

**ESTIMATIVA DA COBERTURA ARBÓREA
UTILIZANDO A COMBINAÇÃO DE IMAGENS
IKONOS E LANDSAT**

CARLOS AUGUSTO ZANGRANDO TONELI

2008

CARLOS AUGUSTO ZANGRANDO TONELI

**ESTIMATIVA DA COBERTURA ARBÓREA UTILIZANDO A
COMBINAÇÃO DE IMAGENS IKONOS E LANDSAT**

Dissertação apresentada à Universidade Federal de Lavras como parte das exigências do curso de Mestrado em Engenharia Florestal, área de concentração Ciências Florestais, para a obtenção do título de “Mestre”.

Orientador:

Prof. Luis Marcelo Tavares de Carvalho

Co-orientador:

Prof. Fausto Weimar Acerbi Jr.

LAVRAS
MINAS GERAIS – BRASIL
2008

**Ficha Catalográfica Preparada pela Divisão de Processos Técnicos da
Biblioteca Central da UFLA**

Toneli, Carlos Augusto Zangrando.

Estimativa da cobertura arbórea utilizando a combinação de imagens Ikonos e Landsat / Carlos Augusto Zangrando Toneli. – Lavras : UFLA, 2008.

81 p. : il.

Dissertação (Mestrado) – Universidade Federal de Lavras, 2008.

Orientador: Luis Marcelo Tavares de Carvalho.

Bibliografia.

1. Árvore de regressão. 2. Cobertura arbórea. 3. Cerrado. 4. Florestas estacionais decíduais. 5. Geoprocessamento. I. Universidade Federal de Lavras. II. Título.

CDD – 634.97

CARLOS AUGUSTO ZANGRANDO TONELI

**ESTIMATIVA DA COBERTURA ARBÓREA UTILIZANDO A
COMBINAÇÃO DE IMAGENS IKONOS E LANDSAT**

Dissertação apresentada à Universidade Federal de Lavras como parte das exigências do curso de Mestrado em Engenharia Florestal, área de concentração Ciências Florestais, para a obtenção do título de “Mestre”.

APROVADA em 11 de abril de 2008.

Prof. Dr. Dalton M. Valeriano

INPE

Prof. Dr. Marcos A. L. Fontes

UFLA

Prof. Dr. Luis Marcelo Tavares de Carvalho
UFLA
(Orientador)

LAVRAS
MINAS GERAIS – BRASIL

A Deus,
aos meus pais,
a todos os irmãos,
ao ambiente na forma natural

Dedico

AGRADECIMENTOS

Aos amigos de graduação, à Escola Superior de Agricultura e à Universidade Federal. Aos amigos da cidade de Lavras, aos costumes da cultura do estado de Minas Gerais.

Ao CNPQ pelo fornecimento de bolsa de pesquisa, essencial para realização deste trabalho.

Em especial, aos orientadores: Luis Marcelo, Fausto e Gleyce, aos professores Scolforo, Donizzete, Zé Marcio, Nelson Venturin, Soraya, Ary Teixeira, ao Dalton Valeriano e Marco Aurélio, por participarem da defesa.

Aos queridos amigos: Duda, Queta, Alans, Bodinho, Bob, Betão, Emilio, Jordani, Marcela, Suzana, Regis, Fred, Carol, Tomas, Grilo, Piu, Gus e Ana, Nori, Luis, Maestro, Viola, Brasil, Kekinho, Adriano, Tais, Mirela, Klavícula, Edgar, Fátima, Simone e família, Adler, Chiodi, Cris...

E todos aqueles que, de alguma forma, contribuíram, durante minha caminhada na UFLA, para a minha formação como pessoa e engenheiro florestal.

SUMÁRIO

LISTA DE FIGURAS.....	i
LISTA DE TABELAS.....	ii
RESUMO GERAL	iii
GENERAL ABSTRACT.....	iv
1 INTRODUÇÃO GERAL.....	1
2 DELIMITAÇÃO E ENUNCIADO DO PROBLEMA	3
3 FORMULAÇÃO DAS PERGUNTAS CIENTÍFICAS.....	4
4 OBJETIVOS.....	5
4.1 Objetivo geral	5
4.2 Objetivos específicos	5
5 REFERENCIAL TEÓRICO	6
5.1 Modelos de representação espacial.....	6
5.2 Sensoriamento remoto	7
5.2.1 Caracterização espectral da vegetação.....	8
5.3 Pré-processamento	9
5.4 Sistema de informação geográfica.....	10
5.5 Análise <i>subpixel</i>	11
5.6 Classificação de imagens digitais	14
5.6.1 Árvores de classificação	15
5.6.2 Árvore de regressão	18
5.6.3 Avaliação de classificação	19
6 MATERIAL E MÉTODO	21
6.1 Esquema da metodologia.....	22
6.2 Área de estudo	22
6.2.1 Meio físico e biológico	24
6.2.2 Clima.....	24
6.2.3 Geologia.....	25
6.2.4 Vegetação	26
6.3 Material.....	27
6.4 Pré-processamento	29
6.4.1 Correção geométrica.....	29
6.4.2 Calibração radiométrica	29
6.4.3 Retificação radiométrica	31
6.4.4 Modelo linear de mistura espectral (MLME)	33
6.4.5 Índice de vegetação.....	35
6.4.6 Índice de cobertura arbórea.....	36
6.5 Caracterização e amostragem para imagens	37
6.5.1 Amostra para o algoritmo árvore de regressão	39

7 RESULTADOS E DISCUSSÃO.....	41
7.1 Correção geométrica das imagens	41
7.2 Calibração para valores de reflectância	41
7.3 Retificação radiométrica da imagem de verão	44
7.4 Acurácia da classificação da imagem Ikonos	45
7.5 Acurácia da classificação das imagens Landsat TM.....	48
7.6 Resultados da classificação nas unidades de conservação.....	50
7.7 Imagens NDVI.....	51
7.8 Imagem fração vegetação	52
7.9 Índice de cobertura arbórea.....	53
7.10 Validação do modelo de árvore de regressão	56
7.11 Comparação da cobertura arbórea nos diferentes ecossistemas.....	59
8 CONCLUSÃO	68
8.1 Respostas às hipóteses científicas	68
9 REFERÊNCIAS BIBLIOGRÁFICAS.....	71
ANEXOS	76

LISTA DE FIGURAS

FIGURA 1	Comportamento espectral dos objetos; solo, vegetação, água.	12
FIGURA 2	Comparação de classificações contínuas e temáticas.	15
FIGURA 3	Representação em diagrama da árvore de decisões.	16
FIGURA 4	Diagrama do esquema metodológico	22
FIGURA 5	Localização da área de estudo em cinza.	23
FIGURA 6	Perfil da formação do solo no decorrer da nascente do rio Peruaçu até o encontro com o rio São Francisco.	25
FIGURA 7	Espaço bidimensional de feições.	33
FIGURA 8	Processo da construção do índice de cobertura arbórea por análise espacial de agregação, crescimento da ordem de 10 vezes.	36
FIGURA 9	Exemplos das amostras de treinamento, vegetação em vermelho, sombra em preto e solo em branco.	37
FIGURA 10	Exemplo da variabilidade no extrato vertical.	38
FIGURA 11	Amostra, em preto, da variável dependente índice de cobertura arbórea, aproximadamente 8% da área total.	40
FIGURA 12	Área de vereda em uma imagem sem calibração dos números digitais, (a.). Mesma área de vereda em uma imagem com valores calibrados para reflectância, (b.).	42
FIGURA 13	Imagem sem calibração dos números digitais, (a.). Mesma área em uma imagem com valores calibrados para reflectância, (b.).	43
FIGURA 14	Gráfico de comportamento espectral médio dos objetos, em que as seis primeiras bandas são relativas ao inverno e as outras seis restantes, ao verão.	45
FIGURA 15	Classificação da cobertura arbórea utilizando-se a imagem Ikono de 10/09/2006	47
FIGURA 16	Classificação da vegetação da bacia do rio Peruaçu.	48
FIGURA 17	Comparação entre as imagens (a.) Ikonos, (b.) NDVI, (c.) imagem TM, (d.) imagem fração vegetação e (e.) cobertura arbórea.	55
FIGURA 18	Comparação de histogramas de frequências (a) real e (b) estimado.	59
FIGURA 19	Comparação entre as imagens (a) Landsat inverno, (b) mapa temático, (c) mapa contínuo e (d) mapa híbrido.	66

LISTA DE TABELAS

TABELA 1	Áreas de proteção pertencentes à bacia do rio Peruaçu.	24
TABELA 2	Nomenclatura utilizada proposta por Veloso (1991).	27
TABELA 3	Características espectrais das imagens dos sensores TM e Ikonos.	28
TABELA 4	Características ópticas dos sensores TM e Ikonos, no momento de aquisição das imagens.	28
TABELA 5	Valores dos coeficientes de transformação radiométrica entre as imagens de inverno e verão, os valores do coeficiente de determinação R^2 e o erro quadrado médio EQM dos modelos.	44
TABELA 6	Matriz de confusão ou matriz de erro, para classificação da variável cobertura arbórea utilizando a imagem Ikonos.	46
TABELA 7	Matriz de confusão ou matriz de erro para classificação das fisionomias vegetais utilizando a imagem TM.	49
TABELA 8	Proporção das áreas em % encontradas para cada área de proteção.	50
TABELA 9	Diferença de valores médios de NDVI de inverno a verão, para as fisionomias vegetais.	51
TABELA 10	Matriz de confusão ou matriz de erro para estimativa de cobertura arbórea por meio do algoritmo CUBIST.	57
TABELA 11	Acurácia do produtor e do usuário.	57
TABELA 12	Resultado da média de cobertura arbórea, em % e seus desvios padrões.	60
TABELA 13	Valores médios e de desvio padrão de parâmetro biofísico medidos na estação chuvosa das cinco fitofisionomias em análise.	61

RESUMO GERAL

TONELI, Carlos Augusto Zangrando. **Estimativa da cobertura arbórea utilizando a combinação de imagens Ikonos e Landsat**. 2008. 81 p. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Lavras, Lavras, MG.¹

O modelo de calibração é capaz de estimar campos contínuos, representando a variabilidade de um determinado alvo temático. Este trabalho foi realizado com o objetivo de desenvolver um modelo numérico para representar a variabilidade da cobertura arboreal em áreas de vegetação nativa, usando o algoritmo de árvore de regressão. O estudo foi conduzido em uma área localizada na sub-bacia do alto médio São Francisco, ao norte do estado de Minas Gerais. O algoritmo utilizado foi o CUBIST, gerando o modelo e a estimativa da cobertura arbórea. Foram utilizadas imagens Ikonos e Landsat TM, na época de verão e de inverno. O modelo de calibração por árvore de regressão gera, para cada estágio, uma partição binária, composta de uma regressão linear, formando ramificações, tornando-se, assim, o erro menor que de um único modelo de regressão. Os resultados gerados foram: o modelo numérico de árvore de regressão e a imagem índice de cobertura de dossel extrapolada para a imagem TM. A utilização do modelo não paramétrico por árvore de regressão apresentou resultados de 72% de correlação e 14,8 de erro para a estimativa em 2.168 ha de transição, nos domínios de Cerrado e Florestas Estacionais Deciduais.

Palavras-chave: árvore de regressão, cobertura arbórea, cerrado, Florestas Estacionais Deciduais e geoprocessamento.

Comitê orientador: Luis Marcelo Tavares de Carvalho – UFLA (Orientador); Fausto Weimar Acerbi Junior – UFLA (Co-orientador); - UFLA

GENERAL ABSTRACT

TONELI, Carlos Augusto Zangrando. **Tree cover estimation using Ikonos and Landsat images combination.** 2008. 81 p. Dissertation (Master of Forest Sciences) – Federal University of Lavras, Lavras, MG.*

The numeric modeling is capable to estimate continuous fields representing the variability of a certain thematic objective. This work had as objective develops a numeric model to represent the variability of the tree covering in areas of native vegetation using the algorithm of regression tree. This research was led in the sub-bacia medium of San Francisco to the North of Minas Gerais. The used algorithm was CUBIST, generating the model and the estimate of the tree cover for other areas. There were used image Ikono and Landsat TM. The numeric modeling for regression tree generates for each node a binary partition composed of a lineal regression, forming ramifications, becoming like this the smaller error than of an only regression model. The generated results were: the numeric model of regression tree and the image index of tree cover extrapolated for the image TM. The use of the model non parametric by regression tree; presented 72% of correlation and 14.8 error results for the estimate in 2168 ha transition at the physiognomy of Savana and Deciduous forest.

Key Word: regression tree, tree cover, Sanava, Deciduous forest, Geoprocessing

* Guidance committee: Luis Marcelo Tavares de Carvalho – UFLA (Supervisor); Fausto Weimar Acerbi Junior – UFLA (Co-supervisor); - UFLA

1 INTRODUÇÃO GERAL

Em Minas Gerais, é importante ressaltar a presença dos três domínios fitogeográficos encontrados no Brasil: o Cerrado, a Caatinga e a Mata Atlântica. Conforme dados do Instituto Brasileiro do Meio Ambiente - IBAMA (2007), o Cerrado é reconhecido como a savana mais rica do mundo em biodiversidade, com a presença de diversos ecossistemas.

Os ecossistemas do bioma Caatinga, os quais se encontram inteiramente restritos ao território nacional, são os menos estudados e os mais ameaçados, com indicadores alarmantes de áreas desérticas. A Mata Atlântica, da qual resta cerca de 7% de sua cobertura florestal original, é identificada como a quinta área mais ameaçada e rica em espécies endêmicas do mundo.

O panorama da conservação desses domínios não é dos mais animadores. Segundo Machado et al.(2004), o estado de conservação do Cerrado é extremamente baixo, com apenas 30% da meta estabelecida para conservação, e a Mata Atlântica, considerada reserva da biosfera pela UNESCO desde 1990, está em risco alarmante, pois possui as maiores cidades e os principais complexos industriais do Brasil.

Atualmente, as pressões da sociedade sobre os ecossistemas vêm alterando as paisagens em grande escala. Em Minas Gerais, grande parte da biodiversidade, ainda não conhecida, vem, anualmente, sendo ameaçada pela forma de exploração descontrolada. Conforme Scolforo & Carvalho (2006), cerca de 1,7%, ou 152 mil hectares, da vegetação nativa no estado de Minas Gerais foi modificado, entre os anos de 2003 a 2005.

