

UNIVERSIDADE FEDERAL DE ALFENAS - UNIFAL-MG

DIEGO GOMES DE SOUSA

**ANÁLISE MULTITEMPORAL DO USO DA TERRA E DA COBERTURA VEGETAL
NA REGIÃO DE ALFENAS - SUL DE MINAS GERAIS, UTILIZANDO IMAGENS
LANDSAT-5 TM**

ALFENAS/MG

2014

DIEGO GOMES DE SOUSA

**ANÁLISE MULTITEMPORAL DO USO DA TERRA E DA COBERTURA VEGETAL
NA REGIÃO DE ALFENAS - SUL DE MINAS GERAIS, UTILIZANDO IMAGENS
LANDSAT-5 TM**

Dissertação apresentada como parte dos requisitos para obtenção do título de Mestre em Ecologia e Tecnologia Ambiental pela Universidade Federal de Alfenas/UNIFAL-MG. Área de Concentração: Meio Ambiente, Sociedade e Diversidade Biológica.

Orientador: Prof. Dr. Fernando Shinji Kawakubo.

ALFENAS/MG

2014

Sousa, Diego Gomes de.

Análise multitemporal do uso da terra e da cobertura vegetal na região de Alfenas - Sul de Minas Gerais, utilizando imagens Landsat-5 TM / Diego Gomes de Sousa. - Alfenas, 2014.

77 f. -

Orientador: Fernando Shinji Kawakubo

Dissertação (Mestrado em Ecologia e Tecnologia Ambiental) - Universidade Federal de Alfenas, Alfenas, MG, 2014.

Bibliografia.

1. Sensoriamento remoto. 2. Mineração de Dados. 3. Imagens de Satélites. 4. Geoprocessamento. I. Kawakubo, Fernando Shinji. II. Título.

CDD: 621.3678



MINISTÉRIO DA EDUCAÇÃO
Universidade Federal de Alfenas / UNIFAL-MG
Programa de Pós-graduação – Ecologia e Tecnologia Ambiental

Rua Gabriel Monteiro da Silva, 700. Alfenas - MG CEP 37130-000
Fone: (35) 3299-1419 (Coordenação) / (35) 3299-1392 (Secretaria)
www.unifal-mg.edu.br/ppgecoambiental/




DIEGO GOMES DE SOUZA

**“ANÁLISE MULTITEMPORAL DO USO DA TERRA E DA COBERTURA
VEGETAL NA REGIÃO DE ALFENAS – SUL DE MINAS GERAIS, UTILIZANDO
IMAGENS LANDSAT-5 TM.”**

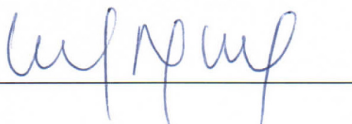
A Banca examinadora, abaixo assinada, aprova a Dissertação apresentada como parte dos requisitos para a obtenção do título de Mestre em Ecologia e Tecnologia Ambiental pela Universidade Federal de Alfenas. Área de Pesquisa: Meio Ambiente, Sociedade e Diversidade Biológica.

Aprovado em: 25 de agosto de 2014.

Prof. Dr. Fernando Shinji Kawakubo
Instituição: UNIFAL-MG

Assinatura: 

Prof. Dr. Marcos Roberto Martines
Instituição: UFSCar-Sorocaba

Assinatura: 

Prof. Dr. Ronaldo Luiz Mincato
Instituição: UNIFAL-MG

Assinatura: 

Dedico a Deus, à família,
amigos e em especial
à Ana Clara.

AGRADECIMENTOS

À FAPEMIG, pela bolsa de estudo.

À Universidade Federal de Alfenas - MG e ao Programa de Pós-Graduação em Ecologia e Tecnologia Ambiental, pela oportunidade.

Ao Prof. Dr. Fernando Shinji Kawakubo, pela paciência, confiança, parceria e orientação.

Ao Prof. Dr. Ronaldo Luiz Mincato, pelo apoio, prestatividade e recomendações.

À Prof. Dra. Rúbia Gomes Morato, pelas recomendações.

Ao grupo de Grupo de Pesquisa ECOFRAG, em especial ao Prof. Dr. Flávio Nunes Ramos, pelo acolhimento e apoio.

Aos companheiros de jornada e de laboratório: Rodrigo Cesário Justino, Diogo Olivetti, Joaquim Ernesto Bernardes Ayer, André dos Santos Ribeiro, pela disponibilidade, companheirismo e amizade.

Ao técnico do laboratório de Geoprocessamento Cochise Libanio, pela disponibilidade.

RESUMO

Vários estudos têm mostrado que fragmentos florestais rodeados por diferentes matrizes sofrem diferentes pressões ecológicas sobre a fauna e flora. A luz disto, o presente estudo objetivou avaliar as mudanças no uso da terra e cobertura vegetal na região de Alfenas, sul do estado de Minas Gerais, focando na conservação de fragmentos florestais. Foram utilizadas as bandas 1 a 5 e 7 das imagens do satélite Landsat-5 Thematic Mapper (TM) dos anos de 1987 e 2011. A classificação das imagens foi realizada utilizando o aplicativo Geographic Data Mining Analyst (GeoDMA), um pacote especialmente voltado para mineração de dados espaciais. Os seguintes procedimentos foram adotados para a realização do estudo: segmentação das imagens; extração de atributos espectrais e espaciais; amostragem; geração da árvore de decisão; classificação; edição dos erros e análise das mudanças por meio de uma matriz de detecção de mudanças. Os resultados mostraram a importância da complementaridade das informações disponíveis em cada banda para a classificação do uso da terra e cobertura vegetal. Com relação as mudanças no uso, observou-se um aumento das classes cana-de-açúcar, café e solo exposto em áreas antes utilizadas para pastagem. Estas informações são importantes nos estudos de ecologia da paisagem, pois podem auxiliar na interpretação da dinâmica ecológica dos fragmentos florestais.

Palavras-chave: segmentação. mineração de dados. árvore de decisão. GeoDMA. detecção de mudanças.

ABSTRACT

Several studies have shown that native forest fragments surrounded by different land-use matrixes undergo different ecological pressures on fauna and flora. In light this, we studied the land-use and land-cover changes in the region of Alfenas, southern Minas Gerais state, aiming the conservation of forest fragments. Landsat-5 Thematic Mapper (TM) images, bands 1 to 5 and 7, from 1987 and 2011, were used. Image classification was achieved using the Geographic Data Mining Analyst (GeoDMA), a toolbox specially addressed for spatial data mining. To carry out this investigation, the following procedures were adopted: image segmentation, spectral and spatial features extraction, sampling, decision tree generation, classification, error edition, and analysis of land-use and land-cover changes by using a change detection matrix. The results showed the importance of complementarity of information available in each band for classifying different land use and land cover types. As for land use change, an increase of sugar cane, coffee and bare soil were registered on previously areas used for pasture. Such information are important, since they may support interpretations of ecological dynamics of forest fragments.

Keywords: segmentation. data mining. decision tree. GeoDMA. change detection.

LISTA DE FIGURAS

FIGURA 1 - CRONOLOGIA DOS SATÉLITES DA SÉRIE LANDSAT.....	18
FIGURA 2 - COMPARAÇÃO ENTRE BANDAS DO LANDSAT-8 E LANDSAT-7.....	20
FIGURA 3 - DIGITAL NUMBER.....	23
FIGURA 4 - ERRO "SKEW"	24
FIGURA 5 - DISTORÇÕES GEOMÉTRICAS PRESENTES EM IMAGENS DE SR	25
FIGURA 6 - CLASSIFICAÇÃO SUPERVISIONADA E NÃO-SUPERVISIONADA.....	29
FIGURA 7 - CRESCIMENTO DE REGIÕES.....	32
FIGURA 8 - GEODMA - PRINCIPAIS ETAPAS.....	33
FIGURA 9 - INTERFACE GEODMA COM AS ABORDAGENS DE SEGMENTAÇÃO.....	34
FIGURA 10 - DIAGRAMA DE EXTRAÇÃO DE CARACTERÍSTICAS	34
FIGURA 11 - SEGMENTAÇÃO	35
FIGURA 12 - FLUXOGRAMA.....	36
FIGURA 13 - LOCALIZAÇÃO DA ÁREA DE ESTUDO	37
FIGURA 14 - GEORREFERENCIAMENTO	40
FIGURA 15 - ÁRVORE DE DECISÃO DA IMAGEM LANDSAT-5 TM DE 09/08/1987.....	44
FIGURA 16 - ÁRVORE DE DECISÃO DA IMAGEM LANDSAT-5 TM DE 27/08/2011.....	46
FIGURA 17 - MAPAS FINAIS DE USO E OCUPAÇÃO DO SOLO.....	48
FIGURA 18 - MAPA DE MUDANÇAS.....	49

LISTA DE TABELAS

TABELA 1 - INTERVALOS DE OPERAÇÃO DAS BANDAS ESPECTRAIS DO SATÉLITE LANDSAT 5 - TM	21
TABELA 2 - COMPARAÇÃO ENTRE MÉTODOS DE INTERPOLAÇÃO	27
TABELA 3 - DESCRIÇÃO DAS IMAGENS LANDSAT UTILIZADAS.....	39

SUMÁRIO

1	INTRODUÇÃO	12
2	OBJETIVOS	16
2.1	OBJETIVO GERAL.....	16
2.2	OBJETIVOS ESPECÍFICOS.....	16
3	JUSTIFICATIVAS	17
4	REVISÃO BIBLIOGRÁFICA	18
4.1	SATÉLITE LANDSAT	18
4.2	LANDSAT-5 TM	20
4.3	PROCESSAMENTO DIGITAL DE IMAGENS	22
4.4	CORREÇÃO GEOMÉTRICA	24
4.5	REALCE	28
4.6	CLASSIFICAÇÃO	28
4.7	SEGMENTAÇÃO	30
4.8	MINERAÇÃO DE DADOS	32
5	METODOLOGIA	36
5.1	ÁREA DE ESTUDO	36
5.2	IMAGENS LANDSAT-5 TM	38
5.3	CORREÇÃO GEOMÉTRICA	39

5.4	SEGMENTAÇÃO E EXTRAÇÃO DE ATRIBUTOS.....	40
5.5	MINERAÇÃO DE DADOS	41
5.6	EDIÇÃO DE ERROS.....	42
5.7	MATRIZ DE DETECÇÃO DE MUDANÇAS.....	42
6	RESULTADOS E DISCUSSÃO.....	44
7	CONCLUSÕES	50
	REFERÊNCIAS	51
	APÊNDICE.....	60

1 INTRODUÇÃO

Originalmente, a Floresta Tropical Atlântica cobria grande parte do território brasileiro e quase completamente a região Sudeste, sendo conhecida por possuir elevados índices de riqueza de espécies e taxas de endemismo (fauna e flora). Com o passar dos anos, em decorrência do desenvolvimento antrópico, a Mata Atlântica passou a sofrer com o desmatamento voltado a agricultura (ALMEIDA et al. 2010). O sul de Minas Gerais apresenta diversos remanescentes florestais imersos em matrizes agrícolas distintas, como café, cana-de-açúcar e pastagens. A fragmentação florestal pode ser entendida como a subdivisão e isolamento de pequenos trechos de vegetação original contínua. Com o avanço tecnológico, novas técnicas de cultivo agrícola vêm sendo desenvolvidas, acarretando grande prejuízo para os ecossistemas. Muitas espécies nativas necessitam de condições bióticas e abióticas específicas para sua manutenção, e o processo de fragmentação pode resultar em grandes perdas para a biodiversidade, como: aumento na taxa de endogamia, mudanças no microclima, dificuldade de dispersão e polinização de sementes, perda de variabilidade genética, entre outras (VIDAL et al. 2007; ZANELLA, 2011; GARMENDIA et al. 2013; KURTEN, 2013).

Qualquer esforço na tentativa de conservação de fragmentos é válido, e informações sobre o uso do solo ao longo de anos podem fornecer novas maneiras de entender a evolução da paisagem, bem como a dinâmica evolutiva de seu entorno. O sensoriamento remoto (SR) é uma ferramenta essencial de apoio às análises de uso e ocupação do solo, facilitando a identificação de elementos componentes da paisagem e complementando informações disponíveis sobre os recursos ambientais. A tecnologia do SR permite a obtenção de informações da paisagem com rapidez, periodicidade, contemplando grandes áreas, a baixo custo e em faixas do espectro eletromagnético inacessíveis a visão humana (CALDERANO FILHO et al. 2009).

Desde a década de 1970, imagens do satélite Landsat têm sido utilizadas como subsídio a pesquisas relacionadas ao mapeamento do uso do solo e cobertura vegetal, pesquisas de prospecção mineral e planejamento territorial. Atualmente, existem várias aplicações utilizando as imagens do Landsat, como por exemplo: monitoramento de qualidade da água (PRADO; NOVO, 2007), recarga de aquíferos (ALBHAISI et al. 2013), mudanças

climáticas (VIEIRA et al. 2013), recessão e movimento de geleiras (JOAQUIM et al. 2011; AHLERT; SIMÕES, 2009), diversidade de espécies (ROCHA, 2007), saúde dos recifes de corais (RUDORFF; GHERARDI, 2008), tipos de uso do solo (FUJACO; LEITE; MESSIAS, 2010), taxas de desmatamento (PHUA et al. 2008) e gestão de recursos agrônômicos e florestais (SHIMABUKURO; MAEDA; FORMAGGIO, 2009). Os dados do Landsat também auxiliam na avaliação de danos causados por desastres naturais (ROBERTSON; CASTIBLANCO, 2011; SANTOS; LINGNAU, 2013), como incêndios (ÁNGEL; ACEVEDO, 2012; PEREIRA et al. 2012), inundações, assoreamento de corpos d'água (LOPES et al. 2013), assim como para os planos de socorro e programas de controle de eventualidades, como infestação de insetos (GOODWIN et al. 2008), entre outros.

Tradicionalmente o mapeamento do uso da terra é realizado de maneira visual baseando-se nos elementos de reconhecimento da fotointerpretação. Por meio do recurso da fotointerpretação, o analista é capaz de identificar os diferentes tipos de usos e coberturas vegetais presentes na fotografia aérea ou cena imageada analisando os elementos associados aos alvos como a cor, tonalidade, tamanho, forma, textura, padrão, contexto, presença de sombra, etc. (CERON; DINIZ, 1966).

Os elementos cor e tonalidade remetem as propriedades espectrais dos objetos. Já os elementos de tamanho, forma, padrão e contexto fornecem informações valiosas a respeito das propriedades espaciais dos objetos. Assim, alvos naturais como manchas de mata nativa possuem, geralmente, formas irregulares e tamanhos variados enquanto alvos antrópicos como campos de agricultura possuem formas geométricas e tamanhos mais definidos. A textura é outro elemento importante que juntamente com a presença de sombra permite diferenciar os alvos utilizando as informações de rugosidade e de altura das classes analisadas (CERON; DINIZ, 1966).

Apesar da fotointerpretação gerar resultados consideravelmente satisfatórios, tal metodologia adota critérios bastante subjetivos no processo de decisão, além de exigir bastante tempo na sua execução, o que encarece o custo do mapeamento e do monitoramento das mudanças na paisagem. As técnicas de classificação digital de imagens de satélites têm se sofisticado ao longo dos anos com significativas melhorias no processo de reconhecimento de padrões de uso da terra e cobertura vegetal. Dentre as vantagens da classificação digital pode-se citar a rapidez com que o mapeamento é

realizado, redução da subjetividade no processo de decisão, além da possibilidade de armazenamento da informação em bases digitais que podem ser integradas com outras informações em um Sistema de Informação Geográfica (SIG), entre outros.

Um dos métodos mais utilizados no mapeamento do uso da terra é a classificação pixel a pixel pela máxima verossimilhança (Maxver), onde amostras de treinamento são selecionadas e modelos probabilísticos definidos para cada classe com base em uma suposição de distribuição normal das amostras. Apesar do classificador Maxver gerar resultados muitas vezes adequados aos objetivos pretendidos, erros de confusão de classes são comuns neste tipo de abordagem. Tal resultado se deve, em parte, ao classificador adotar parâmetros limitados no processo de decisão, considerando apenas os atributos espectrais das amostras. Outros parâmetros espaciais e texturais explorados na fotointerpretação não são utilizados nesta classificação (DRONOVA et al. 2012).

Uma das abordagens mais promissoras atualmente é a classificação de imagens orientada a objeto. A classificação orientada a objeto tem como unidade de análise grupos de pixels delimitados por segmentos - ao invés de pixels isolados como feita na classificação tradicional. Esses segmentos geralmente incorporam um amplo conjunto de informações que inclui atributos espectrais, texturais e espaciais (BLASCHKE, 2010) que são usados para treinar ou construir uma base de conhecimento para a classificação de imagens (KAWAKUBO et al. 2009; KAWAKUBO et al. 2013).

