LANDSAT 1 e 2	17
Tabela 5 – Sensor MSS a bordo dos satélites LANDSAT 1 a 5	18
Tabela 6 – Sensor TM a bordo dos satélites Landsat 4, 5 e 7.....	18
Tabela 7 – Sensor ETM a bordo do satélite Landsat 7	19
Tabela 8 – Sensor CCD a bordo do satélite IKONOS.....	20
Tabela 9 – Índice do coeficiente <i>Kappa</i> e o correspondente conceito do desempenho da classificação.....	28
Tabela 10 – Comparação entre as áreas referentes à classificação utilizando imagens Landsat (2008)e as áreas obtidas após a vetorização da imagem IKONOS(2008)	50
Tabela 11 – Áreas com e sem vegetação e suas respectivas porcentagens para bacia do Rio Turvo Sujo classificadas pelas imagens Landsat adquiridas nos dias de 17/07/1984, 15/07/1989, 27/06/2000 05/09/2008.....	54

RESUMO

VILELA, Tatiane Assis, M.Sc., Universidade Federal de Viçosa, fevereiro de 2009.

Avaliação do Desmatamento e seus possíveis impactos nas mudanças climáticas da bacia do Rio Turvo Sujo - MG. Orientador: Carlos Antônio Oliveira Vieira. Co-orientadores: Dalto Domingos Rodrigues e Antônio Simões Silva.

Este trabalho investiga os impactos do desmatamento nas mudanças climáticas regionais da Bacia do Rio Turvo Sujo, localizada no estado de Minas Gerais, durante os últimos 24 anos. As imagens obtidas do sensor TM/Landsat referente aos anos de 1984, 1989, 2000 e 2008 foram usadas para calcular a taxa de desmatamento existente na área de estudo. Os dados de NDVI anuais ("*Normalized Difference Vegetation Index*") referentes ao período de 1984 a 2006 gerados a partir do sensor NOAA/AVHRR foram empregados no cálculo da tendência de desmatamento. Esta tendência foi comparada a evolução temporal de temperatura e precipitação de forma a proporcionar uma análise dos impactos do desmatamento nas mudanças climáticas locais. Os resultados mostraram que a taxa do desmatamento foi reduzida e a área com cobertura vegetal aumentada de 21,01% em 1984 a 24,00% em 1989, 29.56% em 2000 diminuindo para 25.96% em 2008. Estes dados indicaram aumento do reflorestamento durante o período de 1984 a 2000 e uma tendência de desaceleração após 2000. Da análise da evolução temporal, foi observado que o NDVI relacionou-se diretamente com a precipitação, mas inversamente com a temperatura. Da análise de tendência do NDVI, da precipitação e da temperatura, foi observado que NDVI aumentou ligeiramente de 6.60 a 6.64, a precipitação de 1200 mm para 1220 mm e a temperatura de 19.6 °C para 20.5 °C. Concluiu-se que as séries temporais da média anual de NDVI geradas a partir do satélite NOAA provêm uma importante fonte de investigação dos impactos de desmatamento nas mudanças climáticas regionais como também o reflorestamento minimiza as mudanças climáticas locais. É sugerido que haja melhor administração dos recursos naturais e implantação de novas áreas de reflorestamento de forma a inverter a tendência atual de aumento da temperatura na Bacia.

ABSTRACT

VILELA, Tatiane Assis, M.Sc., Universidade Federal de Viçosa, february of 2009.

Investigates impacts of deforestation on the regional climatic changes of the Turvo Sujo River Basin. Adviser: Carlos Antônio Oliveira Vieira. Co-Advisers: Dalto Domingos Rodrigues and Antônio Simões Silva.

This work investigates impacts of deforestation on the regional climatic changes of the Turvo Sujo River Basin, MG during the past 24 years. Landsat images of 1984, 1989, 2000 and 2008 were used to define the deforestation rate. Annual NDVI data (“Normalized Difference Vegetation Index”) for the period from 1984 to 2006 generated from NOAA satellites were used to generate deforestation tendency. This tendency was compared to temporal evolution of temperature and precipitation to investigate the impacts of deforestation on local climate changes. The results showed that vegetative area increased from 21.01% in 1984 to 24.00% in 1990, 29.56% in 2000 and 25.96% in 2008. It indicated that the studied basin was under reforestation during the years before 2000 which resulted a better climatic change but and deforestation and land degradation afterward. From the temporal evolution analysis, it was observed that NDVI was closed related to precipitation but inversely related to temperature. From the tendency analysis of NDVI, precipitation and temperature, it was observed that NDVI increased slightly from 6.60 to 6.64, precipitation from 1200 mm to 1220 mm and temperature from 19.6 °C to 20.5 °C. It is concluded that the time series of annual NDVI, generated from the NOAA satellites, provides us an important source to investigate the deforestation impacts on regional climatic changes as well as the reforestation effects on minimizing local climatic changes. It is suggested that suitable actions of reforestation and natural resources management should be taken to reverse the current tendency of temperature increase in the Basin.

1. INTRODUÇÃO

A cobertura vegetal exerce uma função importante na diminuição da amplitude diária da temperatura através da evapotranspiração e na retenção de umidade de água no solo, pelas raízes profundas, em uma determinada região. Precipitação e temperatura são dois parâmetros frequentemente usados para monitorar a tendência da mudança climática de uma determinada região. Os usos inadequados dos recursos naturais e os desmatamentos não controlados das florestas tropicais e subtropicais resultam na aceleração da desertificação e nas mudanças climáticas regionais e globais.

O crescimento de áreas agrícolas e urbanas, juntamente com a influência de algumas atividades antrópicas, promovem a alteração da superfície acarretando desflorestamento, perda e erosão do solo. É notório o interesse, por parte dos pesquisadores, no monitoramento da vegetação. Esse fato acontece devido às mudanças da cobertura vegetal afetarem diretamente as atividades humanas e os recursos naturais, assim dados quantitativos e qualitativos referentes ao uso do solo são imprescindíveis em análises de mudanças globais (TOWNSHEND *et al.*, 1993).

A utilização de imagens orbitais para o mapeamento de uso do solo tornou-se uma ferramenta de grande valia, uma vez que permite análises das mudanças ocorridas na superfície terrestre, bem como o monitoramento de recursos naturais (SILVA *et al.*, 2005b), além de promoverem uma visão da dinâmica temporal da superfície terrestre. O monitoramento das evoluções dinâmicas de usos do solo, dos ecossistemas e dos eventos catastróficos da superfície terrestre pode ser realizado através do emprego de imagens orbitais (GALLEGO, 2004).

Segundo Gallego (2004) as imagens geradas pelos satélites podem ser usadas para estimar as áreas de usos do solo de três maneiras:

- (i) Identificação, classificação, delineamento e estimativa das áreas ocupadas pelas várias classes de usos do solo, baseadas nas imagens de satélites. Os dados de observações na superfície terrestre são usados para treinamento no processo da classificação, validação dos métodos de classificação e análise dos pixels de mistura;

- (ii) As imagens de satélites podem auxiliar o levantamento das amostras de várias maneiras, incluindo: definição das unidades das amostras, estratificação das amostras, documentação gráfica para o levantamento e o controle de qualidade da coleta de dados em campo;
- (iii) As técnicas de regressão estatística e os *softwares* utilizados nas análises de imagem e os Sistemas de Informações Geográficas (SIG) podem ser aplicadas para monitorar e prever as evoluções espaciais e temporais da superfície, combinando as informações de imagens de satélites com as obtidas por meio de levantamentos em campo.

Especificamente, esta dissertação é direcionada de forma a investigar as causas e resultados dos desmatamentos ocorridos, bem como seus impactos nas degradações dos recursos naturais e nas mudanças climáticas regionais. Assim, serão analisadas as evoluções temporais de NDVI, temperatura e precipitação durante um período de 1984 a 2007 de forma a investigar os possíveis impactos do desmatamento nas mudanças climáticas da Bacia do Rio Turvo Sujo. A tendência das mudanças climáticas será avaliada com os dados anuais de precipitação e temperatura, observadas nas estações meteorológicas disponíveis no município de Viçosa. A taxa anual de desmatamento durante o período de 1984 a 2006 será analisada usando a evolução temporal de NDVI. As tendências de evoluções temporais das variáveis dependentes, tais como NDVI, temperatura e precipitação serão obtidas pela correlação estatística com a variável independente, o tempo em ano.

1.1 Caracterização do problema

O uso impróprio do solo e os manejos inadequados dos recursos naturais resultam na degradação dos recursos ambientais e conseqüentemente causam mudanças climáticas regionais (NRC, 1988 e IGBP, 1990). Muitas degradações ambientais são causadas pelos conflitos de interesse e pelas negligências dos seus exploradores. Para evitar as agressões ao meio ambiente, torna-se necessário a elaboração de um plano adequado de gerenciamento dos conflitos, dentro de uma unidade de bacia hidrográfica. Contudo, para a elaboração deste plano deve-se primeiramente monitorar as condições atuais, as causas originárias, bem como os efeitos das atividades humanas causadas ao longo do tempo em cada unidade de bacia hidrográfica.

1.2 Justificativa

O sensoriamento remoto orbital tornou-se importante fonte de informações no estudo dos recursos naturais, uma vez que o uso de imagens de satélite no monitoramento da vegetação e de sua dinâmica tem se tornado cada vez mais presente. O estudo da relação entre o clima e a cobertura vegetal, pode ser empregado em diversas áreas incluindo a produtividade agrícola e a modelagem climática. No caso do Brasil, devido à sua vasta extensão territorial, torna-se conveniente o uso de técnicas de sensoriamento remoto (SR) na realização do monitoramento dos recursos naturais (GURGEL, 2003).

Através da utilização do sensoriamento remoto orbital, análises temporais e espaciais referentes às mudanças na cobertura do solo podem ser realizadas proporcionando o monitoramento de queimadas, desmatamentos, expansão urbana e recursos ambientais de forma otimizada.

Segundo Back (2001), a identificação de alterações nos registros meteorológicos é de grande importância para os estudos de engenharia que utilizam as séries históricas, pois tanto as simulações como as aplicações de teorias de probabilidade são realizadas com a hipótese de que as séries históricas são homogêneas, isto é, que não apresentem tendências.

Diante deste contexto torna-se necessário desenvolver metodologias alicerçadas nas ferramentas do sensoriamento remoto (SR) que permitam analisar a relação entre o clima e a cobertura vegetal, de forma a diagnosticar os possíveis impactos do desmatamento nas mudanças climáticas.

1.3 Hipótese

O estudo se baseia em duas hipóteses:

1. É possível definir uma metodologia que permita mensurar os impactos do desmatamento nas mudanças climáticas, a partir de dados do sensoriamento remoto;
2. As séries temporais das medias anuais de NDVI geradas a partir do sensor NOAA/AVHRR, provêm uma importante fonte de investigação dos impactos de desmatamento nas mudanças climáticas.

1.4 Objetivos

Diante deste contexto, os objetivos deste projeto de pesquisa seriam:

- (i) Monitorar a evolução de usos do solo utilizando dados de sensoriamento remoto;
- (ii) Avaliar as viabilidades, a partir do uso dos dados adquiridos com diferentes satélites (IKONOS e Landsat) de resoluções especiais distintas, na estimativa do desmatamento da cobertura vegetal;
- (iii) Estimar a tendência de taxa do desmatamento usando as imagens do sensor to TM/Landsat;
- (iv) Investigar as tendências da evolução temporal dos indicadores ambientais, incluindo: temperatura, precipitação e NDVI do período de 1984 a 2007 da Bacia do Rio Turvo Sujo;
- (v) Investigar os impactos do desmatamento nas mudanças climáticas na Bacia do Rio Turvo Sujo.

1.5 Estruturação da dissertação

Esta dissertação foi estruturada em capítulos. O capítulo 1 apresenta o problema e a justificativa, bem como as hipóteses e os objetivos que geraram as motivações necessárias a realização deste estudo; o capítulo 2 apresenta uma breve fundamentação teórica sobre as metodologias empregadas no pré-processamento de imagens e alguns conceitos relativos ao sensoriamento remoto; o 3 capítulo comenta as etapas de aplicação da metodologia; o capítulo 4 exhibe e discute os resultados obtidos; o capítulo 5 faz as considerações finais apresentando também os problemas constatados.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Influência do Desmatamento nas Mudanças Climáticas

As mudanças climáticas e suas conseqüências, muitas vezes catastróficas, tornaram-se uma das grandes preocupações dos pesquisadores nos últimos anos. Segundo Houghton *et al.*, (1995), a temperatura média global apresentou um acréscimo de 0,3 a 0,6 °C desde o final do último século.

A diminuição da vegetação e as variações no uso do solo geram diversas alterações no ambiente, no ciclo hidrológico e no clima, podendo ser citados como efeitos gerados pelas mudanças climáticas, a elevação da temperatura global e as modificações no regime de chuvas. (LINHARES *et al.*, 2005).

No que se refere ao desmatamento, tem-se observado que este tem atuado de forma a reduzir a precipitação e a evapotranspiração, alterando o ciclo hidrológico local. De acordo com Marengo *et al.*, (2003), as conseqüências provocadas pelas mudanças climáticas no Brasil ocorridas devido ao aquecimento global já abrangem prováveis impactos de dessecamento da Amazônia (devido ao desmatamento) ocasionando incêndios e ameaçando a biodiversidade. Segundo os autores, todo o remanescente da floresta amazônica que resistir ao desmatamento estará sujeito às conseqüências geradas pela diminuição de precipitação devido ao decréscimo de evapotranspiração. Outro evento que pode ser citado refere-se às conseqüências que o desmatamento ou as alterações climáticas podem causar ao Pantanal, localizado no sudoeste do Brasil. Nesta região qualquer aumento significativo da vazão, resultante desses dois fatores, afetará negativamente a capacidade de retenção e controle desta grande área alagada (HULME e SHEARD, 1999).

Liu *et al.*, (2005 a) analisaram o impacto de desmatamento na mudança climática do município de Terenos, Estado do Mato Grosso do Sul, e verificaram que o Município encontra-se no limiar de exploração dos recursos naturais, apresentando graves conseqüências ambientais.

2.2 Reflorestamento

O Brasil é um país privilegiado por apresentar condições de clima e solo altamente adequados para o reflorestamento. O País está entre os 10 maiores em florestas plantadas do mundo (JUVENAL e MATTOS, 2002).

Conforme Vale (2004), no ano de 1966 foi instituído o programa de incentivos fiscais destinados ao reflorestamento, de forma a atender a demanda e os planos desenvolvimentistas das indústrias que empregavam a madeira como matéria-prima, especialmente nas regiões Sul e Sudeste do país, onde a vegetação encontrava-se gravemente afetada.

No ano de 1975 foi estabelecido pelo Banco do Brasil o programa Fundo de Investimentos Setoriais-Florestamento que proporcionava as empresas da Região Sudeste deduzir 17,5% de seu imposto de renda em programas de reflorestamento. O estímulo ao reflorestamento gerado pelo Governo Federal foi essencial para o crescimento das áreas cobertas por florestas de eucaliptos. Porém, as grandes áreas florestais passaram a ser criticadas por ocuparem locais destinados a agricultura. Assim, o Governo Federal estabeleceu as “regiões prioritárias para reflorestamento”, por meio do Decreto-lei 79.046, de 27/12/1976, delimitando as áreas para os novos plantios incentivados (VALE, 2004). Ultimamente, cerca de 80% (4,8 milhões de hectares) das florestas plantadas brasileiras são formadas por pinus e eucalipto (JUVENAL e MATTOS, 2002).

O reflorestamento formado por eucalipto encontra-se em sua maioria localizado na região Sudeste e no Estado da Bahia. Já as florestas plantadas formadas por pinus, localizam-se principalmente nas regiões Sul e Sudeste do País, onde o clima é mais favorável (JUVENAL e MATTOS, 2002). O eucalipto tem sido a principal opção para reflorestamento, em virtude de seu crescimento acelerado, vigor, precocidade e adaptação a diferentes habitats. É utilizado, principalmente, para produção de carvão vegetal, de celulose e papel, bem como chapas, lâminas, compensados, aglomerados, madeira serrada e moveis. Além dos usos tradicionais, podem ser obtidos, também, óleos essenciais e mel (INFORME AGROPECUÁRIO, 2008).

Conforme Golfari (1975), o Estado de Minas Gerais possui condições altamente adequadas ao cultivo do eucalipto. Por esse motivo o Estado é o maior reflorestador, representando 51,77% da área total reflorestada com eucaliptos. Além disso, o Estado é

o maior consumidor de matéria-prima florestal no Brasil, seja na produção de carvão vegetal para atender ao seu grande parque siderúrgico, seja no atendimento da indústria de celulose (VALE, 2004). Em Minas Gerais, as exportações de produtos gerados a partir do reflorestamento proporcionaram um ganho de US\$ 490 milhões ao Estado, gerando um acréscimo de 32%, entre janeiro e outubro de 2007, em relação ao mesmo período de 2006. O setor é o terceiro nas exportações do agronegócio mineiro, ficando atrás somente do café e da carne (INFORME AGROPECUÁRIO, 2008).

Vale (2004), comenta que a intensa influência antropológica sobre a cobertura florestal no Estado de Minas Gerais afetou a Zona da Mata. Marangon (1971), averiguou que a Zona da Mata mineira apresentava déficit de madeira para diversos tipos de indústrias. A Companhia Energética de Minas Gerais (CEMIG) desenvolve no Estado um programa de reflorestamento com o objetivo de proteger as margens dos rios, evitar o aparecimento de focos erosivos, melhorar a paisagem local e criar condições de abrigo e alimentação para a fauna. Os resultados alcançados até agora são: 320 hectares de área reflorestada até o ano de 1999 e 14 municípios beneficiados. Os benefícios gerados pelo reflorestamento são entre outros: a proteção de mananciais, a conservação das margens das hidroviárias, a preservação da biodiversidade, o equilíbrio climático, a remoção de CO₂.

2.3 O uso de Geotecnologias no estudo de Bacias Hidrográficas

O espaço geográfico está em constante mudança devido à evolução natural e as atividades humanas. As bacias hidrográficas vêm sofrendo um processo intenso de degradação causado pela má utilização deste recurso por parte da humanidade. Para compreender essas transformações torna-se necessário realizar diversas observações com uma série de dados do espaço e escalas no tempo. A observação terrestre obtida a partir de dados de satélite é o meio mais efetivo e econômico de unir os dados necessários para monitorar e modelar esses fenômenos (VIEIRA, 2000).

O uso do geoprocessamento, como ferramenta para o estudo de bacias hidrográficas, proporciona uma análise temporal e uma visão espacial da realidade ambiental dessas bacias (LIMA *et al.*, 2007). A utilização das tecnologias do sensoriamento remoto no mapeamento e monitoramento dos recursos naturais tem se intensificado a cada ano. Os dados obtidos a partir de satélites proporcionam a

realização de análise temporal da superfície terrestre em intervalos relativamente curtos, podendo esses dados serem processados através de técnicas de análise associadas aos sistemas computacionais (VILELA *et al.*, 2000).

Segundo Carvalho *et al.*, (2005), a utilização de análise multitemporal, considerando as características espectrais e temporais das imagens de satélite, cada vez mais se intensifica. Esses procedimentos permitem monitorar e auxiliar os trabalhos de extensão agrícola, como também avaliar a evolução dos desmatamentos e ainda o crescimento urbano.

2.4 Sensoriamento Remoto (SR)

O Sensoriamento Remoto é definido como a ciência e a arte de aquisição de dados a respeito de um objeto, área ou fenômeno por meio de análise de informações obtidas por um sensor que não esteja em contato com o objeto, área ou fenômeno em investigação (LILLESAND e KIEFER, 1987).

Segundo Carvalho (2005), o sensoriamento remoto refere-se à medição da radiação refletida ou emitida pelos corpos que se encontram a uma determinada distância do sensor. Erbert (2001) comenta que a função primordial de um sensor remoto é captar e aferir a quantidade de energia refletida e emitida pelos objetos, podendo assim inferir a respeito do elemento em estudo. Todos os corpos presentes na superfície da terra, com temperatura superior a zero absoluto (0° K), podem emitir, refletir, transmitir ou absorver radiação eletromagnética (REM), e por meio dessas características é possível discriminar espectralmente objetos distintos (MATHER, 2004).

Ao penetrar a atmosfera a REM atinge os objetos na superfície terrestre de forma a permitir que a energia incidente atue de três formas: parte sendo absorvida, parte sendo transmitida e parte sendo refletida para o espaço, como também o próprio objeto emitindo sua própria energia. O espectro eletromagnético está relacionado à distribuição da intensidade da REM relativo ao comprimento de onda ou frequência. A classificação por intervalo de comprimento de onda do espectro eletromagnético é formada por: as ondas de rádio, microondas, radiação infravermelha, raios ultravioleta, raios- X e raios gama. A Figura 1 esboça as principais regiões do espectro eletromagnético.




Figura 1 - O espectro eletromagnético

(Fonte: LILLESAND e KIEFER, 1987, adaptado).

A atmosfera contém vários gases entre eles, vapor de água, ozônio e dióxido de carbono, que interagem com a REM produzindo a absorção da energia em determinadas faixas do espectro. Assim, as faixas que permitem a passagem total ou parcial da REM são denominadas janelas atmosféricas. São nessas regiões que são desenvolvidas praticamente todas as atividades de Sensoriamento Remoto (MOREIRA, 2001).

2.5 Comportamento espectral do uso e ocupação do solo

As características espectrais dos objetos estão diretamente ligadas às interações da REM que atua no alvo existente na superfície terrestre refletindo, absorvendo e transmitindo essa mesma radiação em diferentes intensidades de acordo com suas propriedades bio-físico-químicas (RODRÍGUEZ, 2006).

2.5.1 Comportamento espectral da Vegetação

A maior contribuição para o sinal detectado referente à vegetação se deve as folhas. As características espectrais de uma folha estão relacionadas à sua composição química, morfologia e estrutura interna (VERONESE, 2000).

A vegetação sadia apresenta alta interação com a REM na região do visível e no infravermelho próximo. O alto índice de absorção na região do visível ocorre devido à presença de pigmentos nas folhas, como por exemplo, a clorofila que absorve grande quantidade de energia nas regiões concentradas em 0,45 e 0,67 μm. É devido a esse fato

que se enxerga a vegetação sadia na coloração verde, já que ocorre alta absorção de energia nesses comprimentos de onda, e em contra partida baixa refletância, nas regiões do azul e do vermelho. Em vegetações que estão sofrendo alguma forma de estresse, e por conseqüência produzindo baixa quantidade de clorofila, observa-se diminuição da absorção na região do visível, e coloração amarelada nas folhas (CARVALHO, 2005; COURA, 2007).