De fato, é importante o monitoramento das diferentes paisagens no meio ambiente para tornar possível a análise da conservação desses ecossistemas. Um dos maiores desafios científicos deste século é desenvolver e implementar estratégias para evitar a perda de uma parcela importante da biodiversidade

global devido, principalmente, ao aumento acelerado das atividades humanas no planeta (Silva, 2004).

Com os avanços da geotecnologia, em relação aos novos equipamentos de sensores remotos, novas metodologias de processamento de imagens digitais e análise em sistema de informação geográfica, tem-se adquirido maior robustez na análise e no monitoramento da cobertura terrestre. As atuais tecnologias possibilitam a compreensão do comportamento na dinâmica da superfície terrestre em diferentes escalas, dando suporte à tomada de decisões mais confiáveis e eficientes.

Existem diferentes metodologias aplicadas ao monitoramento da cobertura florestal. No Brasil, destaca-se o monitoramento feito pela Empresa Brasileira de Pesquisa Agropecuária - Embrapa (2007), atuante na gestão territorial da agropecuária. O PRODES (2007), monitoramento da Amazônia por satélite, segue a metodologia proposta pelo Instituto Nacional de Pesquisas Espaciais-Inpe (2004), gerando indicadores anuais de taxas de desflorestamento com áreas temáticas. O Departamento de Transportes e Terminais do Estado de Santa Catarina - Deter (2007), ou Detecção de Desmatamento em Tempo Real, segue outra metodologia proposta por Valeriano et al. (2006), utilizando sensores com alta frequência de observações, porém, com baixas resoluções espaciais.

A metodologia utilizada neste trabalho contribui como uma ferramenta compatível com os atuais programas de monitoramento, a fim de alcançar uma expressiva melhora do mapeamento da cobertura, tal como compreender melhor o comportamento nos desmatamentos e os processos de fragmentação e de regeneração.

2 DELIMITAÇÃO E ENUNCIADO DO PROBLEMA

A maior parte das metodologias de mapeamento e monitoramento, como as citadas no item anterior, baseia-se na modelagem da cobertura terrestre em classes temáticas com limites bem definidos. Esses limites são estipulados em função do poder de resolução espacial, ou seja, o tamanho do *pixel* do sensor remoto utilizado.

Devido ao alto custo de imagens de alta resolução espacial, os modelos operacionalmente utilizados para estudar grandes extensões territoriais ainda são baseados em imagens de média resolução espacial. Dessa forma, em áreas de 900m², como no caso dos *pixel* das imagens Landsat TM, assume-se que exista uma única classe de cobertura do solo, como, por exemplo, floresta.

Várias metodologias estão sendo desenvolvidas para representar classes de variações contínuas, utilizando relações empíricas entre densidade arbórea e dados espectrais de imagens digitais (Huang et al., 2001). Para este tipo de estudo, Liu & Strahler (1992), Baret et al. (1995), Maselli et al. (1995) e Huang et al. (2001) exploraram técnicas com modelos baseados em lógicas Fuzzy, mas concluíram que o procedimento ainda é inviável para o processamento de um grande volume de dados. Outras técnicas, como a análise de mistura espectral e regressão linear, foram aplicadas para estimar a densidade arbórea ou de cobertura arbórea como variável contínua (Iverson et al., 1989; Zhu & Evans, 1994 e DeFries et al., 2000).

O desenvolvimento da resolução espacial dos sensores remotos, levando a um detalhamento com escalas de alta resolução, força a evolução dos processos de geração e manutenção de bases cartográficas, como nos processos de classificação digital de imagens. Como consequência, o volume de dados para armazenamento e o tempo de processamento são fatores limitantes das

atuais tecnologias dos sensores de alta resolução espacial no estudo de grandes extensões territoriais.

No entanto, essas limitações podem ser reduzidas quando se utilizam modelos de predição espacial, com imagens de alta resolução espacial, para calibrar um conjunto de média resolução. Esse procedimento é capaz de gerar mapas de médias resoluções espaciais mais aprimorados, sem comprometer o tempo de processamento e sem acarretar em maiores custos.

3 FORMULAÇÃO DAS PERGUNTAS CIENTÍFICAS

1. Quais os pré-processamentos necessários para caracterizar formações florestais decíduais utilizando imagens temporais?
2. O resultado do índice de densidade de cobertura arbórea apresenta diferenças quando comparado com os índices NDVI e imagens fração do modelo linear de mistura espectral?
3. É possível determinar a precisão do modelo não paramétrico de árvore de regressão?
4. É possível caracterizar diferentes ecossistemas dos domínios de savanas e Florestas Estacionais Decíduais e em sua área de transição utilizando a variabilidade da cobertura arbórea?

4 OBJETIVOS

4.1 Objetivo geral

O objetivo geral deste trabalho foi o de estudar a variabilidade da cobertura arbórea dentro das diferentes fitofisionomias que ocorrem na área de estudo.

4.2 Objetivos específicos

- Executar o mapeamento detalhado da variável cobertura arbórea, utilizando amostras de imagem Ikonos de alta resolução espacial.
- Ajustar o modelo de árvore de regressão relacionando a cobertura arbórea com imagens Landsat TM de média resolução espacial, referentes aos períodos de inverno e verão.
- Determinar a precisão do modelo de árvore de regressão ajustado.
- Aplicar o modelo ajustado para estimar a cobertura arbórea, utilizando as imagens Landsat TM.
- Mapear as classes de fitofisionomias presentes na área de estudo.
- Analisar a variabilidade de cobertura arbórea pertencentes às fitofisionomias mapeadas na área de estudo.

5 REFERENCIAL TEÓRICO

5.1 Modelos de representação espacial

Muitos são os esforços desenvolvidos na área de modelagem ambiental, uma vez que a representação dos objetos e dos fenômenos naturais é complexa. Inicialmente, existe a dificuldade de obter variáveis consistentes, as quais possam representar os objetos e os fenômenos naturais por meio de sensores ópticos com níveis de precisão condizentes com a problemática a ser mapeada.

Em geoprocessamento, o espaço geográfico é modelado segundo duas visões complementares: os modelos conceituais de campos contínuos e os modelos de objetos. Inicialmente, devem-se considerar as duas grandes classes de representações geométricas: representação matricial e representação vetorial (Câmara & Medeiros, 1998).

Os dois extremos na aproximação da percepção do espaço estão sendo ocupados ou por uma série de entidades, as quais são descritas pelos atributos e representadas por sistema de coordenada, ou como campos contínuos de variação de limites indistintos. O paradigma de campo contínuo provê uma rica fundamentação para a modelagem espacial, particularmente quando os dados estão organizados em grades regulares, grids ou dados raster (Burrough & McDonnell, 1998).

Contudo, mesmo com este proveito da variabilidade espacial representado em dados raster, ainda existe a questão da mistura espectral dos objetos que ocorrem na área imageada por um *pixel*. Mesmo em dados de alta resolução espacial, os *pixels* apresentam, na maioria das vezes, alto grau de mistura, dificultando a interpretação das cenas.

5.2 Sensoriamento remoto

Em princípio, o sensoriamento remoto é a utilização de sensores para aquisição de informações sobre objetos ou fenômenos, sem que haja contato direto entre o sensor e os alvos de interesse (Novo, 1998). Imagens de sensoriamento remoto são amplamente empregadas, em várias aplicações, nos campos de oceanografia, meio terrestre e atmosférico, tais como mapeamento da superfície, modelagem ambiental, monitoramento e na utilização de banco de dados geográficos (Tso & Mather, 2001).

Muitos avanços em métodos de extração de informação das imagens digitais vêm sendo desenvolvidos desde o primeiro lançamento, na década de 1970, dos satélites orbitais de observação da superfície terrestre. Verificou-se o aprimoramento do sensoriamento remoto como ferramenta de identificação, medição e monitoramento de importantes características biofísicas e atividades humanas na Terra.

Na década de 1980, os esforços foram direcionados para o desenvolvimento de métodos de análise espectral e classificações de imagens. Já na década de 1990a, os avanços em sensores hiperespectrais, compostos com centenas de bandas ou canais espectrais, vieram junto com o aumento da capacidade suporte no campo da computação (Jong et al., 2004). Os métodos de análise espectrais das imagens produziram resultados satisfatórios em muitos dos casos, porém, nem todos os objetos observados na superfície da Terra apresentam uma única assinatura espectral, o que leva a um alto grau de incerteza para distinguir os objetos, incapazes de serem espectralmente separados.

Atualmente, para melhorar a análise dos alvos nas imagens, buscam-se informações providas das vizinhanças das células ou dos padrões ao redor dos *pixels* de interesse, podendo prover acréscimos significativos para o domínio espacial da informação (Burrough, 2004).

Neste contexto, as técnicas que utilizam sensores de alta resolução espacial, como no caso a imagem Ikonos, têm aplicações que podem ajudar o monitoramento e o manejo dos recursos da terra, tais como parques, áreas alagadas e outras áreas protegidas, assim como avaliar os efeitos de desastres naturais ou ações preventivas em áreas com risco de incêndios e alagamentos, dentre outras aplicações (Goetz et al., (2003).

Multirresoluções em conjunto de dados em sensoriamento remoto são utilizadas para ajudar grandes projetos de mapeamento. Associação entre as diferentes resoluções espaciais é uma maneira de aperfeiçoar a informação dos recursos naturais. A densidade de um determinado tipo de cobertura terrestre, *e.g.* cobertura florestal, representada em baixa resolução espacial, pode derivar em novas proporções de outras coberturas, por meio da identificação em uma resolução mais fina.

Hansen et al. (2002) demonstraram que dados em alta resolução espacial permitem a interpretação direta das variáveis de interesse, enquanto dados de resoluções multitemporais, mas de baixa resolução espacial, permitem o mapeamento de maior abrangência territorial, sem grandes custos na aquisição de imagens de satélite.

5.2.1 Caracterização espectral da vegetação

A caracterização espectral da vegetação consiste nos processos de interação entre a radiação eletromagnética, considerada fundamental nas técnicas de sensoriamento remoto e as diferentes características das fisionomias vegetais das quais se deseja extrair algumas informações na área de ocorrência de florestas nativas.

Esses processos podem ser estudados em níveis detalhados de aproximação como, por exemplo, para quantificar taxas de absorção de radiação por meio da ação de pigmentos fotossintetizantes. Para isso, trabalha se com

equipamentos específicos em laboratórios, cujas medições são feitas em partes das plantas. Entretanto, os processos de interação com a radiação e a vegetação também podem ser estudados em níveis mais generalizados, assim como estudos na estimativa de produtividade vegetal, utilizando modelos matemáticos correlacionados com dados espectrais de sensores orbitais (Ponzoni & Shimabukuro, 2007).

Primeiramente, para compreender o comportamento espectral da vegetação, é necessário lembrar que as folhas são constituídas por diferentes tecidos. Estes tecidos conduzem meios com diferentes índices de refração, pelos quais o feixe de radiação deverá interagir.

Os feixes de radiação podem ser transmitidos, refletidos, absorvidos e, conseqüentemente, emitir a energia luminosa. Esta interação é dependente de fatores químicos, como pigmentos fotossintetizantes e físicos, como organização dos tecidos da folha. Isso indica que as assinaturas espectrais da vegetação estão relacionadas com as características físico-químicas das folhas e sua disposição na planta.

A caracterização espectral da vegetação pode ser analisada de forma isolada, como folhas individualizadas ou de forma composta, como dosséis vegetais, como é o caso do desenvolvimento deste estudo.

5.3 Pré-processamento

Dados obtidos de sensoriamento remoto apresentam distorções geométricas e, para se extrair informações a partir desses dados, são necessários alguns passos de pré-processamento para corrigir tais distorções.

A correção das distorções geométricas, de acordo com um sistema de coordenada, tem as seguintes finalidades: (a) georreferenciar a imagem a um sistema de projeção cartográfica padrão; (b) localizar pontos de interesse; (c) sobrepor imagens de uma mesma área obtidas por diferentes sensores e ou datas

e (d) sobrepor à imagem um mapa ou referenciá-lo de acordo com uma base de dados geográficos (Carvalho et al., 2005).

As etapas de processamento da correção geométrica são as transformações de coordenadas x e y e a reamostragem para determinar o valor do novo *pixel* na imagem registrada. Uma das técnicas de correção geométrica mais empregada utiliza pontos de controle para determinar empiricamente uma equação matemática que corrija a geometria da imagem.

Um dos parâmetros utilizados para avaliar o registro é a raiz do erro quadrado médio (EQM) para cada ponto de controle, conforme a equação seguinte:

$$EQM = \sqrt{(X' - X)^2 + (Y' - Y)^2}$$

em que:

x' e y' representam as coordenadas de linha e coluna originais do ponto de controle na imagem.

x e y representam as novas coordenadas estimadas pelas equações polinomiais.

A EQM é um indicador da fidelidade geométrica interna da imagem, podendo ser expressa em termos totais, para todo o conjunto de pontos de controle ou parcial, para cada ponto de controle separadamente (Carvalho et al., 2005).

5.4 Sistema de informação geográfica

Sistema de Informação Geográfica, ou SIG, segundo Silva (2003), é uma tecnologia capaz de realizar análises com dados espaciais. Estes sistemas oferecem alternativas para o entendimento da ocupação e utilização do meio físico, compondo o chamado universo da geotecnologia, ao lado do

processamento digital de imagens de sensoriamento remoto e do sistema de posicionamento global ou GPS.

Os diferentes fenômenos geográficos, ao se distribuírem sobre a superfície da Terra, estabelecem padrões de ocupação. Ao representar tais fenômenos, o geoprocessamento procura determinar e esquematizar os mecanismos implícitos e explícitos de inter-relações entre eles, tais como: correlações espaciais, temáticas, temporais e topológicas (Câmera & Medeiros, 1998).

As principais características do SIG são: a capacidade de inserir e integrar, em uma base de dados georreferenciado, informações espaciais provenientes de dados cartográficos, dados censitários e cadastrais, imagens de sensoriamento remoto, redes e modelos numéricos. Para Burrough & McDonnell (1998), o SIG é definido como um sistema com capacidade para aquisição, armazenamento, processamento, análise e exibição de informações digitais georreferenciadas, topologicamente estruturadas, associados ou não a um banco de dados alfanuméricos.

O SIG é composto por quatro elementos básicos de operação: hardware, software, dados e profissionais. Seu modelo de banco de dados e o gerenciamento são as principais ferramentas para o armazenamento, a manipulação e a organização de grandes volumes de informações. Assim, o aperfeiçoamento da aplicação do sistema é dependente da qualidade da transposição de entidades do mundo real e suas interações para um sistema computadorizado (Rocha, 2000).