Na classificação orientada a objetos, a construção do modelo de interpretação de uma imagem (base do conhecimento) é a fase mais importante e uma das mais difíceis de ser executada, uma vez que o especialista deve ter uma exata noção de quais são os melhores atributos dos objetos que devem ser utilizados na classificação (VIEIRA et al. 2012). Outra abordagem promissora na classificação de imagens é a utilização de técnicas de mineração de dados como forma de geração automática da estrutura do conhecimento (ZHANG et al. 2013). A maneira automática de execução do algoritmo que funciona com a lógica de árvores de decisão, significa um ganho enorme no tempo de implementação do processo de classificação de imagens de satélites, principalmente em estudos que utilizam extensos bancos de dados (KÖRTING et al. 2009). O fato desta técnica analisar parâmetros espaciais e espectrais é interessante em aplicações de uso da terra devido à maior eficácia e precisão na classificação (MONTEIRO; LINGNAU; SOUZA JÚNIOR, 2007), dessa forma, o presente trabalho propõe analisar a evolução do uso e ocupação do

solo discriminando as matrizes e os remanescentes florestais de Mata Atlântica da região, delimitando diferentes classes de uso do solo e suas mudanças entre os anos de 1987 e 2011.

2 OBJETIVOS

Os objetivos determinados para a execução do presente trabalho consistem de:

2.1 GERAL

O presente trabalho propõe analisar a evolução do uso e ocupação do solo discriminando as matrizes e os remanescentes florestais de Mata Atlântica na região de Alfenas, sul de Minas Gerais, utilizando a técnica de classificação de imagens de satélites conhecida como mineração de dados espaciais.

2.2 ESPECÍFICOS

- Mapear a região de Alfenas utilizando técnicas recentes de Processamento Digital de Imagens;
- Delimitar classes de usos da terra e suas mudanças entre os anos de 1987 e 2011 baseadas em imagens Landsat 5 - TM;
- Aplicar a técnica de Mineração de Dados e verificar possíveis vantagens e limitações dessa forma de classificação;
- Avaliar as mudanças ocorridas nas datas analisadas.

3 JUSTIFICATIVAS

O levantamento de informações sobre os diferentes tipos de uso do solo ao longo dos anos é capaz de fornecer novas maneiras de compreensão da evolução da paisagem e da dinâmica evolutiva de seu entorno. Dessa forma, o SR se configura em uma ferramenta crucial de apoio às análises de uso e ocupação do solo, facilitando a identificação de elementos que compõem a paisagem, além de complementar informações disponíveis sobre recursos ambientais da área em questão. Nesse contexto, uma descrição detalhada da paisagem incluindo sua evolução ao longo dos anos é importante por diversos motivos (CALDERANO FILHO et al. 2009):

- É fundamental para compreender a influência das matrizes nas características dos fragmentos, bem como determinar ações visando a conservação dos remanescentes;
- Em estudos relacionados à ecologia da paisagem, o mapeamento do uso e cobertura do solo é importante na avaliação da situação ambiental do ecossistema;
- Identificar a evolução da paisagem ao longo de anos pode ser uma forma de embasar a discussão sobre a conservação de fragmentos;
- A avaliação da dinâmica da paisagem também é importante na conservação dos recursos naturais como qualidade do solo e da água;
- A tecnologia do SR permite a obtenção de informações da paisagem com rapidez, periodicidade, contempla grandes áreas, tem baixo custo financeiro, trabalha em faixas do espectro eletromagnético inacessível a visão humana, reduz a subjetividade no processo de decisão e torna possível o armazenamento da informação em bancos de dados integrados a SIG;
- A técnica de classificação adotada utiliza um conjunto maior de atributos da imagem que outras técnicas, e executa o algoritmo de maneira automática, gerando resultados mais completos e em menor tempo.

4 REVISÃO BIBLIOGRÁFICA

4.1 SATÉLITE LANDSAT

Em meados dos anos 1960, a Administração Nacional da Aeronáutica e do Espaço (NASA) iniciou o programa de monitoramento por satélite conhecido como Landsat. O objetivo era auxiliar cientistas a compreender e avaliar mudanças na paisagem oriundas de processos naturais ou antrópicos, sua formação, evolução e consequências sobre a superfície do planeta. A partir de 1972, com o lançamento do primeiro satélite da série (denominado ERTS-1 e posteriormente rebatizado de Landsat-1), tem início o maior registro contínuo de imageamento da Terra (United State Geological Survey (USGS), 2013). A Figura 1 ilustra os satélites da série Landsat e o tempo de operação de cada um deles.




Figura 1- Cronologia dos satélites da série Landsat.

Fonte: USGS (2013).

O satélite mais utilizado em SR foi o Landsat-5, lançado em março de 1984 e que operou até janeiro de 2013. O satélite foi equipado com dois sensores imageadores, o MSS (*Multispectral Scanner*), com resolução espacial de 80 metros e o principal, o TM (*Thematic Mapper*), com resolução espacial de 30 metros. Ambos recobrimo uma área de 185 Km X 185 Km da superfície terrestre (NASA, 2013).

Outros sensores utilizados na série Landsat são os sensores ETM (*Enhanced Thematic Mapper*) e ETM+ (*Enhanced Thematic Mapper Plus*) (Empresa Brasileira de Pesquisa

Agropecuária (EMBRAPA), 2014). O primeiro foi projetado para ser levado a bordo do Landsat-6, satélite que não atingiu a órbita. O ETM continha as mesmas configurações técnicas de seu antecessor (TM) diferenciando-se apenas pela inclusão de uma banda pancromática, conhecida como TM8, que cobre a faixa do espectro eletromagnético que vai de 0,52 a 0,90 μm e com resolução espacial de 15 metros.

O sensor ETM+ é a evolução do ETM. Em 1999 foi lançado a bordo do Landsat-7 e enviou dados completos até 2003. Devido a danos de hardware, o espelho corretor de linha (SLC) foi desligado e desde então, as imagens adquiridas necessitam de correções prévias acerca do posicionamento e calibração dos *pixels*. Este sensor é conhecido por ter aumentado a acurácia do sistema Landsat. Ampliou a resolução espacial da TM6 de 120 para 60 metros e principalmente, tornou a banda pancromática operante, permitindo assim a geração de composições coloridas com 15 metros de resolução espacial.

Em 11 de fevereiro de 2013, uma parceria entre o Serviço Geológico dos Estados Unidos (USGS) e a NASA, resultou no lançamento do satélite conhecido como Missão de Continuidade de Dados Landsat (*Landsat Data Continuity Mission*). Posteriormente rebatizado Landsat-8, capaz de capturar imagens com precisão e resoluções superiores aos satélites anteriores (NASA, 2014).

O Landsat-8 opera com os sensores OLI (*Operational Land Imager*) e TIRS (*Thermal Infrared Sensor*) com resoluções espaciais de 30 metros (bandas do visível, infravermelho próximo e médio), 100 metros (banda infravermelho termal) e 15 metros (banda pancromática). O satélite possui órbita quase polar e passará sobre o mesmo ponto na superfície a cada 16 dias (NASA, 2014). A Figura 2 ilustra os diferentes intervalos de banda do Landsat-8.

O sensor OLI é responsável pela continuidade dos produtos gerados a partir dos sensores TM e ETM+, diferenciando-se destes pela inclusão de duas bandas espectrais com resoluções de 30 metros: uma concebida para estudos de áreas costeiras, cobrindo o intervalo de 0,435 a 0,451 μm ; e a outra com a finalidade de detectar nuvens do tipo cirrus, cobrindo o intervalo de 1,363 a 1,384 μm .




Figura 2- Comparação entre bandas do Landsat-8 e Landsat-7.

Nota: Os satélites anteriores ao Landsat-7 apresentam as mesmos intervalos de banda do espectro eletromagnético.

Fonte: NASA, 2014.

Já o sensor TIRS, é responsável pela coleta de dados de duas bandas espectrais mais estreitas na região do infravermelho termal (intervalos de 10,60 - 11,19 μm e 11,50 - 12,51 μm), ao passo que nos satélites anteriores era considerada somente uma banda mais larga (Banda 6). Essas novas bandas possuem resolução espacial de 100 metros, e seus dados serão adicionados aos dados OLI com a finalidade de gerar produtos corrigidos radiometricamente, geometricamente e no terreno.

4.2 LANDSAT-5 TM

O sensor TM do Landsat-5 opera em 7 bandas nas regiões do espectro eletromagnético (Tabela 1), sendo 3 delas na região do espectro visível, ou seja, na região onde o olho humano é sensível às luzes refletidas, podendo enxergar cores desde o tom violeta até o vermelho, as demais bandas operam na região do infravermelho próximo, médio e termal. O sensor TM é superior ao sensor MSS na resolução espectral, acurácia radiométrica e posicionamento geométrico (EMBRAPA, 2014; NASA, 2013).

Tabela 1- Intervalos de operação das bandas espectrais do satélite Landsat-5 TM.

Bandas Espectrais	Comprimento de Ondas (μm)
TM1 - Azul	0,45 - 0,52
TM2 - Verde	0,52 - 0,60
TM3 - Vermelho	0,63 - 0,69
TM4 - Infravermelho Próximo	0,76 - 0,90
TM5 - Infravermelho Médio	1,55 - 1,75
TM6 - Infravermelho Termal	10,4 - 12,5
TM7 - Infravermelho Médio Distante	2,08 - 2,35

Fonte: INPE (2013).

A faixa espectral conhecida como Região do Visível, é o intervalo que apresenta maior intensidade de fluxo radiante e onde há a melhor janela atmosférica, que deixa passar grande quantidade de radiação. Devido ao alto espalhamento da radiação solar incidente pelos gases atmosféricos, algumas vezes o contraste de reflectância dos alvos terrestres para essa região pode ser reduzido (MENESES; ALMEIDA, 2012).

Essa região é composta por três bandas espectrais: azul (TM1), verde (TM2) e vermelho (TM3). A TM1 apresenta grande penetração em corpos de água e boa absorção pela clorofila e carotenóides, permitindo distinguir solo de vegetação e vegetações entre si. A TM2 enfatiza o pico de vegetação (avaliador de vigor vegetal), apresenta boa penetração em corpos de água e grande sensibilidade à presença de sedimentos em suspensão. Já a TM3 é a principal banda de absorção da clorofila, a vegetação fica escura, permitindo bom contraste entre os diferentes usos e ocupações do solo (CONCEICAO, 2004; NASA, 2013).

A TM4 é conhecida como banda do infravermelho próximo, seu intervalo de frequência possui algumas janelas de absorção, impedindo que todo o intervalo seja utilizado em SR. Nessa banda ocorrem importantes interações da radiação eletromagnética com a energia eletrônica dos átomos, facilitando a identificação de rochas (MENESES; ALMEIDA, 2012). Os corpos de água absorvem energia e ficam escuros, ao passo que a vegetação densa e uniforme reflete muita energia, se apresentando em tons bem claros de cinza (CONCEICAO, 2004; NASA, 2013). Essa banda apresenta sensibilidade à

rugosidade do dossel florestal e também à morfologia do terreno (EMBRAPA, 2014; INPE, 2013).

A região do infravermelho médio apresenta dois intervalos de operação, um referente à TM5 e outro à TM7. Nessa região, incêndios são facilmente detectados pelos sensores, bem como diversos eventos climáticos e meteorológicos (NASA, 2013). A TM5 é sensível ao teor de umidade do solo e das plantas, apresenta grande diversidade de tons de cinza, evidenciando maior número de detalhes do que as bandas anteriores, sendo indicada para diferenciação de mais de duas classes. A TM7 permite obter informações sobre a morfologia do terreno, identificar minerais com íons hidroxila e discriminar produtos de alterações hidrotermais (CONCEICAO, 2004).

A última faixa de operação do sensor TM é a região conhecida como banda do infravermelho termal (TM6). Essa banda possui resolução espacial de 120 metros (todas as outras bandas são de 30 metros) (INPE, 2013). Essa banda identifica a radiação emitida por objetos em função de sua temperatura de superfície. Apresenta sensibilidade a fenômenos relativos aos contrastes térmicos, servindo para detectar propriedades termais de rochas, solos, vegetação e água (MENESES; ALMEIDA, 2012; NASA, 2013).

4.3 PROCESSAMENTO DIGITAL DE IMAGENS

O que difere uma imagem digital oriunda de sensores remotos de uma imagem digital comum são suas resoluções e estruturas. Para Crosta (1992), as imagens de sensores remotos podem ser estruturadas como um conjunto de elementos dispostos em uma matriz, baseado em um sistema de coordenadas de linhas (x) e colunas (y). As células da imagem recebem o nome de *pixel* e possuem um atributo (z) indicando o nível de cinza (Digital Number).

Quanto à resolução, uma imagem de satélite apresenta quatro parâmetros diferentes: espacial, espectral, radiométrica e temporal (CROSTA, 1992). A resolução espacial define a acurácia geométrica do sensor em capturar objetos na superfície, ou seja, quanto menor for o objeto possível de ser identificado na imagem, maior é sua resolução

espacial. A resolução espectral discrimina o número de bandas e a largura do intervalo de comprimento de onda de cada banda do sistema sensor. Enquanto a resolução radiométrica determina o número de níveis digitais que compõem uma imagem. Já a resolução temporal aponta o intervalo de tempo em horas ou dias, entre a passagem de um sensor pelo mesmo ponto na superfície.

Uma imagem de SR é composta por objetos ou padrões, que possuem grande volume de informação. Os diversos sensores orbitais em funcionamento operam com resoluções espaciais e espectrais distintas. O sensor captura uma cena e o conversor transforma os valores analógicos de energia eletromagnética em valores digitais (MENESES; ALMEIDA, 2012). A Figura 3 ilustra um exemplo de imagem com diferentes valores de radiação espectral expressos em níveis de cinza.

Segundo Dias et al. (1987), o processamento digital de imagens pode ser dividido em três etapas principais: o pré-processamento, o realce e a classificação. O pré-processamento tem como objetivo corrigir as distorções radiométricas e geométricas presentes na imagem. Enquanto o realce tem função de realçar ou atenuar determinadas feições na imagem utilizando métodos de domínio espacial e espectral. Por fim, a classificação tem como objetivo rotular os *pixels* da imagem com relação a uma determinada classe temática.

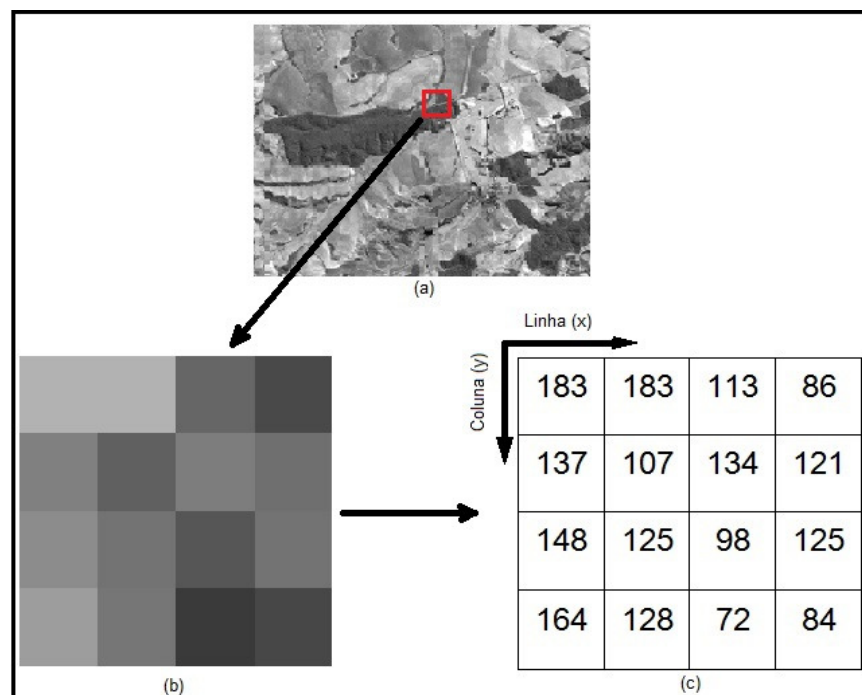


Figura 3- Digital Number.

Nota: (a) Recorte de uma cena Landsat 5-TM da área de estudo; (b) em destaque um grupo de *pixels* em níveis de cinza; (c) DN's em uma matriz de linhas e colunas correspondente à área em destaque.

Fonte: Adaptado de Dias et al. (1987).

4.4 CORREÇÃO GEOMÉTRICA

As imagens apresentam diversos tipos de distorções e deformações geométricas ocasionadas por processos de obtenção, transmissão e visualização das cenas correspondentes. É necessário que elas sejam corrigidas segundo algum sistema de coordenadas, a fim de assumirem propriedades de escala e projeção cartográficas de uma base georreferenciada. Esse procedimento é chamado de correção geométrica (CROSTA, 1992).

As distorções presentes nas imagens são ocasionadas por erros geométricos internos e externos (JENSEN, 2005). Erros internos são gerados pelo próprio sistema de sensoriamento ou em conjunto com características de rotação e curvatura terrestre. Entre eles, destaca-se a distorção sistemática conhecida como "*skew*", caracterizada pela imprecisão do ângulo de inclinação da órbita do satélite em relação ao eixo de rotação da Terra, devido à diferença de velocidade de ambos (Figura 4).