A refletância da vegetação sadia na região do infravermelho próximo pode alcançar valores próximos a 50% do total de energia incidente (CARVALHO, 2005), essa alta refletância se deve a estrutura interna das folhas (THIAM e EASTMAN, 1999). Em comprimentos de onda superiores a 1,3 μm a energia incidente na vegetação é geralmente absorvida ou refletida ocorrendo baixa ou nenhuma transmitância. Para comprimentos de onda acerca de 1,4; 1,9 e 2,7 μm , o aumento da absorção se dá devido à presença de água nas folhas (CARVALHO, 2005).

2.5.2 Comportamento espectral da Água

Os três estados físicos em que a água se apresenta na natureza proporcionam, a cada um, comportamentos espectrais distintos. O comportamento espectral da água no estado líquido apresenta baixa refletância (menor do que 10%) na faixa compreendida entre 0,38 e 0,7 μm e máxima absorção para valores superiores a 0,7 μm . Ressaltando que, o comportamento espectral de corpos d'água é fortemente influenciado pelos processos de absorção e espalhamento causados por objetos dissolvidos e em suspensão, proporcionando assim, o deslocamento máximo de refletância espectral para o verde-amarelo, enquanto que a presença de matéria inorgânica em suspensão implica em um deslocamento em direção ao vermelho. O comportamento espectral de nuvens apresenta elevada refletância (em torno de 70%), em todo o espectro óptico com destacadas bandas de absorção em 1, 1,3 e 2 μm (VERONESE, 2000).

2.5.3 Comportamento espectral dos Solos

A constituição mineral, bem como a presença de matéria orgânica e umidade, determinam o comportamento espectral dos solos. A refletância apresenta valores menores nas regiões do azul, aumentando sucessivamente nas regiões do vermelho, do infravermelho próximo e do infravermelho próximo médio. Os óxidos e os hidróxidos

de ferro diminuem a reflexão no comprimento de onda do azul, aumentando no intervalo espectral do verde ao infravermelho próximo. Os altos teores de umidade no solo ocasionam redução da reflectância, em todos os comprimentos de onda. O aumento de matéria orgânica gera redução da reflectância. O nível de matéria orgânica é melhor discriminado nas regiões do visível e infravermelho próximo até o comprimento de onda igual a 1,2 μm . (VERONESE, 2000).

2.6 Resolução das Imagens

Em sensoriamento remoto existem diferentes resoluções que caracterizam os sensores (MATHER, 2004). Nesta seção serão abordados os conceitos referentes às resoluções mencionando como exemplo as características pertencentes a alguns sensores.

2.6.1 Resolução Espacial

A Resolução espacial está relacionada à capacidade que um sensor possui de distinguir objetos, desta forma, quanto menor o objeto a ser identificado, maior a resolução espacial. Uma referência a essa resolução é o tamanho do pixel. A Tabela 1 apresenta a resolução espacial de alguns sensores que operam na posição nadir .

Tabela 1 - Resolução Espacial dos Sensores.

SENSOR	RESOLUÇÃO ESPACIAL
QUICKBIRD	0,61 a 0,72 m Pancromática 2,4 a 2,8 m Multiespectral
IKONOS	1 m Pancromática 4 m Multiespectral
SPOT	2,5 m Pancromática 10 m Multiespectral
CBERS	20 m
LANDSAT/TM	30 m
NOOA/AVHRR	1 km

2.6.2 Resolução Espectral

A resolução espectral pode ser definida como a capacidade que o sensor possui em distinguir espectralmente corpos semelhantes. Essa resolução está relacionada ao número de canais espectrais bem como a espessura desses canais, uma vez que objetos diferentes podem apresentar resposta espectral semelhante em um determinado intervalo de comprimento de onda e apresentar respostas distintas em outra faixa do espectro. Deste modo, um maior número de canais espectrais implica em uma maior resolução espectral.

2.6.3 Resolução Radiométrica

A resolução radiométrica é dada pelo número de valores digitais (níveis de cinza) usados para expressar os dados coletados pelo sensor. Quanto maior o número de valores, maior é a resolução radiométrica. O número de níveis de cinza é usualmente expresso em função do número de dígitos binários (bits) necessários para armazenar, em forma digital, o valor do nível máximo. O valor em bits é sempre uma potência de 2. Assim, n bits expressam 2^n valores de níveis cinza.

2.6.4 Resolução Temporal

A resolução temporal é definida como a frequência com que um sensor revisita uma determinada área. Segundo Fonseca (2000) a resolução temporal apropriada é imprescindível em estudos de identificação de processos que se modificam dinamicamente como por exemplo, fluxo atmosférico, crescimento de culturas, uso da terra.

2.7 Sistemas Sensores

Sensores orbitais estão a bordo de plataformas localizadas em altitudes superiores a atmosfera terrestre. As características referentes ao tipo de órbita e as resoluções, espacial, espectral, radiométrica e temporal são determinadas inicialmente de modo a atender os objetivos para qual foram projetados (ASSIS, 2008).

Nesta seção serão apresentadas somente características dos sensores a bordo dos satélites: Landsat, NOAA e IKONOS. Liu (2007) oferece um estudo mais completo sobre o assunto.

2.7.1 NOAA

O programa de satélites NOAA é coordenado pela *National Oceanic and Atmospheric Administration* (NOAA), por intermédio do *National Environmental Satellite Data and Information Service* (NESDIS) e pela *National Aeronautics and Space Administration* (NASA) que é responsável pelo desenvolvimento do satélite.

Esse programa foi desenvolvido pelo Departamento de Defesa dos Estados Unidos e pela NASA, com o intuito de gerar um sistema de satélite meteorológico. Esse programa foi denominado inicialmente TIROS (*Television and Infrared Observation Satellite*). Em meados de 1960 foram lançados 10 satélites da série TIROS. Os dados coletados por este satélite comprovaram sua habilidade, na aquisição de imagens.

A segunda geração de satélites meteorológicos teve início com o lançamento do ITOS-1 (*Improved TIROS Operational System*) no ano de 1970. Este satélite carregava a bordo um radiômetro de varredura que permitia medidas diurnas e noturnas, com transmissão dos dados em tempo real.

Outro satélite ITOS foi lançado no final de 1970, esse recebeu o nome de NOAA-1 devido a *National Oceanic and Atmospheric Administration*-NOAA ter assumido a responsabilidade sobre ele.

Durante os anos de 1970 a 1975, foram colocados em órbitas os satélites de número 2 a 5. Esses satélites carregavam a bordo sensores denominados VHRR (*Very High Resolution Radiometer*), capaz de gerar imagens de alta e média resolução espacial, e que substituíram os sensores anteriores. O VHRR era um sensor de varredura de dois canais sensíveis à energia na faixa espectral de (0,6 – 0,7 μm) e no infravermelho termal (10,5–12,5 μm).

Os primeiros satélites da terceira série, TIROS-N e do NOAA-A a D, foram lançados entre 1978 e 1981 e carregavam a bordo os instrumentos:

- *Advanced Very High Resolution Radiometer (AVHRR)* - Constitui-se de um radiômetro multiespectral que fornece imagens em vários canais no visível e no infravermelho, permitindo avaliações precisas do gelo, da massa d'água, das condições das nuvens e temperaturas da superfície do mar. Esse sensor apresenta uma resolução espacial no nadir de aproximadamente 1,1 km. O satélite orbita a Terra a uma altitude de 844 km.
- *Tiros Operational Vertical Sounder (TOVS)* - que fornece dados de sondagem para obter o conteúdo de vapor d'água em três níveis da atmosfera, determinar perfis verticais de temperatura e avaliar o conteúdo total de ozônio, desde a superfície terrestre até a estratosfera.
- *Data Collection System (ARGOS/DCS)* - que coleta e retransmite dados ambientais de plataformas remotas, fixas e móveis, tais como bóias, balões, aviões, navios, etc.
- *Solar Environment Monitor (SEM)* que realiza medições de partículas energéticas para previsão de distúrbios solares.

2.7.2 Landsat

O projeto Landsat iniciou-se como ERTS-1 (*Earth Resource Technology Satellit*) recebendo no ano de 1975 o nome Landsat 1. O projeto teve como principal objetivo a interpretação das informações multiespectrais sobre aspectos agrícolas, florestais, oceanográficos e geológicos. A Tabela 2 apresenta as datas de lançamento dos satélites da série Landsat, a data de desativação bem como os sensores abordo de cada um.

Tabela 2 - Data de lançamento dos satélites da série Landsat.

Satélite	Lançamento	Desativado	Sensores
Landsat – 1	Junho/72	Janeiro/78	MSS, RBV
Landsat – 2	Janeiro/75	Julho/83	MSS, RBV
Landsat – 3	Março/78	Setembro/83	MSS, RBV
Landsat – 4	Junho/82	-	MSS, TM
Landsat – 5	Março/84	-	MSS, TM
Landsat – 6	Abril/94	Abril/94	MSS, TM
Landsat – 7	Abril/99	-	ETM

A configuração da órbita dos satélites Landsat 1, 2 e 3 foi estabelecida de tal modo que a cada 18 dias acontecesse uma revisita sobre uma determinada área. O Landsat 4 fez parte da segunda geração dos sistemas passivos de alta resolução. Em fevereiro de 1983 o canal de transferência dos dados deixou de ser usado, e este foi então substituído pelo Landsat 5. Em setembro 1994, a NASA lançou o Landsat 6, porém o satélite nunca entrou em fase operacional. O Landsat 7 foi lançado para substituir o Landsat 5 já no final de sua vida útil. Essa substituição proporcionou diversos benefícios devido a mudança do scanner TM pelo ETM+ (*Enhanced Thematic Plus*). Entre elas:

- Gravação da banda 6 (infra-vermelho termal) em duas bandas, com ganho alto e ganho baixo (resolução espacial 60 m).
- Nova banda pancromática com 15 metros de resolução espacial de (0.52-0.90 μm), sincronizada às bandas multiespectrais.

As demais características são semelhantes as do Landsat 5 permitindo a fácil integração de dados Landsat 7 com dados dos satélites anteriores. A Tabela 3 apresenta as características da série Landsat.

Tabela 3 - Características dos satélites Landsat.

Características	Landsat 1, 2 e 3	Landsat 4, 5 e 7
Órbita:	Circular, quase polar, síncrona com o sol	Circular, quase polar, síncrona com o sol
Altitude:	± 920 km	705 km
Inclinação da órbita:	99,2°	98,2°
Hora equatorial:	09:30 minutos	09:30 minutos
Volta na terra:	103 minutos, 14 órbitas/dia	99 minutos, 14,5 órbitas/dia
Periodicidade:	18 dias	16 dias
Área imageada:	20 vezes ao ano	20 vezes ao ano
Sistemas imageadores:	MSS, RBV	MSS, TM, ETM

Os sistemas imageadores da série Landsat, entre eles: RBV (*Return Beam Vidicon*), MSS (*Multispectral Scanner System*), TM (*Thematic Mapper*) e ETM (*Enhanced Thematic Mapper*) são apresentados nas Tabelas 4, 5, 6 e 7 respectivamente.

Tabela 4 – Sensor RBV a bordo dos satélites LANDSAT 1 e 2 .

Sensor RBV	
Resolução Espectral:	0,474 – 0,830µm
Canal 1:	0,474 – 0,575µm (verde)
Canal 2:	0,580 – 0,680 µm (vermelho)
Canal 3:	0,690 – 0,830 µm (infravermelho próximo)
Resolução Espacial:	80 metros (canais 1, 2 e 3)
Resolução Radiométrica:	7 bits – 128 tons de cinza
Resolução Temporal:	18 dias

O sensor RBV a bordo do Landsat 3 só possui um canal (0,505 – 0,750 μm) e a resolução espacial é de 30 metros.

Tabela 5 - Sensor MSS a bordo dos satélites LANDSAT 1 a 5.

Sensor MSS	
Resolução espectral:	0,50 – 1,10 μm
Canal 4:	0,50 – 0,60 μm (verde)
Canal 5:	0,60 – 0,70 μm (vermelho)
Canal 6:	0,70 – 0,80 μm (infravermelho próximo)
Canal 7:	0,80 – 1,10 μm (infravermelho próximo)
Resolução espacial:	80 metros (canais 1, 2 e 3)
Resolução radiométrica:	7 bits – 128 tons de cinza
Resolução temporal:	18 dias

Tabela 6 - Sensor TM a bordo dos satélites Landsat 4, 5 e 7.

Sensor TM	
Resolução espectral:	0,45– 12,50 μm
Canal 1:	0,45 – 0,52 μm (azul)
Canal 2:	0,52 – 0,60 μm (verde)
Canal 3:	0,63 – 0,69 μm (vermelho)
Canal 4:	0,76 – 0,90 μm (infravermelho próximo)
Canal 5:	1,55 – 1,75 μm (infravermelho médio)
Canal 6:	10,40 – 12,50 μm (infravermelho termal)
Canal 7:	2,08 – 2,35 μm (infravermelho médio)
Resolução espacial:	30 m (canais 1 a 5 e canal 7), 120 m (canal 6)
Resolução radiométrica:	8 bits – 256 tons de cinza
Resolução temporal:	16 dias

Tabela 7 - Sensor ETM a bordo do satélite Landsat 7.

Sensor ETM	
Resolução Espectral:	0,45– 12,50 μm
Canal 1:	0,45 – 0,52 μm (azul)
Canal 2:	0,52 – 0,60 μm (verde)
Canal 3:	0,63 – 0,69 μm (vermelho)
Canal 4:	0,76 – 0,90 μm (infravermelho próximo)
Canal 5:	1,55 – 1,75 μm (infravermelho médio)
Canal 6:	10,40 – 12,50 μm (infravermelho termal)
Canal 7:	2,08 – 2,35 μm (infravermelho médio)
Pan:	0,52 – 0,90 μm (visível e infravermelho próximo)
Resolução Espacial:	30 m (canais 1 a 5 e canal 7), 60 m (canal 6) e 15m Pan
Resolução Radiométrica:	8 bits – 256 tons de cinza
Resolução Temporal:	16 dias

Entre as principais aplicações do Landsat destacam-se: acompanhamento do uso agrícola do solo; apoio ao monitoramento de áreas de preservação; atividades energético-mineradoras; cartografia e atualização de mapas; monitoramento do desmatamento; detecção de invasões em áreas indígenas; dinâmica de urbanização; monitoramento da cobertura vegetal; queimadas; secas e inundações; sedimentos em suspensão nos rios e estuários.

2.7.3 IKONOS

O satélite IKONOS foi lançado em setembro de 1999, com o objetivo de formar um sistema completo de sensoriamento remoto de alta resolução, compatível com as necessidades internacionais. A tecnologia empregada no desenvolvimento desse satélite foi durante um determinado período de uso exclusivamente militar, porém por decisão do governo ela foi então disponibilizada para a iniciativa privada a partir de 1994.

O IKONOS foi o primeiro satélite comercial a produzir imagens orbitais com resolução espacial de 1 metro. Ele possui órbita com altitude de 680 km e tempo de

revista de aproximadamente 3 dias para regiões com uma latitude de aproximadamente 40°. A frequência de revisita para latitudes maiores será menor, e maior para latitudes próximas ao Equador. As imagens são disponíveis em faixas de 11 km x 100 km até 11 km x 1000 km . O sensor a bordo do satélite IKONOS é o CCD.

As resoluções de 1 metro na banda pancromática (entre 0.45 e 0.90 μm) e 4 metros nas quatro bandas multiespectrais ([0.45 – 0.52], [0.52 – 0.60], [0.63 – 0.69], [0.76 – 0.90]) permitem diversas aplicações até então só realizadas a partir do uso de aerofotos. A Tabela 8 apresenta as resoluções referentes ao Sensor CCD a bordo do satélite IKONOS.

Tabela 8 - Sensor CCD a bordo do satélite IKONOS.

Sensor CCD	
Resolução Espectral:	
Banda 1:	0,45 – 0,52 μm (azul)
Banda 2:	0,52 – 0,60 μm (verde)
Banda 3:	0,70 – 0,80 μm (vermelho)
Banda 4:	0,80 – 1,10 μm (infravermelho próximo)
Banda 5 (Pan):	0,45 – 0,52 μm (Visível e infravermelho próximo)
Resolução Espacial:	4 metros (canais 1, 2 e 3)
Resolução Radiométrica:	11 bits – 2048 tons de cinza
Resolução Temporal:	3 dias para uma latitude de aproximadamente 40°. A frequência de revisita para latitudes maiores será menor, e maior para latitudes próximas ao Equador.

Devido à alta resolução espacial, as imagens produzidas pelo satélite IKONOS podem ser utilizadas na elaboração de mapas urbanos, cadastro, mapeamento de uso e cobertura do solo em grandes escalas e aplicações integradas com SIG's, entre outras aplicações.

2.8 Processamento digital de imagens

O objetivo primordial do processamento digital de imagens refere-se a manipulação de dados digitais e computadores (incluindo *Hardware e Software*) de forma a obter parâmetros de correção e realce aptos a promover a identificação e a extração de dados referentes a essas imagens (CRÓSTA, 1992; LILLESAND E KIEFER, 1994; SCHOWENGERDT, 1997).

A Figura 2 apresenta um diagrama contendo as etapas realizadas no Processamento Digital de Imagens.

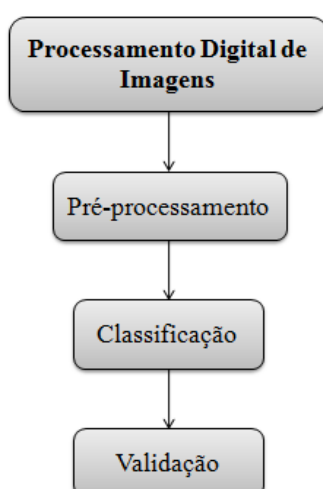


Figura 2– Diagrama referente às etapas realizadas durante o Processamento Digital de Imagens.

2.8.1 Pré-Processamento

O pré-processamento está relacionado ao processamento dos dados brutos, proporcionando a retificação e correção das distorções presentes nas imagens de sensoriamento remoto.

Imagens procedentes de sensores remotos estão sujeitas a uma série de distorções espaciais. Estas distorções são causadas pela instabilidade da plataforma; pelos efeitos panorâmicos relacionados à geometria de aquisição e pela curvatura e rotação da terra (MATHER, 1987; CRÓSTA, 1992; RICHARDS, 1995). Diante da presença destas distorções torna-se necessário submeter as imagens a uma correção geométrica de forma a fornecer precisão cartográfica quanto ao posicionamento dos objetos nelas representado.

Segundo Mather (2004), a correção geométrica de imagens é requerida em diversas situações, como por exemplo, quando se deseja: gerar coincidência entre uma imagem e um mapa; localizar pontos de interesse no mapa e na imagem; sobrepor seqüências temporais de imagens referentes à mesma área, podendo estas serem obtidas por diferentes sensores.

Conforme Veronese (2000), o método mais utilizado para a correção geométrica é por meio de pontos de controle do terreno. Esses pontos devem ser feições bem definidas e facilmente identificáveis no mapa ou imagem de referência bem como na imagem de ajuste. Os pontos de controle podem ser obtidos diretamente no terreno, através de GPS.

Correção por interpolação espacial utiliza equações polinomiais de 1º, 2º ou 3º ordem na realização da correção. A reamostragem destina-se a extrair valores numéricos dos pixels da imagem original de forma a deslocá-los na imagem corrigida, atribuindo a nova posição o valor do nível de cinza do vizinho mais próximo (CROSTA, 1993). Os métodos de interpolação mais utilizados são: o vizinho mais próximo que atribui ao nível de cinza do pixel da imagem corrigida, o mesmo valor do nível de cinza do pixel mais próximo; o bilinear em que o valor do nível de cinza do pixel é atribuído a partir da média ponderada do valor dos 4 pixels vizinhos e a convolução cúbica que utiliza o valor dos 16 pixels mais próximos. Os dois últimos provocam alteração do nível de cinza.

De forma a verificar a eficácia dos coeficientes apontados pelo método selecionado, deve-se proceder ao cálculo antes do erro médio quadrático (*Root Mean Square Error* - RMSe) para cada ponto individualmente e para o somatório de todos eles (RMS total).

Uma técnica relacionada à correção geométrica é conhecida como Registro de imagens. Segundo Mather (2004), o registro permite ajustar o sistema de coordenadas de uma imagem (linha e coluna) as coordenadas de uma segunda imagem, sem que esta esteja referenciada a um sistema conhecido. A utilização do o registro deve-se a necessidade de se realizar:

- Integração de imagens obtidas por sensores diferentes;
- Imagens obtidas em tempos diferentes, análise temporal;
- Imagens tomadas em posições diferentes;

- Mosaico de imagens.

2.8.2 Classificação Digital de Imagens

A classificação pode ser definida como o processo de extração de informação em imagens de maneira a permitir o reconhecimento de padrões e objetos homogêneos. O processo tem como objetivo mapear as áreas da superfície terrestre, obtendo como resultado final um mapa temático. Segundo Mather (2004), a classificação está relacionada ao reconhecimento de padrões dos objetos representado no mundo real bem como a rotulação dos pixels que representam as categorias de cada objeto.

Fonseca (2000), afirma que a classificação é implementada com base nas diferenças de comportamento dos materiais ao longo do espectro eletromagnético. A função de um classificador consiste em estipular uma regra de decisão, que permita a divisão do espaço de atributos em regiões distintas, cada qual representando uma classe. Em relação ao tipo de treinamento, a classificação automática pode ser dividida em dois grupos: supervisionada e não supervisionada.

Na classificação supervisionada, o analista a partir do conhecimento prévio da área ou por inferências, seleciona amostras representativas para cada uma das classes que se deseja identificar na imagem. De acordo com Fonseca (2000), geralmente, assume-se que as classes podem ser descritas por uma função densidade de probabilidade e, portanto, descritas por seus parâmetros estatísticos. Estes parâmetros são estimados através do conjunto de amostras de treinamento, previamente selecionados. A função densidade de probabilidade será, então, usada como um critério de decisão sobre a que classe um pixel pertence. Na classificação não supervisionada, cada pixel da imagem é associado a uma classe espectral sem que se tenha um conhecimento prévio do número ou identificação das diferentes classes presentes na imagem. Essa classificação é feita, basicamente, através de algoritmos de agrupamento.

A classificação automática dos pixels de uma imagem envolve a associação de cada pixel da cena com um rótulo que descreve uma classe informacional. Uma imagem classificada é, portanto, um mapa temático digital, que, se for georreferenciado, pode ser incorporado a um SIG (VERONESE, 2000).