5.5 Análise subpixel

Durante a formação da imagem, os sensores passivos captam a energia refletida ou emitida dos objetos. Quando esses objetos são menores que o *pixel* (Figura 2) ou quando os limites de objetos maiores encontram-se dentro deste,

ocorre a mistura espectral entre os elementos (Aguiar, 1991). Outros fatores, como contaminação atmosférica e variações na geometria de aquisição, também contribuem com a mistura (Ferreira et al., 2003).




FIGURA 1 Comportamento espectral dos objetos; solo, vegetação, água.

A análise *subpixel* consiste na investigação dos possíveis elementos que compõem o universo do *pixel*. A dificuldade maior é determinar a influência de cada elemento da paisagem na composição do *pixel*, uma vez que o seu limite espacial está sob influência nas faixas entre os limites dos elementos vizinhos a ele.

Estudos de *subpixel* que utilizam a análise de mistura espectral para investigar as proporções dos elementos presentes no *pixel* levam em consideração a integridade de *pixels* que representam um único elemento. Este fato não condiz com a realidade, sabendo que, na natureza biológica, dificilmente encontram-se proporções de um único elemento e com limites precisos na cena.

Modelagem de mistura espectral é um método de mapeamento desenvolvido para derivar frações dos materiais que contribuem na formação de uma paisagem (*e.g.* solo, água, vegetação, etc.). Os materiais que formam a paisagem podem apresentar características espectrais sem grandes variações, com padrões homogêneos, ou grandes variações com padrões heterogêneos.

Para uma determinada resolução espacial, os *pixels* são considerados puros quando toda a área do mesmo é composta por um único material. Para o mapeamento de uma represa, por exemplo, os *pixels* inteiramente cobertos por água são chamados de puros, quando 100% dele é coberto por um único material, a água.

Quando uma resolução espacial não é suficiente para captar toda a área de um material, isto é, quando o material é menor que o *pixel*, não é possível encontrar *pixels* puros. Para o mapeamento dos cursos de água com 15 m, utilizando sensores de resoluções espaciais de 30 m, haverá sempre uma mistura com a água e com outros materiais dentro da área coberta pelo *pixel*.

Outra forma de análise de *pixels* que representam misturas espectrais é a investigação das incertezas, por meio de regra *Fuzzy*, utilizando modelos matemáticos de pertinência para determinar as proporções de cada elemento neles presente.

A análise *subpixel* em diferentes escalas e sensores possibilita uma melhor interpretação dos elementos presentes no *pixel*. Dessa forma, é possível uma análise de misturas espectrais diretamente observadas e classificadas em uma escala mais detalhada, para a análise dentro do *pixel* de outra escala menos detalhada. Deve ser observado, nesta análise, o grau de dependência entre as datas de coleta dos dados, uma vez que se utilizam dois sensores de diferentes posições e duas datas ou horários de diferentes angulações na aquisição da imagem.

5.6 Classificação de imagens digitais

Existem diversos algoritmos de classificação utilizados em sensoriamento remoto. Os mais utilizados são os de máxima verossimilhança e isodata, empregados no procedimento de classificação supervisionada e não supervisionada, respectivamente (Figueiredo, 2005).

Classificadores supervisionados são os que requerem amostras de treinamento, ou conhecimento prévio. Os não supervisionados podem ser chamados de classificadores automáticos, pois não requerem amostras de treinamento.

Para a classificação digital, utilizam-se algoritmos que categorizam ou rotulam os valores dos atributos espectrais em padrões estatísticos ou computacionais. Segundo Tso & Mather (2001), no contexto de reconhecimento de padrões, um padrão é um vetor de características que descrevem um objeto distinguível dos demais de forma objetiva.

Diversos métodos estatísticos podem ser utilizados para a classificação das imagens digitais. As relações e os padrões dos objetos podem ser ajustados utilizando-se parâmetros de distribuição previamente conhecidos, chamados de modelos paramétricos; podem utilizar funções matemáticas para desenvolver os conjuntos de pertinência, chamados de lógica *fuzzy*, ou, ainda, utilizar modelos de indução e valorização da informação, chamado de modelos não paramétricos, pois não necessitam de conhecimentos prévios da distribuição dos dados.

Segundo Moreira (2001), durante a classificação de dados digitais, os alvos do universo real recebem a denominação genérica de classes ou temas. Existem duas formas de representação da classificação final em um mapeamento, uma considera as classes em regiões discretas e de elementos puros e a outra abrange em contínuo como multielementos de valores diferentes contidos, cada um, em uma única classe (Foody, 2005), (Figura 2).




FIGURA 2 Comparação de classificações contínuas e temáticas.

5.6.1 Árvores de classificação

Árvores de classificação são algoritmos não paramétricos que podem ser utilizados com distribuições de dados arbitrários ou sem conhecimento prévio da função de probabilidade dos dados. Diferentemente dos métodos de reconhecimento de padrões mais usuais, árvores de classificação são métodos não métricos, isto é, não assumem as feições como valores de medições reais, podendo utilizar dados nominais (Richard et al., 2001).

Os algoritmos de árvore de classificação, de maneira geral, são formados por seqüência de procedimentos bem definidos que, quando seguidas, levam a solução de uma determinada classe de problema. Este classificador, quando aplicado aos dados multiespectrais, segundo Tso & Mather (2001), separa cada classe com base no conhecimento das propriedades espectrais e na relação parental entre as classes vizinhas.

Este um método também chamado de *data mining*, ou mineração de dados, cuja principal característica é a extração de informação previamente desconhecida e de máxima abrangência a partir de grandes bases de dados,

utilizando-as para efetuar decisões (Figueiredo, 2003). Para Coutinho (2003), pode ser considerada uma forma de descobrimento de conhecimento em bancos de dados envolvendo inteligência artificial.

É considerado um classificador não paramétrico que se baseia no aprendizado indutivo, em que o algoritmo aprende as regras para separar as classes de acordo com amostras de treinamento (Quilan, 1986). A partir das amostras de treinamento, o algoritmo separa os atributos do conjunto de amostras, por regras de decisões binárias, em subconjuntos mais homogêneos. Este procedimento é submetido a novas regras, a fim de gerar conjuntos puros determinando as classes finais. Pode-se perceber o uso de heurísticas e outros métodos que não aqueles encontrados nas teorias estatísticas ou que estão sempre relacionados na literatura sobre o assunto, principalmente os procedimentos de análise de variância. (Coelho, 2005)

A árvore de decisão é composta de um nó radical (**t1**), conjunto de nós interiores (**t2**), que contém as decisões ($x_1 \leq 7$ e $x_2 \leq 0,5$) das repartições em nós terminais, folhas (**t3**, **t4** e **t5**), os quais contêm as classes temáticas finais exemplificadas na Figura 3.




FIGURA 3 Representação em diagrama da árvore de decisões.

O método utilizado por Quinlan (1986), o algoritmo de árvore de classificação, considera, para a representação das regras, o conjunto de casos (inicialmente, todos os casos das amostras de treinamento), sendo chamadas de **T** e **C_k** ($k = 1$ a m) as possíveis classes. Então, podem existir três possibilidades nas decisões:

- **T** contém um ou mais casos, todos pertencentes a uma única classe **C_j**. Então, a decisão para **T** é uma folha identificando uma classe.
- **T** é um conjunto vazio, então, a decisão herdará uma folha com a classe mais freqüente do pai desse nó.
- **T** contém casos pertencentes a uma mistura de classes. Então, a idéia fundamental é selecionar divisões de subconjuntos em que os dados de cada descendente sejam mais “puros” que os dados de seu subconjunto parental.

Nesta terceira condição, inicia-se o processo de refinamento (conjunto de atributos), o que é realizado a partir de um teste em um único atributo, produzindo resultados mutuamente exclusivos **O_i** ($i = 1, n$). Dessa forma, obtêm-se as variáveis que explicam os casos de treinamento. Em seguida, deve-se ajustar um modelo para cada atributo de entrada em cada nó (decisão), ou seja, definir quais intervalos de variações são representativos para separar as classes.

Das diversas possibilidades de regras de decisões, o algoritmo utiliza-se da análise dos resíduos para concluir as decisões, quando obtiver resultados mais próximos de zero ou quando for perdida uma menor porção de observações. Então, para concluir, o procedimento de seleção das melhores decisões, a chamada poda, se necessário, será ajustado para minimizar as decisões redundantes.

5.6.2 Árvore de regressão

Semelhante ao processo por árvore de classificação, a árvore de regressão tem a função de separar, a partir de amostras de treinamento, um conjunto de atributos capazes de prever o valor de uma variável numérica.

A técnica de árvore de regressão utiliza regressões lineares para cada ramificação dos nós, nos quais o somatório dos erros de cada nó apresenta erros menores que os gerados pelo melhor modelo de regressão linear (Huang,2001). Comparando as previsões entre regressão linear e árvores de regressão, as previsões da árvore de regressão são mais precisas que as regressões lineares. A representação algébrica da árvore de regressão pode ser interpretada pelo conjunto hierárquico dos parâmetros pertencentes a cada nó ou ramificações (t).

$$Y = \begin{cases} \sum \beta_i^{(3)} x_i + \varepsilon^{(3)} & \text{se } x \in t_3 \\ \sum \beta_i^{(4)} x_i + \varepsilon^{(4)} & \text{se } x \in t_4 \\ \sum \beta_i^{(5)} x_i + \varepsilon^{(5)} & \text{se } x \in t_5 \end{cases}$$

em que:

$\beta_i^{(k)}$: i-ésimo parâmetro β do modelo linear do k-ésimo nó;

$\varepsilon^{(k)}$: ruído do modelo linear do k-ésimo nó;

x : dados de entrada

Y : dados de saída

A grande vantagem na utilização do método de árvore de regressão comparado ao método de regressão linear é a capacidade de realizar estimativas utilizando-se dados temporais, os quais alteram os padrões de distribuição dos dados.

5.6.3 Avaliação de classificação

Na classificação de imagens digitais, o termo acurácia informa o nível de concordância entre as classes especificadas pelo classificador e as classes de referência ou amostras de validação, baseadas nos dados de campo coletados pelo usuário (Figueiredo, 2005). A ferramenta mais comum utilizada para determinar a acurácia da classificação é a matriz de erro, de confusão ou de contingência (Lillesand & Kiefer, 2000; Tso & Mather, 2001; Figueiredo, 2005).

Pela matriz de erro podem ser observados os erros de omissão e inclusão da classificação, a acurácia global e o índice de qualidade *Kappa*.

A exatidão global é calculada pela divisão da soma dos elementos da diagonal principal pelo número total de amostras, conforme a expressão abaixo:

$$P_0 = \frac{\sum_{i=1}^m n_{ij}}{N}$$

em que:

P₀ = exatidão global do mapeamento;

N = número total de unidades amostrais;

n_{ij} = total de elementos da diagonal principal, ou seja, número de *pixels* corretamente classificados;

m = número de classes ou categorias presentes na matriz de erro;

i e j = linhas e colunas da matriz de erro, respectivamente.

O coeficiente *Kappa* representa a concordância entre a imagem classificada com o dado de referência, sendo determinada pela seguinte expressão:

$$K = \frac{P_0 - P_c}{1 - P_c} \quad ; \quad P_c = \frac{\sum_{i=1}^M n_i + n_{+i}}{N^2}$$

em que:

K = coeficiente *Kappa*

P₀ = exatidão global;

P_c = proporção de unidades que concordam ao acaso;

M = número de classes presentes na matriz de erro;

n_i e **n_{+i}** = totais marginais de linha *i* e da coluna *j*, respectivamente;

N = número total de unidades amostrais completadas pela matriz.

6 MATERIAL E MÉTODO

A metodologia deste trabalho é composta de cinco fases: pré-processamento, classificação, ajuste de modelos numéricos, acurácia do modelo e análise dos dados. Para os tratamentos dos dados foram necessárias a correção geométrica, a calibração das bandas espectrais e a retificação radiométrica.

Foi utilizada a classificação da cobertura arbórea em alta resolução espacial de três metros, para a geração do índice de cobertura arbórea. A análise *subpixel* foi feita utilizando-se o índice de cobertura arbórea, proveniente da agregação espacial referente a 30 m e as bandas espectrais das imagens Landsat TM.

Foram processados os índices de vegetação NDVI e imagem fração vegetação, a fim de serem comparados com a estimativa do modelo por árvore de regressão. Esses índices foram desenvolvidos por razões de bandas espectrais e modelo de mistura espectral, respectivamente. Estes são métodos já aplicados na área de processamento de imagem digital e vastamente utilizados em sensoriamento remoto aplicado à vegetação.

Neste trabalho, utilizou-se o índice espacial por agregação, proveniente da imagem de alta resolução, como amostra da variável dependente. O modelo não paramétrico por árvore de regressão é utilizado para ajustar a estimativa de valores de cobertura arbórea em grandes áreas da imagem de baixa resolução.

6.1 Esquema da metodologia

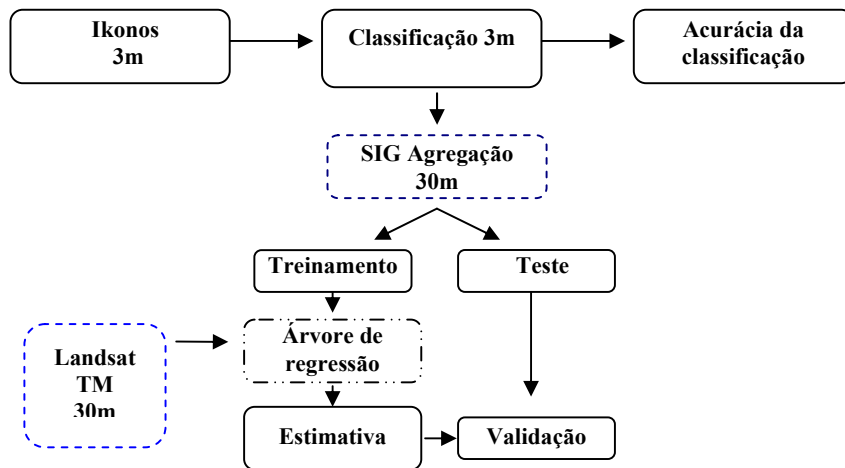


FIGURA 4 Diagrama do esquema metodológico

6.2 Área de estudo

De forma geral, a área de estudo está localizada nos limites da regional alto médio São Francisco, de acordo com divisão do Instituto Estadual de Florestas (IEF), pertencente à sub-bacia hidrográfica do rio Cochá, presente na bacia hidrográfica do rio São Francisco - SF9. Na Figura 5 mostram-se os limites dos rios que fazem parte da área de estudo: São Francisco, Peruaçu, Itacarambi e Japoré, e riachos Borrachudo e da Cruz.