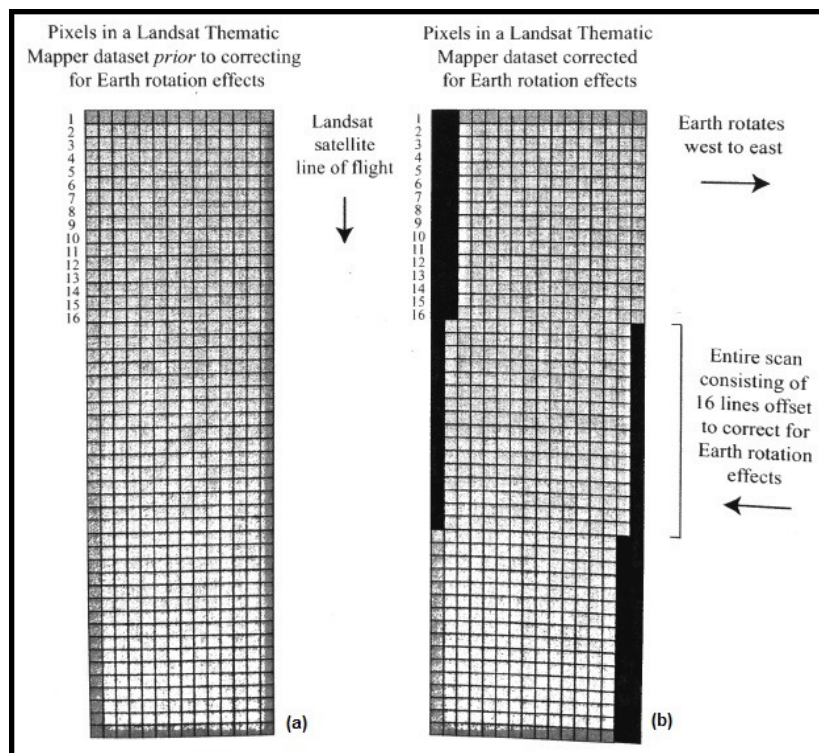


Figura 4- Erro "Skew".

Nota: Ilustração do erro geométrico denominado "skew", gerado pela diferença de velocidade de vôo do satélite e do movimento de rotação terrestre.

Fonte: Jensen (2005).

As variações de altitude do satélite ocasionam diferenças de escala entre imagens. A elevação de altitude faz com que a escala da imagem se torne menor, enquanto a diminuição gera o efeito inverso, aumento da escala da imagem. A Figura 5 é utilizada por Jensen (2005) para ilustrar as principais distorções geométricas externas presentes em imagens de SR.

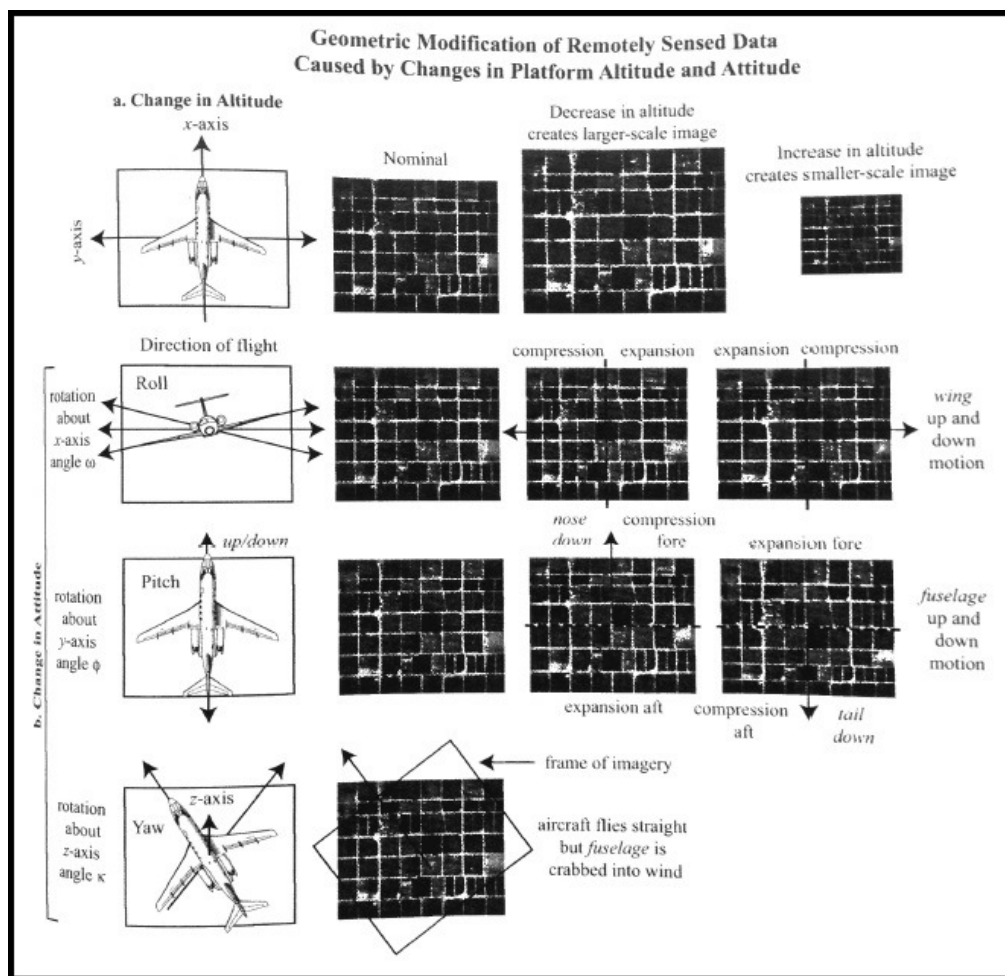


Figura 5- Distorções geométricas presentes em imagens de SR.

Nota: (a) mudanças na altitude da aeronave durante o vôo, podem ocasionar aumento ou diminuição da escala da imagem; (b) mudanças na atitude da aeronave: movimentos de *roll* (eixo x), *pitch* (eixo y) e *yaw* (eixo z).

Fonte: Jensen (2005).

Os erros geométricos externos são aqueles decorrentes da instabilidade da plataforma, como variação de altitude e dos eixos de rotação do satélite, também conhecidos como "roll", "pitch" e "yaw" (CROSTA, 1992). A variação de "roll" é gerada pelo movimento

de rotação do satélite sobre o seu eixo de direcionamento "x", causando compressão ou expansão de *pixels* nas imagens.

O movimento da fuselagem do satélite para cima ou para baixo sobre seu eixo "y" gera a variação "*pitch*". Com a frente se movimentando para baixo, os *pixels* da parte superior da imagem são comprimidos e da parte inferior expandidos, gerando mudanças de escala em uma mesma imagem. Se a frente se movimentar para cima o efeito é inverso. A variação de "*yaw*" acontece quando a fuselagem é forçada para a esquerda ou direita da linha de vôo planejada, ocasionando variação no eixo "z", fazendo com que o enquadramento dos *pixels* da imagem fique fora da posição correta (JENSEN, 2005).

Existem duas formas principais de corrigir as distorções presentes nas imagens, que podem ser utilizadas de forma complementar. Os erros internos, geralmente sistemáticos e previsíveis, podem facilmente ser corrigidos através do conhecimento exato dos parâmetros geométricos da órbita do satélite e de rotação da Terra (MENESES; ALMEIDA, 2012).

Segundo Crosta (1992), essa correção é conhecida como Modelo de Geometria Orbital. Quase todas as imagens de satélites disponíveis já se encontram corrigidas, para as demais, os dados contendo informações sobre os parâmetros geométricos são disponibilizados junto com as imagens (JENSEN, 2005).

Mesmo após essa correção, algumas imprecisões podem permanecer. Outra forma de correção geométrica, com maior precisão e confiabilidade, é então aplicada sobre a imagem. Esse procedimento é conhecido como correção geométrica baseada em Pontos de Controle (CROSTA, 1992).

A ideia é simples, o usuário identifica e posiciona diversos pontos de controle (GCPs - *Ground Control Points*) em uma base planimétrica confiável e na mesma escala da imagem. Para cada ponto identificado na base, o mesmo ponto deve ser identificado na imagem. Estes GCPs são armazenados em uma matriz formada por coordenadas de "i" linhas por "j" colunas. Para Meneses e Almeida (2012) esse procedimento representa o georreferenciamento de imagens, já que a imagem será corrigida de acordo com determinado sistema de coordenadas (DU; TEILLET; CIHLAR, 2002).

A correção por GCPs permite uma precisão mais elevada e pode ser implementada tanto em imagens orbitais como fotografias aéreas (TUOMINEN; HAAKANA, 2005; KENNEDY; COHEN, 2003). Uma forma de identificação de pontos de controle pode ser realizada por registro de campo utilizando dispositivo GPS (PFLUGMACHER; COHEN; KENNEDY, 2012). No entanto, a maneira mais utilizada para a identificação de tais pontos é através da interface de um Sistema de Informações Geográficas, onde os pontos podem ser identificados na base cartográfica e registrados na imagem a ser corrigida (XIANG; TIAN, 2011; PIROMAL et al. 2008).

Os GCPs devem ser bem distribuídos na imagem e estarem localizados em feições facilmente identificáveis ou com grande contraste espectral em relação à objetos vizinhos na imagem. Pontes, confluências de corpos d'água, limites de cultivos, estradas rurais ou rodovias, são alguns exemplos (BREWER et al. 2005; D'ALGE, 1987). O conceito é identificar pontos reconhecíveis da imagem na base cartográfica, e por meio de modelos polinomiais, gerar coeficientes de transformação geométrica (CROSTA, 1992).

Após a identificação dos pontos de controle ou GCPs e ajuste dos pontos com um modelo polinomial, é realizada a reamostragem das imagens por meio de métodos de interpolação. Os métodos mais comuns são: interpolação bilinear, convolução cúbica e vizinho mais próximo (Tabela 2) (BREWER et al. 2005; TESHIMA; IWASAKI, 2008; MCROBERTS et al. 2011).

Tabela 2- Comparação entre métodos de interpolação.

Método	Técnica	Vantagem	Desvantagem
Vizinho Mais Próximo	transferência de DN a partir do vizinho mais próximo	cálculo simples / preserva DN original da imagem	imagem final pouco estética
Interpolação Bi-linear	cálculo da média ponderada dos quatro vizinhos	imagem final mais suave / precisão geométrica	alteração do DN dos pixels originais
Convolução Cúbica	cálculo da média ponderada dos 16 vizinhos	imagem final esteticamente melhor	complexidade de cálculos

Fonte: Crosta (1992).

A reamostragem utilizando o interpolador por meio do Vizinho Mais Próximo (Nearest Neighbour) funciona da seguinte maneira: o DN mais próximo do identificado pelas coordenadas x',y' da base cartográfica, é atribuído à coordenada x,y da imagem de saída. Algumas vezes os GCPs podem ser projetados em coordenadas que não sejam de números inteiros, sendo necessária a aplicação do Teorema de Pitágoras nestes casos

(JENSEN, 2005). Por não envolver cálculos mais complexos, esse método de reamostragem é implementado rapidamente.

Os outros tipos de interpoladores trabalham com valores de médias de diversos *pixels* vizinhos. Essa é a principal diferença entre eles, já que o Nearest Neighbour permite que quase nenhuma informação espectral presente na imagem seja perdida (MCROBERTS et al. 2011; PIROMAL et al. 2008). Em trabalhos de classificação de imagens de satélite, as mudanças em valores de intensidade de brilho dos *pixels* são fundamentais para se distinguir diferentes tipos de usos agrícolas de uma região (BINS et al. 1996; SINGH; HADDON; MARKOU, 2001).

4.5 REALCE

As técnicas de realce tem como objetivo realçar feições espaciais e espectrais na imagem. Existem diversos métodos que se enquadram dentro da categoria de realce. De maneira geral, as técnicas de realce podem ser agrupadas em duas categorias: as de domínio espacial e as de domínio espectral.

Os realces no domínio espacial utilizam filtros espaciais com o objetivo de amplificar ou atenuar feições na imagem, como limites de usos, corpos d'água, direções de falhas, entre outros. Os filtros do tipo passa-baixa atenuam as feições. Já os filtros passa-alta amplificam os limites.

Os realces no domínio espectral tem como objetivo amplificar feições espectrais. Crosta (1992) e Jensen (2005) citam vários métodos de realce no domínio espectral. Uma das técnicas mais simples é o aumento linear de contraste seguido pela construção de composição colorida utilizando filtros RGB.

O aumento linear de contraste (*contrast stretch*) é uma técnica de realce que redistribui os valores dos *pixels* da imagem de maneira linear. O resultado de um aumento de contraste é uma imagem com maior número de tonalidades de cinza. Quando combinado com filtros coloridos (RGB), a imagem resultante apresenta maior variedade de cor, brilho e tonalidade. Para aplicar o aumento linear de contraste é preciso saber o

valor mínimo e máximo da imagem. Estes valores são facilmente adquiridos no histograma da imagem. Após a aplicação do aumento linear de contraste, as imagens são combinadas em filtros coloridos para a construção de composições coloridas reais ou em falsa-cor.

4.6 CLASSIFICAÇÃO

A classificação de imagens pode ser entendida como o reconhecimento e identificação de diferentes usos e coberturas da superfície terrestre. A escala de trabalho e a resolução espacial do sensor remoto são características fundamentais para uma classificação bem definida (ANDERSON et al. 1976). Em alguns casos, determinadas parcelas da imagem podem apresentar áreas muito pequenas para serem distinguidas. Ou podem existir parcelas com grandes áreas, abrangendo diferentes usos em uma mesma classe. De acordo com o autor, para se atingir uma classificação adequada do uso e cobertura do solo, alguns critérios devem ser obedecidos, como nível de precisão, data de aquisição e levantamento de campo, entre outros.

Os algoritmos classificadores podem ser enquadrados em duas formas considerando o grau de interação do usuário, classificação supervisionada e não-supervisionada. Nesta última, o intérprete tem pouco ou nenhuma participação durante o procedimento, sendo a maior parte do procedimento realizado pelo software. Na classificação supervisionada, a intervenção do usuário é essencial para uma boa classificação, visto que é necessário realizar a amostragem das classes (MENESES; ALMEIDA, 2012; ATKINSON; LEWIS, 2000). A Figura 6 ilustra os diversos tipos de classificação comumente utilizados em SR.

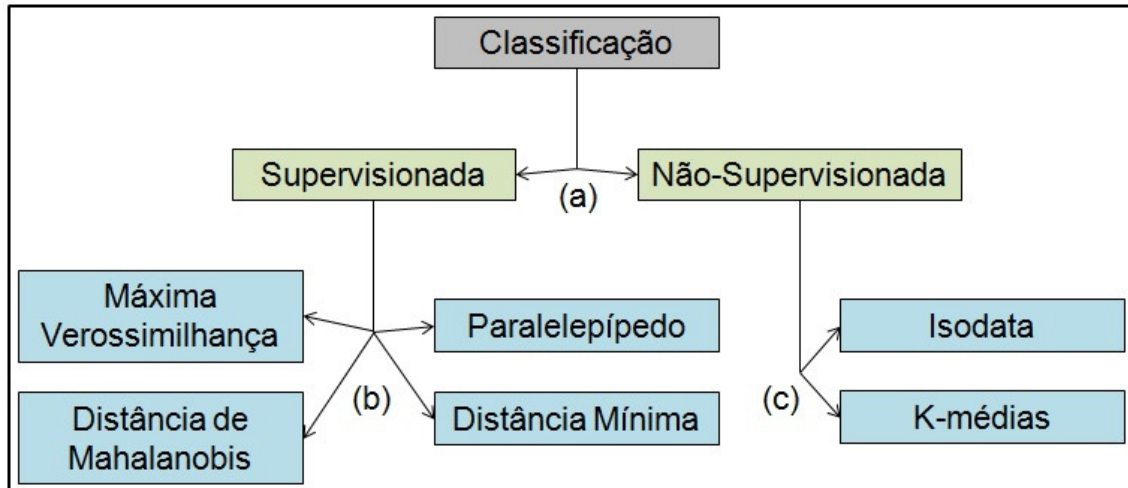


Figura 6- Classificação Supervisionada e Não-Supervisionada.

Nota: (a) Pelo nível de interação do usuário no processo, considera-se as classificações como supervisionada ou não-supervisionada; (b) Diferentes algoritmos de classificação supervisionada de imagens; (c) Diferentes algoritmos de classificação não-supervisionada de imagens.

Fonte: Meneses; Almeida (2012).

Algoritmos estatísticos baseados no *pixel* foram desenvolvidos principalmente durante os anos 1980 e 1990. Utilizavam um conjunto limitado de parâmetros, como média e desvio padrão de grupos de *pixels* individuais para representar a informação sobre padrões de ocupação do solo (BLASCHKE, 2010). Estes algoritmos utilizam informações espectrais dos *pixels* para definir as regiões homogêneas, baseados em medidas de distâncias ou valores estatísticos das classes (MENESES; ALMEIDA, 2012).

Outra abordagem que tem sido recentemente incorporada é a classificação baseada em regiões ou segmentos. Ou seja, primeiramente realiza-se a segmentação das imagens, e em seguida é feita a classificação baseando-se nos resultados da segmentação (LIU; XIA, 2010).

4.7 SEGMENTAÇÃO

A segmentação pode ser entendida como um processo no qual a imagem é fracionada em diferentes regiões, com o intuito de discriminar *pixels* que apresentem determinadas características predefinidas pelo usuário, como níveis de cinza, propriedades texturais ou valores médios.

As principais metodologias de segmentação utilizam algoritmos que se baseiam em duas propriedades complementares de valores de intensidade de *pixels*, a similaridade e a descontinuidade (ZHANG, 1997). Os algoritmos de descontinuidade são aqueles que dividem a imagem com base em mudanças bruscas de intensidade, são conhecidos como algoritmos de segmentação baseada em bordas. Essas transições podem ser classificadas de acordo com seus perfis de intensidade (GONZALEZ; WOODS, 2010).