Um exemplo que pode ser citado referente a um classificador são as Redes Neurais Artificiais (RNAs) que são uma linha de pesquisa da Inteligência Artificial. As RNAs são compostas por unidades de processamento fundamentadas no funcionamento do cérebro humano e inspiradas no sistema biológico dos neurônios.

Uma Rede possui diversas unidades de processamento distribuídas em camadas. A primeira camada, também conhecida como camada de entrada, é responsável por representar as variáveis discriminantes (no caso do SR as bandas espectrais e/ou infamações auxiliares). As camadas intermediárias com suas ligações promovem o armazenamento do aprendizado da rede. E por fim, a última camada denominada camada de saída, na qual aparece uma unidade de processamento para cada classe informacional a ser mapeada. A quantidade de unidades de processamento, as ligações com seus pesos e o número de camadas definem a arquitetura da RNA. Toda camada é constituída de unidades de processamento conectadas e cada interconexão entre elas possuem um peso. Em cada unidade de processamento é gerada um somatório das diversas entradas ponderadas pelos pesos, o resultado é então transmitido por uma função de ativação que determinará um valor de saída (LIPPMAN, 1987).

Conforme Ribeiro e Centeno (2005) para que se obtenha êxito na solução de um determinado problema utilizando uma RNA, torna-se necessário proceder ao ajuste dos pesos referentes a cada unidade de processamento, este ajuste é realizado em uma primeira fase de treinamento. Segundo os mesmos autores o treinamento de uma RNA pode ser definido como sendo o ajuste da matriz de pesos (W) pertencente à rede, de modo que o vetor de saída concorde com um determinado valor esperado para cada vetor de entrada. No treinamento, o vetor de entrada é aplicado e a saída da rede calculada. A partir da comparação entre a resposta da rede e o vetor de saída esperado, calcula-se o erro. Baseado neste erro, os pesos são ajustados de modo a minimizar essa diferença. O treinamento é então reproduzido até que o erro para o conjunto de treinamento obtenha um limiar previamente estabelecido.

O algoritmo empregado no treinamento da RNA com maior frequência é conhecido como “*backpropagation*”. Autores como Logan, *et al.*, (1997), Bennediktsson *et al.*, (1991), e Gong (1996), utilizaram este algoritmo para treinar a rede e empregá-la na classificação de imagens orbitais. De acordo com Gonzalez e Woods (2000), a quantidade de unidades de processamento pertencentes à primeira camada está relacionada à quantidade de variáveis de entrada, a camada de saída

apresentará o mesmo número de elementos que as classes a serem identificadas. Eles mencionam ainda que a maior dificuldade está relacionada a determinação tanto da quantidade de camadas ocultas a serem utilizadas quanto da quantidade de unidades de processamento pertencentes a cada uma delas. Usualmente esta dificuldade tem sido contornada pelo conhecimento prévio do usuário.

A integração de dados fundamentada na utilização das RNAs é benéfica para o desenvolvimento de metodologias que automatizem e otimizem a geração de mapas temáticos, proporcionando melhora em sua precisão (RIBEIRO e CENTENO, 2005). Sabo e Galo (2007) aplicaram Redes Neurais Artificiais na classificação e mapeamento da cobertura do solo urbano de Presidente Prudente e concluíram que o processo apresentou resultados satisfatórios na identificação das classes de interesse. Ribeiro e Centeno (2005), utilizaram as redes neurais na classificação de paisagens e concluíram que com a técnica das RNAs foi possível a separação das unidades fisionômicas, e que esta permitiu a associação de dados de diferentes origens e escalas.

Várias metodologias utilizadas no mapeamento de uso do solo têm sido desenvolvidas utilizando imagens procedentes do sensoriamento remoto (ORTIZ *et al.*, 1997; FOODY e AURORA, 1997). Coppin *et al.*, (2004) apresentaram uma revisão dos métodos de detecção das evoluções dinâmicas dos ecossistemas, apontando que as técnicas baseadas nos dados multitemporais e multiespectrais, adquiridos pelos satélites, demonstraram alto potencial na identificação, classificação, delineamento, mapeamento e detecção das evoluções de usos do solo.

Para o monitoramento da aceleração do desmatamento e degradação ambiental, os cientistas aplicam as imagens orbitais do sensoriamento remoto (LIU, 2007). Os dados coletados via satélite fornecem altas frequências temporais e espaciais das informações sobre as evoluções das características dos recursos ambientais e usos do solo na superfície terrestre.

2.8.3 Validação da Classificação

Devido à complexidade das imagens classificadas utilizando o sensoriamento remoto, deve-se avaliar a confiabilidade espacial dos resultados, indicando claramente em um mapa temático, os aspectos da exatidão (WRIGHT, 1942; e CONGALTON, 1991).

Um fator de influência na qualidade da classificação refere-se à representatividade das amostras, pois esta pode influenciar na extração de características das classes que se pretende discriminar, de maneira tendenciosa. A escolha do tipo de amostragem dependerá de diversos fatores, entre eles o tamanho da área de estudo, o tipo e distribuição das características a serem mapeadas, e os custos para aquisição dos dados de verificação (BANKO, 1998).

Conforme Congalton e Green (1999), em uma amostra aleatória simples cada unidade de amostra referente à área de estudo possui a mesma probabilidade de ser selecionada para pertencer a amostra, fornecendo dados representativos escolhidos sem influências e atendendo exigências essenciais de inferência estatística.

Segundo Vieira (2000), na amostragem aleatória estratificada a área de estudo é dividida em partes sendo selecionada uma amostra aleatória de cada parte. Essa amostragem exige um conhecimento a priori sobre a área.

Congalton e Green (1999) comentam que no caso da amostragem sistemática as amostras são selecionadas uniformemente, porém essa amostragem apresenta como desvantagem o fato de que cada unidade de amostra na área não possui a mesma probabilidade de ser adicionada na amostra. De acordo com Congalton (1991) uma combinação de amostragem estratificada e aleatória simples é ideal para uso no sensoriamento remoto.

A avaliação da exatidão temática a partir da utilização de dados do sensoriamento remoto é de extrema importância, uma vez que a confiabilidade dos dados provenientes dos mapas temáticos derivados da classificação é de grande interesse por parte dos usuários (VIEIRA, 2000). Para que seja realizada a avaliação da classificação e se quantifique o nível de acerto, utiliza-se a matriz de confusão ou matriz de erros a qual expressa, tomando como referência áreas de teste previamente selecionadas, essa matriz fornece elementos necessários para obtenção do índice Kappa, usualmente empregado na avaliação da qualidade do processo de classificação (MATHER, 2004).

Uma matriz de classificação ideal deve apresentar os valores da diagonal principal próximos a 100%, indicando que não houve confusão entre as classes. Contudo, esta é uma situação difícil em imagens com alvos de características espectrais semelhantes. Para diminuir a confusão entre as classes, aconselha-se a análise das amostras utilizadas. De posse das informações contidas na matriz dos erros é possível obter o índice de

Exatidão Global e o índice kappa bem como os erros de Omissão e Comissão. A matriz de erro apresenta em sua diagonal o número de pixels corretamente classificados, nas linhas os erros de omissão e nas colunas os erros de comissão. O índice de Exatidão Global representa o número de pixels corretamente classificados divididos pelo número total de pixels da imagem de referência.

A exatidão Global é calculada pela divisão das somas das entradas que formam a diagonal principal da matriz, ou seja, o número de classificações corretas pelo número total de amostras utilizadas. O erro de Omissão refere-se aos pixels omitidos de uma classe e assinalados a outra. O erro de Comissão esta relacionado aos pixels que são erroneamente incluídos em uma classe a que eles não pertencem. A Figura 3 exemplifica uma Matriz de Erros, mostrando os cálculos do índice de Exatidão Global, os erros de Omissão e Comissão.

Imagem de Referência	Imagem Classificada				
	Água	Pasto	Brejo	Total	Erro de Omissão (%)
Água	45	10	6	61	26,20
Pasto	2	15	1	18	16,70
Brejo	6	5	52	63	17,50
Total	53	30	59	142	-
Erro de Comissão (%)	15,09	50,00	13,46	-	-

Índice de Exatidão Global = (45 + 15 + 52) / 142 = 78,9 %			
Erro de Comissão (%)		Erro de Omissão (%)	
Água	16/61 = 26,20	Água	8/53 = 15,09
Pasto	3/18 = 16,70	Pasto	15/30 = 50,00
Brejo	11/63 = 17,5	Brejo	7/52 = 13,46

Figura 3 - Matriz de Erros.

A análise do índice Kappa é uma técnica multivariada discreta usada na avaliação da exatidão para determinar estatisticamente se uma matriz de erro é significativamente diferente de outra CONGALTON (1999). A Equação 1 mostra como o Kappa pode ser obtido.

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

Em que:

K = índice *Kappa*;

r = número de linhas ou colunas da matriz de confusão;

x_{ii} = número de observações dos elementos da diagonal da matriz;

$$X_{i+} = \sum_j X_{ij} \quad = \text{soma dos valores da linha } i ;$$

$$X_{+i} = \sum_j X_{ji} \quad = \text{soma dos valores da coluna } i ;$$

N = número total de observações.

Conforme Vieira (2000), o índice *Kappa* é uma medida que permite ao usuário observar o quanto a classificação concorda com os dados de referência. Congalton (1991), comenta que devido o índice *kappa* considerar todos os elementos da matriz de erro, a sua utilização na avaliação temática é considerada satisfatória.

Segundo Figueiredo (2007), mesmo com a alta frequência com que o índice *kappa* é empregado, não há uma fundamentação teórica que sugira quais são os valores mínimos admissíveis para esse índice numa classificação. No entanto, a Tabela 9 apresenta níveis de desempenho da classificação para os valores de *Kappa* obtidos, geralmente aceitos pela sociedade científica.

Tabela 9 - Índice do coeficiente *Kappa* e o correspondente nível de desempenho da classificação.

Índice Kappa	Desempenho da classificação
< 0	Péssimo
$0 < k \leq 0,2$	Mau
$0,2 < k \leq 0,4$	Razoável
$0,4 < k \leq 0,6$	Bom
$0,6 < k \leq 0,8$	Muito Bom
$0,8 < k \leq 1,0$	Excelente

Fonte: Fonseca (2000).

Congalton e Green (1999) sugeriram que se testasse o significado do coeficiente de *Kappa* de uma única matriz de erro para determinar se o nível de acordo entre a classificação feita através do sensoriamento remoto e os dados de referência eram significantes. O teste estatístico aplicado nesse caso é dado pela Equação 2:

$$Z = \frac{Ka}{\sqrt{\text{Var}(Ka)}} \quad (2)$$

Em que:

Z = teste estatístico Z de distribuição normal;

Var = variância da amostra;

Ka = coeficiente *Kappa*.

Vieira (2000) utilizou o teste estatístico Z para determinar se os valores independentes do índice *Kappa* apresentaram diferença significativa, permitindo assim a comparação estatística entre dois métodos ou algoritmos de classificação diferentes.

2.9 Técnicas de análise temporal do uso do solo - LCM

O *Land Change Modeler* (LCM) é um módulo do sistema IDRISI Andes, que pode ser integrado a alguns outros *softwares* de geoprocessamento, possibilitando a utilização de recursos dinâmicos para a modelagem de cenários direcionados à variação do ambiente.

Esse módulo destina-se a projetos de sustentabilidade ambiental, sendo orientado às necessidades analíticas de conservação da biodiversidade, cuja finalidade principal é auxiliar na tomada de decisão nesse aspecto, gerando para isso: relatórios e parâmetros auxiliares que permitem planejar intervenções para manutenção da sustentabilidade ecológica.

Além disso, ele amplia as aplicações relativas ao sensoriamento remoto através de um conjunto de técnicas de processamento, que incluem o aperfeiçoamento dos algoritmos de classificação, tais como redes neurais e análise de árvore de decisão; caracterização do potencial das variáveis envolvidas nas mudanças; funções de previsão de crescimento e dispositivos capazes de estimar implicações relacionadas ao ambiente e à biodiversidade.

Esse módulo necessita de pelo menos duas imagens temáticas de diferentes datas da mesma área, contendo as mesmas características (linhas, colunas, classes temáticas), nas quais constam as mudanças ocorridas nesse intervalo de tempo, permitindo ao analista trabalhar tais informações.

O módulo LCM fornece uma interface intuitiva, organizada seqüencialmente, que abrange funções associadas à análise de mudanças, previsão e modelagem de variáveis relativas às transições do ambiente e habitat. O LCM é organizado em um conjunto de cinco áreas de tarefas principais expressas como ambientes de análise. São elas: Análise de mudanças, Potencial de Transição, Predição de Mudanças, Implicações e Planejamento.

O ambiente de Análise de mudanças disponibiliza um conjunto de ferramentas para a avaliação rápida de mudanças, permitindo gerar avaliações de ganhos e perdas, mudança líquida, persistência e transições específicas em forma de mapa e/ou forma gráfica.

O ambiente de Potencial de Transição permite agrupar transições em um conjunto de sub-modelos e explorar o potencial de variáveis explicativas. Podem ser acrescentadas ao modelo: variáveis estáticas (expressam aspectos de conveniência básica para a consideração da transição, e são invariáveis com o passar do tempo, por exemplo, o relevo) ou componentes dinâmicos (são dependentes do tempo sendo recalculadas durante o curso de uma predição, geralmente relacionadas à infra-estrutura, por exemplo, as estradas, que geram crescimento econômico na região na qual se insere).

O ambiente de Predição de Mudança provê os controles para uma cobertura do solo mais dinâmica mudando o processo de predição. Depois de especificar a data final, a quantidade de mudança em cada transição que pode ser modelada por uma cadeia de análise Markov ou especificando a matriz de probabilidade de transição de um modelo externo.

O ambiente de Planejamento oferece um conjunto de intervenções, que podem ser: Restrições e incentivos (avaliam os impactos gerados por ferramentas como incentivos fiscais, por redirecionar o curso das mudanças. Estas intervenções são integradas com o processo de predição de mudança); modificações de infra-estrutura (especificam um conjunto principal de infra-estrutura indicando infra-estrutura existente e as datas em que eles foram efetivados); desenvolvimento de corredor (desenvolve corredores biológicos baseado em modelos de conveniência de espécies e ponderação de desenvolvimento de conveniência).

A Figura 4 apresenta um diagrama contendo os ambientes e a hierarquia do módulo LCM.

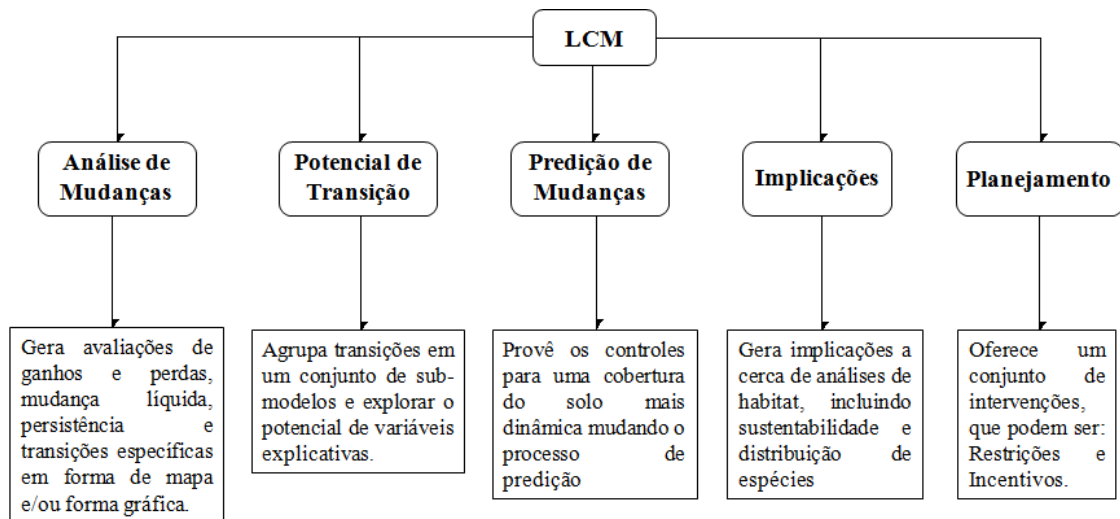


Figura 4- Diagrama contendo os ambientes e a hierarquia do módulo LCM.

Silva *et al.*, (2008) utilizaram análise multitemporal e o módulo LCM, juntamente com duas imagens temáticas da cidade de Chiquitania (Bolívia) relativas ao período de 1986 e 1994 para modelar o potencial de mudança das classes informacionais de uso do solo.

2.10 Índices de Vegetação

Os índices de vegetação foram desenvolvidos com o intuito de auxiliar no monitoramento da vegetação. A maior parte destes índices está baseada em interações entre a vegetação e a energia eletromagnética nos comprimentos de onda do vermelho e do infravermelho próximo. Os índices podem ser uma razão, diferença ou várias combinações entre os valores de reflectância do visível e do infravermelho próximo. Segundo Liu (2007), o emprego dos índices de vegetação permite sintetizar as informações espectrais e discriminar as áreas cobertas por vegetação, além de avaliar as condições de crescimento das culturas, ocorrências de doenças, pragas, secas e geadas e diversos eventos catastróficos meteorológicos.

A vegetação absorve a radiação na faixa do visível (0,4 a 0,7 μm) e reflete na faixa do infravermelho próximo (0,725 a 1,10 μm). Um índice de vegetação ideal deve ser sensível à vegetação, insensível ao fundo do solo e não ter interferências atmosféricas. Rouse *et al.*, (1973) desenvolveram um índice de vegetação, chamado NDVI (*Normalized Difference Vegetation Index*), para inferir o grau de cobertura vegetal da superfície terrestre. O NDVI é calculado pela Equação (3) a seguir:

$$NDVI = \frac{NIR - R}{NIR + R} \quad (3)$$

Em que:

NDVI = Normalized Difference Vegetation Index;

NIR = Banda do infravermelho próximo;

R = Banda do Visível.

Segundo Holben (1986), os valores de NDVI referentes a áreas com cobertura vegetal estão sujeitos a arquitetura, densidade e umidade, podendo variar de 0,1 a 0,6. Os maiores valores referem-se a coberturas vegetais mais densas. A presença de nuvens e água, na maioria das vezes está associada a valores negativos de NDVI. Rochas e solos expostos apresentam reflectância semelhantes nas regiões espectrais do vermelho e infravermelho, utilizadas no cálculo do NDVI, gerando assim, valores próximos a zero.

Rouse *et al.*, (1973) afirmam que maiores valores de NDVI referem-se a um grau de verde mais elevado e em conseqüência, em maior densidade de vegetação. Segundo Shimabukuro *et al.*, (1998), mudanças na cobertura vegetal do solo podem ser detectadas através da análise de imagens de índices de vegetação. Conforme Mather (2004), a utilização de somas e diferenças de bandas no NDVI ao invés do uso de nível de cinza proporciona ao resultado final, menor influência das variações de condições atmosféricas, tornando assim esse índice o mais apropriado para aplicação em análises temporais. Por ser fruto da combinação de duas bandas, o NDVI suaviza os efeitos causados pelos constituintes atmosféricos e pelas perturbações radiométricas e geométricas (HOLBEN, 1986). Essa é uma vantagem do NDVI sobre os outros índices. O NDVI tem sido largamente empregado por proporcionar um forte sinal da vegetação, e apresentar um contraste satisfatório com diferentes objetos da superfície terrestre (TUCKER e SELLERS, 1986).

Esse índice pode ser aplicado em diversos estudos, tais como: monitoramento da cultura agrícola, monitoramento de seca, monitoramento ambiental terrestre, e estudos globais de balanços de água e energia. Portanto, o grau de verde inferido pelo NDVI reflete, a produção de biomassa, a radiação fotossintética ativa, a produtividade da cultura, os efeitos dos fatores ambientais, tais como disponibilidade de água e nutrientes

no solo e a presença de doenças e de pragas em uma vegetação específica. Diversas pesquisas têm mostrado que o NDVI apresenta uma correlação considerável com variáveis climáticas, tais como a precipitação e a temperatura da superfície terrestre, (SCHULTZ e HALPERT, 1995; EHRLICH e LAMBIN, 1996; ROY *et al.*, 1997 e MANSO *et al.*, 1998).

Aronoff (1989) sugere a utilização de estudos de monitoramento do vigor vegetativo de culturas agrícolas através do uso de índices de vegetação, derivados de imagens orbitais, de forma a verificar a presença de áreas que necessitem de alguma intervenção. Um dos índices de vegetação mais utilizados é o NDVI (*Normalized Difference Vegetation Index*) destinado a inferir o grau de verde da superfície terrestre ocupada pela vegetação (ROUSE *et al.*, 1974). Diversas pesquisas evidenciam que o NDVI correlaciona-se com variáveis climáticas. Liu *et al.*, (1991), divulgaram que as áreas de vegetação com estresse, inferidas pelo NDVI, relacionavam-se em sua maioria com as áreas afetadas pelos impactos da seca geradas pelo *El Niño*. Barbosa (1998), em um estudo realizado na região Nordeste do Brasil verificou que as distribuições: espacial e temporal de precipitação e NDVI apresentam padrões semelhantes quando empregado dados de médias mensais dessas duas variáveis.

3. METODOLOGIA

Este estudo buscou avaliar a evolução de usos do solo e seus possíveis impactos e influências nas mudanças climáticas da bacia do Rio Turvo Sujo utilizando para isso, os dados adquiridos pelos satélites NOAA (*National Oceanic and Atmospheric Administration*), Landsat e IKONOS, além de dados meteorológicos. Desta forma, três etapas foram desenvolvidas: aplicação do classificador RNA (Redes Neurais Artificiais) na classificação e delineamento das áreas ocupadas por vegetação; monitoramento da evolução temporal da taxa de desmatamento estimada pela classificação das imagens obtidas pelo satélite Landsat e aplicação de modelos estatísticos que relacionem os dados meteorológicos com as mudanças temporais na cobertura do solo de forma a investigar o impacto da vegetação nas mudanças climáticas.