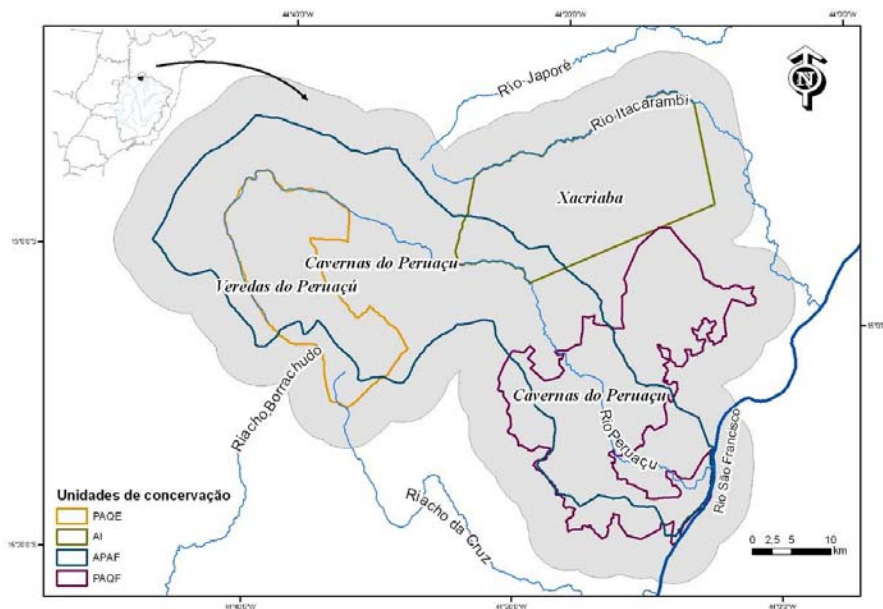


FIGURA 5 Localização da área de estudo em cinza.

Esta região se encontra em uma zona de transição entre os domínios fitogeográficos do Cerrado e de Florestas Estacionais Deciduais e é dotada de um extenso patrimônio natural, paisagístico, espeleológico e arqueológico.

Parte do Parque Nacional sobrepõe-se aos limites da área de proteção ambiental (APA) das cavernas do Peruaçu, a qual coincide com os limites geográficos da bacia hidrográfica do rio Peruaçu, afluente da margem esquerda do médio curso do Rio São Francisco.

Na área da APA existe, ainda, a sobreposição de uma unidade de conservação estadual, denominada Parque Estadual Veredas do Peruaçu, de responsabilidade do IEF-MG e na porção do médio curso do rio Peruaçu, sobrepõe-se à APA uma pequena porção de uma Reserva Indígena Xacriabá, de responsabilidade da Fundação Nacional do Índio (FUNAI). Pelos dados da

Tabela 1 observa-se a dimensão que cada unidade representa na área e seus respectivos usos.

TABELA 1 Áreas de proteção pertencentes à bacia do rio Peruaçu.

Áreas de proteção	Tipo	Sigla	Uso	Área (ha)
Parque Nacional Cavernas do Peruaçu	Parque nacional	(PAQF)	Proteção integral	56.448
Parque Estadual Veredas do Peruaçu	Parque estadual	(PAQE)	Proteção integral	31.429
APA Cavernas do Peruaçu	Área de proteção ambiental	(APAF)	Uso sustentável	143.353
Área Indígena Xacriabá	Área indígena	(AI)	Outros	46.437

6.2.1 Meio físico e biológico

6.2.2 Clima

O clima é do tipo tropical quente semi-úmido, com quatro a cinco meses secos (Instituto Brasileiro de Geografia e Estatística - IBGE, 2004), tendendo a seco pela irregularidade da ação das massas de ar, abrangendo o sertão nordestino e o vale do médio rio São Francisco.

A temperatura média de verão é de 24°C e no inverno é de 22°C. A precipitação média total acumulada situa-se por volta de 1.200 mm e apresenta períodos chuvosos entre outubro a março e períodos secos, correspondentes ao inverno, de abril a setembro. A umidade relativa do ar é de 66%, no inverno e de 79%, no verão. Os dados foram registrados, ao longo dos anos entre 1961 a 1990, pelas estações climatológicas do estado de Minas Gerais.

6.2.3 Geologia

Ocorrem na área três grandes unidades litoestratigráficas: Coberturas Cenozóicas indiferenciadas, Formação Urucuia, de idade Mesozóica e o Grupo Bambuí, de idade Pré-Cambriana (Proterozóico Superior).

O rio Peruaçu nasce nos planaltos desenvolvidos sobre os pacotes sedimentares (arenitos, siltitos e concreções látero-manganesíferas), de idade Cretácea da formação Urucuia. Passa a correr em seu médio curso sobre as rochas carbonáticas e pelitos, de idade Proterozóica, do grupo Bambuí e, posteriormente, no seu baixo curso, sobre as coberturas inconsolidadas, de idade Cenozóica, da depressão do São Francisco (RADAMBRASIL, 1982) (Figura 6).




FIGURA 6 Perfil da formação do solo no decorrer da nascente do rio Peruaçu até o encontro com o rio São Francisco.

O relevo é, na sua maior parte, ondulado, variando em planalto e montanhas delimitadas por escarpas; o processo de desgaste supera o de deposição de materiais (IBGE, 2004).

O tipo de solo predominante é o neossolo quartzarênico RQ (areias quartzosas). A rede hidrográfica da região é composta pelos afluentes da bacia do rio São Francisco.

6.2.4 Vegetação

Conforme distribuição fitogeográfica apresentada no mapa de vegetação do Brasil (IBGE, 2004). A região de estudo situa-se em área ocupada por formações de Floresta Estacional Decidual Montana, Floresta Estacional Semidecidual, Savana Arborizada e área de tensão ecológica entre Savana Estépica e Floresta Estacional, denominada de enclave florístico. Ainda há as formações com a presença de campos rupestres em afloramentos rochosos.

Segundo Veloso (1991), a cartografia deste domínio denominado de enclave é uma questão de escala, pois, nas escalas de semidetalhamento e de detalhamento, tanto o ecótono como o enclave são perfeitamente detectados e, por este motivo, devem ser separados e mapeados como entidades independentes.

Este estudo caracterizou os domínios fitogeográficos utilizando como referência a classificação proposta por Veloso (1991). As nomenclaturas associadas a este sistema encontram-se na Tabela 2. Ainda outros objetos foram mapeados na área, como as formações de solo exposto, corpos de águas e afloramentos rochosos associados com os campos rupestres.

Segundo Scolforo & Carvalho (2006), a sub-bacia SF9 do rio Cochá, a segunda mais bem preservada por vegetação nativa, encontra-se com 1.838.146 ha, aproximadamente 59,01% da área coberta por vegetação nativa e 0,07% da área com reflorestamento ou 2.189 ha de eucalipto.

TABELA 2 Nomenclatura utilizada proposta por Veloso (1991).

Floresta Estacional Decidual	FED
Savana Arborizada	As
Pecuária	Ap
Contato Savana / Floresta Estacional	SNc
Floresta Estacional Semidecidual Aluvial	Fa
Formações com influência fluvial e/ou lacustre	Pab
Savana Gramíneo-Lenhosa	Sgs
Agricultura	Ac
Afloramento Rochoso	Afl. Roc.
Solo Exposto	Solo exp.
Água	Água

6.3 Material

Foram utilizadas as imagens de 30 metros de resolução espacial com 6 bandas espectrais do sistema sensor TM, a bordo do satélite Landsat 5, nas épocas de inverno e verão. Foram utilizadas as imagens de alta resolução espacial Ikonos, fusionadas para 1 metro de resolução espacial, adquiridas segundo a parceria UFLA e IEF.

As características espectrais de cada sensor utilizado neste estudo são apresentadas na Tabela 3

TABELA 3 Características espectrais das imagens dos sensores TM e Ikonos.

Sensor	Landsat 5 TM	Ikonos
Banda 1	0,45 a 0,52 μm	0,45 a 0,52 μm
Banda 2	0,53 a 0,61 μm	0,52 a 0,60 μm
Banda 3	0,63 a 0,69 μm	0,63 a 0,69 μm
Banda 4	0,78 a 0,90 μm	0,76 a 0,90 μm
Banda 5	1,55 a 1,75 μm	-
Banda 7	2,09 a 2,35 μm	-
Banda pan	-	1 m
Pixel	30 m	4 m

Na Tabela 4 são apresentadas algumas características ópticas referentes ao momento de aquisição das imagens. A observação dos parâmetros de inclinação solar e a data de aquisição são importantes para a noção de sombreamento nas imagens, quando se deseja utiliza-las para o modelo de calibração.

TABELA 4 Características ópticas dos sensores TM e Ikonos, no momento de aquisição das imagens.

Satélite	Date	Horário	Elevação solar	Azimuth solar
Ikonos 2	10/9/06	13h35min	62,40	53,11
Ikonos 2	29/9/06	13h27min	66,96	59,52
Landsat 5 TM	14/9/06	12h55min	55,44	58,11
Landsat 5 TM	20/1/07	12h57min	58,84	10,57

Foram utilizados os software de processamento de imagens ENVI 4.3, software de árvore de regressão CUBIST e os sistemas de informações geográficas ArcGIS 9.2. Foi utilizado hardware PC Desktop Pentium 4, com configuração 3.0 GHz com 1024 MB de RAM e capacidade de HD com 120 Gb.

6.4 Pré-processamento

6.4.1 Correção geométrica

As correções geométricas das imagens Landsat TM (inverno e verão) foram realizadas com o objetivo de obter a integridade geométrica de um mapa, sem as distorções causadas pelo processo de aquisição.

Os pontos de controle no terreno (GCPs) foram extraídos de outra imagem, da mesma cena imagiada devidamente corrigida, fornecida pelo programa de distribuição de imagens da National Aeronautics and Space Administration - Nasa (2003).

Os métodos utilizados para correções sistemáticas de ambas as imagens foram o modelo polinomial do segundo grau e a reamostragem bilinear. A avaliação desse procedimento foi realizada utilizando o erro quadrático médio (RME) das diferenças entre as posições dos pontos de controles da imagem referência e a posição estimada pelo modelo polinomial.

6.4.2 Calibração radiométrica

Os valores digitais das imagens durante sua aquisição são reflexos das interações entre a energia eletromagnética incidente na atmosfera e dos objetos na superfície, captada pelo sensor do satélite em órbita.

A fim de atenuar os problemas da correlação entre os dados de diferentes satélites, os números digitais são convertidos para valores de radiância. Segundo Markham & Barker (1987), os valores, em números digitais, das imagens brutas são transformados para valores de radiância a partir de parâmetros orbitais do satélite e de calibração do sensor usando a seguinte equação:

$$L_{\lambda} = L_{\text{MIN}\lambda} + ((L_{\text{MAX}\lambda} - L_{\text{MIN}\lambda}) * \text{QCAL} / \text{QCAL}_{\text{MAX}})$$

em que:

λ = comprimento de onda

$L\lambda$ = radiância espectral aparente;

ND = valor do *pixel* calibrado, valor em número digital;

$L_{MIN\lambda}$ = radiância espectral mínima;

$L_{MAX\lambda}$ = radiância espectral máxima;

$QCAL_{MAX}$ = número digital máximo;

$QCAL$ = número digital.

Após a transformação dos valores digitais em valores de radiância espectral aparente ($L\lambda$), esses valores serão utilizados para o cálculo de reflectância aparente, segundo o método proposto por Markham e Barker (1987), do seguinte modo:

$$\rho_a = \frac{\pi * L_\lambda * d^2}{E_{sun_\lambda} * \cos \theta}$$

em que:

ρ_a = reflectância aparente;

$L\lambda$ = radiância espectral ($mW.cm^{-2}.ster^{-1}.\mu m^{-1}$);

d = distância sol-Terra, em unidades astronômicas;

E_{sun_λ} = irradiância espectral média do sol no topo da atmosfera ($mW.com^{-2}.\mu m^{-1}$)

Θ = ângulo solar zenital.

Uma vez convertidos os valores digitais em valores biofísicos de reflectância, é possível realizar operações aritméticas utilizando dados de diferentes bandas espectrais, uma vez que os valores representam parâmetros para uma mesma escala.

No entanto, mesmo estando os valores em uma mesma escala, não se podem comparar os comportamentos dos objetos representados pelas imagens em épocas diferentes, pois ainda existe o efeito da condição atmosférica, fato que torna necessária a retificação radiométrica.

6.4.3 Retificação radiométrica

Devido às diferentes condições climáticas ou atmosféricas, decorrentes dos períodos sazonais, é visualmente possível notar as variações de brilho nas cenas de inverno e de verão. A utilização de imagens multitemporais em sensoriamento remoto demanda etapas de pré-processamento que normalizem a radiometria para realizar, com maior confiabilidade, as análises nesses dados.

Existem diversos métodos para atenuar as respostas dos objetos presentes em diferentes épocas do ano. Esses métodos podem utilizar modelos complexos que utilizam parâmetros de transferência radiativa no momento da aquisição da imagem, ou modelos mais simples, como aqueles que utilizam objetos de baixa variabilidade presentes na cena.

Em virtude da indisponibilidade de informações no momento de aquisição da imagem, Hall et al. (1991) propuseram a normalização das condições atmosférica utilizando médias de objetos claros e escuros presentes nas diferentes imagens de satélites previamente calibradas para valores de reflectância.

A estimativa de uma imagem radiometricamente corrigida em relação a uma imagem referência induz a uma mesma condição atmosférica os objetos

presente nas diferentes imagens. Este procedimento de normalização é capaz de assegurar as comparações entre diferentes épocas.