A ideia é que as fronteiras das regiões são diferentes entre si o suficiente para permitir a identificação de limites com variações locais de intensidade. Abordagem muito comum em estudos focados na identificação de limites ou formas definidas presentes nas imagens (MUELLER; SEGL; KAUFMANN, 2004; XU; AHUJA; BANSAL, 2007).

Algoritmos baseados na similaridade entre os valores de intensidade dos *pixels* são mais adequados para identificar diferentes classes de uso do solo, uma vez que os comportamentos espectrais de *pixels* vizinhos tendem a apresentar valores semelhantes. Para Gonzalez; Woods (2010) a imagem de satélite pode ser dividida em regiões homogêneas de acordo com parâmetros predefinidos por meio destes algoritmos. Esse processo é conhecido como segmentação baseada na região e possui três tipos principais: segmentação usando *watersheds*, divisão e fusão de regiões e crescimento de regiões (CHEN et al. 2004; LI; YANG, 2008; FAN et al. 2005).

Diversos fatores podem influenciar de formas distintas na abordagem escolhida para realizar a segmentação. Os tipos de dados e a área em questão são fundamentais para determinar qual tipo de segmentação deve ser implementada. A detecção de bordas é uma técnica muito sensível à variação de intensidade dos *pixels* e os limites nem sempre são interligados ou bem definidos, podendo haver pequenas lacunas nos limites das bordas que resultarão em erros de fusão de regiões com características distintas (JENSEN, 2005). Na segmentação baseada em regiões, os agrupamentos de *pixels* apresentam limites interligados, é de simples execução e muito eficaz nos resultados. A desvantagem dessa técnica é a associação de *pixels* de borda à regiões vizinhas, devido principalmente à presença de ruídos nas imagens (BINS et al. 1996).

Dentre as técnicas que abordam a similaridade de intensidade dos *pixels*, a segmentação por divisão e fusão de regiões é a menos utilizada. Consiste no particionamento sucessivo da imagem em quadrantes, que por sua vez podem ser particionados em quatro sub-

quadrantes, e assim por diante até quando não for mais possível ou até que a informação desejada seja evidenciada. Algumas regiões adjacentes podem apresentar as mesmas propriedades, sendo possível realizar a fusão de regiões nestes casos, simplificando o algoritmo (GONZALEZ; WOODS, 2010; CHEN et al. 2004).

A segmentação do tipo *watershed* tem seu algoritmo baseado na lógica de delimitação de bacias hidrográficas (GONZALEZ; WOODS, 2010). O algoritmo testa os valores atribuídos aos *pixels* em relação a um valor mínimo regional especificado. Os *pixels* são então atribuídos a determinadas regiões de acordo com seus valores. Pontos que apresentam valores que podem ser atribuídos às duas regiões adjacentes, são conectados de forma a gerar linhas similares às linhas de divisores. Estas linhas recebem o nome de barragem, e formam fronteiras contínuas em toda a imagem segmentada. (HARIS et al. 1998). Estes algoritmos produzem muitas pequenas fronteiras, em função do ruído existente na imagem. Para amenizar esse excesso de segmentação é necessário alterar o algoritmo (WANG, 1998).

A técnica de crescimento de regiões vêm sendo amplamente utilizada em estudos de cunho ambiental (MUNYATI; RATSHIBVUMO; OGOLA, 2013; KAWAKUBO et al. 2009; IM; JENSEN; TULLIS, 2008; SHIMABUKURO et al. 1999). Gonzalez; Woods (2010) entendem este processo de segmentação como o agrupamento de *pixels* ou conjuntos destes em regiões maiores de acordo com características preestabelecidas. A ideia é iniciar o processo com um conjunto de *pixels* base, que recebem o nome de "semente", e então anexar a cada semente os *pixels* vizinhos que possuem propriedades semelhantes.

Existem diversas maneiras de se estabelecer o crescimento de regiões. A Figura 7 exemplifica um método de crescimento de regiões baseado em um simples limiar de diferença entre os valores do *pixel* semente e o *pixel* vizinho.

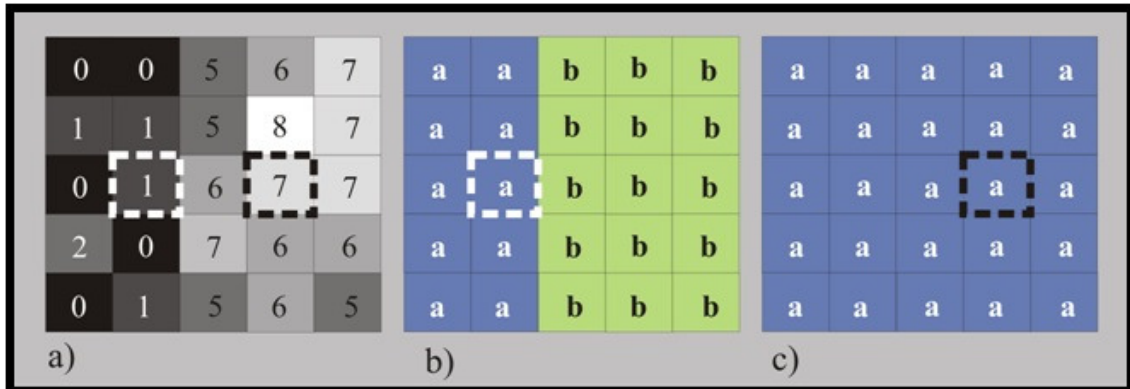


Figura 7- Crescimento de regiões.

Nota: (a) Imagem original identificando os *pixels* sementes com valores 1 (coordenadas: 3º linha, 2º coluna) e 7 (coordenadas: 3º linha, 4º coluna); (b) resultado da segmentação rotulado como classes **a** e **b** usando um limiar T com diferença de menos 3 entre os níveis de cinza; (c) resultado da segmentação rotulado como classe **a** adotado um T com diferença de menos 8.

Fonte: Kawakubo (2010), adaptado de Gonzalez; Woods (1992).

Inicialmente seleciona-se um *pixel* semente e se estabelece o limiar. Caso a diferença entre o valor do *pixel* semente e o *pixel* vizinho esteja dentro do limiar estabelecido, agrega-se o *pixel* vizinho formando uma região. Após concluir a segmentação, os segmentos ou regiões são submetidos a mesma rotina de classificação, que pode ser realizada de forma supervisionada ou não-supervisionada.

4.8 MINERAÇÃO DE DADOS

A mineração de dados é um método de classificação de imagens que vêm sendo desenvolvido e muito utilizado nos últimos anos (ZHANG et al. 2013; VIEIRA et al. 2012). Em estudos que utilizam extensos bancos de dados, esta ferramenta pode ser muito útil, uma vez que a carga de trabalho é leve, o tempo de processamento é curto e os passos executados pelo usuário seguem uma sequência lógica de procedimentos de análise de imagens (KORTING et al. 2009).

A classificação por mineração de dados funciona com a lógica de árvores de decisão. Vieira et al. (2012) entendem o processo de mineração de dados da seguinte maneira, o algoritmo escolhe um atributo da imagem segmentada que servirá de parâmetro e divide os dados correspondentes em dois subconjuntos. Baseado na diferença de entropia entre os dois subconjuntos deste parâmetro, os segmentos são rotulados como pertencentes ou não a determinada classe. Aqueles que apresentem valores que satisfaçam o limiar, são

alocados no ramo esquerdo, os que ultrapassam o limiar, no ramo direito, e por fim, as classes são atribuídas aos nós terminais da árvore. Este procedimento é repetido até todos os segmentos serem classificados.

A maneira automática de execução do algoritmo de mineração de dados significa um ganho enorme no tempo de implementação do processo de classificação de imagens de satélite. O fato desta ferramenta analisar parâmetros espaciais e espectrais é interessante em aplicações de uso e ocupação do solo devido à maior eficácia e precisão na classificação. A técnica de mineração de dados une a velocidade de implementação e a eficácia nos resultados, e, em estudos ambientais, estas vantagens são fundamentais, visto o grande tamanho dos conjuntos de dados utilizados nestas pesquisas (ZHANG et al. 2013; VIEIRA et al. 2012; KORTING et al. 2009).

Em seu trabalho, Körting; Fonseca; Câmara (2013) descrevem as características básicas e o funcionamento da ferramenta de classificação de imagens GeoDMA (Geographic Data Mining Analyst). Esse sistema de análise de imagens funciona como um *plugin* do *software* TerraView, desenvolvido pelo INPE. Seu funcionamento compreende basicamente 4 etapas de processamento (Figura 8).



Figura 8- GeoDMA - Principais etapas.

Nota: Diagrama com as principais etapas de processamento para análise de imagens no GeoDMA.

Fonte: Adaptado de Körting; Fonseca; Câmara (2013).

Na primeira etapa, o usuário define os dados de entrada e o método de segmentação (Figura 9). Na segunda etapa, o software realiza a extração de diferentes características baseadas nas informações presentes na imagem para em seguida armazená-las em um banco de dados. Características espectrais, espaciais, multitemporais e de ecologia da paisagem podem ser extraídas a partir de dados no formato vetorial ou *raster* (Figura 10).

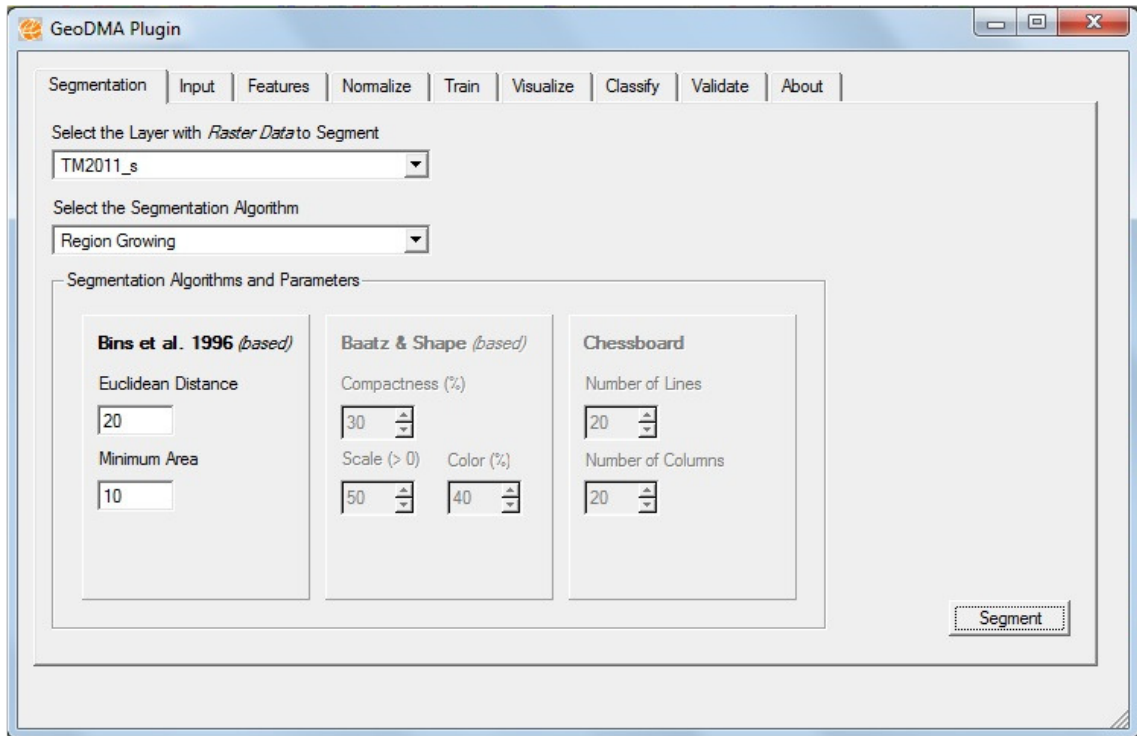


Figura 9- Interface GeoDMA com as abordagens de segmentação.

Fonte: do autor.

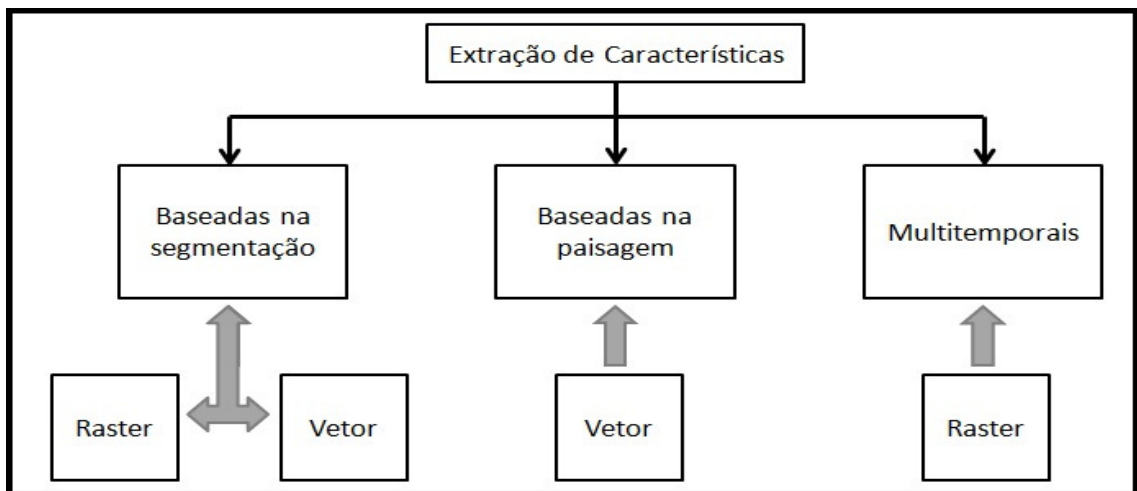


Figura 10- Diagrama de Extração de Características.

Nota: Aponta as características extraídas de imagens de SR disponíveis nos formatos *raster* e vetorial.

Fonte: Adaptado de Körting; Fonseca; Câmara (2013).

Na terceira fase o usuário seleciona amostras de treinamento para cada classe, reconhecendo e selecionando diferentes padrões de cobertura da terra. O GeoDMA fornece três algoritmos de classificação: redes neurais, mapas auto-organizáveis (SOM) e árvores de decisão. Na quarta e última etapa, é realizada a avaliação dos resultados da classificação.

O algoritmo inicialmente seleciona um *pixel* semente. Este *pixel* inicia o processo de agregação dos *pixels* vizinhos formando regiões maiores. Para o *pixel* vizinho ser agregado é necessário que o limiar de similaridade, expresso pela distância euclidiana, seja inferior ao limiar definido pelo usuário. Para evitar que se formem regiões muito pequenas, o limiar de área mínima define o tamanho mínimo de área particionada na imagem. Enquanto isso o valor médio da região é atualizado constantemente. Quando os critérios não são satisfeitos inicia-se o crescimento de uma nova região. Este processo é repetido até que não existam mais regiões a serem delimitadas na imagem.

O valor do parâmetro de similaridade fornecido pelo usuário varia de acordo com a aplicação e dados específicos. Alguns valores podem ser satisfatórios para uma análise de uso do solo e não servirem para uma estimativa de índice de vegetação. Um valor de limiar de similaridade muito baixo com valor de área pequena, gera uma segmentação excessivamente densa ao passo que a adoção de limiares mais altos e com tamanhos de área maiores geram uma falta de segmentação. O resultado prático destas duas abordagens é uma imagem com excesso e falta de segmentos (Figura 11).




Figura 11- Segmentação.

Nota: (A) Imagem Landsat de 2011, recorte de parte da área de estudo; (B) Resultado da segmentação por crescimento de regiões com os seguintes parâmetros: 30 para similaridade e 15 para área mínima.

Fonte: do autor.

5 METODOLOGIA

A Figura 12 ilustra o fluxograma dos procedimentos adotados no presente trabalho. A etapa de preparação das imagens (correção geométrica) e detecção das mudanças foram realizadas no SIG ILWIS. As etapas de segmentação das imagens e de mineração de dados foram realizadas no GeoDMA. Esse sistema de análise de imagens funciona como um plugin do software TerraView, desenvolvido pelo INPE (Körting et al. 2013).

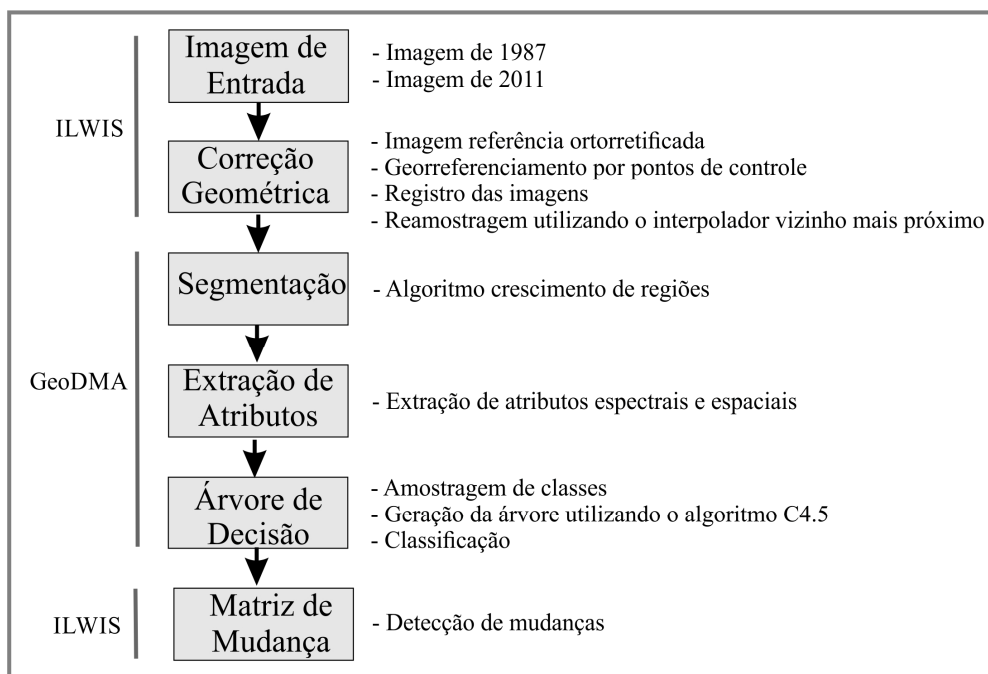


Figura 12. Fluxograma.