No delineamento, na classificação das áreas ocupadas por vegetação e no monitoramento da evolução temporal da taxa de desmatamento, foram utilizados os *softwares* Arcview e Idrisi e as imagens dos satélites: Landsat/TM, com 30m de resolução espacial, bandas 1, 2, 3, 4, 5, e 7 referente aos anos: 1984, 1989, 2000, 2008; IKONOS/CCD relativo ao ano de 2008, com 4m de resolução espacial, e imagens do NOAA/AVHRR, neste caso, fornecendo os Índices de Vegetação da Diferença Normalizada - NDVI (*Normalized Difference Vegetation Index*), para o período de 1984 a 2006, com 8 km de resolução espacial. Os dados cumulativos anuais do NDVI foram empregados com o intuito de investigar as tendências de mudanças climáticas regionais, esses dados foram obtidos a partir do uso do NOAA AVHRR (Radiômetro Avançado de Altíssima Resolução) para o período de 1984 a 2006, fornecidos pelo “*Global Inventory Modeling and Monitoring System (GIMMS)*”, do “*Goddard Space Flight Center-GSFC/NASA*” (Centro Espacial de Vôo Goddard/Administração Nacional Aeroespacial).

Primeiramente para que a primeira etapa referente ao delineamento das áreas ocupadas por vegetação fosse realizada procedeu-se a geração do mapa de referência, então foi realizado o registro das imagens Landsat relativo ao período em estudo; a segunda etapa referente ao monitoramento da evolução temporal da taxa de desmatamento foi realizado a partir da estimativa das áreas ocupadas por vegetação que

foram geradas a partir da classificação das imagens Landsat; na realização da terceira etapa aplicou-se modelos estatísticos de forma a relacionar os dados meteorológicos com as mudanças temporais na cobertura do solo possibilitando a investigação do impacto da vegetação nas mudanças climáticas. A Figura 5 apresenta um diagrama contendo as etapas realizadas neste estudo.

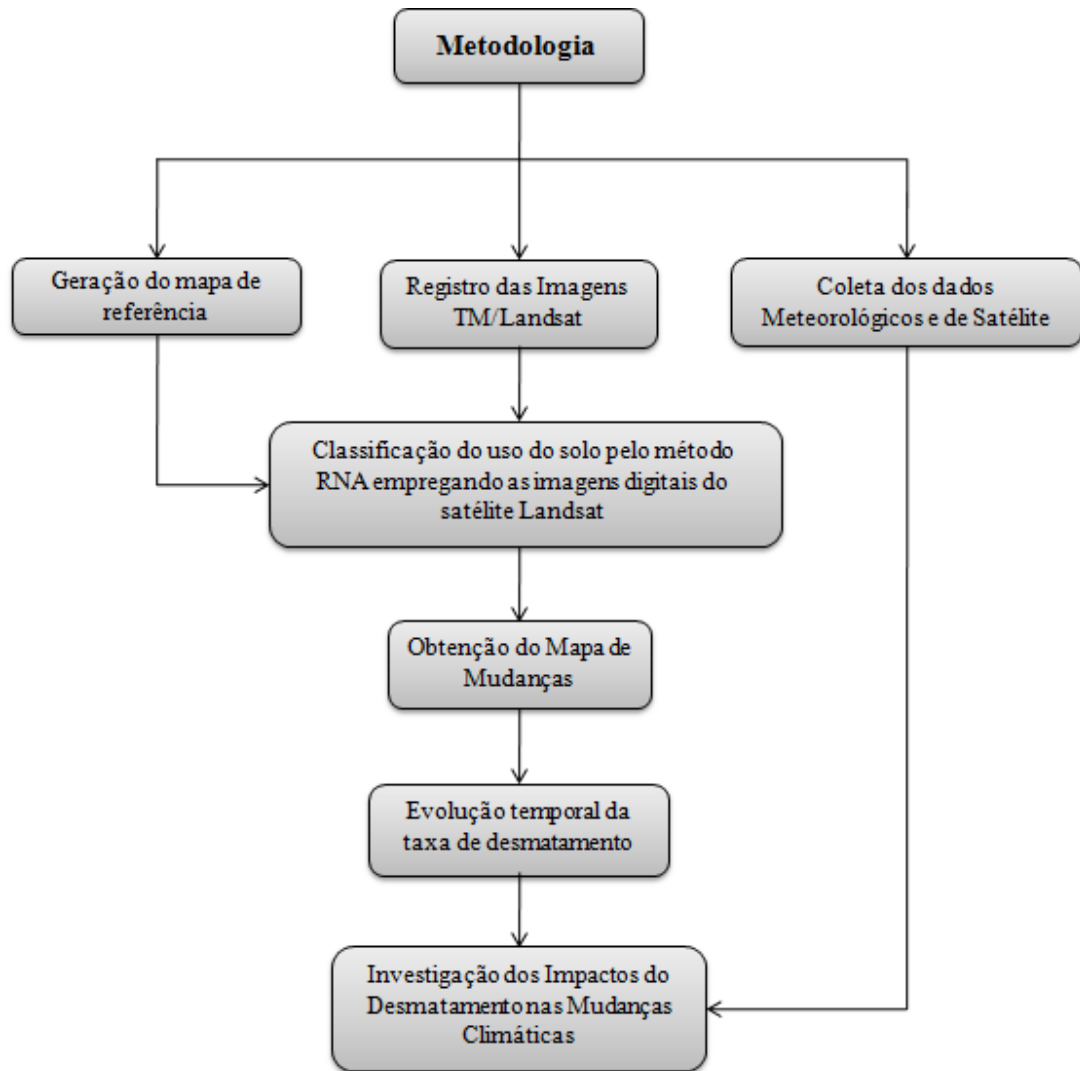


Figura 5- Diagrama contendo as etapas realizadas no estudo.

3.1 Caracterização da Área de Estudo

A bacia hidrográfica do Rio Turvo Sujo possui área total de 406,44 km² e pertence à bacia hidrográfica do Rio Doce. Esta bacia está compreendida entre as coordenadas geográficas 42°40' e 43°00' de longitude oeste e 20°39' e 20°55' de latitude sul,

abrangendo parte dos municípios de Viçosa, Cajurí, Coimbra e Teixeira, no Estado de Minas Gerais (Figura 6).

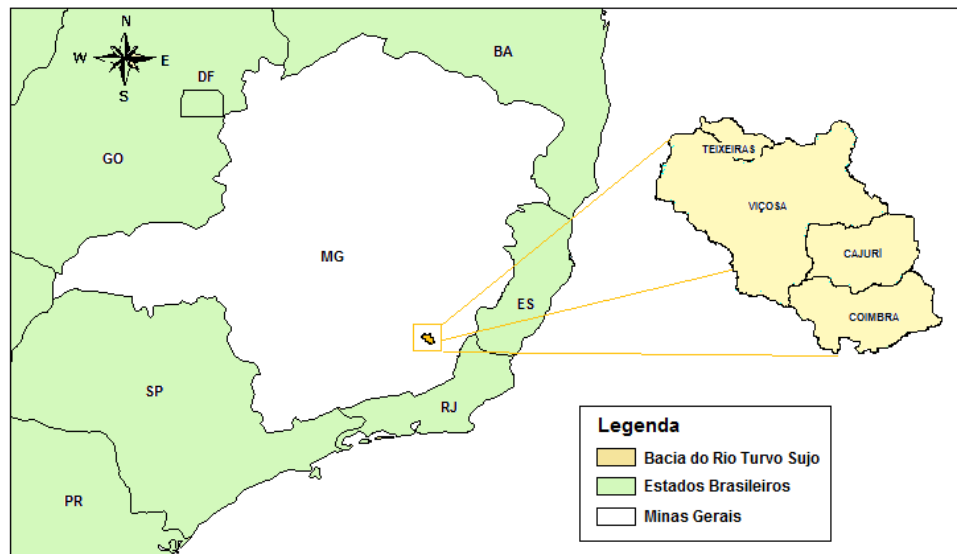


Figura 6- Área de estudo: bacia do Rio Turvo Sujo e os municípios localizados nesta bacia.

As Figuras 7, 8, 9 e 10 apresentam respectivamente a composição RGB das imagens do satélite Landsat referentes à área em estudo para os anos de 1984, 1989, 2000 e 2008.

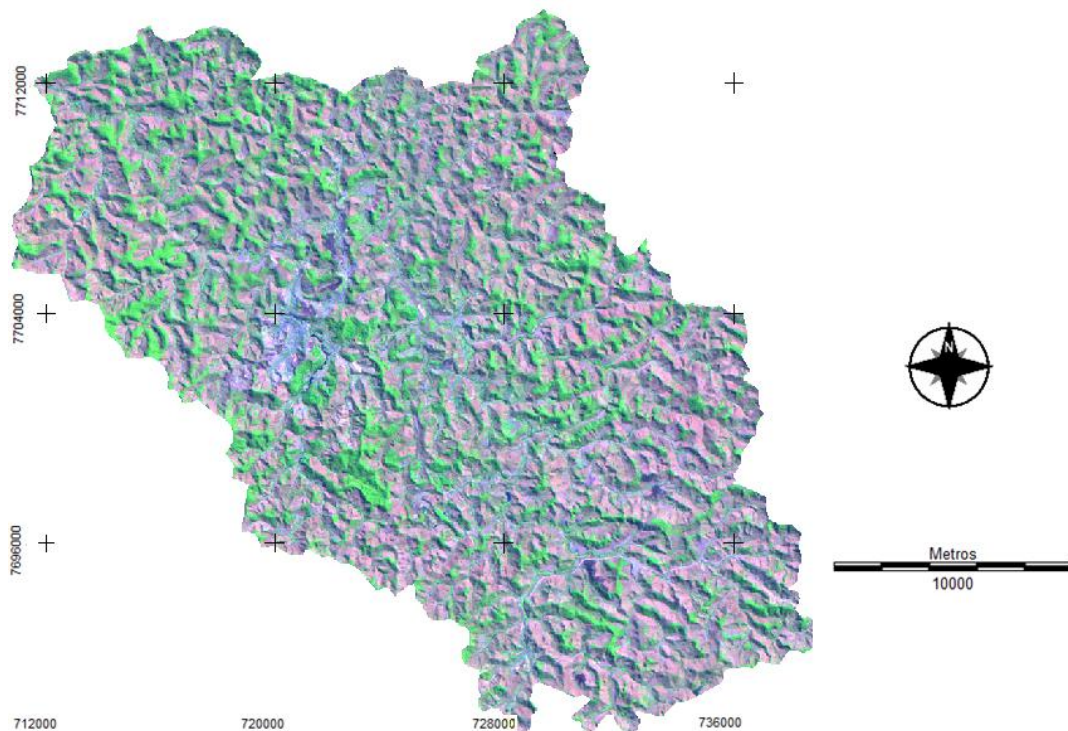


Figura 7- Imagem composta do Landsat (R/G/B) banda 3/4/5 do ano de 1984 da bacia do Rio Turvo Sujo.

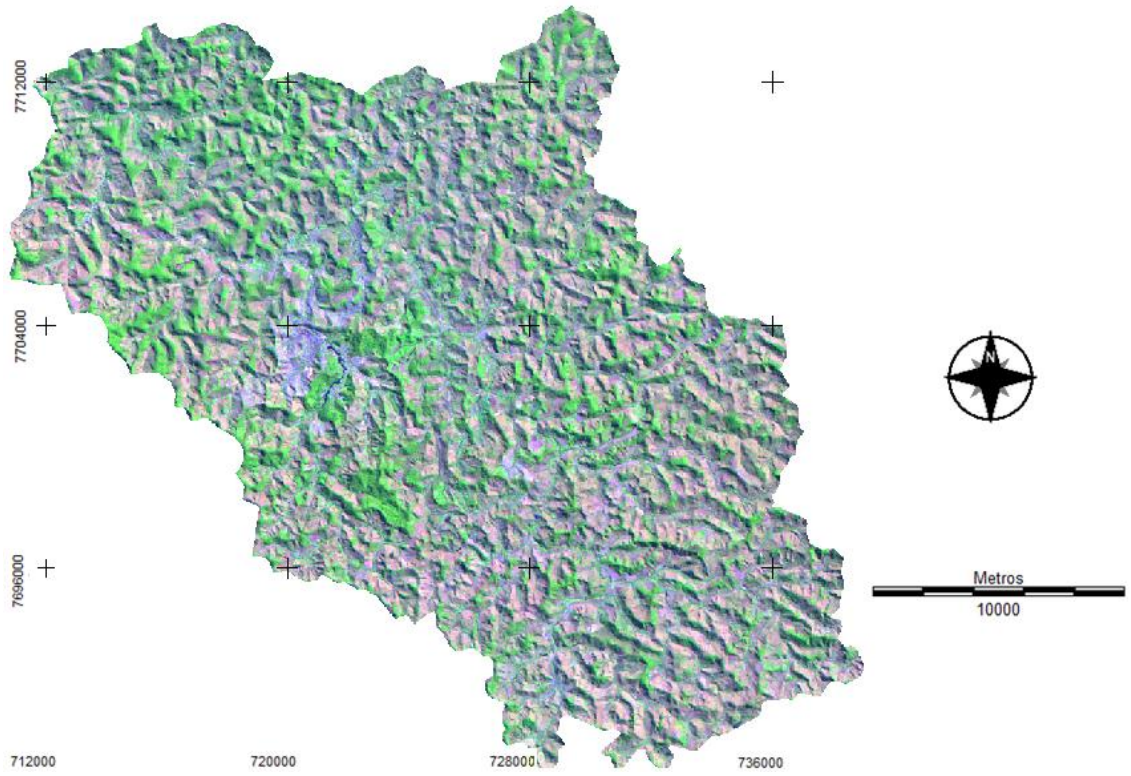


Figura 8- Imagem composta do Landsat (R/G/B) banda 3/4/5 do ano de 1989 da bacia do Rio Turvo Sujo.




Figura 9- Imagem composta do Landsat (R/G/B) banda 3/4/5 do ano de 2000 da bacia do Rio Turvo Sujo.

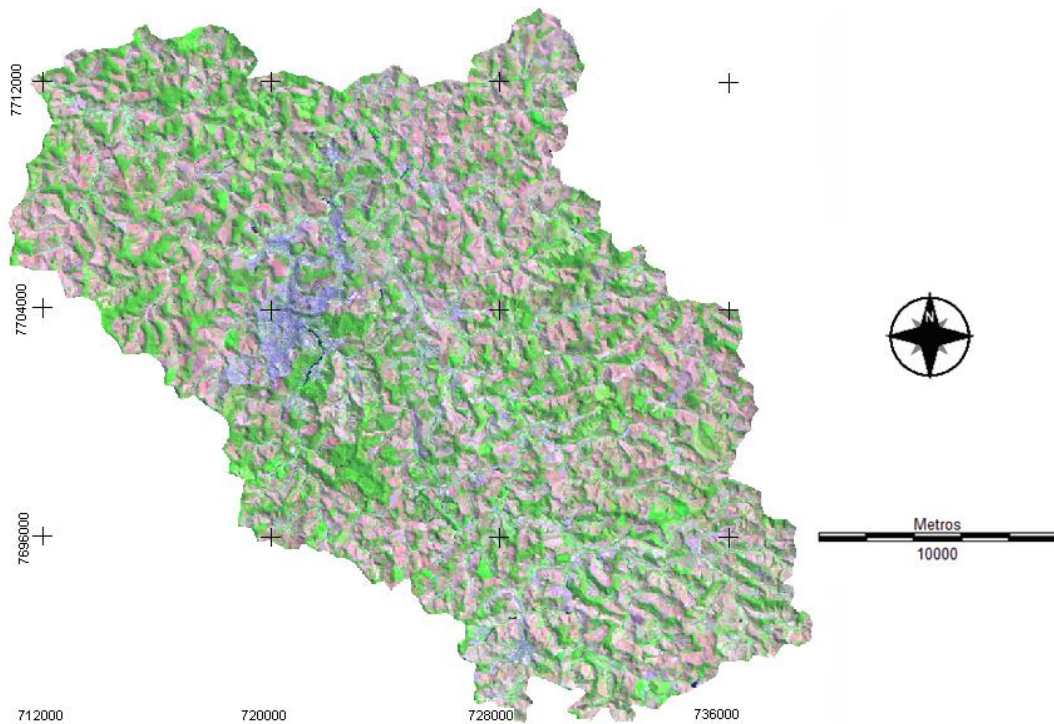


Figura 10- Imagem composta do Landsat (R/G/B) banda 3/4/5 do ano de 2008 da bacia do Rio Turvo Sujo.

3.2 Usos do solo e cobertura vegetal

A bacia hidrográfica do Rio Turvo Sujo foi originalmente coberta por Mata Atlântica, hoje suas matas correspondem a uma vegetação que sofreu influência antropológica intensa, constituindo-se em vegetação secundária. Os solos da bacia são em grande parte cobertos por pastos e capoeiras, demonstrando a predominância da atividade pecuária. Os campos e áreas cultivadas apresentam-se em menores proporções. Devido às características dos solos da bacia do Rio Turvo Sujo e aos manejos inadequados, a erosão está se tornando um problema ambiental na região.

3.3 Geração do mapa de referência

Primeiramente gerou-se uma imagem de referência da sub-bacia do Ribeirão São Bartolomeu, pertencente à bacia do Rio Turvo Sujo, a partir de um mosaico formado por imagens IKONOS referente ao ano de 2008. Para que o mapa de referência apresentasse maior veracidade foram realizadas visitas em campo em toda área correspondente a sub-bacia. De forma a dinamizar as visitas utilizou-se uma grade com

espaçamento regular, de modo que cada retângulo quando plotado na escala 1/5000, representasse uma área de 1 ha aproximadamente. Esta escala foi escolhida para que cada quadrícula pudesse ser representada em formato A4 facilitando assim o seu manuseio em campo.

Esse quadriculado foi rotulado com um índice remissivo composto por números e letras de modo a facilitar a identificação das regiões de trabalho (Figura 11).

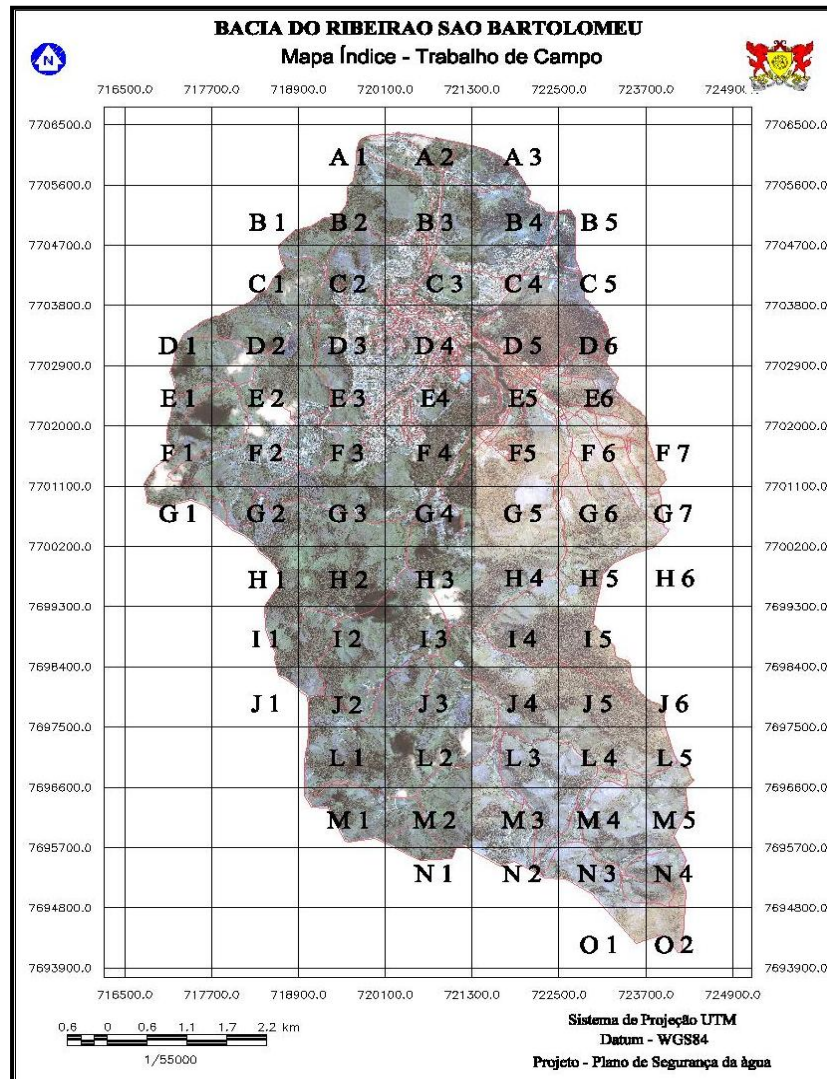



Figura 11– Modelo de plotagem do mosaico formado a partir da imagem IKONOS do ano de 2008, referente à bacia do Ribeirão São Bartolomeu – MG.

Juntamente com a imagem da região visitada, foram sobrepostas folhas transparentes que, fixadas a imagem, permitiram as anotações. A Figura 12 apresenta o modelo do recorte de cada quadrícula, no formato A4, formada a partir do mosaico de

imagens IKONOS da sub-bacia do Ribeirão São Bartolomeu, utilizado nas visitas a campo.



OU

Figura 12– Modelo do recorte de cada quadrícula, no formato A4, formada a partir do mosaico de imagens IKONOS, do ano de 2008, da sub-bacia do Ribeirão São Bartolomeu – MG, utilizada nas visitas a campo.

Após a visitação de toda área pertencente à sub-bacia do Ribeirão São Bartolomeu foi realizada a identificação dos polígonos e rotulação da imagem. Todos os polígonos foram digitalizados manualmente e utilizando o *software* ArcView, foi feita a identificação e atribuição das classes de interesse. Esta imagem incluiu as seguintes classes informacionais: agricultura, área urbana, café, eucalipto, hidrografia, mata alta, mata baixa, milho, nuvem, pastagem degradada, pastagem não degradada, solo exposto e vias. A Figura 13 apresenta o mapa de uso e cobertura do solo gerado para a bacia do Ribeirão São Bartolomeu.