Primeiramente, é necessário adquirir as amostras de dados de controle, caracterizados por baixa ou nenhuma variação de reflectância média entre as imagens. Posteriormente, é necessário o ajuste dos coeficientes para a regressão linear da imagem a ser corrigida em relação aos dados da imagem referência. O modelo empregado nas transformações lineares é o seguinte:

$$T_i = m_i * x_i + b_i,$$

em que:

T_i = número digital da imagem retificada;

x_i = número digital da imagem original;

m_i = (B_{ri} – D_{ri})/(B_{si} – D_{si}); **b_i** = (D_{ri} * B_{si} – D_{si} * B_{ri}) / (B_{si} – D_{si})

e em que:

B_{ri} = média do conjunto de referência clara;

D_{ri} = média do conjunto de referência escura;

B_{si} = média do conjunto claro a ser retificado;

D_{si} = média do conjunto escuro a ser retificado;

i = bandas do TM (1 a 5 e 7).

Para retificação radiométrica deste estudo, foi selecionada a imagem de inverno como referência, devido à baixa influencia das partículas de água na atmosfera. Foram identificados, por meio de interpretações visuais em imagens de alta resolução espaciais, alguns objetos escuros e de baixa variação em todas as bandas espectrais em ambas as épocas (*e.g.* água, sombras e rochas) e objetos claros com baixa variação espectral em ambas as épocas (*e.g.* solo exposto, areias e estradas).

6.4.4 Modelo linear de mistura espectral (MLME)

Uma das maneiras mais usadas para obter as frações de *pixels* puros é utilizar o espaço bidimensional de atributos, método conhecido como teoria do simplex (Correia, 1982; Aguiar, 1991). Conhecendo o comportamento espectral dos objetos na faixa do vermelho e do infravermelho próximo, como mostrado na Figura 7, o vértice de um triângulo inclui o conjunto de dados que correspondem aos *pixels* com as proporções mais puras de um determinado elemento da cena (Ponzoni & Shimabukuro, 2007).

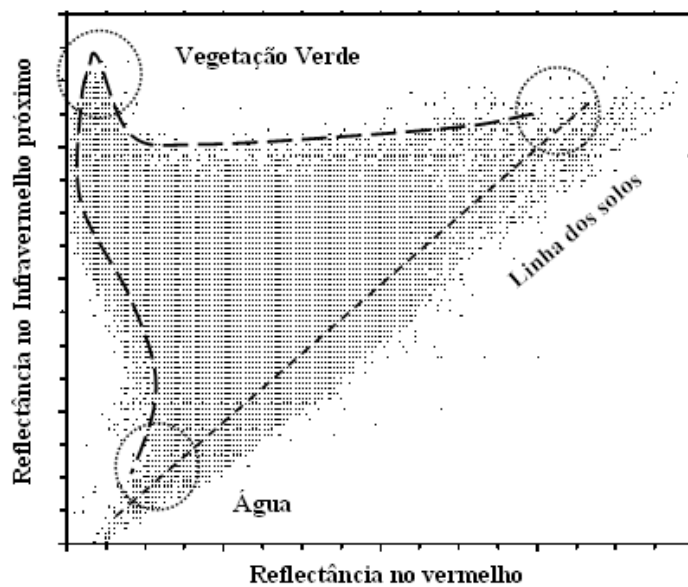


FIGURA 7 Espaço bidimensional de feições.

O modelo linear é o método de regressão para estimar a variação de mistura espectral para cada *pixel* da imagem. Este método utiliza o conceito dos

mínimos quadrados, ou seja, minimizando a soma dos quadrados dos erros para o ajuste dos parâmetros da equação.

A relação linear é usada para representar a mistura espectral dos componentes dentro do *pixel*. Assim, a resposta de cada *pixel*, em qualquer banda espectral, pode ser definida como uma combinação linear das respostas de cada componente, desde que esteja no alvo sensoriado. Desse modo, cada *pixel* da imagem, que pode assumir qualquer valor dentro da escala de cinza, contém informações sobre a proporção e a resposta espectral de cada componente dentro de cada elemento de resolução (Shimabukuru, 1987). O modelo pode ser escrito como:

$$R_1 = a_{11} x_1 + a_{12} x_2 + \dots + a_{1n} x_n + e_1$$

$$R_2 = a_{21} x_1 + a_{22} x_2 + \dots + a_{2n} x_n + e_2$$

$$R_m = a_{m1} x_1 + a_{m2} x_2 + \dots + a_{mn} x_n + e_m$$

ou, reescrevendo,

$$R_i = \sum_{j=1}^n (a_{ij} x_j) + \varepsilon_i$$

em que:

I = 1, ..., m (número de bandas)

J = 1, ..., n (número de componentes, classes, ou materiais)

R_i = reflectância espectral da *i*-ésima banda espectral de um *pixel* contendo um ou mais componentes;

A_{ij} = reflectância espectral conhecida do *j*-ésimo componente no *pixel* para a *i*-ésima banda espectral;

X_j = valor da proporção do j-ésimo componente no *pixel*;

E_i = erro para a i-ésima banda espectral.

Foi aplicado o modelo linear de mistura espectral nas cenas referente ao inverno e ao verão. As aplicações do modelo de mistura visam melhorar as estimativas de áreas obtidas pelos métodos convencionais de classificação, aprimorar as análises das imagens de baixa resolução espacial (*e.g.* Landsat Thematic Mapper – TM -, NOAA AVHRR, etc.) e utilizar as abundâncias de diferentes materiais como parâmetros de entrada para alguns modelos (*i.e.* *land degradation models, crop growth models, hydrologic models, etc.*).

6.4.5 Índice de vegetação

Uma vez que os dados das imagens foram convertidos de números digitais para valores físicos e as séries temporais parametrizadas, pôde-se, então, prosseguir com o conceito de índices de vegetação.

Identificando o comportamento de baixos valores de reflectância das folhas na região espectral referente ao vermelho e altos valores de reflectância na região espectral referente ao infravermelho próximo, é possível caracterizar a ocorrência de dosséis foliares.

O índice de vegetação utilizado será o *Normalized Difference Vegetation Index* (NDVI). Este índice gerado a partir da normalização da diferença das bandas referentes às larguras espectrais do infravermelho próximo NIR e o vermelho R gera, em uma única imagem, o destaque da distribuição de vegetação foliar verde.

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

6.4.6 Índice de cobertura arbórea

Este índice foi processado dentro do sistema de informação geográfica, pela função de análise espacial por agregação, que consiste na contagem dos *pixels* de três metros numa razão de crescimento em 10 vezes, resultando em 30 metros de resolução espacial final.

Os valores presentes neste índice utilizam os resultados da classificação feita nas imagens Ikonos para extrair a informação referente somente à cobertura arbórea. O somatório de cobertura mapeada na imagem de alta resolução de três metros relaciona-se com a dimensão espacial da imagem Landsat de 30 metros.

Os valores de cada *pixel* do índice representam a porcentagem arbórea mapeada, com uma densidade relativa a 900 m² na imagem de média resolução. O processamento deste índice está ilustrado na Figura 8.

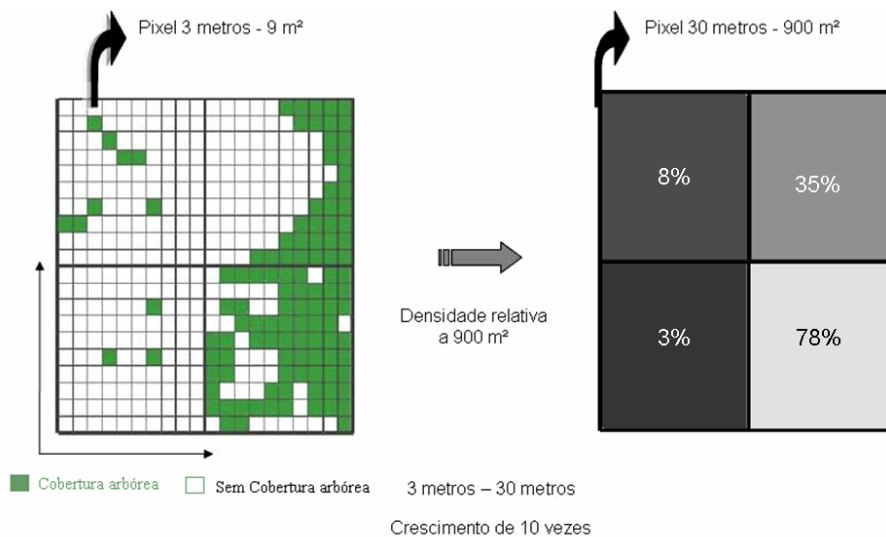


FIGURA 8 Processo da construção do índice de cobertura arbórea por análise espacial de agregação, crescimento da ordem de 10 vezes.

6.5 Caracterização e amostragem para imagens

Para análise da classificação da cobertura arbórea utilizando-se as imagens Ikonos e o algoritmo de árvore de regressão, foram utilizados 450 pontos de controle como verdade de campo, distribuídos nas melhores condições das imagens, sem nuvens e abrangendo uniformemente as classes de ocorrência. Foram coletadas amostras das classes: vegetação, sombra e solo para a classificação supervisionada com uso do algoritmo árvore de classificação, conforme os exemplos na Figura 9.




FIGURA 9 Exemplos das amostras de treinamento, vegetação em vermelho, sombra em preto e solo em branco.

A classe solo caracteriza-se por apresentar uma tonalidade mais clara na imagem e valores mais altos em todas as quatro bandas espectrais. Em campo, podem ser observadas formações de bancos de areias, estradas e áreas desmatadas, entre diversos outros casos.

A classe sombra, diferente da classe solo, apresenta valores baixos em todas as bandas espectrais. Por isso, apresenta coloração escura na imagem. No

campo, pode ser observada a distribuição em áreas em declive, acompanhadas com afloramento de rochas escuras e ou corpos d'água.

A classe vegetação corresponde a valores mais altos na faixa espectral do infravermelho próximo e valores mais baixos na faixa espectral do vermelho. No campo, nesse padrão podem ser encontradas áreas de vegetação com folhas verdes, pois vegetação sem clorofila ou sem folha apresenta padrões diferentes deste comportamento espectral.

Dentre as outras classes, a vegetação foi o objeto de maior interesse para a estimativa da cobertura arbórea. Pôde-se observar, na classificação da vegetação da imagem Ikonos, a identificação de árvores com três metros de estrutura vertical, sendo possível caracterizar árvores e arbustos, como o exemplo da Figura 10.




FIGURA 10 Exemplo da variabilidade no extrato vertical.

A amostragem para o mapeamento das imagens Landsat TM foi realizada por interpretações visuais, utilizando como referência o mapeamento do estado de Minas Gerais (Scolforo & Carvalho, 2006). Foi necessário o agrupamento das duas imagens em um único conjunto, formando um conjunto temporal com total de 14 bandas espectrais. Foi utilizado 20% do total de *pixels* da imagem, para amostragem do classificador por árvore de classificação. Desse

conjunto, metade foi selecionada para amostras de treinamento e a outra metade para amostra de validação.

Foram identificadas as seguintes classes: água, pasto (**AP**), agricultura (**AC**), afloramento rochoso, solo exposto e as formações florestais de savana arborizada (**As**), savana gramíneo-lenhosa (**Sgs**), Floresta Estacional decidual (**FED**), contato savana/Floresta Estacional (**SNe**), Floresta Estacional Semidecidual Aluvial (**Fa**) e formações com influência fluvial e ou lacustre (**Pab**), também chamadas de veredas.

6.5.1 Amostra para o algoritmo árvore de regressão

Foram utilizados dois conjuntos da classificação da cobertura arbórea gerada a partir da imagem de alta resolução espacial, um deles como amostra para o processamento do algoritmo de regressão, total de 104.000 *pixels*. O outro conjunto da classificação armazenado para aferição da validação das estimativas quantitativas e qualitativas do modelo de regressão foi composto por 96.000 *pixels*, o total de 180.00 ha amostrados ou 8,3% da área total (Figura 11).




FIGURA 11 Amostra, em preto, da variável dependente índice de cobertura arbórea, aproximadamente 8% da área total.

Foram utilizadas, como variáveis independentes para a regressão, as bandas espectrais, calibradas e retificadas, das imagens de inverno e verão, referentes às bandas espectrais 1, 2, 3, 4, 5 e 7 do sensor TM.

7 RESULTADOS E DISCUSSÃO

7.1 Correção geométrica das imagens

Para a imagem de inverno, foram utilizados 58 pontos de controles identificados na imagem referência, com aproximação de 0,67 *pixels* de erro, o equivalente a 20,1 metros em campo. Para imagem verão foram utilizados 60 pontos de controle, com aproximação de 0,78 *pixels* de erro, o equivalente a 23,4 metros de erros em campo.

É notável uma menor precisão na imagem referente ao período de verão, uma vez que esta apresenta ocorrência de nuvens e, de maneira geral, apresenta menos contrastes entre os objetos na cena, quando comparados com a imagem de inverno.

Os métodos de correções geométricas resultaram em imagens com erros aceitáveis para o mapeamento da cobertura vegetal na escala de 1:50.000, uma vez que os erros aceitáveis nesta escala são menores que 25 metros ou 0,83 *pixels*, segundo D'Alge (1999).

As imagens Ikonos foram adquiridas com precisão geométrica horizontal de 5 metros de erros, aceitáveis para este tipo de mapeamento.

7.2 Calibração para valores de reflectância

No intuito de reduzir o volume de dados, os valores de reflectância aparente de 32 bits foram truncados em 0,6375 e, posteriormente, multiplicados por 400, para produzir dados em 8 bits novamente (Scolforo & Carvalho, 2006).

Difícilmente alguém é capaz de perceber diferenças entre uma imagem sem calibração de outra com valores calibrados para reflectância (figura 12). Porém, nos gráficos na Figura 13, a diferença nas bandas espectrais 1 e 5 é facilmente compreensível.




FIGURA 12 Área de vereda em uma imagem sem calibração dos números digitais, (a.). Mesma área de vereda em uma imagem com valores calibrados para reflectância, (b.).




FIGURA 13 Imagem sem calibração dos números digitais, (a.). Mesma área em uma imagem com valores calibrados para reflectância, (b.).

Contudo, para uma efetiva caracterização dos objetos em diferentes sensores e em diferentes épocas do ano, devem ser considerados os efeitos causados pela atmosfera.

7.3 Retificação radiométrica da imagem de verão

Após a seleção de objetos claros e escuros como amostra para a retificação radiométrica, foi ajustada uma regressão linear para a nova estimativa dos valores da imagem de verão. Na Tabela 5 são apresentados os valores dos coeficientes de retificação, o valor descritivo do grau de associação (R^2) entre a imagem referente e a imagem estimada e o erro quadrado médio para os ajustes dos modelos utilizados para cada banda espectral.