Nota: Procedimentos adotados em diferentes softwares ao longo da execução do trabalho.

Fonte: do autor.

5.1. ÁREA DE ESTUDO

A área de estudo corresponde ao entorno da região sul do Reservatório da Usina Hidrelétrica de Furnas, sul de Minas Gerais, delimitada pelas coordenadas 21° 18' 55" e 21° 28' 31"S e 45° 58' 08" e 46° 21' 23"W, cobrindo parte dos Municípios de Alfenas, Alterosa, Areado, Cabo Verde, Divisa Nova e Monte Belo (Figura 13). A região se encontra na bacia hidrográfica do Rio Grande, que tem os rios Sapucaí, Machado e

Cabo Verde como seus principais afluentes (Instituto Mineiro de Gestão das Águas (IGAM), 2012).

A região se encontra no Cinturão Orogênico Brasília, integrante do Sistema Tocantins, apresenta litologias estruturadas após diversos eventos tectônicos, como convergência de placas e colisão de massas continentais, ocorridos no Brasiliano II, entre 670 e 530 Ma (HASUI, 2010). Segundo o autor, trata-se de um dobramento antigo, basicamente composto por rochas metamórficas, que sofreu longos processos erosivos durante milhões de anos. Ross (2006) aponta a região como pertencendo à unidade dos Planaltos e Serras de Goiás - Minas, o relevo desenvolvido é de serras e morros alongados e estreitos, com altitudes médias entre 800 e 1000 metros, e solos do tipo Latossolo Vermelho e Argissolo Vermelho-Amarelo.

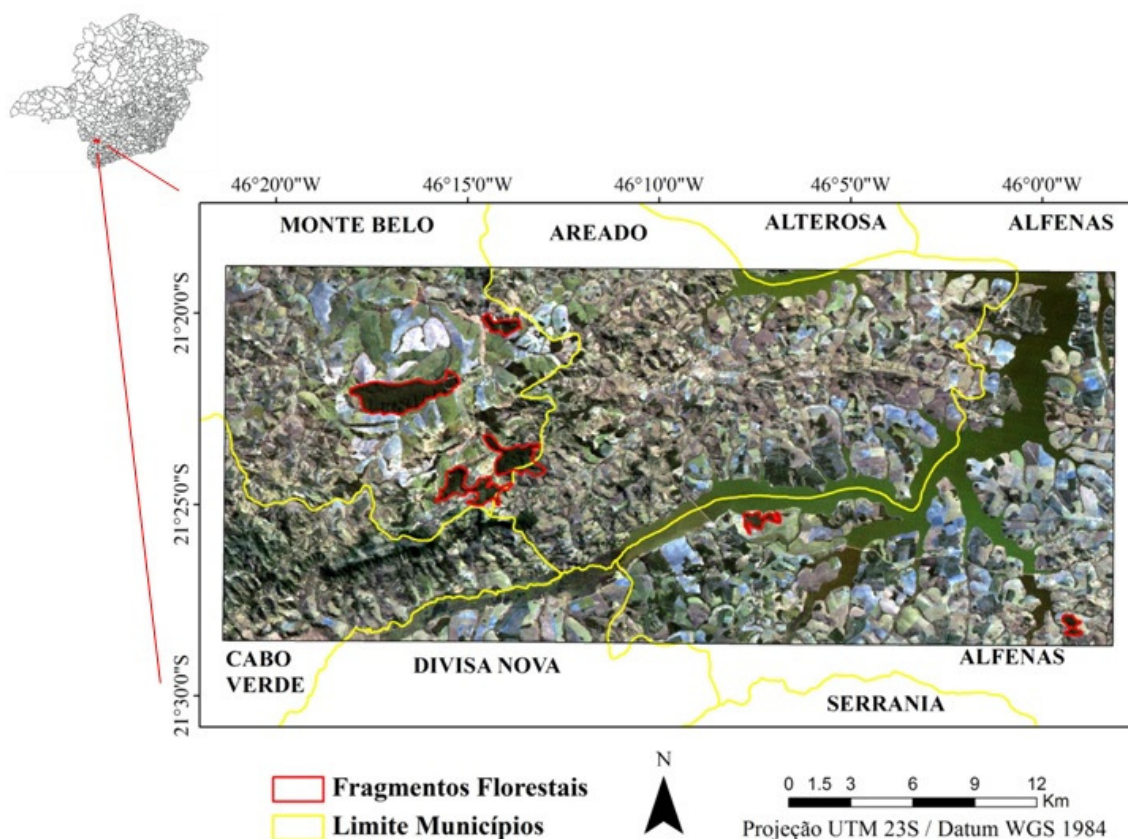


Figura 13- Localização da Área de estudo.

Nota: A área de estudo cobre parte dos Municípios de Alfenas, Alterosa, Areado, Cabo Verde, Divisa Nova e Monte Belo, no sul de Minas Gerais. A imagem corresponde a uma composição colorida 3R2G1B do satélite Landsat-5 TM de 27/08/2011. Em destaque os principais fragmentos florestais estudados pelo projeto temático que este trabalho engloba.

Fonte: do autor.

O clima predominante na região sul de Minas é o Cwa (temperado úmido), apresentando estações bem definidas com o inverno seco e frio, média de 19,7 °C, e o verão quente e

chuvoso, média de 22,7 °C (PEEL; FINLAYSSON; MCMAHON, 2007). As chuvas se concentram entre os meses de Outubro e Março, com precipitação mensal média acima de 110 mm, sendo que nos meses de Novembro e Dezembro, as médias de precipitações excedem os 210 mm (MELLO et al. 2007). Regiões caracterizadas por esse clima são propícias para o desenvolvimento de atividades agrícolas que necessitam de baixas temperaturas e média menor que 20 °C no inverno (SÁ JUNIOR et al. 2011).

A vegetação original predominante da região era a Floresta Tropical Atlântica, caracterizada por ser uma floresta semi-decidual e de encosta (ROSS, 2006). Seu desenvolvimento foi favorecido pelo relevo montanhoso e condições climáticas quentes e úmidas, formando florestas perenifólias com diversos extratos vegetais, ricas em espécies vegetais capazes de fornecer grande volume de biomassa. Em função dos muitos anos de ocupação humana, quase toda a cobertura vegetal foi convertida em agricultura e pastagens, aumentando o risco de extinção de diversas espécies animais e vegetais, além dos problemas de erosão e contaminação de corpos d'água (CARVALHO JUNIOR et al. 2008; SERAFIM et al. 2008).

A ocupação da região se deu por volta do séc. XVIII, com pequenas propriedades que utilizavam técnicas rudimentares e pequenos roçados para agricultura de subsistência, próximo ao fim da exploração do ouro no Estado de Minas Gerais. No séc. XIX, durante as décadas de 1860 e 1870, teve início o cultivo do café na região, ajudando a introduzir um grande número de escravos nas fazendas cafeeiras (PASCOAL, 2007). Alguns anos mais tarde o café se tornou o cultivo predominante na região, influenciando diretamente a economia sulmineira. A cana-de-açúcar e o milho também eram cultivados, fornecendo produtos derivados destinados ao comércio com localidades vizinhas. Outra fonte de renda à época era a criação de gado (MARTINS, 2013).

Ao longo dos anos, mais florestas nativas foram derrubadas para o plantio do café. Algumas áreas de cultivo abandonadas se tornavam áreas de pastagens. Com a evolução de técnicas agrícolas no séc. XX, os cultivos tradicionais começaram a ser substituídos por sistemas mais desenvolvidos, utilizando técnicas modernas de cultivo e diversas variedades de café (ROSS, 2006).

5.2 IMAGENS LANDSAT-5 TM

Para a realização do presente estudo foram utilizadas imagens do satélite Landsat-5 TM bandas 1 a 5 e 7 datadas de 09/08/1987 (ângulo de elevação solar: 35,86° e de azimute: 49,0°) e 27/08/2011 (ângulo de elevação solar: 44,58° e de azimute: 48,6°) correspondentes a órbita 219/75, conforme está indicado na Tabela 3. As duas cenas utilizadas foram adquiridas em datas próximas para evitar as diferenças de brilho das imagens causadas por fatores de iluminação e mudanças nos estágios fenológicos dos cultivos. O período seco foi escolhido para evitar confusões espectrais principalmente entre as classes pastagem e cana-de-açúcar. Estas imagens foram adquiridas gratuitamente no sítio do INPE (<http://www.dsr.inpe.br/>).

Tabela 3- Descrição das imagens Landsat utilizadas.

Bandas	Intervalos (μm)	Datas	Ângulo de azimute	Elevação solar
TM 1	0,45 - 0,52			
TM 2	0,52 - 0,60	09/08/1987	49,09	35,86
TM 3	0,63 - 0,69			
TM 4	0,76 - 0,9			
TM 5	1,55 - 1,75	27/08/2011	48,65	44,58
TM 7	2,08 - 2,35			

Fonte: do autor.

5.3 CORREÇÃO GEOMÉTRICA

Para realizar a correção geométrica, foi utilizada como referência uma composição colorida do satélite Landsat-5 TM ortorretificada de 03/05/2004 adquirida gratuitamente no sítio do *Global Land Cover Facility* (GLCF) (<http://glcf.umd.edu/>). Esta imagem foi recortada e utilizada como base cartográfica para identificação de pontos de controle. Nas imagens Landsat de 1987 e 2011 foram distribuídos 35 pontos de controle (Figura 14). O valor de ajuste polinomial após a definição dos pontos de controle foi abaixo do valor médio recomendado de 1 *pixel* (CROSTA, 1992). O interpolador

utilizado na reamostragem foi o Vizinho Mais Próximo. Este interpolador foi utilizado porque não altera o valor do pixel da imagem original: critério este importante na classificação de imagens.

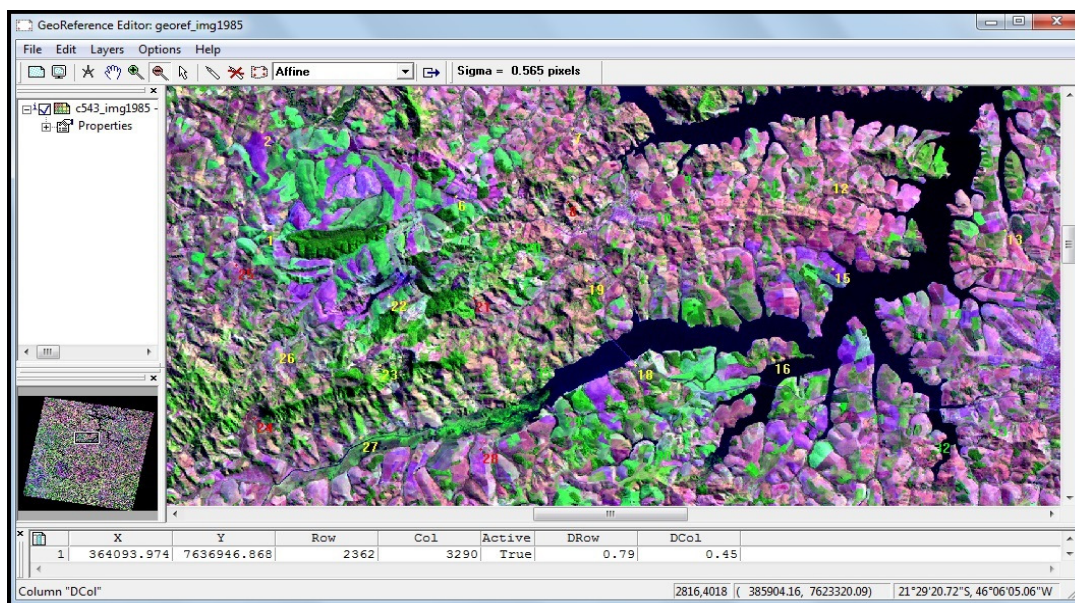


Figura 14- Georreferenciamento.

Nota: Interface do SIG Ilwis no momento da identificação dos 35 pontos de controle da imagem de 1987.

Fonte: do autor.

5.4 SEGMENTAÇÃO E EXTRAÇÃO DE ATRIBUTOS

Os tipos de dados e a área em questão são fundamentais para determinar qual tipo de segmentação deve ser implementada. Na segmentação baseada em regiões, os agrupamentos de *pixels* apresentam limites interligados, é de simples execução e muito eficaz nos resultados. A desvantagem dessa técnica é a associação de *pixels* de borda à regiões vizinhas devido principalmente à presença de ruídos nas imagens (BINS et al. 1996; JENSEN, 2005).

A segmentação das imagens de 1987 e 2011 foi feita utilizando o algoritmo de crescimento de regiões apresentado por Bins et al. (1996). Dois parâmetros são definidos na segmentação: o critério de similaridade e de área. O critério de similaridade define a distância espectral entre os valores das médias de intensidade de duas regiões e o critério

de área define o tamanho mínimo da região a ser definida. Os limiares de segmentação para cada conjunto de imagem foram definidos de maneira visual testando-se diferentes valores até alcançar um particionado considerado adequado, ou seja, um resultado de segmentação que apresentasse nem excesso de segmentos (*over-segmentation*) e nem falta de segmentos (*under-segmentation*). Finalizada a etapa de segmentação, iniciou-se a etapa de extração de atributos. Todos os atributos espectrais e espaciais disponíveis no GeoDMA foram utilizados (KÖRTING et al. 2013).

5.5 MINERAÇÃO DE DADOS

Seguindo a definição de Fayyad et al. (1996), mineração de dados é entendido como a aplicação de algoritmos específicos para a extração de padrões de dados. A mineração de dados se insere dentro de um contexto maior denominado de *Knowledge Discovery in Databases* (KDD) cujo objetivo primordial é a descoberta de conhecimento útil a partir de volumosos bancos de dados.

No campo do SR, a grande vantagem da mineração de dados em aplicações relacionadas ao mapeamento do uso da terra é a possibilidade de contemplar uma ampla gama de atributos sejam espectrais, espaciais ou texturais. Além disto, possibilita a geração automática da estrutura do conhecimento que por meio da árvore de decisão é possível ter a exata noção dos critérios adotados no processo de classificação.

Foram definidas 6 classes de uso da terra: Água, Café, Cana-de-açúcar, Mata, Pastagem e Solo Exposto. A classe Mata engloba principalmente os remanescentes florestais, incluindo também regiões de mata ciliar, e pequenos trechos com vegetação mais densa. A classe Café inclui os cultivos em produção e os cafezais velhos. As classes Solo Exposto e Pastagem apresentam grande diversidade espectral, sendo a primeira composta principalmente por solos que estão sendo preparados para cultivos. Já a classe Pastagem inclui tanto os pastos secos quanto os pastos sujos e os banhados, encontrados principalmente nas regiões onde a Represa de Furnas apresenta variação de nível de acordo com o regime das chuvas.

A amostragem foi feita visualmente utilizando os critérios da fotointerpretação (CERON; DINIZ, 1966), visitas em campo e auxílio das imagens de alta resolução do *Google Earth* (datas: 19/05/2013 e 02/02/2014). Após a seleção das amostras, todos os atributos extraídos na etapa anterior foram selecionados para a geração da árvore de decisão. O GeoDMA utiliza o algoritmo C4.5 desenvolvido por Quinlan (1993) para a geração da árvore de decisão. A escolha dos atributos é baseada em uma métrica de entropia denominada de ganho de informação. Assim, os atributos com maiores ganhos de informação são selecionados na construção da árvore de decisão.

5.6 EDIÇÃO DE ERROS

Os erros gerados na classificação (erros de omissão e comissão) foram corrigidos manualmente com base em informações de campo e com auxílio das imagens do *Google Earth*. As confusões de rotulação das classes foram corrigidas por meio da edição de polígonos. Já os erros de fronteira de classes resultantes da segmentação foram corrigidos por meio da edição matricial.

5.7 MATRIZ DE DETECÇÃO DE MUDANÇAS

A matriz de detecção de mudanças (MDM) é um método quantitativo muito utilizado em SR. Através deste método, dois mapas são comparados por meio de uma tabulação de base *pixel-a-pixel*. A MDM é construída confrontando um mapa com as suas respectivas classes na linha da matriz (classificação de 1987) e outro mapa na coluna da matriz (classificação de 2011). Na diagonal principal desta matriz encontram-se discriminados os números de *pixels* que não sofreram alteração. Fora da diagonal principal são registrados os números de pixels que correspondem as mudanças (JENSEN, 2005).