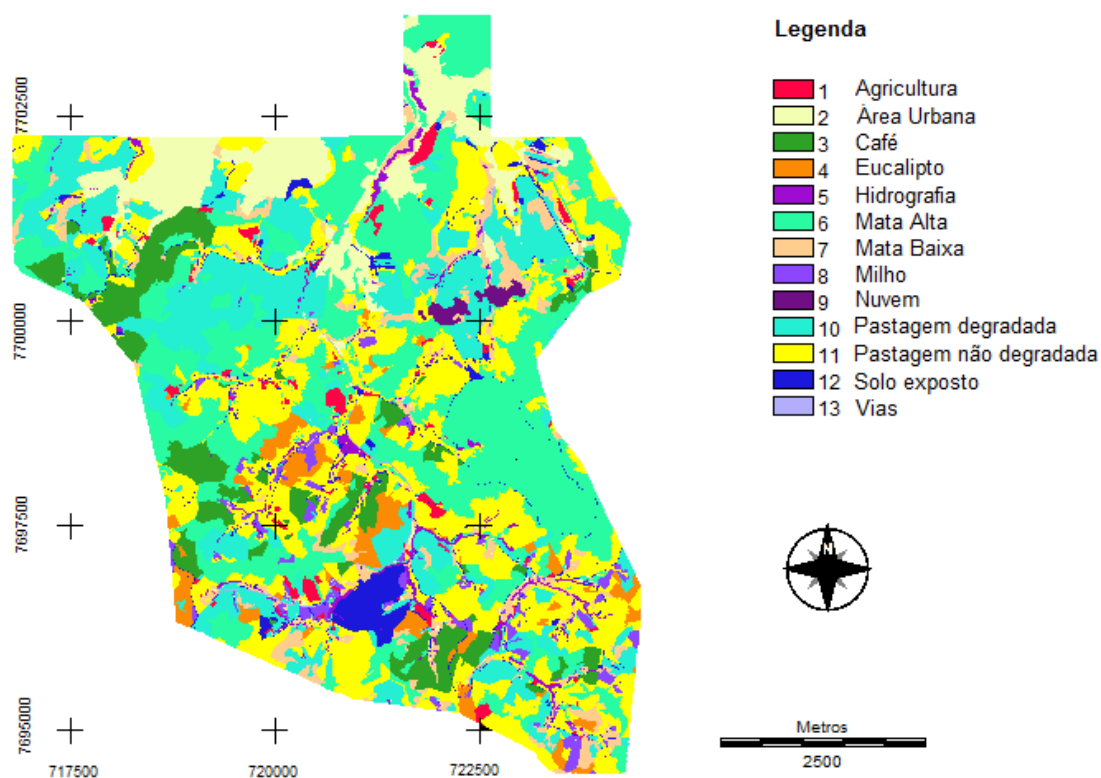


Figura 13- Mapa de uso e cobertura do solo gerado para a bacia do Ribeirão São Bartolomeu, do ano de 2008, a partir de uma imagem Ikonos.

Após a geração do mapa de uso e cobertura do solo realizou-se então uma fusão entre as classes eucalipto, mata alta e mata baixa, atribuindo a nova classe gerada o rotulo áreas com cobertura vegetal, procedendo da mesma forma, realizou-se a junção das classes: agricultura, área urbana, café, hidrografia, milho, nuvem, pastagem degradada, pastagem não degradada, solo exposto e vias, atribuindo a nova classe o rotulo, áreas sem cobertura vegetal. A Figura 14 apresenta o mapa de referência gerado contendo as duas classes de interesse: áreas com cobertura vegetal e áreas sem cobertura vegetal. Esta imagem foi utilizada para a validação das imagens temáticas geradas pelos processos classificatórios usando RNAs.

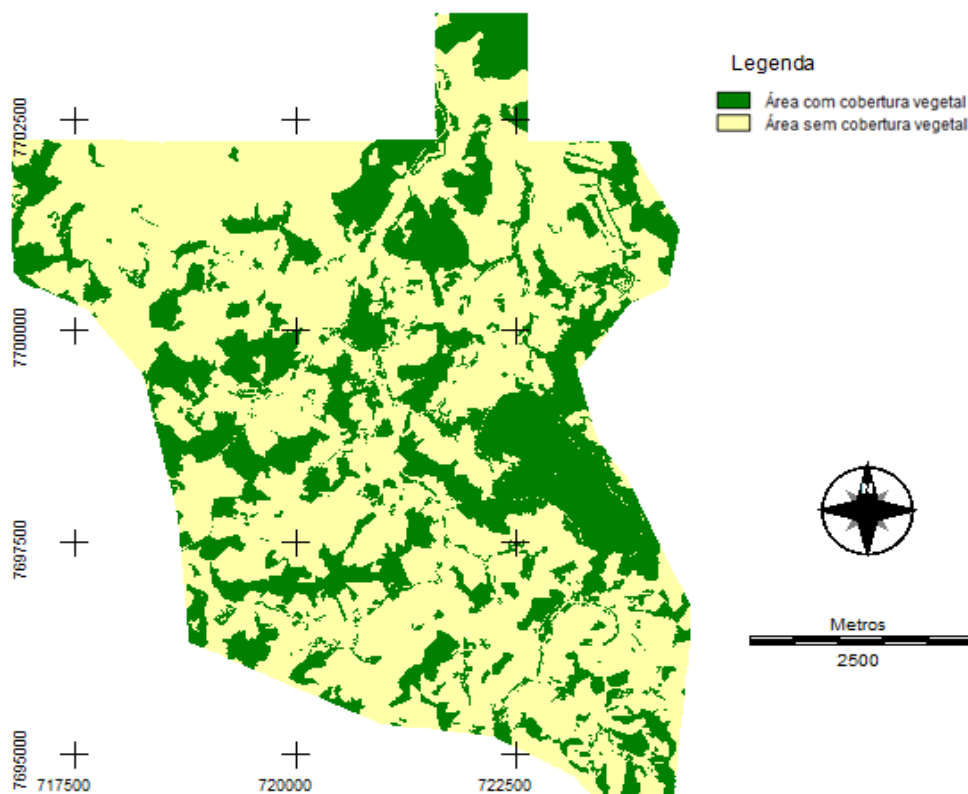


Figura 14- Mapa de referência gerado contendo as duas classes de interesse: áreas com cobertura vegetal e áreas sem cobertura vegetal.

3.4 Coleta dos dados Meteorológicos e de Satélites

Os dados meteorológicos foram coletados diretamente da estação meteorológica de Viçosa, durante o período de 1984 a 2007, na região referente à bacia do Rio Turvo Sujo existem diversas estações meteorológicas não registradas, dessa forma optou-se por utilizar apenas a estação pertencente à Viçosa. Os dados anuais de NDVI foram obtidos a partir de dados do NOAA AVHRR (Radiômetro Avançado de Altíssima Resolução) para o período de 1984 a 2006, fornecidos pelo “*Global Inventory Modeling and Monitoring System (GIMMS)*”, do “*Goddard Space Flight Center-GSFC/NASA*” (Centro Espacial de Vôo Goddard/Administração Nacional Aeroespacial), disponíveis no site: (<<http://glcf.umd.edu/data/gimms/>>), os dados quinzenais foram convertidos em dados mensais usando os valores médios. As imagens digitais do satélite Landsat adquiridas nos dias de 17/07/1984, 15/07/1989, 27/06/2000 e 05/09/2008, foram obtidas diretamente do INPE.

3.5 Registro das Imagens TM/Landsat

Os pontos de controle utilizados no registro das imagens, foram obtidos a partir da utilização da imagem Ikonos, referente a sub-bacia do Ribeirão São Bartolomeu, e do vetor contendo a hidrografia da região relativa a bacia do Rio Turvo Sujo, ambos referenciados ao sistema SAD 69.

O Registro das imagens foi executado através do método polinomial, utilizando o polinômio do 1º grau. Esse método modelou matematicamente a rotação da imagem de maneira que ela se ajustasse as coordenada de referência. Foram utilizados 15 pontos de controle em cada imagem. As equações 4 e 5 apresentam o polinômio do 1º grau.

$$X = a_0 + a_1x + a_2y \quad (4)$$

$$Y = b_0 + b_1x + b_2y \quad (5)$$

Em que:

x = coordenadas da imagem original;

y = coordenadas da imagem original;

X = coordenadas de referência;

Y = coordenadas de referência;

a_n = coeficientes de ajuste da equação determinado pelo método dos mínimos quadrados;

b_n = coeficientes de ajuste da equação determinado pelo método dos mínimos quadrados.

Após determinados os coeficientes de transformação, verificou-se a eficiência de cada um antes de aplicá-los na correção de toda a cena. O método utilizado envolveu a computação do erro médio quadrático (*Root Mean Square Error* - RMSe) para cada ponto de controle terrestre a partir da equação (6):

$$\text{RMSe} = [(X - x_{\text{original}})^2 + (Y - y_{\text{original}})^2]^{1/2} \quad (6)$$

Em que:

RMSe = Erro médio quadrático;

x_{original} = coordenadas da imagem original;

y_{original} = coordenadas da imagem original;

X = coordenadas estimadas pela equação;

Y = coordenadas estimadas pela equação.

O Registro foi realizado utilizando quinze pontos de controle, o RMSe total não apresentou valores superiores a 0,5 pixel, o equivalente a 15m. Foi utilizado como sistema de referência o SAD 69, fuso 23s e o sistema UTM.

3.6 Classificação do uso do solo pelo método RNA empregando as imagens digitais do satélite Landsat

A partir das imagens referentes ao sensor TM/Landsat, bandas 1, 2, 3, 4, 5 e 7, adquiridas nos dias de 17/07/1984, 15/07/1989, 27/06/2000 e 05/09/2008, todas relativas à área da bacia do Rio Turvo Sujo, foi realizada a classificação e identificação das classes: áreas com cobertura vegetal e áreas sem cobertura vegetal.

O classificador Redes Neurais Artificiais do *software* IDRISI Andes, disponível no Departamento de Engenharia Civil da Universidade Federal de Viçosa, foi utilizado para classificar e delinear as categorias de interesse. Obteve-se também através da utilização deste *software* o valor correspondente a cada área ocupada pelas classes com e sem cobertura vegetal.

Inicialmente as imagens foram registradas e então recortadas com o limite da bacia do Rio Turvo Sujo. A partir das visitas realizadas em campo foram identificadas amostras de áreas com vegetação e de áreas sem cobertura vegetal, em cada uma das imagens Landsat referentes ao período em estudo.

Uma Rede Neural Artificial foi então treinada atribuindo ao classificador duas camadas ocultas variando, cada uma, de três a trinta neurônios. Variou-se também a taxa de aprendizado iniciando com o maior valor, igual a 0,2 e baixando pra 0,1 e por fim 0,075. Utilizou um valor de *momentum* constante e igual a 0,9.

De forma a validar as classificações utilizou-se o índice *kappa*, disponível no *software* Idrisi, para isso relacionou-se a imagem de referência com as imagens temáticas obtidas a partir do classificador Redes Neurais.

Outra forma utilizada para verificar se a rede estava bem treinada e se os resultados estavam consistentes foi proceder à classificação utilizando as classes: áreas com cobertura vegetal e áreas sem cobertura vegetal, porém utilizando nas imagens o limite da sub-bacia do Ribeirão São Bartolomeu. Após a classificação, as áreas referentes às classes de interesse, obtidas a partir da classificação da imagem Landsat do ano de 2008, foram então comparadas às áreas identificadas na imagem IKONOS, do ano de 2008, após visitas a campo.

A partir das classificações foi estimada a evolução da taxa do desmatamento baseada nas porcentagens das áreas com vegetação e sem vegetação.

3.7 Obtenção do Mapa de Mudanças

Utilizou-se então o módulo LCM para analisar as mudanças ocorridas na área em estudo, gerando dados de ganhos e perdas (mudança líquida) para as classes de interesse, focando as transições ocorridas entre a classe área sem cobertura vegetal.

Inicialmente, inseriram-se os parâmetros no ambiente de projetos do LCM, dentre eles: uma imagem temática obtida a partir da classificação da área em estudo na data de 1984 com resolução de 30 m; uma imagem temática obtida a partir da classificação da área de estudo do ano 2008 com resolução de 30 m; e desta maneira criou-se um novo projeto.

Em seguida, utilizando o ambiente de Análise de Mudanças do módulo, obteve-se um gráfico de ganhos e perdas, em hectares, ocorridos para as duas classes temáticas contidas nas duas imagens no intervalo de tempo de 1984 e 2008.

Gerou-se, então, um mapa de tendência que possibilitou identificar a direção na qual ocorre maior mudança entre as classes em estudo.

Em seguida foi gerado um mapa de mudanças, que possibilitou a visualização das células que sofreram alteração de classe informacional no período de 1984 a 2008. Para gerar tal mapa, foi utilizado dentro do ambiente de análise de mudanças o item mapas de mudanças, e em seguida escolhida a opção mapa de transição de todas as classes para a classe áreas com cobertura vegetal.

3.8 Evolução temporal da taxa de desmatamento

As imagens digitais do satélite Landsat/TM adquiridas nos dias de 17/07/1984, 15/07/1989, 27/06/2000 e 05/09/2008 foram utilizadas nas análises da evolução do desmatamento durante os 24 anos decorridos. A porcentagem de desmatamento anual foi estimada a partir da área total sem cobertura vegetal, obtida a partir da classificação, dividida pela área total da bacia do Rio Turvo.

3.9 Investigação dos Impactos do Desmatamento nas Mudanças Climáticas

A evolução temporal da taxa de desmatamento em porcentagem obtida com as imagens do Landsat foi comparada com a tendência da diminuição da cobertura vegetal inferida pelo NDVI/AVHRR anual durante o período de 1984 a 2006 a fim de confirmar que a evolução temporal deste índice é uma fonte importante para inferir a tendência do desmatamento. Foram comparadas as tendências dos fatores climáticos, incluindo temperatura e precipitação, tendências da evolução temporal de NDVI e da evolução da porcentagem do desmatamento para investigar os impactos das mudanças climáticas na bacia em estudo.

Os dados anuais de precipitação e temperatura foram usados para investigar as tendências de mudanças climáticas regionais, utilizando para isso regressão linear e os *softwares* SAS e Excel.

Os modelos de estimativa das tendências de mudanças climáticas regionais em função do NDVI, temperatura e precipitação, foram construídos usando as técnicas de regressão linear, disponíveis no *software* SAS (“*Statistical Analysis System*”).

As equações (7) à (9) representam os modelos de tendência referentes a precipitação, temperatura e NDVI respectivamente.

$$T_{\text{Precipitação}} = -3596,77 + (2,42 * \text{Ano}) \quad (7)$$

$$T_{\text{Temperatura}} = -58,95 + (0,04 * \text{Ano}) \quad (8)$$

$$T_{\text{NDVI}} = -6,13 + (0,006 * \text{Ano}) \quad (9)$$

Em que:

$T_{\text{Precipitação}}$ = Tendência de precipitação;

$T_{\text{Temperatura}}$ = Tendência de temperatura;

T_{NDVI} = Tendência de NDVI;

O Apêndice C apresenta o modelo de Tendência gerado relativo a precipitação, temperatura e NDVI respectivamente.

E por fim foi realizada a aplicação de modelos estatísticos que relacionaram os dados meteorológicos com as mudanças temporais na cobertura vegetal inferida pelo NDVI, de forma a investigar o impacto da vegetação nas mudanças climáticas.

4. RESULTADOS

4.1 Classificação do uso do solo pelo método RNA empregando as imagens digitais do satélite Landsat/TM

A partir da utilização de Redes Neurais e das bandas 1, 2, 3, 4, 5 e 7 das imagens Landsat/TM, foram geradas as imagens classificadas. As Figuras 15, 16, 17, 18 mostram respectivamente as imagens obtidas após a classificação, contendo as classes: área com cobertura vegetal e sem cobertura vegetal, referentes à área em estudo para os anos de 1984, 1989, 2000 e 2008. Os valores de *Kappa* obtidos a partir das classificações das 4 imagens foram iguais a 0,97; 0,98, 0,98 e 0,98 para os anos de 1984, 1989, 2000 e 2008 respectivamente. Esses valores de Kappa foram considerados satisfatórios. Acredita-se ter encontrado valores tão altos referentes ao índice *kappa* por ter utilizado maior número de bandas e desejar identificar apenas duas classes informacionais.

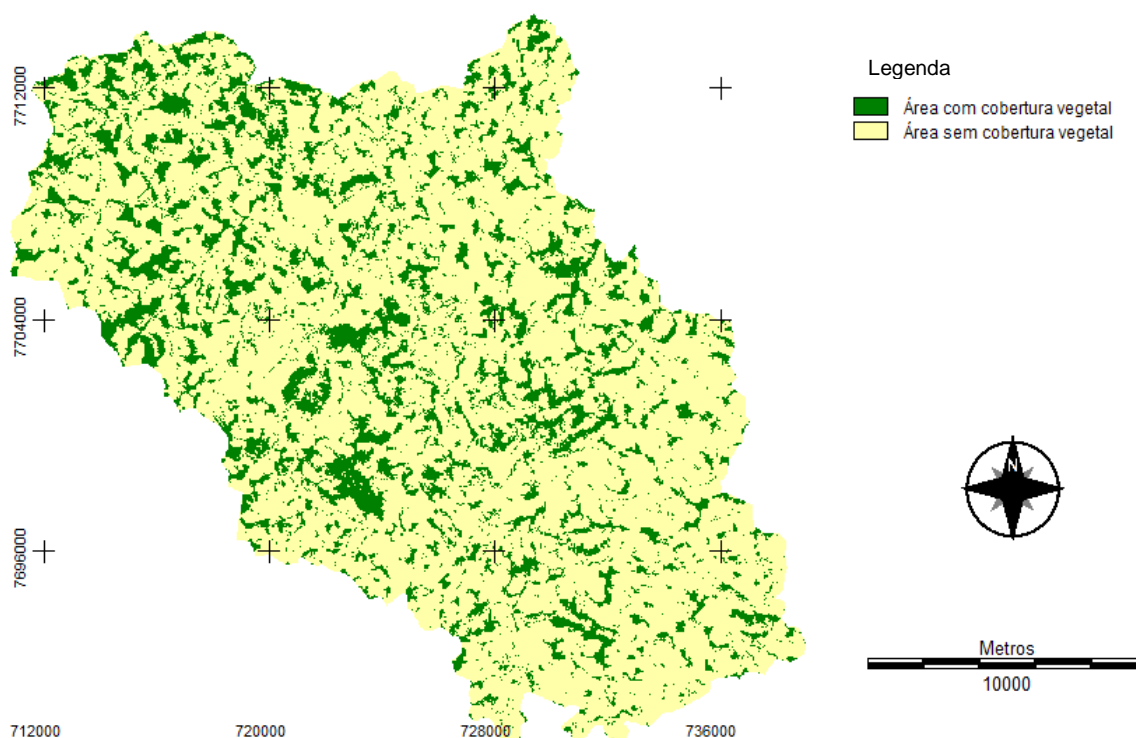


Figura 15- Imagem temática contendo as classes de interesse referentes ao ano 1984 da bacia do Rio Turvo Sujo - MG.

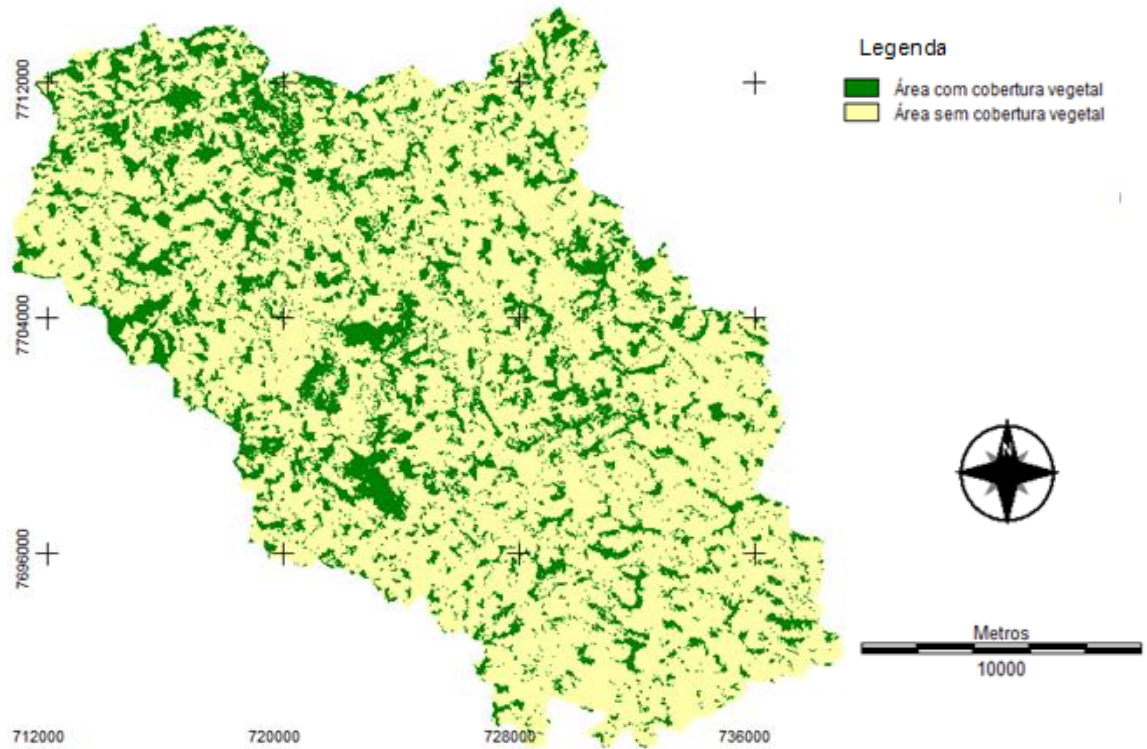


Figura 16- Imagem temática contendo as classes de interesse referentes ao ano 1989 da bacia do Rio Turvo Sujo-MG.

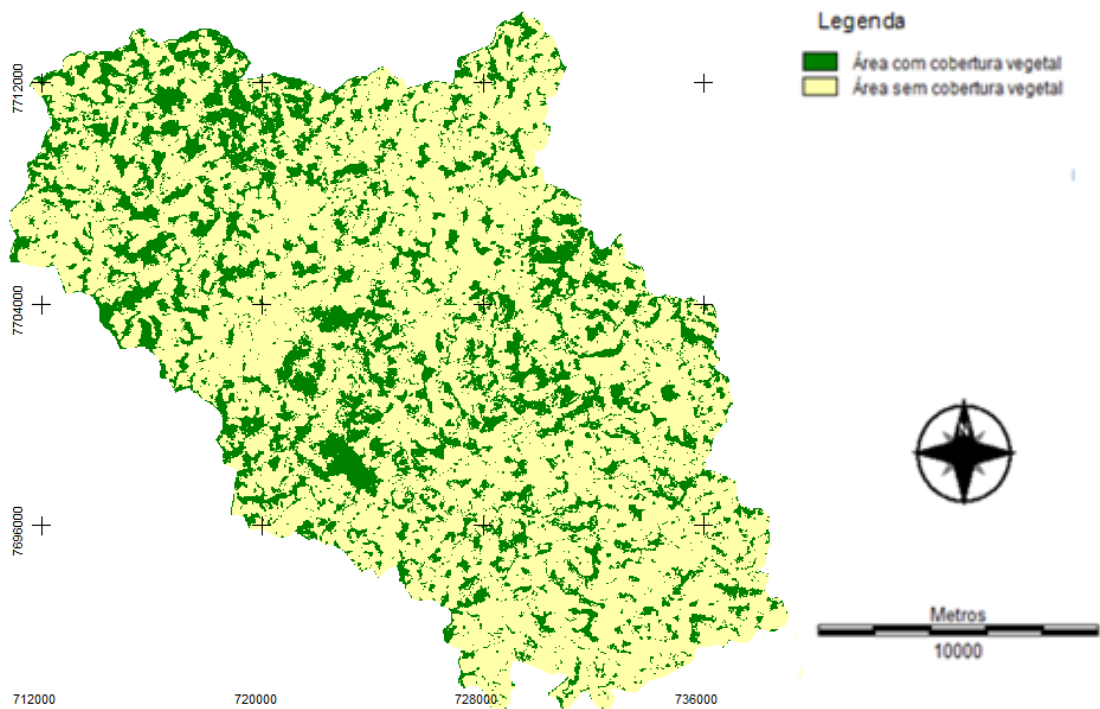


Figura 17- Imagem temática contendo as classes de interesse referentes ao ano de 2000 da bacia do Rio Turvo Sujo - MG.