TABELA 5 Valores dos coeficientes de transformação radiométrica entre as imagens de inverno e verão, os valores do coeficiente de determinação R^2 e o erro quadrado médio EQM dos modelos.

Coeficiente de retificação	Banda 1	Banda 2	Banda 3	Banda 4	Banda 5	Banda 7
m_1	0,8350	0,9431	1,03803	0,76939	1,02706	0,97217
b_2	4,9517	2,8252	4,94016	9,84455	5,49778	8,44524
R^2	92,33	95,91	95,76	96,80	97,02	95,96
EPR	1,7292	3,7056	5,6126	7,3946	9,0658	8,0437

Foram encontrados os coeficientes de retificação bem próximos, quando comparados aos valores obtidos pelo estudo desenvolvido por Shimabukuro et al.(1998), utilizando o mesmo método de retificação. Os valores do erro quadrado médio da estimativa se devem a uma fração não explicada pelo modelo, possivelmente aleatória ou atribuída a mudanças da atmosfera. Devido aos baixos erros dos modelos, a imagem do verão obteve uma boa atenuação dos efeitos da atmosfera e pode ser comparada com a imagem de inverno.

Foram feitas as análises dos objetos registrados entre as duas épocas, inverno e verão, para melhorar a caracterização ou a padronização espectral das amostras para a classificação das fitofisionomias (Figura 14).

A utilização de dados temporais foi suficiente para distinguir, por meio dos ganhos nos valores de reflectância, alvos como a Floresta Estacional Decidual, marcada por forte sazonalidade, de alvos como a Savana, em que a sazonalidade é menos pronunciada.

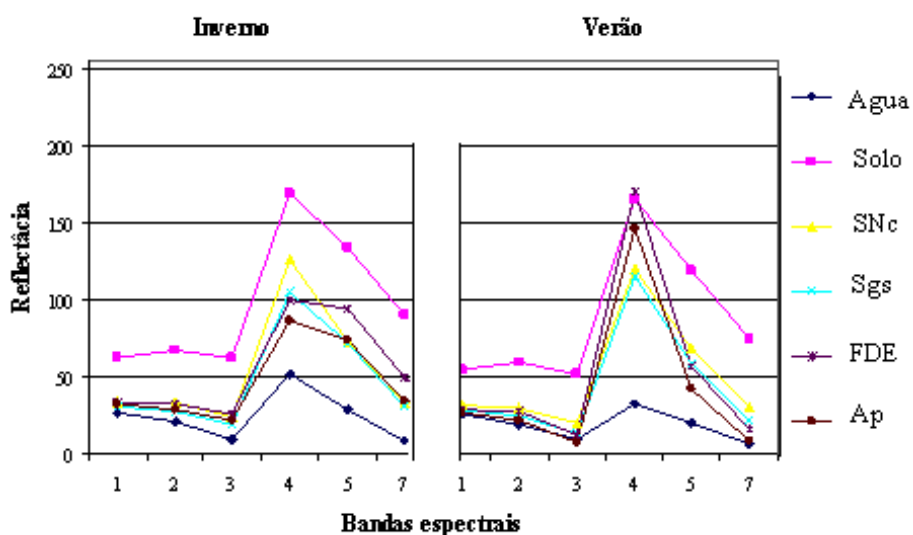


FIGURA 14 Gráfico de comportamento espectral médio dos objetos, em que as seis primeiras bandas são relativas ao inverno e as outras seis restantes, ao verão.

7.4 Acurácia da classificação da imagem Ikonos

A precisão do mapeamento da cobertura arbórea apresentou 86,44% de acurácia global e 0,72 de índice Kappa. Este resultado pode ser verificado na matriz de confusão na Tabela 6. Esta matriz apresenta, em sua diagonal principal, os *pixels* classificados corretamente.



A análise pode ser feita observando-se as linhas; considerando a classe não vegetação, em um total de 205% ou 45,56% dos *pixels* classificados como não vegetação, 183% ou 82,22% realmente pertencem a essa classe e 21% ou 9,25% deste total pertencem a outra classe vegetação. A análise pode ser feita observando-se a coluna; do total dos *pixels* de referência para a vegetação, 206% ou 90,75% pertencem a essa classe e 21% ou 9,25% pertencem a outra classe.

TABELA 6 Matriz de confusão ou matriz de erro, para classificação da variável cobertura arbórea utilizando a imagem Ikonos.

	Não vegetação	Vegetação	Total
Não vegetação	183/82,06%	21/9,25 %	205/45,56%
Vegetação	40/17,94%	206/90,75%	245/54,44%
	223/100%	227/100%	450/100%

A grande dificuldade encontrada nessa classificação foi mapear as árvores com características de perderem as folhas, também encontradas por outros autores (Hansen et al., 2002). Estas árvores não apresentaram as copas evidenciadas, mais foi possível associá-las à sua própria sombra.

É possível observar o resultado da classificação na Figura 15 utilizando-se um subconjunto da imagem Ikonos, em que a imagem (a.) apresenta coloração na composição 1-4-3; a faixa espectral do azul colorido de vermelho, a faixa espectral do infravermelho próximo colorida de verde e a faixa espectral do vermelho colorida de azul e a imagem (b.), sobreposição da classificação da cobertura arbórea na imagem (a.).




 Cobertura arbórea

FIGURA 15 Classificação da cobertura arbórea utilizando-se a imagem Ikonos de 10/09/2006

7.5 Acurácia da classificação das imagens Landsat TM

O resultado encontrado na Figura 16 foi de 92,4% de acurácia global e 0,9145 de coeficiente *Kappa*. A matriz de erro, utilizando 1.000 pontos aleatorizados das amostras de teste para validação da classificação, é mostrada na Tabela 7.

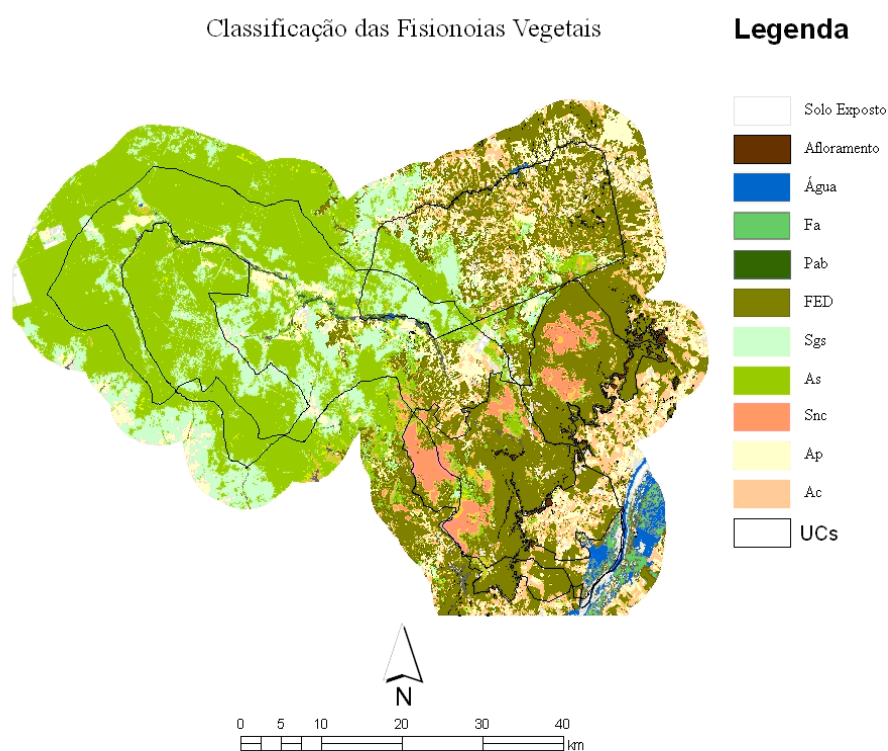


FIGURA 16 Classificação da vegetação da bacia do rio Peruaçu

TABELA 7 Matriz de confusão ou matriz de erro para classificação das fisionomias vegetais utilizando a imagem TM

	Água	FED	As	Ap	SNe	Afl. Roc.	Solo exp.	Fa	Pab	Sgs	Ac	Total
Água	64	0	0	0	0	0	0	1	0	0	0	65
Floresta Estacional Decidual	0	144	3	2	3	0	0	2	2	1	1	158
Savana Arborizada	0	2	169	0	15	2	0	0	8	1	0	197
Pecuária	0	1	0	92	0	0	4	0	0	10	1	108
Contato Savana/Floresta Estacional	0	0	0	0	56	0	0	0	1	0	0	57
Afloramento Rochoso	0	0	0	0	0	98	0	0	0	0	0	98
Solo Exposto	1	0	0	0	0	0	39	0	0	0	0	40
Floresta Estacional Semidecidual Aluvial	0	0	0	0	0	0	0	49	0	0	0	49
Formações com influência fluvial e/ou lacustre	0	0	0	0	0	0	0	0	56	0	0	56
Savana Gramíneo-Lenhosa	0	0	1	7	0	0	0	0	0	93	0	101
Agricultura	0	2	0	5	0	0	0	0	0	0	64	71
Total	65	149	173	106	74	100	43	52	67	105	66	1000

7.6 Resultados da classificação nas unidades de conservação

Na Tabela 8 são apresentados os resultados das proporções das classes da cobertura terrestre mapeadas para cada unidade. O Parque Nacional Cavernas do Peruaçu (**PAQF**) apresentou maior proporção de Floresta Estacional Decidual (FED) e Enclave (SNC). APA Cavernas do Peruaçu (**APAF**) apresentou maior quantidade de área coberta por Savana arborizada (As) e FED. O Parque Estadual Veredas do Peruaçu (**PAQE**) já apresentou predominância de As. A Área Indígena Xacriabá (**AI**) apresentou a maioria de sua área coberta por AS e FED com expressiva ocorrência de pastagens Ap em relação às unidades de conservação.

TABELA 8 Proporção das áreas em % encontradas para cada área de proteção.

PAQF	área %	APAF	área %
Afloramento			
Afloramento Rochoso	2,12	Rochoso	0,24
Água	1,90	Água	0,73
Fa	1,02	Fa	0,39
Solo exposto	0,56	Solo exposto	0,30
Pab	0,02	Pab	0,68
Ac	3,39	Ac	1,88
FED	69,80	FED	30,20
Sgs	1,26	Sgs	9,85
As	3,68	As	49,51
SNC	11,78	SNC	1,25
Ap	4,47	Ap	4,98
	100		100
PAQE	área %	AI	área %
Afloramento			
Afloramento Rochoso	0,00	Rochoso	0,17
Água	0,01	Água	0,06

(...continua...)

TABELA 8, Cont.

Fa	0,00	Fa	0,00
Solo exposto	0,01	Solo exposto	0,14
Pab	0,45	Pab	0,21
Ac	0,00	Ac	1,94
FED	0,01	FED	35,96
Sgs	15,44	Sgs	4,39
As	82,64	As	50,55
SNC	0,02	SNC	0,16
Ap	1,40	Ap	6,42
	100		100

7.7 Imagens NDVI

Para melhorar as características dos objetos, foram utilizadas duas imagens de épocas contrastantes de inverno e verão, devidamente retificadas. Na Tabela 9 é mostrada a diferença do valor médio do NDVI de inverno 2006 para verão 2007, para cada fitofisionomia.

TABELA 9 Diferença de valores médios de NDVI de inverno a verão, para as fisionomias vegetais.

SNC	Ganho em NDVI
média	3,92%
desvio	1,74
FED	
média	13.82%
desvio	2,12
Sgs	
média	3,15%
desvio	1,25
As	
média	0,71%
desvio	1,24

(...continua...)

TABELA 9, Cont.

Ap	
média	5,02%
desvio	4,46
Pab	
média	-1,18%
desvio	3,46

Esta variação quer dizer que, em média, a fitofisionomia SNc apresentou um aumento no valor de NDVI de 3,92% e desvio padrão de 1,74. Porém, na fitofisionomia Pab, houve um decréscimo no valor de NDVI de 1,18% e desvio de 3,46. Este fato pode ser explicado com o aumento do alagamento da Vereda no verão, conseqüentemente maior absorção da radiação solar. Maillard (2007), estudando a mesma Vereda, localizada no rio Peruaçu, concluiu que o período de seca no mês de setembro é a melhor época para a classificação por imagens de satélite.

O maior ganho no valor de NDVI foi o da fitofisionomia FED, uma vez que esta vegetação apresenta deciduidade pronunciada. O maior valor de desvio padrão foi encontrado nas áreas de pastagens AP, devido à heterogeneidade dos pastos encontrados nesta região.

7.8 Imagem fração vegetação

O resultado da imagem fração vegetação foi obtido utilizando-se o modelo linear de mistura espectral. Este resultado apresentou a mesma tendência encontrada pelo índice de vegetação NDVI. No entanto, apresentou valores menos saturados quando comparados aos ganhos de valores de NDVI entre as épocas de inverno e verão.

7.9 Índice de cobertura arbórea

O resultado da imagem de cobertura arbórea foi desenvolvido utilizando-se a análise por agregação espacial, desenvolvida pelo Sistema de Informação Geográfico (SIG). O resultado desta análise consiste no somatório dos *pixels* classificados como árvores, em um total de 900 m², relativos à dimensão de um *pixel* da imagem TM. Smith (2000), utilizando o mesmo método para estimar a cobertura de superfícies impermeáveis em análise *subpixel*, obteve resultados satisfatórios em suas estimativas.

A imagem de cobertura arbórea apresenta variação de 0-100 % em tons de cinza; quanto mais claro o *pixel*, mais próximo de 100% ou maior a área do *pixel* coberta por vegetação arbórea. É possível notar visualmente a relação de similaridade entre as imagens Ikonos e cobertura arbórea, quando se pretende observar a vegetação.

Visualmente, é possível notar as diferenças entre os três índices de vegetação (NDVI, imagem fração e cobertura arbórea) desenvolvidos para esta área. Porém, cada índice, com seus respectivos métodos, expressa a vegetação em valores diferente, sendo um tanto incorretas suas comparações de forma direta.

O NDVI, proveniente da razão de bandas, realça as características da vegetação pela absorvância e reflectância do vermelho e do infravermelho. Este método está intimamente ligado à característica da composição das folhas, sobreposição de camadas de folhas e a arquitetura do dossel. Dessa forma, a relação esperada entre o NDVI e a biomassa, por exemplo, pode não ser identificada para alguns tipos de cobertura vegetal ou ângulo de observação e de iluminação (Shimabukuro & Ponzoni, 2007).