Ao utilizar MDM é importante que cada mapa a ser analisado esteja adequadamente classificado, pois caso um dos mapas contenha alguma imprecisão, esta estará contida no mapa de detecção de mudanças. Além disto, é importante que os mapas de entrada estejam perfeitamente registrados, pois caso haja erro de posicionamento, as mudanças identificadas na matriz não expressarão as mudanças registradas na paisagem.

Para realizar o mapeamento do uso da terra/cobertura vegetal, optou-se por utilizar a classificação baseada em segmentos por meio da técnica de mineração de dados implementado no GeoDMA.

A segmentação utilizada no trabalho foi pela técnica de crescimento de regiões proposta por Bins et al. (1996). Para realizar a segmentação da imagem, são necessários dois valores de limiares, um para a similaridade e um para área mínima. O limiar de similaridade é o valor que expressa a distância Euclidiana entre as médias de intensidade de duas regiões. O tamanho da área expressa o número mínimo de *pixels* que serão considerados em uma única região.

6 RESULTADOS E DISCUSSÃO

Após a realização de vários testes de segmentação, os limiares que resultaram em uma segmentação mais adequada foram 25 para similaridade e 10 para área mínima. Estes limiares foram adotados para as duas datas analisadas. Foram gerados neste processo 24729 segmentos para a imagem de 1987 e 22469 segmentos para a imagem de 2011.

A árvore de decisão gerada para o ano de 1987 é ilustrada na Figura 15. Conforme pode ser observado, primeira divisão realizada utilizou a moda da banda 3 (vermelho), onde os objetos com valores iguais ou abaixo de 34,0 e com valores de moda da banda 4 (infravermelho próximo) iguais ou abaixo de 8,0 foram classificados como Água. Os valores acima de 8,0 e abaixo de 13,2 de desvio padrão da banda 4 foram classificados como Mata. Os valores iguais ou acima de 13,2 e com valores iguais ou abaixo de 13,3 de homogeneidade na banda 7 (infravermelho médio) também foram classificados como Mata, enquanto os valores acima de 13,3 foram classificados como Café.

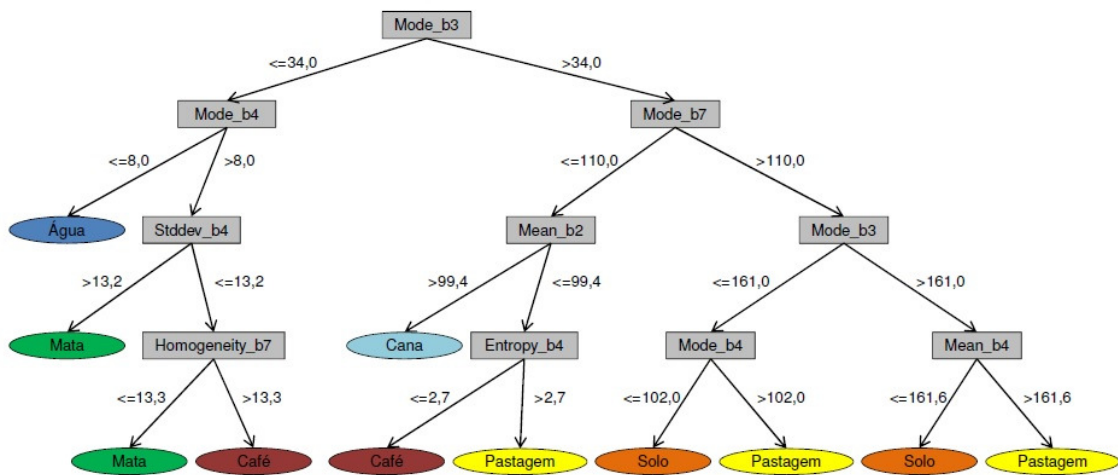


Figura 15. Árvore de decisão da imagem Landsat-5 TM de 09/08/1987.

Fonte: do autor.

Objetos com valores superiores a 34,0 de moda na banda 3 foram subdivididos. Aqueles que apresentam valores iguais ou abaixo de 110,0 de moda na banda 7 e superiores a 99,4 de média na banda 2 (verde) foram rotulados como Cana-de-açúcar. Os objetos com valores iguais ou acima de 99,4 e iguais ou abaixo de 2,7 de entropia na banda 4 foram classificados como Café. Já os valores acima de 2,7 foram rotulados como Pastagem.

Os objetos com valores superiores a 110,0 de moda na banda 7 foram subdivididos. Na divisão seguinte, objetos com valores de moda na banda 3 iguais ou abaixo de 161,0 e de moda na banda 4 iguais ou inferiores a 102,0 foram classificados como Solo Exposto, enquanto os objetos que apresentam valores superiores a 102,0 foram classificados como Pastagem. Já os objetos com valores acima de 161,0 e iguais ou abaixo de 161,5 de média na banda 4 também foram rotulados como Solo Exposto, enquanto os objetos com valores acima de 161,5 foram classificados como Pastagem.

Apenas atributos espectrais foram selecionados na árvore de decisão de 1987, indicando a importância do comportamento espectral dos objetos na determinação de sua classificação. Os parâmetros de moda e média determinaram a rotulação das classes Água e Cana-de-açúcar, respectivamente. Para as classes Mata e Café, os atributos desvio padrão, homogeneidade e entropia (atributos texturais), determinaram a classificação dos objetos. Objetos rotulados como Mata apresentam em geral textura mais grosseira em relação a outros objetos, embora o seu comportamento espectral seja similar ao Café. A classe Café apresenta grande diversidade espectral em razão do manejo adotado no cultivo. Nos estágios iniciais de desenvolvimento, por exemplo, o café formação apresenta comportamento espectral similar a pastagem verde.

As classes Pastagem e Solo Exposto apresentam certa confusão de associação de objetos, o que pode ser explicado pelo fato destas classes englobarem áreas de solo em diferentes níveis de preparação para cultivo (cana-de-açúcar principalmente), bem como áreas de pastagem suja, pastagem limpa e áreas de cultivo abandonadas que se transformaram em pastagem. Devido a grande diversidade espectral do Café, da Pastagem e do Solo Exposto, estas foram classificados em diferentes partes da árvore de decisão. Percebe-se que as informações derivadas da banda 4, infravermelho próximo, foi determinante na delimitação de cinco das seis classes, confirmando a eficácia da informação do infravermelho próximo no mapeamento do uso da terra.

A Figura 16 ilustra a árvore de decisão gerada para a imagem de 2011. Nessa árvore a primeira divisão envolveu os objetos com valores de média na banda 3 iguais ou abaixo de 66,4. Os objetos foram subdivididos e aqueles com valores de moda na banda 4 iguais ou abaixo de 17,0 foram classificados como Água. Os objetos de valores acima de 17,0 e com valores de moda na banda 7 iguais ou abaixo de 59,0 foram classificados como Mata. Os objetos com valores acima de 59,0 e iguais ou abaixo de 187,5 de média na

banda 4 foram classificados como Café, enquanto os objetos com valores acima de 187,5 também foram classificados como Mata.

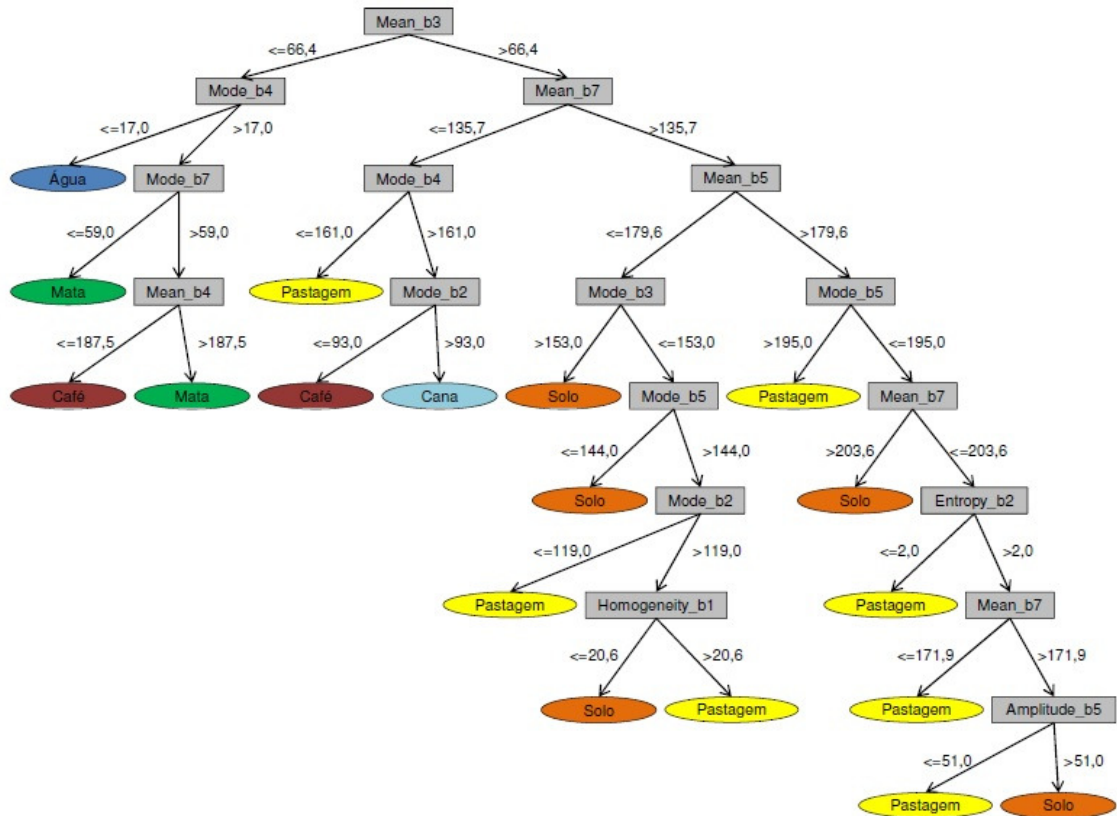


Figura 16. Árvore de decisão da imagem Landsat-5 TM de 27/08/2011.

Fonte: do autor.

Aqueles objetos com valores superiores a 66,4 de média na banda 3 foram subdivididos. Objetos com valores de média na banda 7 iguais ou inferiores a 135,7 e de moda na banda 4 iguais ou inferiores a 161,0 foram rotulados como Pastagem. Os objetos superiores a 161,0 e iguais ou inferiores a 93,0 de moda na banda 2 foram classificados como Café, enquanto os objetos superiores a 93,0 foram classificados como Cana-de-açúcar.

Os objetos com valores superiores a 135,7 foram subdivididos de acordo com os valores de média na banda 5 (infravermelho médio). Aqueles com valores iguais ou abaixo de 179,5 e com valores de moda na banda 3 superiores a 153,0 foram classificados com Solo Exposto. Objetos com valores iguais ou abaixo de 153,0 e com valores de moda na banda 5 iguais ou abaixo de 144,0 também foram rotulados como Solo Exposto. Já aqueles com valores acima de 144,0 e com valores de moda na banda 2 iguais ou abaixo de 119,0 foram classificados como Pastagem. Os objetos com valores superiores a 119,0 e com

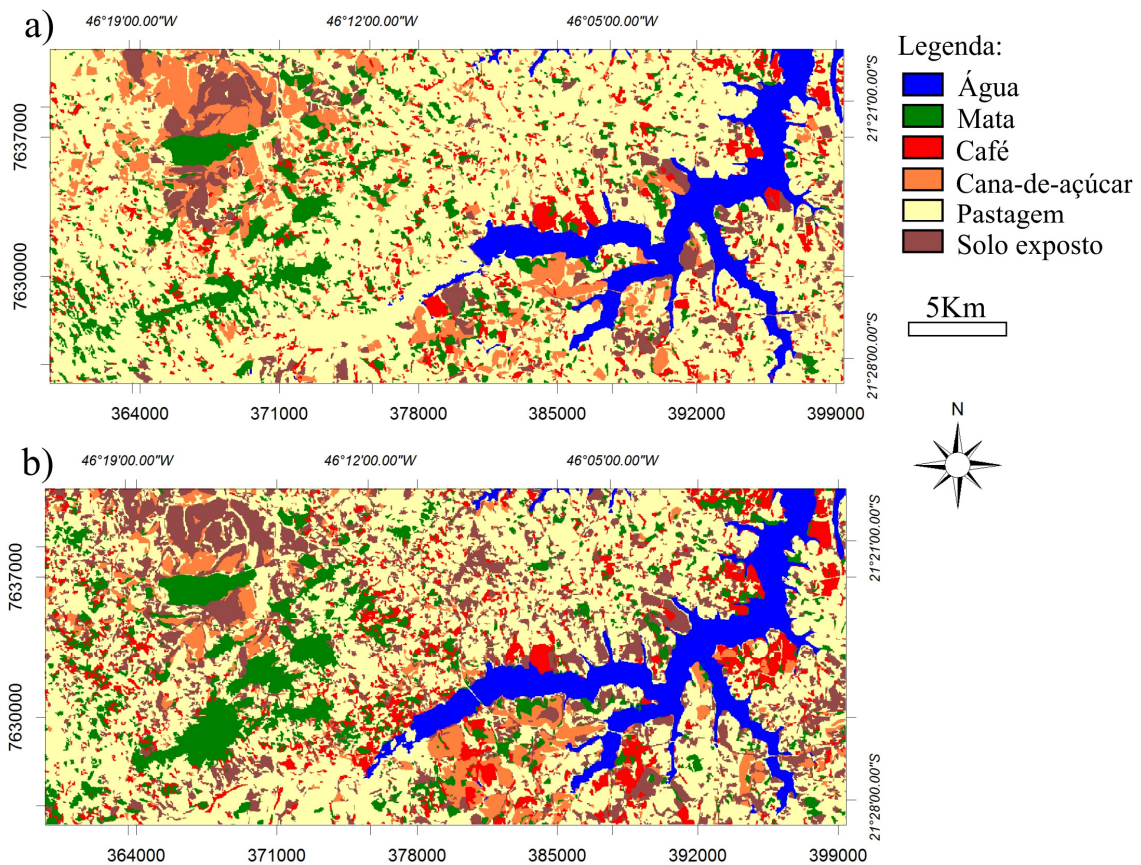
valores de homogeneidade na banda 1 (azul) iguais ou abaixo de 20,6 foram classificados como Solo Exposto, enquanto os que apresentam valores superiores a 20,6 foram classificados como Pastagem.

Objetos com valores superiores a 179,5 de média na banda 5 e com valores de moda na banda 5 superiores a 195,0 foram classificados como Pastagem. Os objetos com valores iguais ou abaixo de 195,0 foram subdivididos, e aqueles com valores de média na banda 7 e superiores a 203,6 foram classificados como Solo Exposto. Objetos com valores iguais ou abaixo de 203,6 e de entropia na banda 2 iguais ou abaixo de 2,0 foram rotulados como Pastagem, assim como os objetos com valores acima de 2,0 e com média na banda 7 iguais ou abaixo de 171,9. Os objetos com valores superiores a 171,9 e com valores de amplitude na banda 5 iguais ou abaixo de 51,0 também foram rotulados como Pastagem, enquanto os que apresentam valores acima de 51,0 foram classificados como Solo Exposto.

Assim como na árvore anterior, esta árvore selecionou somente atributos espectrais. O parâmetro moda foi o mais utilizado, seguido pela média, enquanto a homogeneidade, entropia e amplitude foram utilizados somente uma vez cada. A classe Água foi atribuída a um nó distinto, já que objetos a ela associados possuem comportamento espectral singular. Como na árvore anterior, a classe Mata apresentou alguma confusão com a classe Café. O mesmo ocorreu com a classe Cana-de-açúcar (confusão com Café), podendo estar associado ao comportamento espectral de algumas áreas de cultivo de café e de cana-de-açúcar que se encontram em estágios próximos de desenvolvimento.

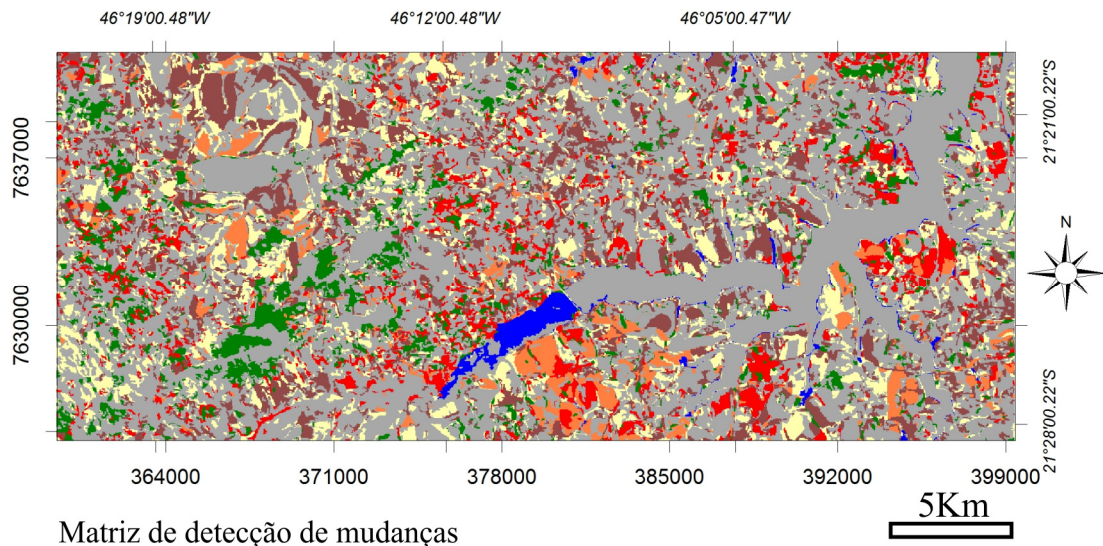
As classes Pastagem e Solo Exposto apresentam confusão em dois momentos, sendo que em ambos o algoritmo selecionou atributos texturais (homogeneidade e amplitude). Isto pode ser explicado pela generalização de áreas durante o processo de amostragem, visto que áreas com diferentes tipos de solo exposto (solos preparados para cultivo de café ou cana-de-açúcar) e de pastagens (pastagem limpa, pastagem suja, cultivos abandonados) apresentam características espectrais próximas. Pastagem e Solo Exposto também foram definidos em nós distintos da árvore, sendo a moda o atributo espectral de maior relevância. É importante ressaltar que os valores de moda de cinco das seis bandas analisadas foram selecionados pelo algoritmo, comprovando a importância da complementaridade das informações espectrais de diferentes faixas do espectro.