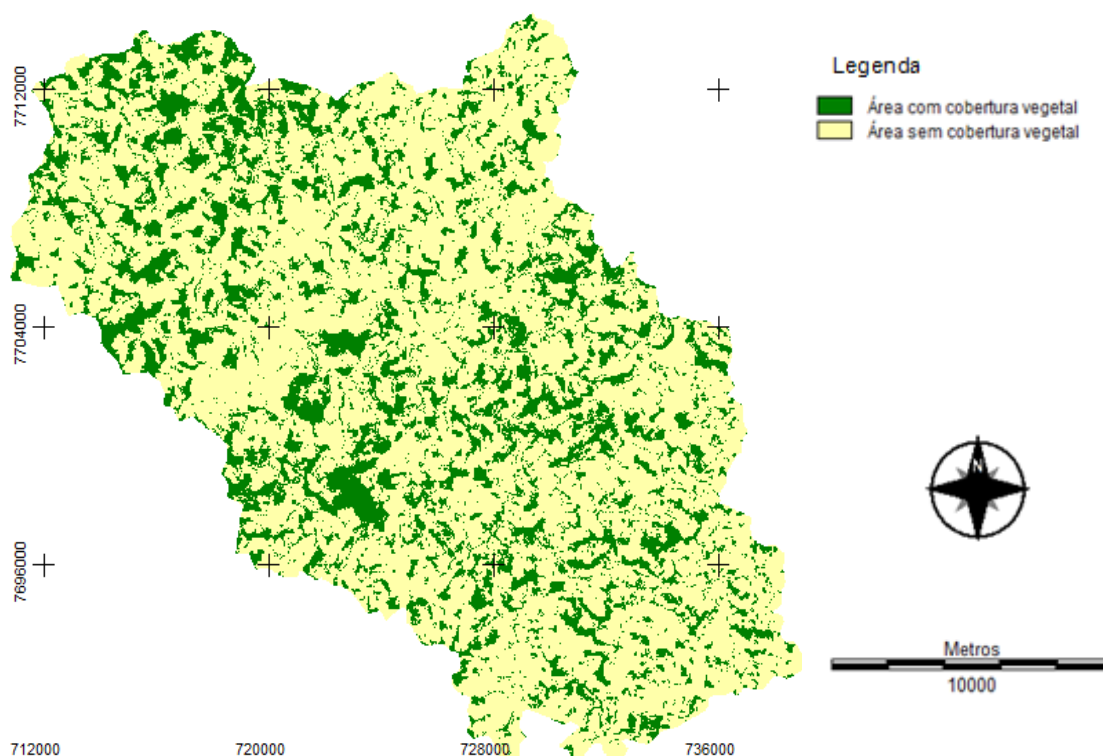


Figura 18- Imagem temática contendo as classes de interesse referentes ao ano de 2008 da bacia do Rio Turvo Sujo - MG.

De forma a se verificar se a rede estava bem treinada e se os resultados estavam consistentes, realizou-se uma classificação utilizando as classes: áreas com cobertura vegetal e áreas sem cobertura vegetal, porém utilizando nas imagens o limite da sub-bacia do Ribeirão São Bartolomeu. Após a classificação, as áreas referentes as classes de interesse foram então comparadas as áreas identificadas na imagem IKONOS após visitas a campo. A Tabela 10 apresenta a comparação entre as áreas referentes à classificação utilizando as imagens Landsat/TM do ano de 2008 e as áreas obtidas após a vetorização da imagem IKONOS.

Tabela 10. Comparação entre as áreas referentes à classificação utilizando imagens Landsat (2008) e as áreas obtidas após a vetorização da imagem IKONOS (2008).

	IKONOS	%	LANDSAT	%	% Diferença
Áreas com cobertura vegetal (km ²)	15,12	35,23	15,19	35,35	-0,12
Áreas sem cobertura vegetal (Km ²)	27,80	64,77	27,73	64,65	0,12

A Figura 19 apresenta as imagens temáticas obtidas a partir da classificação de uma imagem Landsat/TM e imagem temática obtida a partir da digitalização de uma imagem Ikonos, ambas contendo as classes de interesse referentes ao ano de 2008 da sub-bacia do bacia do Ribeirão São Bartolomeu. A amostra visual desta figura apresenta uma grande semelhança entre as duas imagens, o que foi comprovado pela análise quantitativa da Tabela 10.

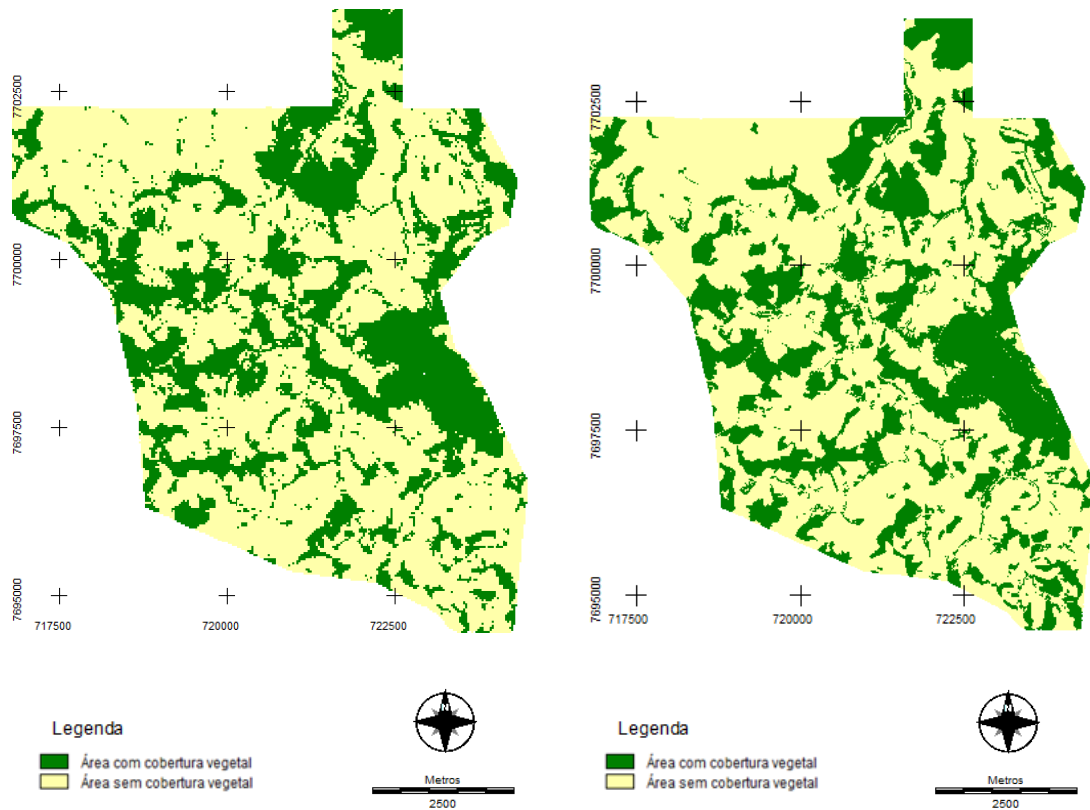


Figura 19 - Imagem temática obtida a partir da classificação de uma imagem Landsat, de 2008 (a esquerda) e imagem temática obtida a partir da digitalização de uma imagem Ikonos, de 2008 (a direita) ambas contendo as classes de interesse referentes ao ano de 2008 da sub-bacia do bacia do Ribeirão São Bartolomeu.

4.2 Obtenção do mapa de Mudanças

Utilizando o módulo LCM foi possível analisar as mudanças ocorridas na área em estudo, uma vez que este permitiu a geração de um gráfico de ganhos e perdas (mudança líquida) para as classes de interesse, focando as transições ocorridas entre a classe área sem cobertura vegetal. A partir do gráfico foi possível observar um ganho de 5192 ha para classe áreas com cobertura vegetal, representado no gráfico pela cor verde e uma perda referente a mesma classe igual a 3195 ha, representado pela cor roxa. A Figura 20 apresenta o gráfico gerado

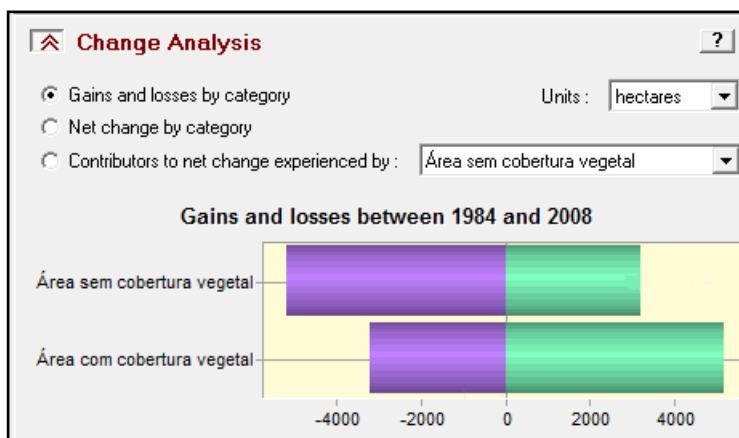


Figura 20- Gráfico de ganhos e perdas das classes entre 1984 e 2008.

A fim de identificar e visualizar a direção na qual ocorreu maior mudança da classe área com cobertura vegetal no período de 1984 a 2008, gerou-se um mapa de tendência que proporcionou esta análise. A Figura 21 apresenta o mapa de tendência gerado (a esquerda) e a imagem formada a partir da composição R/G/B da imagem Landsat do ano de 2008 (a direita).

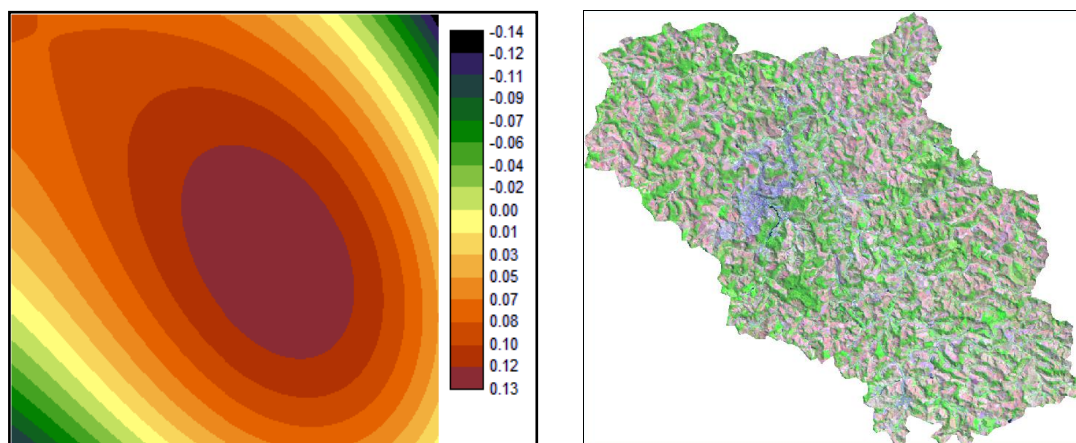


Figura 21- Mapa de tendência de mudanças gerado para classe área com cobertura vegetal (a esquerda) e a imagem formada a partir da composição R/G/B da imagem Landsat do ano de 2008 (a direita).

Como pode ser observado este processo provê meios mais efetivos de generalizar a tendência, ficando evidente que a mudança para a classe área com cobertura vegetal é concentrada principalmente nas direções noroeste e sudeste da imagem, onde ocorrem os maiores valores de tendência.

A fim de complementar as análises, gerou-se um mapa de mudanças, que apresenta as células que sofreram alterações de classe informacional no intervalo de

tempo em estudo, de modo a se ter uma idéia da distribuição espacial dessa mudança. A Figura 22 apresenta o mapa de mudança gerado durante o período de 1984 a 2008, utilizando para isso as imagens classificadas, obtidas a partir da utilização das imagens Landsat/TM, referentes aos anos de 1984 e 2008

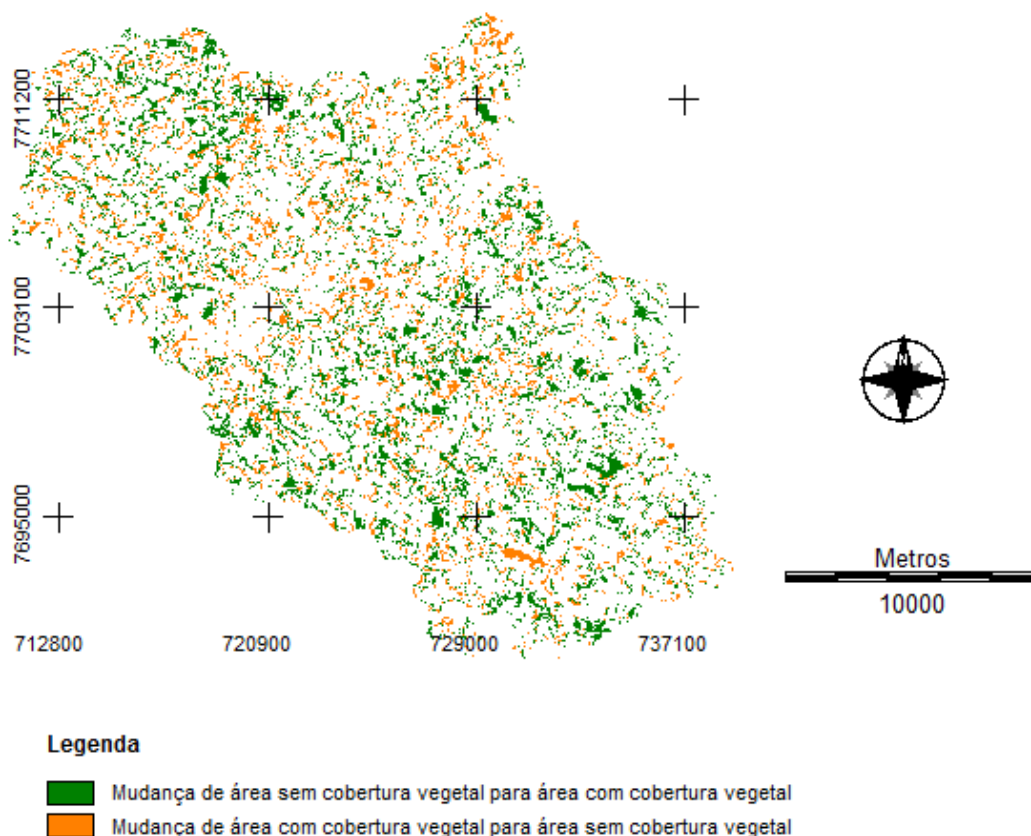


Figura 22- Mapa de mudanças gerado para as classes área com cobertura vegetal e área sem cobertura vegetal, durante o período de 1984 a 2008.

4.3 Monitoramento da evolução temporal da taxa de desmatamento

A Tabela 11 mostra os resultados das áreas com e sem vegetação e suas porcentagens referentes à bacia do Rio Turvo Sujo. Foram observadas que a evolução da área com vegetação aumentou de 21,01% no ano 1984, para 24,00% em 1989 alcançando 29,56% em 2000 e diminuindo para 25,96% no ano de 2008. Estes dados indicaram aumento do reflorestamento durante o período de 1984 a 2000 e uma tendência de desaceleração após 2000. Vale ressaltar que restam somente cerca de 30% da área da bacia ocupada por vegetação desde o ano 1984. Considerando que a região é montanhosa e que a topografia é caracterizada como ondulada e fortemente ondulada, e que existe pouca área ocupada por vegetação nativa e florestal, a bacia pode apresentar maior vulnerabilidade a degradação do solo.

Tabela 11. Áreas com e sem vegetação e suas respectivas porcentagens para bacia do Rio Turvo Sujo classificadas pelas imagens Landsat adquiridas nos anos de 17/07/1984, 15/07/1989, 27/06/2000 e 05/09/2008.

Ano / Porcentagem	1984	%	1989	%	2000	%	2008	%
Área com vegetação (km ²)	84,85	21.08	96,92	24.00	120,16	29,56	104,83	25.96
Área sem vegetação (km ²)	318,71	78.92	306.64	75.93	286,28	70,44	298,73	73.97

4.4 Investigação dos Impactos do Desmatamento nas Mudanças Climáticas

A Figura 23 apresenta a comparação entre a tendência e a evolução temporal de NDVI (a), Temperatura (b) e Precipitação (c) para a bacia do Rio Turvo Sujo, MG durante o período de 1984 a 2007. As tendências mostram que o NDVI anual aumentou de 6,60 para 6,74 durante o período de 1984 a 2006 (Figura 23a), a temperatura média anual aumentou de 19,6 °C para 20,5 °C (Figura 23b) e precipitação total anual aumentou de 1198 mm para 1251 mm (Figura 23c). Comparando as evoluções de NDVI, temperatura e precipitação na Figura 23, foi observado que a variação anual de NDVI acompanhou bem a evolução da precipitação. A diminuição da tendência do NDVI após o ano de 2000 coincidiu com o a tendência de aumento da temperatura e com uma tendência de instabilidade na precipitação que apresentou seu maior valor, nesta série, no ano de 2004 e seu menor valor no ano de 2007. Estes resultados apresentaram indícios de que houve um processo de reflorestamento nas décadas de 80 e 90 na Bacia do Rio Turvo Sujo - MG além de um manejo inadequado de usos do solo após o ano de 2000. Os dados indicaram que o clima da Bacia em estudo respondeu bem aos atos de reflorestamento e desmatamento.

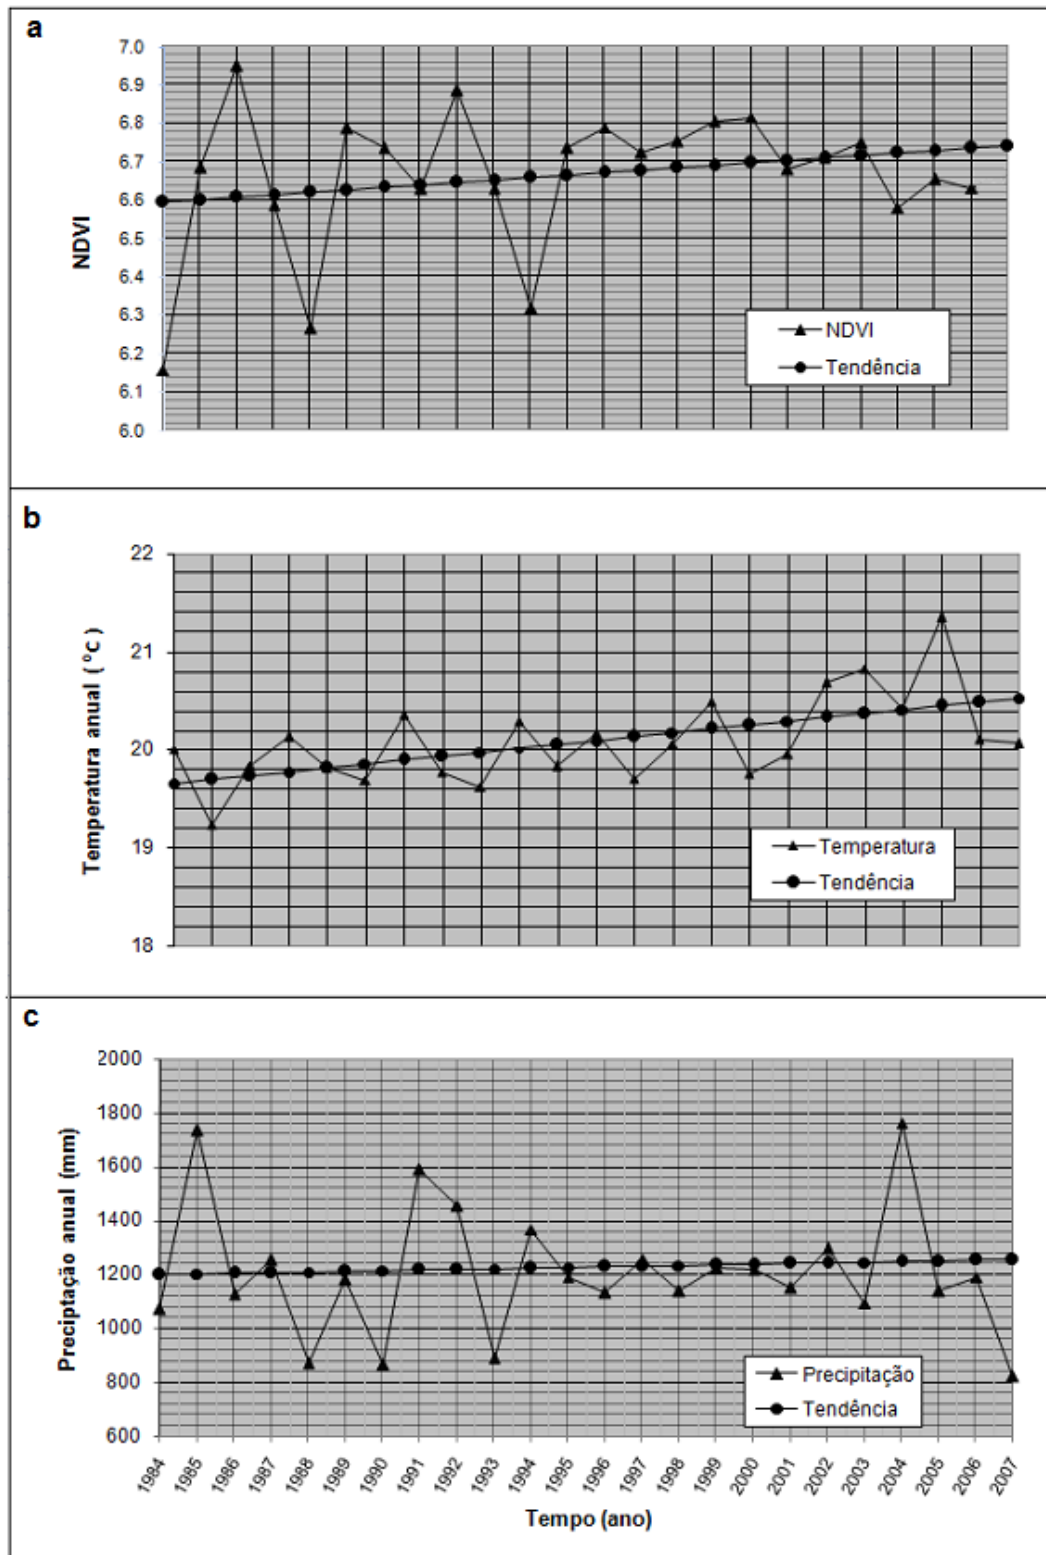


Figura 23- Comparação das tendências das evoluções temporais de NDVI anual (a), Temperatura media anual (b) e Precipitação total anual (c) para a bacia do Rio Turvo Sujo –MG durante o período de 1984 a 2007.