A imagem fração da vegetação, proveniente do modelo linear de mistura espectral, expressa o conceito de proporção de mistura de classes e a resposta espectral em *subpixel*. Porém, esse método segue a mesma tendência de valores

encontrados no NDVI. Portanto, não deve ser utilizado para correlações entre biomassa ou estruturas de diferentes fisionomias.

A imagem índice de cobertura arbórea, por ser um método que utiliza amostras de árvores e arbustos provenientes de uma escala mais detalhada, expressa a cobertura vegetal de árvores em função das características espectrais em duas épocas distintas. Dessa forma, este índice pode corresponder à estrutura horizontal de uma determinada fisionomia e pode ser comparada com outras fitofisionomias. Como este índice expressa uma variável biofísica, a cobertura arbórea, este pode ser utilizado para estimativa da biomassa (Huang et al., 2001; Hansen et al., 2002 e Goetz et al., 2003).

Pela Figura 17 é possível fazer a comparação entre as imagens (a.) de resolução espacial de 3 metros – Ikonos referente ao inverno e as imagens de resolução espacial de 30 metros; (b.) NDVI referente à imagem TM de inverno; (c.) TM coloridas na composição 4-1-3; a faixa espectral do infravermelho próximo colorido de vermelho, a faixa espectral do azul colorida de verde e a faixa espectral do vermelho colorida de azul; (d.) imagem fração vegetação referente à imagem TM de inverno e (e.) imagem índice de cobertura arbórea proveniente do modelo de árvore de regressão.

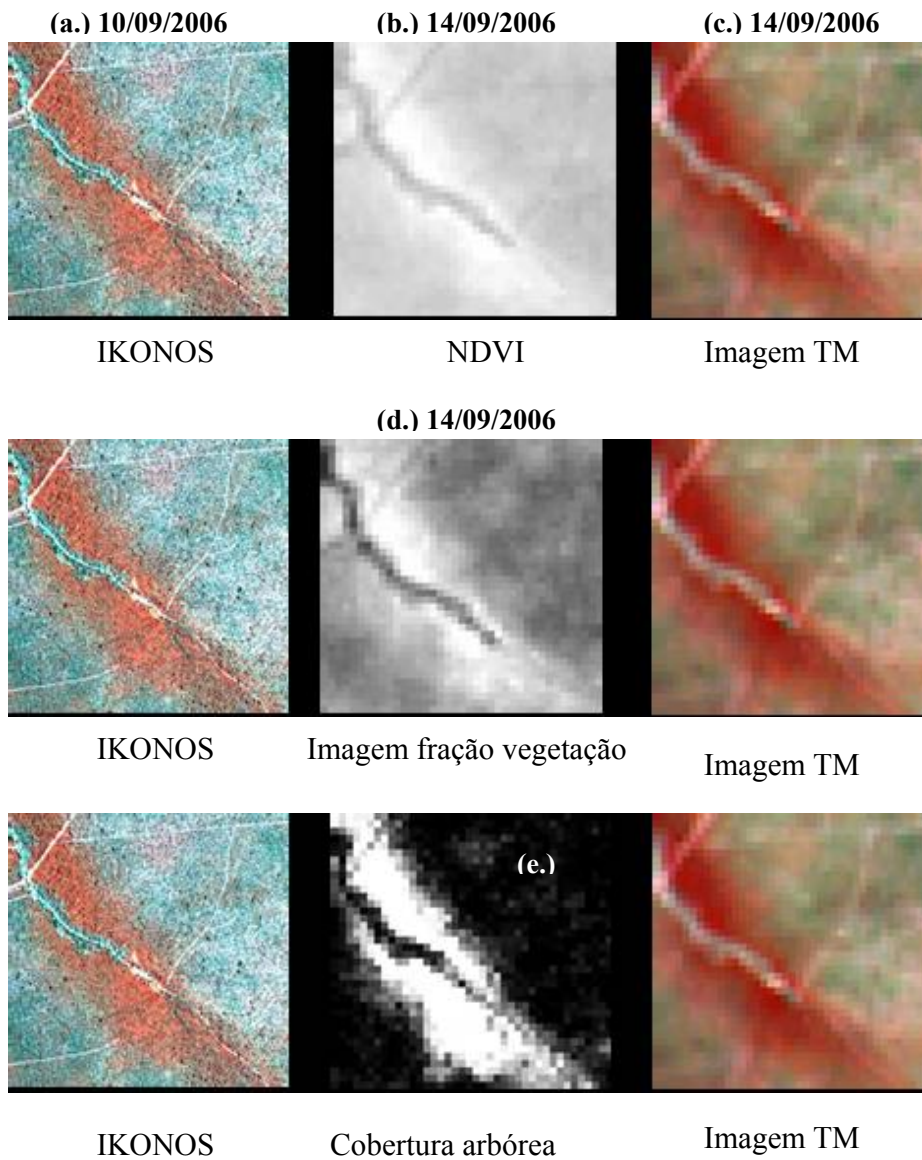


FIGURA 17 Comparação entre as imagens (a.) Ikonos, (b.) NDVI, (c.) imagem TM, (d.) imagem fração vegetação e (e.) cobertura arbórea.

7.10 Validação do modelo de árvore de regressão

A escolha do modelo não paramétrica por árvore de regressão foi feita levando-se em consideração o alto grau de dependência entre as variáveis, uma vez que são utilizados dois sensores diferentes. A heterocedasticidade e o desconhecimento do tipo de distribuição, nas duas épocas, da variável dependente, não cumprem os pressupostos básicos de uma regressão linear.

O modelo de árvore de regressão vem sendo utilizado como uma robusta ferramenta para ajustes de relações não lineares em conjuntos de dados de sensoriamento remoto (Defrie et al., 1997; Smith, 2000; Carvalho, 2001; Huang et al., 2001 e Hansen et al., 2002).

A avaliação do ajuste deste modelo é feita por meio da validação cruzada entre a amostra de referência e a estimativa do modelo. O resultado do coeficiente de correlação da estimativa foi de 0,72 com erro quadrado médio de 14,8%, utilizando conjunto amostral de 95.000 *pixels* aleatorizados.

Trabalho realizado por Hansen et al.(2002), utilizando modelos semelhantes para a estimativa de cobertura arbórea, aplicada em imagens MODIS de 1.000 metros de resolução espacial, apresentou erros médios de 9,06%. Os valores do erro padrão da estimativa se devem a uma fração não explicada pelo modelo, possivelmente aleatória ou atribuída à amostragem insuficiente para caracterizar os casos de ocorrência da cobertura arbórea utilizando seus atributos espectrais.

Outra forma de avaliação do ajuste do modelo pode ser feita utilizando a matriz estatística de erro ilustrada na Tabela 10. Para a utilização desse método, foi necessário agrupar os valores contínuos de 0 a 100 em classes de 33,33% de cobertura, a fim de simplificação das análises. As amostras de teste, devidamente separadas das amostras de treinamento do modelo, foram consideradas como referência de campo para esta avaliação.

TABELA 10 Matriz de confusão ou matriz de erro para estimativa de cobertura arbórea por meio do algoritmo CUBIST.

	0-33	33 - 66	66 - 100	Total
0 - 33	35/68%	5/21,74%	2/9,09%	41/43,16%
33 - 66	15/30%	13/56,52%	5/22,73%	33/34,74%
66 - 100	1/2%	5/21,74%	15/68,18 %	21/22,11%
Total	50/100%	23/100%	22/100%	95/100%

A acurácia global foi de 65,26% e o índice *Kappa* de 0,455. Este resultado, aparentemente, é de baixa qualidade, porém, pode ser observada, na matriz da Tabela 11, a tendência de aproximação dos maiores valores de acerto à diagonal principal. Este método apresenta algumas imperfeições quando utiliza classes, pois existem valores que se encontram próximos aos limites entre as classes. Dessa forma, ocorrem erros de aproximação nesta classificação (Smith 2000). A qualidade do ajuste pode ser interpretada da seguinte forma, quanto mais os valores se aproximam da diagonal principal, melhor a distribuição no ajuste da estimativa.


A acurácia do produtor, na Tabela 16, indica a fração dos *pixels* de referência de determinada classe que foram classificados corretamente. A acurácia do usuário indica a probabilidade de um *pixel* classificado dentro de uma determinada classe realmente pertencer àquela classe checada em campo.

TABELA 11 Acurácia do produtor e do usuário.

	Acurácia do produtor %	Acurácia do usuário %
0-33	68	82,93
33-66	56,52	39,39
66-100	68,18	71,43

Uma forma geral de analisar graficamente a precisão da estimativa do modelo de calibração é observando-se o histograma de frequência, na Figura 18.

O resultado do histograma da estimativa apresenta tendência semelhante na distribuição dos dados, quando comparado com o histograma de frequência dos dados de referência. É visualmente notável, nesta comparação, uma pequena diferença dos valores mais baixos e, nos maiores, forte desvio padrão, o que explica os 14,8% de erro.



(...continua...)

FIGURA 18, Cont.




FIGURA 18 Comparação de histogramas de frequências (a) real e (b) estimado.

7.11 Comparação da cobertura arbórea nos diferentes ecossistemas.

O resultado gerado a partir do modelo de calibração da cobertura arbórea foi utilizado para o cálculo da média de cobertura arbórea de cada classe das fitofisionomias mapeadas anteriormente, como pode ser observado na tabela 12.

TABELA 12 Resultado da média de cobertura arbórea, em % e seus desvios padrões.

SNe	Cobertura arbórea	
	Média	89,23%
	Desvio	11,2
FED		
	Média	88,08%
	Desvio	19,11
Fa **		
	Média	66,62%
	Desvio	19,98
Pab		
	Média	52,43%
	Desvio	22,98
As		
	Média	37,87%
	Desvio	19,7
Afloramento rochoso **		
	Média	34,80%
	Desvio	<u>33,74</u>
Sgs		
	Média	31,64%
	Desvio	20,2
Ap		
	Média	28,58%
	Desvio	21,58

As classes de cobertura Fa e Afloramento rochoso não possuem amostragem. Logo, os valores estimados para este tipo de cobertura não são confiáveis.

Felfili (2001) estudou a biogeografia do bioma Cerrado, considerando o estrato lenhoso do Cerrado ou As variando entre 3-5 metros de altura e cobertura

arbórea de 10% a 60%. Para a fisionomia de Vereda ou Pab de 12 -15 metros de altura, uma cobertura arbórea de 5% e 12%. Para a fisionomia de Cerradão, um dossel de 7 a 20 metros e cobertura igual ou superior a 50%. Para a fisionomia de Campo Cerrado ou Sgs, cobertura arbórea de 10%. Para vegetação Decidual ou FED, com 20 a 30 metros de fuste, 70% a 90 % de cobertura arbórea.

As notáveis diferenças de média e de desvios podem ser compreendidas pelos diferentes métodos de obtenção dos valores de cobertura arbórea e, principalmente, as características intrínsecas aos diferentes sítios fitogeográficos utilizados para cada autor.

Os resultados encontrados neste estudo também podem ser comparados com os resultados observados na Tabela 13, proveniente do produto *Vegetation Continuous Field* (Hansen et al., 2002), os quais foram obtidos por meio de processamento de dados do sensor MODIS, no período de novembro a dezembro de 2001, início da estação chuvosa.

TABELA 13 Valores médios e de desvio padrão de parâmetro biofísico medidos na estação chuvosa das cinco fitofisionomias em análise.


Parâmetros biofísicos	FITOFISIONOMIAS				
	FESD	FED	AS	SP	FP
Cobertura arbórea (%)	55,62+/-10,28	50,70+/-11,01	39,60+/-10,37	25,20+/-9,56	36,85+/-13,13
Cobertura herbácea (%)	44,36+/-10,26	49,3+/-11	59,70+/-10,08	71,66+/-7,29	63,15+/-13,13
Solo exposto (%)	-	-	0,7+/-0,85	3,13+/-3,87	-

FESD = Floresta Estacional semi-decídua; FED = Floresta Estacional decídua; SA Savana Arbórea; SP = Savana Parque; FP = Floresta Pluvial.

As diferenças encontradas entre os resultados obtidos neste estudo, comparados aos resultados obtidos por outros pesquisadores, podem ser explicadas por diversos motivos, como, por exemplo, diferentes métodos de pré-processamento, sensores com resoluções espaciais e espectrais diferentes.

As comparações feitas neste estudo têm o intuito de orientar os parâmetros físicos de cobertura arbórea encontrados nos ecossistemas pertencentes a esta área de estudo.

A utilização das duas formas de classificação, temática e contínua, para a mesma área está ilustrada na Figura 29. Essas duas formas de mapeamento podem auxiliar, por exemplo, na amostragem de inventários florestais em campo, utilizando-se para estratificação da variabilidade da cobertura arbórea para os fragmentos das fitofisionomias.



(...continua...)

FIGURA 19, Cont.



FIGURA 19, Cont.

69




FIGURA 19, Cont.

99



FIGURA 19 Comparação entre as imagens (a) Landsat inverno, (b) mapa temático, (c) mapa contínuo e (d) mapa híbrido.

De acordo com os estudos feitos por Defries et al. (2000), o mapeamento da cobertura arbórea por algoritmos não paramétricos de árvore de regressão apresenta vantagens na classificação ou na representação de valores contínuos da vegetação que não eram incorporados por meio de classificadores paramétricos. Este mapeamento vem sendo utilizado para aplicações relacionadas à conectividade de grandes áreas e como avaliação preliminar da biomassa contabilizada sobre a superfície terrestre.

8 CONCLUSÃO

De acordo com os objetivos propostos neste estudo, dois métodos de mapeamento da cobertura vegetal foram utilizados, um baseado no conceito de classes temáticas fitogeográficas e o outro, conceito de variável contínua de valores da cobertura arbórea. Os resultados gerados pela metodologia desenvolvida neste trabalho contribuem para aprimorar o reconhecimento dos padrões de dois importantes ecossistemas brasileiros, as Florestas Estacionais Deciduais e a Savana, e o complexo contexto na área de transição.

O modelo gerado utiliza imagens Landsat da época de inverno e verão para a estimativa da cobertura arbórea. Tal modelo pode ser utilizado em outras áreas dos mesmos ecossistemas e contribuir para o monitoramento da vegetação em escala de 1:50.000. Aconselha-se utilizar imagens dos mesmos períodos do ano e executar os pré-processamentos necessários. No entanto, devem ser aprimoradas as metodologias que controlem as variações radiométricas em séries temporais de imagens Landsat TM ou de outros sensores, como, por exemplo, o CBERS, satélite com sensor CCD semelhante ao TM.