Os resultados das classificações após as edições realizadas são ilustrados na Figura 17. Conforme pode ser observado, a Pastagem é a classe predominante na região constituindo a matriz da paisagem. Fragmentos de Mata se encontram principalmente na porção oeste, em áreas de relevo mais acidentado. As culturas de Café concentram-se nas proximidades da represa de Furnas. O cultivo de maior expressão espacial é a Cana-de-açúcar, localizada nas porções noroeste e centro-sul da área de estudo onde o terreno mais plano favorece a mecanização do cultivo. As manchas de Solo Exposto localizadas nas proximidades das lavouras de Cana-de-açúcar correspondem as terras sendo preparadas para este mesmo cultivo.



O mapa com a matriz de detecção de mudanças é ilustrado na Figura 18. Os valores da diagonal principal correspondem ao número de pixels que não mudaram. A última coluna e linha descrevem a porcentagem de mudança ocorrida para cada classe analisada. As classes que apresentaram maiores mudanças foram o Café, a Cana-de-açúcar e o Solo Exposto. Tal fato se deve ao incremento das atividades agrícolas na

região. Em termos de números absolutos, a classe Pastagem foi que apresentou maior perda de área em razão do incremento dos cultivos mencionados.



Classificações		2011					Totais	Mudanças (%)	
		Água	Café	Cana	Mata	Pastag.			Solo Exp.
1987	Água	56303	366	246	662	1335	239	59151	4,8
	Café	359	9620	3427	6100	21797	6505	47808	80,6
	Cana	411	3354	13499	3280	26445	23208	70197	80,7
	Mata	258	7359	1731	40796	16231	2647	69022	40,8
	Pastag.	7164	38924	20598	33037	269370	73397	442490	39,1
	Solo Exp.	249	3889	7669	1024	22030	21059	55920	62,3
Totais		64744	63512	47170	84899	357208	127055	744588	
Mudanças (%)		13,0	84,8	71,3	51,9	24,5	83,4		

Figura 18. Mapa de mudanças.

Nota: Produzido utilizando a lógica de matriz de detecção de mudanças aplicado as imagens Landsat-5 TM de 09/08/1987 e 27/08/2011. Cada *pixel* corresponde a uma área de 900 metros quadrados.

Fonte: do autor.

A classe Café apresentou mudanças consideráveis principalmente na porção leste. Nota-se um aumento da expansão da Cana-de-açúcar principalmente na porção sul. Já a classe Solo Exposto apresentou mudanças em toda a extensão, envolvendo principalmente áreas de solo que estão sendo ou já foram preparadas para cultivo de cana-de-açúcar (porção noroeste) e de café (centro, no entorno do reservatório). A classe Mata foi incrementada principalmente na porção centro-oeste, onde o terreno apresenta maior declividade, e também onde a vegetação consegue se desenvolver mais facilmente, seja

por proteção legal ou por condições ambientais. Em razão da diferença no nível do reservatório, observou-se um incremento considerável da classe Água.

7 CONCLUSÕES

Conforme foi observado, nenhum atributo espacial foi considerado na geração das árvores de decisão. Tal resultado demonstra que neste estudo, o comportamento espectral foi mais decisivo que a distribuição e o arranjo espacial dos objetos. A utilização de árvores de decisão em classificação de imagens de satélite possui várias vantagens. Além de não requerer suposições com relação à distribuição das amostras, a árvore de decisão é de fácil interpretação, possibilita considerar variáveis categóricas e numéricas e permite incorporar relações não lineares entre classes. Tal característica explica o fato de classes com grande diversidade espectral serem alocadas em diferentes ramos da árvore de decisão.

Com relação ao método de detecção por meio da matriz de mudanças, este se mostrou bastante eficaz na comparação entre duas datas analisadas. As áreas que não sofreram mudanças foram alocadas na diagonal principal da matriz e os valores alocados fora da diagonal principal revelaram as mudanças ocorridas entre os anos observados. Por meio dessa matriz, foi possível ter uma clara noção da dinâmica que ocorreu na paisagem estudada, destacando o aumento em termos de área das classes Solo Exposto, Cana-de-açúcar e Mata. É importante salientar que muitas das áreas de Solo Exposto são áreas preparadas para o cultivo da Cana-de-açúcar, explicando assim a grande diminuição da classe Pastagem.

Os resultados mostraram que a paisagem se tornou mais fragmentada na classificação de 2011, sugerindo um maior aproveitamento da paisagem com outros cultivos agrícolas, como: cana-de-açúcar, café e solo exposto. A cana-de-açúcar é o cultivo que mais se expandiu na região, favorecido pelo relevo plano e pelo desenvolvimento tecnológico no campo da agricultura. Percebe-se que os fragmentos se encontram imersos em diferentes matrizes agrícolas, como café, cana-de-açúcar e pastagens, e cada uma dessas matrizes influenciam de formas distintas estes fragmentos, visto que cada uso apresenta características próprias, portanto, o ganho de informações sobre o comportamento de diferentes usos ao longo dos anos se traduz em uma excelente ferramenta para o direcionamento de alternativas para conservação e gestão de fragmentos.

REFERÊNCIAS

AHLERT, S.; SIMÕES, J. C. Padrões morfológicos da ilha Brabant, Antártica. **Pesquisas em Geociências**. Porto Alegre, v. 36, n. 1, p. 05-10, 2009.

ALBHAISI, M.; BRENDONCK, L.; BATELAAN, O. Predicted impacts of land use change on groundwater recharge of the upper Berg catchment, South Africa. **Water SA**, v. 39, n. 2, p. 211-220, 2013.

ALMEIDA, A. et al. Análise sobre a fragmentação dos remanescentes de Mata Atlântica na APA do Pratigi para identificar as áreas com maiores potenciais para a construção de corredores ecológicos baseados no método AHP. **Revista AGIR de Ambiente e Sustentabilidades Ibirapitanga**, v. 2, n. 3, p. 31-43, 2010.

ANDERSON, J. R. et al. **A land use and land cover classification system for use with remote sensor data**. Washington: USGS, United States Government Printing Office, 1976.

ÁNGEL, S. P.; ACEVEDO, J. A. A. Evaluation of the causes of error in the MCD45 burned-area product for the savannas of northern South America. **Dyna**. Medellín, v. 79, n. 176, p. 35-44, 2012.

ATKINSON, P. M.; LEWIS, P. Geostatistical classification for remote sensing: an introduction. **Computers & Geosciences**, v. 26, n. 4, p. 361-371, 2000.

BINS, L. S.; ERTHAL, G. J.; FONSECA, L. M. G. Um método de classificação não supervisionada por regiões. **SIBGRAPI**, v. 6, p. 65-68, 1993.

BINS, L. S. et al. Satellite imagery segmentation: a region growing approach. In: Simpósio Brasileiro de Sensoriamento Remoto, 8, 1996, Salvador. **Anais...** Salvador: INPE, 1996. p. 677-680.

BLASCHKE, T. Object based image analysis for remote sensing. **Journal of Photogrammetry and Remote Sensing**, v. 65, n. 1, p. 2-16, 2010.

BREWER, C. K. et al. Classifying and mapping wildfire severity: a comparison of methods. **Photogrammetric Engineering & Remote Sensing**, v. 71, n. 11, p. 1311-1320, 2005.

CALDERANO FILHO, B. et al. Diagnóstico geoambiental da área do entorno do reservatório da usina hidrelétrica de Tombos, para fins de recuperação de áreas degradadas. **Caminhos da Geografia**, v. 10, n. 30, p. 118-134, 2009.

CARVALHO JUNIOR, O. A. et al. Mapeamento da vegetação na floresta atlântica usando o classificador de árvore de decisão para integrar dados de sensoriamento remoto e modelo digital de terreno. **Revista Brasileira de Geofísica**, v. 26, n. 3, p. 331-345, 2008.

CERON, A. O.; DINIZ, J. A. F. O uso de fotografias aéreas na identificação das formas de utilização agrícola da terra. **Revista Brasileira de Geografia**. v. 2, n. 28, p.161-173, 1966.

CHEN, Q. et al. Fast segmentation of high-resolution satellite images using watershed transform combined with an efficient region merging approach. **Lecture Notes in Computer Science**, v. 3322, p. 621-630, 2004.

CONCEIÇÃO, L. A. B. S. **Diagnóstico ambiental através do uso técnico de sensoriamento remoto como apoio para o planejamento de unidades administrativas: o caso de Osório, RS.** 2004. 82f. Dissertação (Mestrado em Sensoriamento Remoto) - Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, UFRS, Porto Alegre, 2004.

CROSTA, A. P. **Processamento digital de imagens de sensoriamento remoto.** 3°. Reimp. Campinas: IG UNICAMP, 1992. 164 p.

DIAS, L. A. V. et al. Imagens e computadores: o olho que tudo vê. **Revista Ciência Hoje**, v. 7, n. 37, 1987.

DRONOVA, I. et al. Landscape analysis of wetland plant functional types: the effects of image segmentation scale, vegetation classes and classification methods. **Remote Sensing of Environment**, v. 127, p. 357-369, 2012.

DU, Y.; TEILLET, P. M.; CIHLAR, J. Radiometric normalization of multitemporal high-resolution satellite images with quality control for land cover change detection. **Remote Sensing of Environment**, v. 82, n. 1, p. 123-134, 2002.

D'ALGE, J. C. L. Qualidade geométrica de imagens TM do LANDSAT-5. **Congresso Brasileiro de Cartografia**, INPE: DPI, 1987.

EMBRAPA. **Satélites de Monitoramento**. Campinas: Embrapa Monitoramento por Satélite, 2013. Disponível em: <<http://www.sat.cnpm.embrapa.br>>. Acesso em: 23 abr. 2014.

FAN, J. et al. Seeded region growing: an extensive and comparative study. **Pattern Recognition Letters**, v. 26, n. 8, p. 1139-1156, 2005.

FAYYAD, U. et al. From data mining to knowledge discovery in databases. **AI Magazine**, v. 17, n. 3, p. 37-54, 1996.

FRIEDL, M. A.; BRODLEY, C. E. Decision tree classification of land cover from remotely sensed data. **Remote Sensing of Environment**, v. 61, n. 3, p.399–408, 1997.

FUJACO, M. A. G.; LEITE, M. G. P.; MESSIAS, M. C. T. B. Multitemporal analysis of land use changes in the Itacolomi State Park (MG) by geoprocessing techniques. **Revista Escola de Minas**. Ouro Preto, v. 63, n. 4, p. 695-701, 2010.

GARMENDIA, A. et al. Landscape and patch attributes impacting medium- and large-sized terrestrial mammals in a fragmented rain forest. **Journal of tropical Ecology**, v. 29, n. 4, p. 331-344, 2013.

GONZALEZ, R. C.; WOODS, R. C. **Processamento Digital de Imagens**. Tradução de Cristina Yamagami e Leonardo Piamonte. 3ª ed. São Paulo: Pearson Prentice Hall, 2010. 624p.

GOODWIN, N. R. et al. Estimation of insect infestation dynamics using a temporal sequence of Landsat data. **Remote Sensing of Environment**, v. 112, n. 9, p. 3680-3689, 2008.

HARIS, K. et al. Hybrid image segmentation using watersheds and fast region merging. **Transactions on image processing**, v. 7, n. 12, p. 1684-1699, 1998.

HASUI, Y. A grande colisão pré-cambriana do sudeste brasileiro e a estruturação regional. São Paulo, UNESP, **Geociências**, v. 29, n. 2, p. 141-169, 2010.

IGAM. Secretaria do Estado de Meio Ambiente e Desenvolvimento Sustentável. **Unidade de planejamento e gestão de recursos hídricos do entorno do reservatório de Furnas**. 2010. Disponível em: <<http://www.igam.mg.gov.br/geoprocessamento/mapas/1260>>. Acesso em: jul. 2014.

IM, J.; JENSEN, J. R.; TULLIS, A. Object-based change detection using correlation image analysis and image segmentation. **International Journal of Remote Sensing**, v. 29, n. 2, p. 399-423, 2008.

INPE. Ministério da Ciência, Tecnologia e Inovação. **Satélites**. 2014. Disponível em: <http://www.dgi.inpe.br/siteDgi/index_pt.php>. Acesso em: jul. 2014.

JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. 3ª ed. EUA: Pearson Education, Inc., 2005. 544p.

JOAQUIM, G. et al. Mapeamento das geleiras de rocha com o uso de imagens satelitais e geoprocessamento, Cordilheira Tres Cruces, Bolívia. In: Simpósio Brasileiro de Sensoriamento Remoto, 15, 2011, Curitiba. **Anais...** Curitiba: INPE, 2011. p. 4194-4201.

KAWAKUBO, F. S. et al. Land-use and vegetation-cover mapping of an indigenous land area in the state of Mato Grosso (Brazil) based on spectral linear mixing model, segmentation and region classification. **Geocarto International**, v. 24, n. 2, p. 165-175, 2009.

KAWAKUBO, F. S. et al. Use of fraction imagery, segmentation and masking techniques to classify land-use and land-cover types in the Brazilian Amazon. In: **International Journal of Remote Sensing**. v. 34, n. 15, p. 5452–5467, 2013.

KENNEDY, R. E.; COHEN, W. B. Automated designation of tie-points for image-to-image coregistration. **International Journal of Remote Sensing**, v. 24, n. 17, p. 3467-3490, 2003.

KÖRTING, T. S. et al. GeoDMA - Um sistema para mineração de dados de sensoriamento remoto. In: Simpósio Brasileiro de Sensoriamento Remoto, 14, 2009, Natal. **Anais...** Natal: INPE, 2009. p. 7813-7820.

KÖRTING, T. S.; FONSECA, L. M. G.; CÂMARA, G. GeoDMA - Geographic Data Mining Analyst. **Computers & Geosciences**, v. 57, p. 133-145, 2013.

KURTEN, E. L. Cascading effects of contemporaneous defaunation on tropical forest communities. **Biological Conservation**, v. 163, p. 22-32, 2013.

LI, S.; YANG, B. Multifocus image fusion using region segmentation and spatial frequency. **Image and Vision Computing**, v. 26, n. 7, p. 971, 979, 2008.

LIU, D.; XIA, F. Assessing object-based classification: advantages and limitations. **Remote Sensing Letters**, v. 1, n. 4, p. 187-194, 2010.

LOPES, H. L. et al. Mapeamento de áreas aluvionares no semiárido brasileiro por meio de dados colaterais e imagens orbitais. **Revista Brasileira de Engenharia Agrícola e Ambiental**. Campina Grande, v. 17, n. 7, p. 763-769, 2013.

MARTINS, M. L. Plantar, pasturar e fiar na Vila Formosa de Alfenas, MG: décadas de 1850-1890. **Estudos Econômicos**, v. 43, n. 2, p. 397-429, 2013.

MCROBERTS, R. E. et al. Parametric, bootstrap, and jackknife variance estimators for the k-Nearest Neighbors technique with illustration using forest inventory and satellite image data. **Remote Sensing of Environment**, v. 115, n. 2, p. 3165-3174, 2011.

MELLO, C. R. et al. Erosividade mensal e anual da chuva no Estado de Minas Gerais. **Pesquisas agropecuárias brasileiras**, Brasília, v. 42, n. 4, p. 537-545, 2007.

MENESES, P. R.; ALMEIDA, T. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: UNB, 2012. 266p.

MONTEIRO, A.; LINGNAU, C.; SOUZA JÚNIOR., C. Classificação orientada a objeto para detecção da exploração seletiva de madeira na Amazônia. **Revista Brasileira de Cartografia**, v. 59, n. 3, p. 225-234, 2007.

MUELLER, M.; SEGL, K.; KAUFMANN, H. Edge- and region-based segmentation technique for the extraction of large, man-made objects in high-resolution satellite imagery. **Pattern Recognition**, v. 37, n. 8, p. 1619-1628, 2004.

MUNYATI, C.; RATSHIBVUMO, T.; OGOLA, J. Landsat TM image segmentation for delineating geological zone correlated vegetation stratification in the Kruger National Park, South Africa. **Physics and Chemistry of the Earth**, v. 55-57, p. 1-10, 2013.