5. CONCLUSÕES E RECOMENDAÇÕES

Após a análise e discussão dos resultados, chegou-se as seguintes conclusões:

- A taxa do desmatamento foi reduzida e a área com cobertura vegetal aumentada de 21,01% em 1984 a 24,00% em 1989, 29.56% em 2000 diminuindo para 25.96% em 2008. Esses valores indicaram que a bacia estudada sofreu reflorestamento durante o período anterior ao ano 2000 e desmatamento e degradação de terra nos anos posteriores. O processo de reflorestamento apresentado pelo NDVI anual resultou em dados de precipitação anual e de temperatura média anual mais estáveis.
- Da análise da evolução temporal, foi observado que o NDVI relacionou-se diretamente com precipitação, mas inversamente com a temperatura. Da análise de tendência do NDVI, precipitação e temperatura, foi observado que o NDVI aumentou ligeiramente de 6.60 a 6.64, a precipitação de 1200 mm para 1220 mm e a temperatura de 19.6 °C para 20.5 °C. Concluiu-se que as séries temporais de NDVI anual geradas a partir do satélite NOAA/AVHRR provêm uma importante fonte de investigação dos impactos de desmatamento nas mudanças climáticas regionais como também o reflorestamento minimiza as mudanças climáticas locais.
- Restam somente cerca de 30% da área da bacia ocupada por vegetação desde o ano 1984. Considerando que a região é montanhosa e que a topografia é caracterizada como ondulada e fortemente ondulada, e que existe pouca área ocupada por vegetação nativa e florestal, a bacia pode apresentar maior vulnerabilidade a degradação do solo.
- Este estudo demonstrou que a utilização dos dados de satélites ambientais, tais como NOAA e Landsat, é altamente viável por permitir o monitoramento da evolução temporal de usos do solo e o estudo dos impactos dos desmatamentos na mudança climática local.

Sugerindo-se que ações adequadas no reflorestamento e na preservação dos recursos ambientais devem ser tomadas na Bacia do Rio Turvo Sujo para inverter a

tendência de aumento da temperatura e tendência diminuição da precipitação após o ano de 2000.

Com base neste estudo sugere-se para trabalhos futuros o aprofundamento de novas pesquisas, com ênfase em intervenções que revertam ou minimizem os impactos do desmatamento nas mudanças climáticas locais, utilizando para isso, dados do sensoriamento remoto e o Sistema de Informações Geográficas.

REFERÊNCIAS BIBLIOGRÁFICAS

AGÊNCIA NACIONAL DE ÁGUAS (ANA). Disponível em <<http://www.ana.gov.br>>. Acesso em: 28 de fevereiro de 2008.

ARONOFF, S.; **Geographic Information System: a Management Perspective**. Publications, Canada, 1989.

ASSIS, L. C. **Uso de informações contextuais no processo de classificação de imagens do sensoriamento remoto**. p. 139. Dissertação (Mestrado em Informações Espaciais) Universidade Federal de Viçosa. Viçosa, MG. 2008.

BACK, A. J. **Aplicação de análise estatística para identificação de tendências climáticas**. Pesquisa Agropecuária Brasileira. Brasília, v. 36, n. 5, p. 717-726, maio 2001.

BARBOSA, H. A. **Análise espaço temporal de índice de vegetação AVHRR/NOAA e precipitação na região nordeste do Brasil em 1982-85. São José dos Campos**. p.164. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, 1998.

BENEDIKTSSON, J. A.; SWAIN, P. H.; ERSOY, O. K. **Neural network approaches versus statistical methods in classification of multicourse remote sensing data**. IEE Transactions on Geosciences and Remote Sensing, v.28 n.4, p. 540- 552. 1991.

CARVALHO, L. M. T. **Sistemas de informações Geográficas e Sensoriamento Remoto dos Recursos Florestais**. UFLA/FAEPE. Lavras, p. 109. 2005.

CEMIG - Companhia Energética de Minas Gerais Disponível em: <http://www.cemig.com.br/meio_ambiente/prog_matas.asp> Acesso em 20 de janeiro de 2009.

CEMIG - Companhia Energética de Minas Gerais. Disponível em: <http://www.cemig.com.br/meio_ambiente/reserv_viveiro.asp>. Acesso em 20 de janeiro de 2009.

CONGALTON, R. **Assessing the accuracy of Remotely Sensed data: Principles e Practices**, by CRC USA. 1999.

CONGALTON, R. G. & GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers. 137p. 1999.

CONGALTON, R. G. **A review of assessing the accuracy of classifications of remotely sensed data**. Remote Sensing of Environment, 49(12), p.1671-1678. 1991.

COPPIN, P.; JONCKHEERE, I.; NACKAERTS, K.; MUYS, B.; LAMBIN, E. **Review article digital change detection methods in ecosystem**. International Journal of the techniques of detection of changes in the Remote Sensing, v. 25, n. 9, p. 1565-1596, 2004.

COURA, S. M. C. **Mapeamento de vegetação do Estado de Minas Gerais utilizando dados Modis**. 147 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais. São José dos Campos. 2007.

CROSTA, A.P. **Processamento Digital de Imagens de Sensoriamento Remoto**. IG/UNICAMP, Campinas, SP, 170p. 1993.

CRÓSTA, A.P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: IG/UNICAMP, 170 p. 1992.

EBERT, J.A., LYONS, T.R. **Archaeology, Anthropology, and cultural resources management**. In: Manual of remote sensing, 2nd edition, Falls Church, American Society of Photogrammetry and Remote Sensing. v. 2, p. 1233 - 1304. 1983.

EHRlich, D.; LAMBIN, E. F. **Broad scale land-cover classification and interannual climatic variability**. International Journal of Remote Sensing, v. 17, n. 5, p. 845- 862. Mar. 1996.

FONSECA, L. M. G. **Introdução ao Processamento Digital de Imagens**. Manuais Técnicos em Geociências - número 9. INPE. Junho de 2000.

FOODY, G. & ARORA, M. **Incorporating mixed pixels in the training, allocation and testing stages of supervised classifications**. Pattern Recognition Letters, Vol. 17, Nº 13, p. 1389-1398. 1996.

GALLEGO F.J., **Remote sensing and land cover area estimation**. International Journal of Remote Sensing, Volume 25, Number 15, p. 3019-3047(29). August 2004.

FIGUEIREDO, G. C. **Exatidão posicional e temática de imagens orbitais**. p 104. Dissertação (Mestrado em Informações Espaciais) Universidade Federal de Viçosa. Viçosa, MG. 2007.

GLOBAL LAND COVER FACILITY. Disponível em: <<http://glcf.umiacs.umd.edu/data/gimms/>>. Acesso em 10/10/2008.

GOLFARI, L. **Zoneamento ecológico do Estado de Minas Gerais para reflorestamento**. Belo Horizonte: PNUD/FAO/IBDF-BRA/71/545. 65 p. (Série Técnica, 3). 1975.

GONG, P., **Integrated analysis of spatial data from multiple sources: using evidential reasoning and artificial neural network techniques from geological mapping**. Photogrammetric Engineering & Remote Sensing, v. 62, n. 5, p. 513-523, 1996.

GONZALES, R. C; WOODS, R. E. **Processamento de Imagens Digitais**. Tradução de Roberto Marcondes César Junior e Luciano da Fontoura Costa. Editora Edgard Blücher Ltda. p.509. 2000.

GURGEL, H. C. **Variabilidade Espacial e Temporal do NDVI sobre o Brasil e suas conexões com o clima**. p. 120. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais - INPE. São José dos Campos. 2003.

HOLBEN, B. N. **Characteristics of maximum value composite images from temporal AVHRR data**. International Journal of Remote Sensing, v. 7, n. 11, p. 1417-1435, 1986.

HOUGHTON, J. T.; MEIRA FILHO, L. C.; CALLANDER, B. A.; HARRIS, N.; KATTERBERG, A.; MASKELL, K. (Ed.). **Climate change 1995: the science of climate change: contribution of working group I to the second assessment report of the Intergovernmental Panel on Climate Change**. Cambridge (Inglaterra): Cambridge University Press. p. 584. 1996.

HULME, M., SHEARM, N. **Cenários e alterações climáticas para o Brasil**. Climate Research Unit, Norwich, UK. p. 6. 1999.

INFORME AGROPECUÁRIO. **Eucalipto**. V.29 – n. 242 – janeiro/ fevereiro 2008.

INTERNATIONAL GEOSPHERE-BIOSPHERE PROGRAM (IGBP). **International Geosphere-Biosphere Program Report: the initial core projects**. Stockholm: IGBP. n.12., 330 p. 1990.

LILLESAND, T. M.; KIEFER, R. W. **Remote Sensing and Image Interpretation**. 2nd Ed .Jonh Wiley e Sons, 1987.

LILLESAND, T.M; KIEFER, R.W. **Remote sensing and image interpretation**. 4. ed. New York: Jonh Wiley, 750p. 1994.

LINHARES, C. A.; SOARES, J. V.; BATISTA, G. T. **Influência do desmatamento na dinâmica da resposta hidrológica na bacia do Ji-Paraná**. Anais XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, INPE, p. 3097-3105. 16-21 abril 2005.

LIMA, S. F. S.; MELLO, E. M. K.; FLORENZANO, T. G. **Tutorial sobre o uso de Geotecnologias no estudo de Bacias Hidrográficas para professores da Educação Básica**. Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, Brasil, INPE, p. 1515-1522. 21-26 abril 2007.

LIPPMANN, R. P. **An introduction to computing with neural nets**. IEEE ASSP Magazine, v.4, 4-22p, 1987.

LIU, W. T. **Aplicações de Sensoriamento Remoto**. Campo Grande: Editora da UNIDERP. p. 908. 2007.

LIU, W.T.; KANAZAWA, P.; SANTIAMI, E.; KANAZAWA, P. J. **Impacto de desmatamento na mudança climática regional via satélite**. Anais do XII Simpósio Brasileiro de Sensoriamento Remoto, São Jose dos Campos, SP, Brasil. 593-600. 2005a.

LIU, Z. K. e XIAO, J. Y. **Classification of remotely-sensed image data using artificial neural networks**. International Journal of Remote Sensing, v.12, p.2433-2447, 1991.

LOGAN, T.; RITTER, N.; BRYANT N. **Artificial neural network classification using a minimal; training set: comparison to conventional supervised classification**. Photogrammetric Engineering & Remote Sensing. v. 56, n. 4, p. 1285-1294. 1997.

MANSO, A. F.; ILLERA, P.; DELGADO, J. A.; UNZUETA, A. F. **Climatic interpretation of the NDVI: applications for vegetation monitoring in Castilla y León (Spain)**. In: EUROPTO Conference on Remote Sensing for Agriculture, Ecosystems, and Hydrology, Barcelona. Proceedings. v. 3499, p. 372-383. 1998.

MARANGON, B. **Consumo de produtos florestais na Zona da Mata de Minas Gerais**. p 141. Dissertação (Mestrado em Extensão Rural) – Universidade Federal de Viçosa, Viçosa. 1971.

MARENGO, J, SOARES, W. **Impacto das modificações da mudança climática-Síntese do Terceiro Relatório do IPCC**. Condições climáticas e recursos hídricos no Norte do Brasil. Chapter 6 in Clima e Recursos Hídricos 9. Associação Brasileira de Recursos Hídricos/FBMC-ANA. Porto Alegre, Brasil. p. 209-233. 2003.

MATHER, P. M. **Computer processing of remotely-sensed images: an introduction**. 3rd. Ed. Chichester: John Wiley & Sons. 324 p. ISBN 0-470- 84919-3. 2004.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. São José dos Campos, 2001. Instituto Nacional de Pesquisas Espaciais (INPE). 208p.

NATIONAL RESEARCH COUNCIL (NRC). **Toward an understanding of global change:initial priorities for US contributions to the international Geosphere-BiosphereProgram**. Washington DC: National Academy Press, 1988.

ORTIZ, M. J.; FORMAGGIO, A. R.; EPIPHANIO, J. C. N. **Classification of croplands through integration of remote sensing, GIS, and historical database**. International Journal of Remote Sensing, v. 18, n. 1, p. 95-105, 1997.

RIBEIRO, S. R. A., CENTENO, J. A. S. IV. **Utilização de Redes Neurais Artificiais na separação de unidades fisionômicas (paisagem) mediante imagens orbitais e dados complementares**. Colóquio Brasileiro de Ciências Geodésicas - IV CBCG Curitiba, 16 a 20 de maio de 2005.

RICHARDS, J.A. **Remote sensing digital image analysis: an introduction**. 3.ed. Berlin: Springer-Verlag, 340 p. 1995.

RODRÍGUEZ, A C M. **Sensoriamento Remoto e Geoprocessamento aplicados na análise da legislação ambiental no Município de São Sebastião (SP)**. p. 120. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais - INPE. São José dos Campos. 2006.

ROUSE, J. W.; HAAS, R.H.; SCHELL, J. A.; DEERING, D.W. **Monitoring vegetation systems in the Great Plains with ERTS**. Third Symposium of ERTS, Greenbelt, Maryland, USA, NASA SP-351, V1:309-317. 1973.

ROUSE, J. W.; HASS, R. H.; DEERING, D. W.; SCHELL, J. A. **Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation**. Austin: Texas A. M. University, College Station, 1974.

ROY, D. P.; KENNEDY, P.; FOLVING, S. **Combination of the Normalized Difference Vegetation Index and surface temperature for regional scale European Forest cover mapping using AVHRR data**. International Journal of Remote Sensing, v. 18, n. 5, p. 1189-1195, Mar. 1997.

SABO, L. A.; GALO, M. L. B. T. **Representação da incerteza e entropia em classes de cobertura do solo urbano resultantes da aplicação de uma rede neural artificial**. Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, Brasil. INPE, p. 6103-6110. 2007.

SCHOWENGERDT, R. A. **Remote sensing, models and methods for image processing**. 2. ed. San Diego: Academic Press, 1997. p.522. 1997.

SCHULTZ, P. A.; HALPERT, M. S. **Global Analysis of the relationships among a vegetation index, precipitation and land surface temperature**. International Journal of Remote Sensing, v. 16, n. 15, p.2755-2777. 1995.

SHIMABUKURO, Y. E., NOVO, E. M., PONZONI, F. J. **Índice de vegetação e Modelo Linear de Mistura Espectral no monitoramento do Pantanal**. Pesquisa Agropecuária Brasileira, Brasília, v.33, Número Especial, p.1729-1739. 1998.

SILVA, C. H. C., POLETO, L. J. C., VILELA, T. A., VIEIRA, C. A. O. **Utilização do módulo LCM para modelar o potencial de transição entre classes de uso e ocupação do solo** In: COBRAC, Florianópolis. 2008.

SILVA, M. K. A.; BRITO, J. L. S.; ROSA, R. **Mapeamento do uso do solo no município de Pedrinópolis – MG**. In: Simpósio Brasileiro de Sensoriamento Remoto. Goiânia. INPE. Anais. São José dos Campos: INPE, 2005b.

THAIS LINHARES JUVENAL, T. L.; MATTOS, R. L. G. **O setor florestal no Brasil e a importância do reflorestamento**. BNDES Setorial, Rio de Janeiro, n. 16, p. 3-30, 2002.

THIAM, A.; EASTMAN, R. **Principles of Remote Sensing and Image Processing**. Rwanda: IDRISI. 170 p. 1999.

TOWNSHEND, J. R. G.; TUCKER, C. J.; GOWARD, S. N. **Global vegetation mapping**. In: Gurney R. J. Foster, J. L.; Parkinson, C. L. ed. Atlas of satellite observations related to global change. 1.ed. London: Cambridge University Press. Cap. 6, p. 301-311. 1993.

TUCKER, C. J.; SELLERS, P. J. **Satellite remote sensing of primary production**. International Journal of Remote Sensing, v. 7, n. 11, p.1395-1416, Nov. 1986.

VALE, R. S. **Agrossilvicultura com eucalipto como alternativa para o desenvolvimento sustentável da Zona da Mata de Minas Gerais**. 2004. p. 115. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2004.

VERONESE, V. R., **Introdução ao Processamento Digital de Imagens. Manuais Técnicos em Geociências** - número 9 IBGE. Rio de Janeiro, 2000. XXIII Congresso Brasileiro de Cartografia, Rio de Janeiro, Brasil, 21 a 24 de outubro de 2007.

VIEIRA, C. A. O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study**. p 327. Thesis (Doctor of Philosophy in Physical Geography) - University of Nottingham, Nottingham. 2000.

VILELA, M. F.; SOARES, V. P.; RIBEIRO, J. C.; BRITES, R. S. **Avaliação de técnicas de realce e classificação digital na elaboração de um mapa de uso da terra mediante uma imagem TM/LANDSAT-5**. Revista Árvore, v. 24, n. 2, p. 161-173, 2000.

WRIGHT, J. K. (1942) **Map makers are humans: comments on the subjective in maps**. The Geographical Review, 32, 527-544.

APÊNDICE A

Matriz de Erro

As Matrizes de Erro foram obtidas a partir das classificações utilizando as imagens Landsat, realizadas nessa dissertação.

A1. Matriz de erros referente a classificação da imagem Landsat relativo ao ano de 1984.

Imagem Classificada	Imagem de Referência			
	1	2	Total	Erro de Comissão
1	3766	87	3853	0.0226
2	71	9615	9686	0.0073
Total	3837	9702	13539	-
Erro de Omissão	0.0185	0.0090	-	0.0117

Legenda: 1- áreas com cobertura vegetal; 2- áreas sem cobertura vegetal.

A2. Matriz de erros referente a classificação da imagem Landsat relativo ao ano de 1989.

Imagem Classificada	Imagem de Referência			
	1	2	Total	Erro de Comissão
1	1444	6	1450	0.0041
2	4	1928	1932	0.0021
Total	1448	1934	3382	-
Erro de Omissão	0.0028	0.0031	-	0.0030

Legenda: 1- áreas com cobertura vegetal; 2- áreas sem cobertura vegetal.

A3. Matriz de erros referente a classificação da imagem Landsat relativo ao ano de 2000.

Imagem Classificada	Imagem de Referência			Erro de Comissão
	1	2	Total	
1	1983	5	1988	0.0025
2	12	2121	2133	0.0056
Total	1995	2126	4121	-
Erro de Omissão	0.0060	0.0024	-	0.0041

Legenda: 1- áreas com cobertura vegetal; 2- áreas sem cobertura vegetal.

A4. Matriz de erros referente a classificação da imagem Landsat relativo ao ano de 2008.

Imagem Classificada	Imagem de Referência			Erro de Comissão
	1	2	Total	
1	1995	1	1996	0.0005
2	0	2125	2125	0.0000
Total	1995	2126	4121	-
Erro de Omissão	0.0000	0.0005	-	0.0002

Legenda: 1- áreas com cobertura vegetal; 2- áreas sem cobertura vegetal.

APÊNDICE B

Série histórica de temperatura, precipitação e NDVI para o período em estudo.

B1. Série histórica de temperatura, precipitação para o período de 1984 a 2007 e NDVI para o período de 1984 a 2006.

Anos	Precipitação Anual (mm)	Temperatura Anual (°C)	NDVI
1984	1072,30	20,00	6.16
1985	1732,30	19,23	6.69
1986	1124,80	19,84	6.95
1987	1253,00	20,13	6.59
1988	869,30	19,81	6.27
1989	1178,50	19,69	6.79
1990	863,90	20,36	6.74
1991	1589,40	19,77	6.63
1992	1453,90	19,62	6.89
1993	886,50	20,28	6.63
1994	1366,60	19,83	6.32
1995	1190,40	20,17	6.74
1996	1131,10	19,71	6.79
1997	1256,60	20,06	6.72
1998	1139,20	20,49	6.75
1999	1224,80	19,76	6.81
2000	1217,90	19,96	6.82
2001	1148,00	20,68	6.68
2002	1295,70	20,82	6.71
2003	1091,90	20,42	6.75
2004	1761,60	21,35	6.58
2005	1137,10	20,10	6.65
2006	1188,80	20,06	6.63
2007	821,00	18,04	-

B2. Dados quinzenais de NDVI para o ano de 1984.

	Mês	NDVI	Média do mês
a	Janeiro	7.43	6.94
b		6.45	
a	Fevereiro	7.41	7.30
b		7.18	
a	Março	6.87	5.43
b		4.00	
a	Abril	6.74	6.64
b		6.54	
a	Maio	6.71	6.68
b		6.64	
a	Junho	5.49	5.60
b		5.71	
a	Julho	5.32	5.40
b		5.47	
a	Agosto	5.89	5.73
b		5.56	
a	Setembro	4.03	4.71
b		5.38	
a	Outubro	4.11	4.85
b		5.59	
a	Novembro	6.91	6.81
b		6.72	
a	Dezembro	7.70	7.80
b		7.91	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B3. Dados quinzenais de NDVI para o ano de 1985.