8.1 Respostas às hipóteses científicas

1. Quais os pré-processamentos necessários para caracterizar formações florestais deciduais utilizando-se imagens temporais?

As aplicações de modelos ambientais que utilizam dados temporais de imagens Landsat TM necessitam de importantes pré-processamentos, principalmente as correções geométricas, a calibração e a retificação radiométrica. Ainda assim, outros pré-processamentos são necessários, tal como a remoção de nuvens. As imagens temporais, em diferentes épocas do ano, são

essenciais para classificar o padrão de formações florestais estacionais decíduais e semidecíduais. De fato, quanto mais imagens ao longo do ano, devidamente pré-processadas, melhor a caracterização da vegetação.

2. O resultado do índice de densidade de cobertura arbórea apresenta diferenças quando comparado com os índices NDVI e imagens fração do modelo linear de mistura espectral?

Uma vez que os índices são provenientes de métodos de processamento diferentes, eles não devem ser diretamente comparados. Visualmente, esses índices são claramente diferenciados. O índice de cobertura arbórea, diferentemente dos outros dois, apresenta resultados que podem ser associados com valores biofísicos, tal como biomassa. Mas, ainda são necessários outros estudos desta natureza que utilizem medições de variáveis quantitativas de campo, para correlacionarem com a variável cobertura arbórea.

3. É possível determinar a precisão do modelo não paramétrico de árvore de regressão?

A utilização dos dados da variável cobertura arbórea, agrupados em 33,33% de cobertura arbórea, na matriz de erro, foi o mais apropriado para determinar a precisão e as falhas do modelo desenvolvido.

4. É possível caracterizar diferentes ecossistemas dos domínios de Savanas e Florestas Estacionais Decíduais e em sua área de transição, utilizando a variabilidade da cobertura arbórea?

Foi possível inferir sobre parâmetros populacionais de média e desvio padrão da cobertura arbórea nos diferentes ecossistemas, a partir da combinação de dados contínuos, provenientes do modelo de árvore de regressão e dados temáticos, provenientes do modelo de árvore de classificação.

Conclui-se que esta análise *subpixel*, utilizando diferentes sensores, pode ser promissora no monitoramento da vegetação e na geração de variáveis contínuas, utilizadas em modelos ambientais mais complexos. Tais modelos podem auxiliar nos estudos do monitoramento da regeneração natural de ecossistemas degradados, podem auxiliar em estudos de quantificação da biomassa e fixação de carbono e podem auxiliar estudos de fragmentação de habitat na paisagem, dentre outras aplicações ambientais de grandes extensões.

9 REFERÊNCIAS BIBLIOGRÁFICAS

AGUIAR, A.P.D. **Utilização de atributos derivados proporções de classes dentro de um elemento de resolução de imagens (“pixel”) na classificação multiespectral de imagens de sensoriamento remoto.** 1991. 227p. Dissertação (Mestrado em Sensoriamento Remoto e Aplicações) - Instituto de Pesquisa Espaciais, São José dos Campos.

ALENCAR-SILVA, T.; MAILLARD, P. Delimitação e caracterização do ambiente de Vereda: II. O potencial das imagens ópticas ASTER. In: SIMPOSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** Florianópolis: SBSR/INPE, 2007. p.1733-1740.

BARET, F.; CLEVERS, J.G.P.W.; STEVEN, M.D. The robustness of canopy gap fraction estimates from red and near-infrared reflectances: a comparison of approaches. **Remote Sensing of Environment**, New York, v.54, n.2, p.141-151, 1995.

BURROUGH, P.A.; MCDONNELL, R.A. **Principle of geographic information systems.** Oxford: Clarendon, 1998. 333p.

CÂMERA, G.; MEDEIROS, J.S. Modelagem de dados em geoprocessamento. In: ASSAD, E.D.; SANO, E.E. **Sistema de informação geográficas: aplicações na agricultura.** 2.ed. Brasília, DF: Embrapa, 1998. cap.4, p.59-64.

CARVALHO, L.M.T. **Mapping and monitoring forest remnants: a multi-scale analysis of spatio-temporal data.** 2001. 140p. Thesis (Doctor in Forestry Engineering)-Wageningen University, Wageningen.

CARVALHO, L.M.T. **Sistemas de informações geográficas e sensoriamento remoto dos recursos florestais.** Lavras: UFLA/FAEPE, 2005. 109p. Apostila.

COELHO, P.S.S. **Um sistema para indução de modelos de predição baseados em árvores.** 2005. 252p. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal do Rio de Janeiro, Rio de Janeiro.

CORREIA, V.R.M. **Estudo das medidas de qualidade para estimação de proporções de classes em elementos de resolução de imagens.** 1982. 118p. Dissertação (Mestrado em Sensoriamento Remoto)-Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

COUTINHO, V.C. **Data mining**. Brasília, DF: DwBrasil, 2003. Disponível em: <<http://www.dwbrasil.com.br/html/dmining.html>>. Acesso em: 13 set. 2005.

D'ALGE, J.C.L. **Precisão de registro de imagens digitais**. São José dos Campos: INPE, 1999.

DEFRIES, R.S.; HANSEN, M.C.; TOWNSHEND, J.R.G. Global continuous fields of vegetation characteristics: a linear mixture model applied to multi-year 8km AVHRR data. **International Journal of Remote Sensing**, Basingstoke, v.21, n.6/7, p.1389-1414, 2000.

DETER. **Detecção de desmatamento em tempo real**. São José dos Campos: INPE, 2007. Disponível em: <<http://www.obt.inpe.br/deter/>>. Acesso em: 26 nov. 2007.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA.
Monitoramento por satélite. Brasília, DF: Ministério da Agricultura, Pecuária e Abastecimento, 2007. Disponível em: <<http://www.cnpm.embrapa.br/>>. Acesso em: 26 nov. 2007.

FELFILI, J.M.; SILVA, M.C.J. **Biogeografia do bioma cerrado**: estudo fitofisionômico da Chapada do Espigão Mestre do São Francisco. Brasília, DF: UnB/MMA, 2001. 152p.

FERREIRA, M.E.; FERREIRA, L.G.; SANO, E.E.; SHIMABUKURO, Y.E. Uso do modelo linear de mistura espectral para o mapeamento sistemático e operacional do bioma cerrado: possibilidades, implicações e procedimentos metodológicos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte. **Anais...** Belo Horizonte: SBSR/INPE, 2003. p.657-664.

FIGUEIREDO, S.M. de M. **Comparação entre técnicas de classificação digital em imagens landsat no mapeamento do uso e ocupação do solo em capixaba, Acre**. 2005. 127p. Dissertação (Mestrado em Engenharia Florestal)- Universidade Federal de Lavras, Lavras.

FOODY, G.M.; DOAN, H.T.X. Variability in soft classification prediction and its implications for sub-pixel scale change detection and super-resolution mapping. **Photogrammetric Engineering and Remote Sensing**, Falls Church, v.73, p.923-933, 2007.

GOETZ, S.J.; WRIGHT, R.K.; SMITH, A.J.; ZINECKER, E.; SCHAUB, E. Ikonos imagery for resource management: tree cover, impervious surface, and riparian buffer analyses in the mid-Atlantic region. **Remote Sensing of Environment**, New York, v.88, p.195-208, 2003.

HALL, F.G.; STREBEL, D.E.; NICKESON, J.E.; GOETZ, S.J. Radiometric rectification: toward a common radiometric response among multirate, multisensor images. **Remote Sensing of Environment**, New York, v.35, p.11-27, 1991.

HANSEN, M.C.; DEFRIES, R.S.; TOWNSHEND, J.R.G.; SOHLBERG, R.; DIMICELI, C.; CARROLL, M. Towards an operational MODIS continuous field of percent tree cover algorithm: example using AVHRR and MODIS data. **Remote Sensing of Environment**, New York, v.83, p.303-319, 2002.

HUANG, C.; TOWNSHEND, J.R.G. A stepwise regression tree for nonlinear approximation: applications to estimating subpixel land cover. **International Journal of Remote Sensing**, Maryland, v.24, n.1, p.75-90, 2003.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Ecosistemas brasileiros**. Rio de Janeiro, 2004. Disponível em: <<http://www.ibge.gov.br/cidadesats>>. Acesso em: 7 jun. 2005.

INSTITUTO BRASILEIRO DO MEIO AMBIENTE E DOS RECURSOS RENOVÁVEIS. **O Brasil município por município**. Brasília, 2007. Disponível em: <<http://www.ibama.gov.br/ecossistemas/projetosCerrado>>. Acesso em: 28 nov. 2007.

IVERSON, L.R.; COOK, E.A.; GRAHAM, R.L. A technique for extrapolating and validating forest cover across large regions: calibrating. **International Journal of Remote Sensing**, v.10, n.11, p.1805-1812, 1989.

JONG, S.M.; MEER, F.D. van der. **Remote sensing image analysis including the spatial domain**: remote sensing and digital image processing. Herdcover: Kluwer Academic, 2004. v.5.

LIU, X.; STRAHLER, A.H. Geometric optical bidirectional reflectance modeling of the discrete crown vegetation canopy: effects of crown shape and mutual shadowing. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v.30, n.2, p.276-292, 1992.

MACHADO, R.B.; RAMOS NETO, M.B.; HARRIS, M.B.; LOURIVAL, R.; AGUIAR, L.M.S. Análise de lacunas de proteção da biodiversidade de cerrado. In: CONGRESSO BRASILEIRO DE UNIDADE DE CONSERVAÇÃO, 1., 2004, Curitiba, PR. **Anais...** Curitiba: Fundação O Boticário de Proteção à Natureza; Rede Nacional Pró Unidades de Conservação, 2004. 224p.

MARKHAM, B.L.; BARKER, J.L. Radiometric properties of U.S. processes Landsat MSS data. **Remote Sensing of Environment**, New York, v.17, p.39-71, 1987.

MASELLI, F. Estimation of forest parameters through fuzzy classification of TM data. **Geoscience and Remote Sensing, IEEE Transactions on Geoscience and Remote Sensing**, New York, v.33, n.1, p.77-84, 1995.

MOREIRA, M.A. **Fundamentos do sensoriamento remoto e metodologia de aplicações**. São José dos Campos: INPE, 2001. 250p.

NASA LANDSAT PROGRAM. **Landsat ETM+ scene L71008058_05820031026, SLC-Off, USGS**. Sioux Falls, 2003. Disponível em: <<http://glcf.umd.edu/data/landsat/>>. Acesso em: 30 nov. 2007.

NOVO, E.M.L. de M. **Sensoriamento remoto: princípios e aplicações**. 2.ed. São Paulo: E. Blucher, 1998. 308p.

PONZONI, F.J.; SHIMABUKURO, Y.E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos: A.S. Vieira, 2007. 127p.

PRODES. **Monitoramento da floresta Amazônica Brasileira por satélite**. Brasília, DF: Ministério da Ciência e Tecnologia, 2007. Disponível em: <<http://www.obt.inpe.br/prodes/>>. Acesso em: 28 nov. 2007.

QUILAN, J.R. Induction of decision trees. **Machine Learning**, Dordrecht, v.1, p.81-106, 1986.

RADAMBRASIL. **Geologia geomorfologia, pedologia, vegetação e uso potencial da terra**. Rio de Janeiro: Ministério das Minas e Energia, 1982. 660p.

RICHARD, D.O.; PETER, H.E.; DAVID, S.G. **Pattern classification**. 2.ed. Ottawa: J. Wiley, 2001. 654p.

ROCHA, C.H.B. **Geoprocessamento: tecnologia transdisciplinar**. 2.ed. rev. e ampl. Juiz de Fora: Edição do Autor, 2000. 220p.

SCOLFORO, J.R.; CARVALHO, L.M.T. **Mapeamento e inventário da flora nativa e dos reflorestamentos de Minas Gerais**. Lavras: UFLA, 2006. 288p.

SHIMABUKURO, Y.E. **Shade images derived from linear mixing models of multispectral measurements of forested areas**. 1987. 177f. Thesis (Doctor of Philosophy)-Colorado State University, Fort Collins.

SHIMABUKURO, Y.E.; NOVO, E.M.; PONZONI, F.J. Índice de vegetação e modelo linear de mistura espectral no monitoramento da região do pantanal. **Pesquisa Agropecuária Brasileira**, Brasília, v.33, p.1729-1737, out. 1998. Número especial.

SILVA, A. de B. **Sistema de informações geo-referenciadas: conceitos e fundamentos**. Campinas: Unicamp, 2003. 236p.

SILVA, J.M.C. da. **O conceito de hotspots como base para definição de áreas prioritárias para conservação: unidade de conservação: atualidades e tendências 2004**. Curitiba: Fundação O Boticário de Proteção a Natureza, 2004. 208p.

SMITH, A.J. **Subpixel estimation of impervious surface cover using Landsat TM Imagery**. College Park: Geography Department University of Maryland, 2000. 28p.

TSO, B.; MATHER, P.M. **Classification methods for remotely sensed data**. New York: Taylor & Francis, 2001. 332p.

VALERIANO, D. de M.; SHIMABUKURO, Y.E.; DUARTE, V.; ANDERSON, L.O.; ESPÍRITO-SANTO, F.; ARAI, E.; MAURANO, L.E.; SOUZA, R.C. de; FREITAS, R.M. de; AULICINO, L. Detecção do desflorestamento da Amazônia Legal em tempo real: projeto DETER. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. **Anais...** São José dos Capôs: INPE, 2005. p.3403-3409.

VELOSO, H.P.; RANGEL FILHO, A.L.R.; LIMA, J.C.A. **Classificação da vegetação brasileira adaptada a um sistema universal**. Rio de Janeiro: IBGE, 1991. 124p.

ZHU, Z.; EVANS, D.L. US forest types and predicted percent forest cover from AVHRR data. **Photogrammetric Engineering & Remote Sensing**, Falls Church, v.60, n.5, p.525-531, 1994.

ANEXOS

FIGURA 1A Imagem NDVI referente ao verão 2007.

FIGURA 1B Imagem fração vegetação referente ao inverno de 2006.

FIGURA 1C Imagem fração vegetação referente ao verão de 2007.

FIGURA 1D Imagem índice de cobertura arbórea referente ao inverno de 2006 e ao verão de 2007, simultaneamente.

FIGURA 1D Mapa híbrido de classes temáticas e valores contínuos de cobertura arbórea.

77