	Mês	NDVI	Média do mês
a	Janeiro	7.94	7.72
b		7.51	
a	Fevereiro	6.19	6.69
b		7.19	
a	Março	7.70	7.68
b		7.66	
a	Abril	6.29	6.19
b		6.09	
a	Maio	7.27	7.01
b		6.75	
a	Junho	6.48	5.88
b		5.28	
a	Julho	6.12	6.01
b		5.91	
a	Agosto	5.93	6.09
b		6.25	
a	Setembro	6.67	6.66
b		6.65	
a	Outubro	6.53	6.70
b		6.86	
a	Novembro	7.07	7.00
b		6.93	
a	Dezembro	6.66	6.60
b		6.54	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B4. Dados quinzenais de NDVI para o ano de 1986.

	Mês	NDVI	Média do mês
a	Janeiro	6,79	6,95
b		7,10	
a	Fevereiro	7,26	7,51
b		7,76	
a	Março	7,80	7,93
b		8,06	
a	Abril	6,99	7,27
b		7,55	
a	Maio	6,90	6,65
b		6,41	
a	Junho	6,64	6,37
b		6,09	
a	Julho	6,28	6,43
b		6,59	
a	Agosto	6,56	6,62
b		6,68	
a	Setembro	7,36	6,83
b		6,30	
a	Outubro	6,89	6,80
b		6,71	
a	Novembro	6,65	6,59
b		6,52	
a	Dezembro	7,30	7,44
b		7,58	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B5. Dados quinzenais de NDVI para o ano de 1987.

	Mês	NDVI	Média do mês
a	Janeiro	7,54	7,78
b		8,03	
a	Fevereiro	8,48	8,24
b		7,99	
a	Março	7,58	7,38
b		7,18	
a	Abril	7,01	6,51
b		6,02	
a	Maio	6,34	6,08
b		5,82	
a	Junho	6,10	5,99
b		5,87	
a	Julho	4,98	4,98
b		4,98	
a	Agosto	6,15	6,50
b		6,85	
a	Setembro	6,68	6,24
b		5,80	
a	Outubro	5,24	4,95
b		4,67	
a	Novembro	6,44	6,77
b		7,11	
a	Dezembro	7,49	7,61
b		7,74	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B6. Dados quinzenais de NDVI para o ano de 1988.

	Mês	NDVI	Média do mês
a	Janeiro	8,18	8,04
b		7,90	
a	Fevereiro	7,97	7,36
b		6,76	
a	Março	7,26	7,19
b		7,11	
a	Abril	6,60	6,59
b		6,59	
a	Maio	6,33	6,21
b		6,10	
a	Junho	5,83	5,60
b		5,38	
a	Julho	5,78	5,70
b		5,63	
a	Agosto	4,85	4,61
b		4,37	
a	Setembro	5,32	5,56
b		5,80	
a	Outubro	5,53	5,91
b		6,29	
a	Novembro	6,58	6,47
b		6,36	
a	Dezembro	6,03	5,93
b		5,83	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B7. Dados quinzenais de NDVI para o ano de 1989.

	Mês	NDVI	Média do mês
a	Janeiro	6,19	6,63
b		7,07	
a	Fevereiro	7,80	7,98
b		8,17	
a	Março	7,81	7,61
b		7,41	
a	Abril	7,10	6,98
b		6,86	
a	Maio	6,48	6,39
b		6,30	
a	Junho	6,43	6,45
b		6,48	
a	Julho	6,19	6,37
b		6,55	
a	Agosto	7,04	6,87
b		6,71	
a	Setembro	4,99	6,05
b		7,11	
a	Outubro	6,59	6,57
b		6,56	
a	Novembro	6,84	6,75
b		6,65	
a	Dezembro	6,73	6,78
b		6,84	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B8. Dados quinzenais de NDVI para o ano de 1990.

	Mês	NDVI	Média do mês
a	Janeiro	6,70	7,17
b		7,64	
a	Fevereiro	7,87	7,84
b		7,82	
a	Março	6,89	6,84
b		6,79	
a	Abril	6,70	6,71
b		6,72	
a	Maio	6,61	6,45
b		6,30	
a	Junho	6,10	6,19
b		6,28	
a	Julho	6,50	6,47
b		6,44	
a	Agosto	6,36	6,49
b		6,61	
a	Setembro	6,92	6,91
b		6,89	
a	Outubro	6,27	6,13
b		5,99	
a	Novembro	5,34	6,41
b		7,47	
a	Dezembro	7,40	7,25
b		7,10	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B9. Dados quinzenais de NDVI para o ano de 1991.

	Mês	NDVI	Média do mês
a	Janeiro	6,47	6,57
b		6,66	
a	Fevereiro	7,60	7,55
b		7,50	
a	Março	6,15	6,57
b		6,99	
a	Abril	6,63	6,75
b		6,88	
a	Maio	6,07	6,27
b		6,48	
a	Junho	6,52	6,69
b		6,86	
a	Julho	6,75	6,73
b		6,71	
a	Agosto	6,28	6,07
b		5,86	
a	Setembro	5,87	6,00
b		6,12	
a	Outubro	6,57	6,48
b		6,39	
a	Novembro	6,82	7,19
b		7,55	
a	Dezembro	6,96	6,71
b		6,45	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B10. Dados quinzenais de NDVI para o ano de 1992.

	Mês	NDVI	Média do mês
a	Janeiro	8,20	8,09
b		7,99	
a	Fevereiro	7,62	7,63
b		7,64	
a	Março	7,01	7,18
b		7,36	
a	Abril	7,45	7,21
b		6,97	
a	Maio	6,83	6,66
b		6,49	
a	Junho	6,16	6,03
b		5,89	
a	Julho	5,85	5,74
b		5,63	
a	Agosto	6,03	6,11
b		6,20	
a	Setembro	6,59	6,93
b		7,27	
a	Outubro	6,71	6,97
b		7,23	
a	Novembro	7,23	6,84
b		6,44	
a	Dezembro	7,38	7,26
b		7,14	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B11. Dados quinzenais de NDVI para o ano de 1993.

	Mês	NDVI	Média do mês
a	Janeiro	7,37	7,53
b		7,69	
a	Fevereiro	7,73	7,25
b		6,77	
a	Março	6,96	6,85
b		6,73	
a	Abril	7,20	6,89
b		6,59	
a	Maio	6,04	5,99
b		5,94	
a	Junho	5,98	5,80
b		5,62	
a	Julho	5,26	5,01
b		4,75	
a	Agosto	6,07	6,17
b		6,27	
a	Setembro	5,92	6,10
b		6,27	
a	Outubro	6,73	6,88
b		7,02	
a	Novembro	7,54	7,32
b		7,10	
a	Dezembro	7,45	7,78
b		8,12	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B12. Dados quinzenais de NDVI para o ano de 1994.

	Mês	NDVI	Média do mês
a	Janeiro	8,02	7,67
b		7,31	
a	Fevereiro	7,03	6,20
b		5,36	
a	Março	7,79	7,68
b		7,57	
a	Abril	6,80	6,44
b		6,07	
a	Maio	5,32	4,88
b		4,44	
a	Junho	5,14	5,29
b		5,45	
a	Julho	5,94	5,60
b		5,26	
a	Agosto	6,18	5,35
b		4,53	
a	Setembro	5,20	5,62
b		6,04	
a	Outubro	6,22	6,23
b		6,23	
a	Novembro	7,54	7,69
b		7,83	
a	Dezembro	7,37	7,20
b		7,03	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B13. Dados quinzenais de NDVI para o ano de 1995.

	Mês	NDVI	Média do mês
a	Janeiro	5,95	6,50
b		7,06	
a	Fevereiro	7,19	7,47
b		7,74	
a	Março	7,26	7,25
b		7,24	
a	Abril	7,36	7,34
b		7,32	
a	Maio	6,88	6,68
b		6,47	
a	Junho	5,80	6,01
b		6,21	
a	Julho	6,37	6,51
b		6,65	
a	Agosto	6,50	6,42
b		6,34	
a	Setembro	6,30	6,49
b		6,67	
a	Outubro	6,90	6,71
b		6,51	
a	Novembro	6,39	6,56
b		6,73	
a	Dezembro	6,88	6,92
b		6,96	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B14. Dados quinzenais de NDVI para o ano de 1996.

	Mês	NDVI	Média do mês
a	Janeiro	7,07	7,38
b		7,68	
a	Fevereiro	7,12	7,44
b		7,75	
a	Março	7,60	7,24
b		6,88	
a	Abril	6,04	6,67
b		7,29	
a	Maio	6,43	6,36
b		6,30	
a	Junho	6,40	6,28
b		6,15	
a	Julho	6,19	6,36
b		6,53	
a	Agosto	6,56	6,73
b		6,90	
a	Setembro	6,27	6,27
b		6,27	
a	Outubro	5,93	6,38
b		6,83	
a	Novembro	6,62	6,99
b		7,37	
a	Dezembro	7,37	7,39
b		7,40	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B15. Dados quinzenais de NDVI para o ano de 1997.

	Mês	NDVI	Média do mês
a	Janeiro	7,60	7,63
b		7,67	
a	Fevereiro	7,61	7,60
b		7,60	
a	Março	8,10	7,79
b		7,48	
a	Abril	6,79	6,49
b		6,19	
a	Maio	5,87	5,76
b		5,65	
a	Junho	6,10	6,08
b		6,06	
a	Julho	6,24	6,52
b		6,79	
a	Agosto	7,17	6,95
b		6,73	
a	Setembro	6,39	6,56
b		6,73	
a	Outubro	5,89	5,94
b		5,99	
a	Novembro	6,27	6,36
b		6,44	
a	Dezembro	6,74	7,02
b		7,30	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B16. Dados quinzenais de NDVI para o ano de 1998.

	Mês	NDVI	Média do mês
a	Janeiro	7,75	7,86
b		7,97	
a	Fevereiro	7,59	7,32
b		7,05	
a	Março	6,84	6,91
b		6,98	
a	Abril	6,70	6,61
b		6,51	
a	Maio	6,31	6,07
b		5,83	
a	Junho	6,44	6,42
b		6,41	
a	Julho	7,02	6,97
b		6,93	
a	Agosto	7,08	6,52
b		5,97	
a	Setembro	6,28	6,49
b		6,70	
a	Outubro	6,48	6,37
b		6,26	
a	Novembro	6,69	6,56
b		6,42	
a	Dezembro	6,55	6,94
b		7,34	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B17. Dados quinzenais de NDVI para o ano de 1999.

	Mês	NDVI	Média do mês
a	Janeiro	7,71	7,79
b		7,86	
a	Fevereiro	8,37	8,12
b		7,86	
a	Março	7,93	7,57
b		7,21	
a	Abril	6,23	6,22
b		6,21	
a	Maio	6,39	6,15
b		5,92	
a	Junho	6,08	6,15
b		6,21	
a	Julho	6,57	6,98
b		7,40	
a	Agosto	7,60	7,13
b		6,65	
a	Setembro	6,29	6,19
b		6,09	
a	Outubro	6,39	5,95
b		5,51	
a	Novembro	6,00	6,23
b		6,47	
a	Dezembro	6,85	7,19
b		7,52	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B18. Dados quinzenais de NDVI para o ano de 2000.

	Mês	NDVI	Média do mês
a	Janeiro	7,95	8,31
b		8,67	
a	Fevereiro	8,20	7,97
b		7,73	
a	Março	7,61	7,43
b		7,25	
a	Abril	6,47	6,43
b		6,39	
a	Maio	6,56	6,57
b		6,58	
a	Junho	5,85	6,23
b		6,60	
a	Julho	6,74	6,57
b		6,40	
a	Agosto	5,78	5,75
b		5,73	
a	Setembro	5,34	6,16
b		6,98	
a	Outubro	6,47	6,74
b		7,00	
a	Novembro	6,97	6,73
b		6,49	
a	Dezembro	6,39	6,92
b		7,45	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B19. Dados quinzenais de NDVI para o ano de 2001.

	Mês	NDVI	Média do mês
a	Janeiro	7,36	7,31
b		7,26	
a	Fevereiro	7,59	7,64
b		7,69	
a	Março	7,37	7,17
b		6,97	
a	Abril	6,37	6,35
b		6,32	
a	Maio	5,21	5,85
b		6,50	
a	Junho	6,46	6,58
b		6,70	
a	Julho	6,89	6,87
b		6,84	
a	Agosto	6,63	6,55
b		6,46	
a	Setembro	6,29	6,39
b		6,49	
a	Outubro	6,01	5,98
b		5,95	
a	Novembro	6,31	6,37
b		6,44	
a	Dezembro	6,93	7,13
b		7,32	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B20. Dados quinzenais de NDVI para o ano de 2002.

	Mês	NDVI	Média do mês
a	Janeiro	7,49	7,68
b		7,87	
a	Fevereiro	7,55	7,71
b		7,87	
a	Março	7,25	7,15
b		7,04	
a	Abril	6,56	6,16
b		5,76	
a	Maio	6,05	6,05
b		6,05	
a	Junho	5,76	6,26
b		6,76	
a	Julho	7,06	7,06
b		7,06	
a	Agosto	7,13	6,98
b		6,83	
a	Setembro	6,56	6,39
b		6,22	
a	Outubro	5,77	5,91
b		6,06	
a	Novembro	6,65	6,25
b		5,84	
a	Dezembro	6,70	6,92
b		7,14	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B21. Dados quinzenais de NDVI para o ano de 2003.

	Mês	NDVI	Média do mês
a	Janeiro	7,74	7,88
b		8,02	
a	Fevereiro	7,86	7,79
b		7,73	
a	Março	7,65	7,37
b		7,09	
a	Abril	6,85	6,64
b		6,43	
a	Maio	6,53	6,46
b		6,39	
a	Junho	5,76	6,05
b		6,33	
a	Julho	6,21	6,12
b		6,04	
a	Agosto	6,39	6,23
b		6,08	
a	Setembro	5,99	5,95
b		5,90	
a	Outubro	6,40	6,51
b		6,63	
a	Novembro	6,62	6,71
b		6,80	
a	Dezembro	7,04	7,26
b		7,49	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B22. Dados quinzenais de NDVI para o ano de 2004.

	Mês	NDVI	Média do mês
a	Janeiro	7,46	7,64
b		7,81	
a	Fevereiro	7,75	7,63
b		7,51	
a	Março	7,17	7,06
b		6,95	
a	Abril	6,43	6,30
b		6,17	
a	Maio	3,08	4,62
b		6,16	
a	Junho	6,16	6,04
b		5,93	
a	Julho	6,43	6,64
b		6,85	
a	Agosto	6,84	6,68
b		6,52	
a	Setembro	6,10	6,24
b		6,39	
a	Outubro	6,37	6,45
b		6,52	
a	Novembro	6,49	6,57
b		6,65	
a	Dezembro	6,86	7,11
b		7,35	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B23. Dados quinzenais de NDVI para o ano de 2005.

	Mês	NDVI	Média do mês
a	Janeiro	7,76	7,86
b		7,95	
a	Fevereiro	7,73	7,37
b		7,00	
a	Março	6,86	6,63
b		6,39	
a	Abril	6,15	6,10
b		6,05	
a	Maio	6,36	6,41
b		6,46	
a	Junho	6,53	6,48
b		6,43	
a	Julho	6,84	6,73
b		6,62	
a	Agosto	6,54	6,41
b		6,29	
a	Setembro	6,23	6,15
b		6,08	
a	Outubro	5,85	6,14
b		6,43	
a	Novembro	6,72	6,74
b		6,75	
a	Dezembro	7,07	6,85
b		6,62	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

B24. Dados quinzenais de NDVI para o ano de 2006.

	Mês	NDVI	Média do mês
a	Janeiro	6,68	6,83
b		6,99	
a	Fevereiro	7,38	7,35
b		7,33	
a	Março	7,21	7,13
b		7,05	
a	Abril	6,82	6,81
b		6,79	
a	Maio	6,55	6,35
b		6,14	
a	Junho	5,90	5,81
b		5,71	
a	Julho	6,15	6,34
b		6,54	
a	Agosto	6,37	6,47
b		6,58	
a	Setembro	6,20	6,08
b		5,96	
a	Outubro	6,13	6,38
b		6,63	
a	Novembro	6,98	6,92
b		6,86	
a	Dezembro	7,18	7,11
b		7,04	

Legenda: a- primeira quinzena do mês; b- segunda quinzena do mês.

APÊNDICE C

Modelo de Tendência de temperatura, precipitação e NDVI

C1. Modelo de Tendência de temperatura, precipitação e NDVI gerados a partir do *software* SAS.

```
DATA NDVIT;
INPUT ANO PRECIPTACAO TEMPERATURA NDVI;
CARDS;
```

1984	1072.30	20.0	6.16
1985	1732.30	19.2	6.69
1986	1124.80	19.8	6.95
1987	1253.00	20.1	6.59
1988	869.30	19.8	6.27
1989	1178.50	19.7	6.79
1990	863.90	20.4	6.74
1991	1589.40	19.8	6.63
1992	1453.90	19.6	6.89
1993	886.50	20.3	6.63
1994	1366.60	19.8	6.32
1995	1190.40	20.2	6.74
1996	1131.10	19.7	6.79
1997	1256.60	20.1	6.72
1998	1139.20	20.5	6.75
1999	1224.80	19.8	6.81
2000	1217.90	20.0	6.82
2001	1148.00	20.7	6.68
2002	1295.70	20.8	6.71
2003	1091.90	20.4	6.75
2004	1761.60	21.4	6.58
2005	1137.10	20.1	6.65
2006	1188.80	20.1	6.63
2007	821.00	18.0	

```
;
PROC GLM;
MODEL PRECIPTACAO=ANO;
OUTPUT OUT=PRECP PREDICTED=P;
PROC GLM;
MODEL TEMPERATURA=ANO;
OUTPUT OUT=TEMP PREDICTED=T;
PROC GLM;
MODEL NDVI=ANO;
OUTPUT OUT=NDVI PREDICTED=N;
RUN;
```

The SAS System

03:53 Friday, November 14, 2008 1

The GLM Procedure

Number of Observations Read 24
 Number of Observations Used 24

The SAS System

03:53 Friday, November 14, 2008

2

The GLM Procedure

Dependent Variable: PRECIPTACAO

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	4206.400	4206.400	0.07	0.7971
Error	22	1366594.198	62117.918		
Corrected Total	23	1370800.598			

R-Square Coeff Var Root MSE PRECIPTACAO Mean

0.003069 20.63016 249.2347 1208.108

Source	DF	Type I SS	Mean Square	F Value	Pr > F
ANO	1	4206.400313	4206.400313	0.07	0.7971

Source	DF	Type III SS	Mean Square	F Value	Pr > F
--------	----	-------------	-------------	---------	--------

ANO	1	4206.400313	4206.400313	0.07	0.7971
-----	---	-------------	-------------	------	--------

Parameter	Estimate	Standard Error	t Value	Pr > t
Intercept	5024.545464	14666.07396	0.34	0.7352
ANO	-1.912522	7.34953	-0.26	0.7971

The SAS System 03:53 Friday, November 14, 2008 3

The GLM Procedure

Number of Observations Read	24
Number of Observations Used	24

The SAS System 03:53 Friday, November 14, 2008 4

The GLM Procedure

Dependent Variable: TEMPERATURA

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	0.22121957	0.22121957	0.55	0.4646
Error	22	8.78503043	0.39931957		
Corrected Total	23	9.00625000			

R-Square	Coeff Var	Root MSE	TEMPERATURA Mean
0.024563	3.157613	0.631917	20.01250

Source	DF	Type I SS	Mean Square	F Value	Pr > F
ANO	1	0.22121957	0.22121957	0.55	0.4646

Source	DF	Type III SS	Mean Square	F Value	Pr > F
ANO	1	0.22121957	0.22121957	0.55	0.4646

Parameter	Estimate	Standard Error	t Value	Pr > t
Intercept	-7.664217391	37.18482310	-0.21	0.8386
ANO	0.013869565	0.01863423	0.74	0.4646

The SAS System 03:53 Friday, November 14, 2008 5

The GLM Procedure

Number of Observations Read	23
Number of Observations Used	23

The SAS System 03:53 Friday, November 14, 2008 6

The GLM Procedure

Dependent Variable: PRECIPTACAO

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	5911.489	5911.489	0.10	0.7518
Error	21	1208520.906	57548.615		
Corrected Total	22	1214432.395			

R-Square	Coeff Var	Root MSE	PRECIPTACAO Mean
0.004868	19.58407	239.8929	1224.939

Source	DF	Type I SS	Mean Square	F Value	Pr > F
ANO	1	5911.488943	5911.488943	0.10	0.7518

Source	DF	Type III SS	Mean Square	F Value	Pr > F
ANO	1	5911.488943	5911.488943	0.10	0.7518

Parameter	Estimate	Standard Error	t Value	Pr > t
Intercept	-3596.770850	15044.31717	-0.24	0.8134
ANO	2.416897	7.54097	0.32	0.7518

The SAS System

03:53 Friday, November 14, 2008 7

The GLM Procedure
 Number of Observations Read 23
 Number of Observations Used 23

The SAS System

03:53 Friday, November 14, 2008 8

The GLM Procedure

Dependent Variable: TEMPERATURA

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	1.58894269	1.58894269	10.46	0.0040
Error	21	3.19105731	0.15195511		
Corrected Total	22	4.78000000			

R-Square	Coeff Var	Root MSE	TEMPERATURA Mean
0.332415	1.939374	0.389814	20.10000

Source	DF	Type I SS	Mean Square	F Value	Pr > F
ANO	1	1.58894269	1.58894269	10.46	0.0040

Source	DF	Type III SS	Mean Square	F Value	Pr > F
ANO	1	1.58894269	1.58894269	10.46	0.0040

Parameter	Estimate	Standard Error	t Value	Pr > t
Intercept	-58.95088933	24.44627535	-2.41	0.0251
ANO	0.03962451	0.01225370	3.23	0.0040

The SAS System 03:53 Friday, November 14, 2008 9

The GLM Procedure

Number of Observations Read 23
 Number of Observations Used 23

The SAS System

03:53 Friday, November 14, 2008

10

The GLM Procedure

Dependent Variable: NDVI

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	0.04162065	0.04162065	1.17	0.2910
Error	21	0.74495326	0.03547396		
Corrected Total	22	0.78657391			

	R-Square	Coeff Var	Root MSE	NDVI Mean		
Source	0.052914	2.825979	0.188345	6.664783		
		DF	Type I SS	Mean Square	F Value	Pr > F
ANO		1	0.04162065	0.04162065	1.17	0.2910
Source		DF	Type III SS	Mean Square	F Value	Pr > F
ANO		1	0.04162065	0.04162065	1.17	0.2910

Parameter	Estimate	Standard Error	t Value	Pr > t		
Intercept	-6.129239130	11.81163205	-0.52	0.6092		
ANO		0.006413043	0.00592058		1.08	0.291

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)