NASA. **Landsat Data Continuity Mission**. 2013. Disponível em: <<http://ldcm.gsfc.nasa.gov/index.html>>. Acesso em: jul. 2013.

PASCOAL, I. Economia e trabalho no sul de Minas no século XIX. **Economia e Sociedade**, v. 16, n. 2, p. 259-287, 2007.

PEEL, M. C.; FINLAYSON, B. L.; MCMAHON, T. A. Update world map of the Köppen-Geiger climate classification. **Hydrology and Earth System Sciences**, v. 11, p. 1633-1644, 2007.

PEREIRA, A. A. et al. Validação de focos de calor utilizados no monitoramento orbital de queimadas por meio de imagens TM. **Cerne**. Lavras, v. 18, n. 2, p. 335-343, 2012.

PFLUGMACHER, D.; COHEN, W. B.; KENNEDY, R. E. Using Landsat-derived disturbance history (1972-2010) to predict current forest structure. **Remote Sensing of Environment**, v. 122, p. 146-165, 2012.

PIROMAL, R. A. S. et al. Utilização de dados MODIS para a detecção de queimadas na Amazônia. **Acta Amazonica**, v. 38, n. 1, p. 77-84, 2008.

PHUA, M. H. et al. Detecting deforestation with a spectral change detection approach using multitemporal Landsat data: a case study of Kinabalu Park, Sabah, Malaysia. **Journal of Environmental Management**, v. 88, n. 4, p.784-795, 2008.

PRADO, R. B.; NOVO, E. M. L. M. Avaliação espaço-temporal da relação entre o estado trófico do reservatório de Barra Bonita (SP) e o potencial poluidor de sua bacia hidrográfica. **Sociedade & Natureza**, Uberlândia, v.19, n. 2, p. 5-18, 2007.

QUINLAN, J. R. **C4. 5: Programs for Machine Learning**. Morgan Kaufmann, San Francisco, 1993. 302 p.

ROBERTSON, K.; CASTIBLANCO, M. A. Amenazas fluviales en el piedemonte amazónico colombiano. **Revista Colombiana de Geografía**. Bogotá, v. 20, n. 2, p. 125-137, 2011.

ROCHA, C. F. D. et al. The remnants of restinga habitats in the Brazilian Atlantic Forest of Rio de Janeiro state, Brazil: habitat loss and risk of disappearance. **Brazilian Journal of Biology**. Rio de Janeiro, v. 67, n. 2, p. 263-273, 2007.

ROSS, J. L. S. **Ecogeografia do Brasil**: subsídios para planejamento ambiental. São Paulo: Oficina de textos, 2006. 208p.

RUDORFF, F. M.; GHERARDI, D. F. M. Coral reef detection using SAR/RADARSAT-1 images at Costa dos Corais, PE/AL, Brazil. **Brazilian Journal of Oceanography**. São José dos Campos, v. 56, n. 2, p. 85-96, 2008.

SANTOS, J. S.; LINGNAU, C. Monitoramento em área de catástrofe ambiental através de técnica de detecção de mudanças. **Cerne**. Lavras, v. 19, n. 1, p. 133-140, 2013.

SÁ JUNIOR, A. et al. Application of the Köppen classification for climatic zoning in the state of Minas Gerais, Brazil. **Theoretical and Applied Climatology**, v. 108, n. 1-2, p. 1-7, 2011.

SERAFIM, H. et al. Anurofauna de remanescentes de floresta Atlântica do município de São José do Barreiro, estado de São Paulo, Brasil. **Biota Neotropica**, v. 8, n. 2, p. 0-0, 2008.

SINGH, S.; HADDON, J.; MARKOU, M. Nearest-neighbour classifiers in natural scene analysis. **Pattern Recognition**, v. 34, n. 8, p. 1601-1612, 2001.

SHIMABUKURO, Y. E. et al. Levantamento de áreas desflorestadas na Amazônia através de processamento digital de imagens orbitais. **Floresta e Ambiente**, v. 6, n. 1, p. 38-44, 1999.

SHIMABUKURO, Y. E.; MAEDA, E. E.; FORMAGGIO, A. R. Remote Sensing and Geographic Information Systems applied to the study of agriculture and forest resources. **Ceres**, v. 56, n. 4, p. 399-409, 2009.

TESHIMA, Y.; IWASAKI, A. Correction of attitude fluctuation of Terra spacecraft using ASTER/SWIR imagery with parallax observation. **Transactions on Geoscience and Remote Sensing**, v. 46, n. 1, p. 222-227, 2008.

TUOMINEN, S.; HAAKANA, M. Landsat TM imagery and high altitude aerial photographs in estimation of forest characteristics. **Silva Fennica**, v. 39, n. 4, p. 573-584, 2005.

USGS. **Landsat - A Global Land-Imaging Mission**: U.S. Geological Survey Fact Sheet 2012-3072. 2012, 4 p. (Revised July 19, 2012).

VIDAL, M. M. et al. Produção de serrapilheira em floresta Atlântica secundária numa paisagem fragmentada (Ibiúna, SP): importância da borda e tamanho dos fragmentos. **Revista Brasileira Botânica**, vol. 30, n. 3, p. 521-532, 2007.

VIEIRA, M. A. et al. Object based image analysis and data mining applied to a remotely sensed Landsat time-series to map sugarcane over large areas. **Remote Sensing of Environment**, v. 123, p. 553-562, 2012.

VIEIRA, R. M. S. P. et al. Land use and land cover map of a semiarid region of Brazil for meteorological and climatic models. **Revista Brasileira de Meteorologia**. São José dos Campos, v. 28, n. 2, p. 129-138, 2013.

WANG, D. Unsupervised video segmentation based on watersheds and temporal tracking. **Transactions on circuits and systems for video technology**, v. 8, n. 5, 1998.

XIANG, H.; TIAN, L. Method for automatic georeferencing aerial remote sensing (RS) images from an unmanned aerial vehicle (UAV) platform. **Biosystems Engineering**, v. 108, n. 2, p. 104-113, 2011.

XU, N.; AHUJA, N.; BANSAL, R. Object segmentation using graph cuts based active contours. **Computer Vision and Image Understanding**, v. 107, n. 3, p. 210-224, 2007.

ZANELLA, L. **Análise da interferência antrópica na fragmentação da mata atlântica e modelos de simulação da paisagem na microrregião da Serra da Mantiqueira do estado de Minas Gerais**. 117f. Dissertação (Mestrado em Ecologia Aplicada), UFLA, Lavras, 2011.

ZHANG, Y. Evaluation and comparison of different segmentation algorithms. **Pattern Recognition Letters**, v. 18, n. 10, p. 963-974, 1997.

ZHANG, Y. et al. A study on coastline extraction and its trend based on remote sensing image data mining. **Abstract and Applied Analysis**, v. 2013, p. 1-7, 2013.

APÊNDICE

Artigo submetido à Revista Brasileira de Geografia Física.

Redigido conforme as normas dessa revista.

Autores: Diego Gomes de Sousa, Ronaldo Luiz Mincato, Fernando Shinji Kawakubo.

Análise Multitemporal do Uso da Terra Utilizando Imagens Landsat-5 TM da Região de Alfenas, Sul de Minas Gerais, Visando a Conservação de Fragmentos Florestais*

Diego Gomes de Sousa¹, Ronaldo Luiz Mincato², Fernando Shinji Kawakubo³

¹Programa de Pós-Graduação em Ecologia e Tecnologia Ambiental da Universidade Federal de Alfenas, MG. Rua Gabriel Monteiro da Silva, 700, Centro - Alfenas/MG. CEP: 37130-000. E-mail: dgomes.sousa@gmail.com

²Professor Doutor da Universidade Federal de Alfenas, MG. Rua Gabriel Monteiro da Silva, 700, Centro - Alfenas/MG. CEP: 37130-000. E-mail: ronaldomincato@gmail.com

³Professor Doutor da Universidade Federal de Alfenas, MG. Avenida Jovino Fernandes Sales, 2600 Bairro Santa Clara - Alfenas/MG. CEP: 37130-000. E-mail: fskgeo@gmail.com

RESUMO

Vários estudos têm mostrado que fragmentos florestais rodeados por diferentes matrizes sofrem diferentes pressões ecológicas sobre a fauna e flora. A luz disto, o presente estudo objetivou avaliar as mudanças no uso da terra e cobertura vegetal na região de Alfenas, sul do estado de Minas Gerais focando na conservação de fragmentos florestais. Foram utilizadas as bandas 1 a 5 e 7 do satélite Landsat-5 Thematic Mapper (TM) dos anos de 1987 e 2011. A classificação das imagens foi realizada utilizando o aplicativo Geographic Data Mining Analyst (GeoDMA), um pacote especialmente voltado para mineração de dados espaciais. Os seguintes procedimentos foram adotados para a realização do estudo: segmentação das imagens; extração de atributos espectrais e espaciais; amostragem; geração da árvore de decisão; classificação; edição dos erros e; análise das mudanças por meio de uma matriz de detecção de mudanças. Os resultados mostraram a importância da complementaridade das informações disponíveis em cada banda para a classificação do uso da terra e cobertura vegetal. Com relação as mudanças no uso, observou-se um aumento das classes cana-de-açúcar, café e solo exposto em áreas antes utilizadas para pastagem. Estas informações são importantes nos estudos de ecologia da paisagem, pois podem auxiliar na interpretação da dinâmica ecológica dos fragmentos florestais.

* Artigo extraído da dissertação de mestrado do primeiro autor.

Palavras-chave: segmentação, mineração de dados, árvore de decisão, GeoDMA, detecção de mudança.

Multitemporal Analysis of Land Use Types Using Landsat-5 TM Images in the Region of Alfenas, South of Minas Gerais, Aiming the Conservation of Native Forest Fragments

ABSTRACT

Several studies have shown that native forest fragments surrounded by different land-use matrixes undergo different ecological pressures on fauna and flora. In light this, we studied the land-use and land-cover changes in the region of Alfenas, southern Minas Gerais state, aiming the conservation of forest fragments. Landsat-5 Thematic Mapper (TM) images, bands 1 to 5 and 7, from 1987 and 2011, were used. Image classification was achieved using the Geographic Data Mining Analyst (GeoDMA), a toolbox specially addressed for spatial data mining. To carry out this investigation, the following procedures were adopted: image segmentation, spectral and spatial features extraction, sampling, decision tree generation, classification, error edition, and analysis of land-use and land-cover changes by using a change detection matrix. The results showed the importance of complementarity of information available in each band for classifying different land use and land cover types. As for land use change, an increase of sugar cane, coffee and bare soil were registered on previously areas used for pasture. Such information are important, since they may support interpretations of ecological dynamics of forest fragments.

Keywords: segmentation data mining, decision tree, GeoDMA, change detection.

1. Introdução

Originalmente, a Floresta Tropical Atlântica cobria grande parte do território brasileiro e quase completamente a região Sudeste, sendo conhecida por possuir elevados índices de riqueza de espécies e taxas de endemismo (fauna e flora). Com o passar dos anos, em decorrência do desenvolvimento antrópico, a Mata Atlântica passou a sofrer com o desmatamento voltado a agricultura (Almeida et al., 2010). O sul de Minas Gerais apresenta diversos remanescentes florestais imersos em matrizes agrícolas distintas, como café, cana-de-açúcar e pastagens. A fragmentação florestal pode ser entendida como a subdivisão e isolamento de pequenos trechos de vegetação original

contínua. Com o avanço tecnológico, novas técnicas de cultivo agrícola vêm sendo desenvolvidas, acarretando grande prejuízo para os ecossistemas. Muitas espécies nativas necessitam de condições bióticas e abióticas específicas para sua manutenção, e o processo de fragmentação pode resultar em grandes perdas para a biodiversidade, como: aumento na taxa de endogamia, mudanças no microclima, dificuldade de dispersão e polinização de sementes, perda de variabilidade genética, entre outras (Zanella, 2011).

Qualquer esforço na tentativa de conservação de fragmentos é válido, e informações sobre o uso do solo ao longo de anos podem fornecer novas maneiras de entender a evolução da paisagem, bem como a dinâmica evolutiva de seu entorno. O sensoriamento remoto (SR) é uma ferramenta essencial de apoio às análises de uso e ocupação do solo, facilitando a identificação de elementos componentes da paisagem e complementando informações disponíveis sobre os recursos ambientais (Calderano Filho et al., 2009). A tecnologia do SR permite a obtenção de informações da paisagem com rapidez, periodicidade, contemplando grandes áreas, a baixo custo e em faixas do espectro eletromagnético inacessíveis a visão humana.

Desde a década de 1970, imagens do satélite Landsat têm sido utilizadas como subsídio a pesquisas relacionadas ao mapeamento do uso do solo e cobertura vegetal, pesquisas de prospecção mineral e planejamento territorial. Atualmente, as imagens Landsat são utilizadas nas mais diversas aplicações: diversidade de espécies, usos do solo, taxas de desmatamento, gestão de recursos agronômicos e florestais, queimadas, entre outros.

Tradicionalmente o mapeamento do uso da terra é realizado de maneira visual baseando-se nos elementos de reconhecimento da fotointerpretação (Ceron & Diniz, 1966). Por meio do recurso da fotointerpretação, o analista é capaz de identificar os diferentes tipos de usos e coberturas vegetais presentes na fotografia aérea ou cena imageada analisando os elementos associados aos alvos como a cor, tonalidade, tamanho, forma, textura, padrão, contexto, presença de sombra, etc.

Os elementos cor e tonalidade remetem as propriedades espectrais dos objetos. Já os elementos de tamanho, forma, padrão e contexto fornecem informações valiosas a respeito das propriedades espaciais dos objetos. Assim, alvos naturais como manchas de mata nativa possuem, geralmente, formas irregulares e tamanhos variados enquanto alvos antrópicos como campos de agricultura possuem formas geométricas e tamanhos

mais definidos. A textura é outro elemento importante que juntamente com a presença de sombra permite diferenciar os alvos utilizando as informações de rugosidade e de altura das classes analisadas.

Apesar da fotointerpretação gerar resultados consideravelmente satisfatórios, tal metodologia adota critérios bastante subjetivos no processo de decisão, além de exigir bastante tempo na sua execução, o que encarece o custo do mapeamento e do monitoramento das mudanças na paisagem. As técnicas de classificação digital de imagens de satélites têm se sofisticado ao longo dos anos com significativas melhorias no processo de reconhecimento de padrões de uso da terra e cobertura vegetal. Dentre as vantagens da classificação digital pode-se citar a rapidez com que o mapeamento é realizado, redução da subjetividade no processo de decisão, além da possibilidade de armazenamento da informação em bases digitais que podem ser integradas com outras informações em um Sistema de Informação Geográfica (SIG), entre outros.

Um dos métodos mais utilizados no mapeamento do uso da terra é a classificação pixel a pixel pela máxima verossimilhança (Maxver), onde amostras de treinamento são selecionados e modelos probabilísticos são definidos para cada classe com base em uma suposição de distribuição normal das amostras. Apesar do classificador Maxver gerar resultados muitas vezes adequados aos objetivos pretendidos, erros de confusão de classes são comuns neste tipo de abordagem. Tal resultado se deve, em parte, em razão do classificador adotar parâmetros limitados no processo de decisão, considerando apenas os atributos espectrais das amostras. Outros parâmetros espaciais e texturais explorados na fotointerpretação não são contemplados nesta classificação.

Uma das abordagens mais promissoras atualmente é a classificação de imagens orientada a objeto. A classificação orientada a objeto tem como unidade de análise, grupos de pixels delimitados por segmentos - ao invés de pixels isolados como feita na classificação tradicional. Esses segmentos geralmente incorporam um amplo conjunto de informações que inclui atributos espectrais, texturais e espaciais (Blaschke, 2010) que são usados para treinar ou construir uma base de conhecimento para a classificação de imagens (Kawakubo et al., 2009; 2013).

Na classificação orientada a objetos, a construção do modelo de interpretação de uma imagem (base do conhecimento) é a fase mais importante e uma das mais difíceis de ser executada, uma vez que o especialista deve ter uma exata noção de quais são os melhores atributos dos objetos que devem ser utilizados na classificação (Vieira et al.,

2012). Outra abordagem promissora na classificação de imagens é a utilização de técnicas de mineração de dados como forma de geração automática da estrutura do conhecimento (Zhang et al., 2013). A maneira automática de execução do algoritmo que funciona com a lógica de árvores de decisão, significa um ganho enorme no tempo de implementação do processo de classificação de imagens de satélites, principalmente em estudos que utilizam extensos bancos de dados (Korting et al., 2009).

O fato desta técnica analisar parâmetros espaciais e espectrais é interessante em aplicações de uso da terra devido à maior eficácia e precisão na classificação, dessa forma, o presente trabalho analisa a evolução do uso e ocupação do solo discriminando as matrizes e os remanescentes florestais de Mata Atlântica da região, delimitando diferentes classes de uso do solo e suas mudanças entre os anos de 1987 e 2011.

2. Material e Métodos

A Figura 1 ilustra o fluxograma dos procedimentos adotados no presente trabalho. A etapa de preparação das imagens (correção geométrica) e detecção das mudanças foram realizadas no SIG ILWIS. As etapas de segmentação das imagens e de mineração de dados foram realizadas no GeoDMA. Esse sistema de análise de imagens funciona como um plugin do software TerraView, desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE) (Körting et al. 2013).

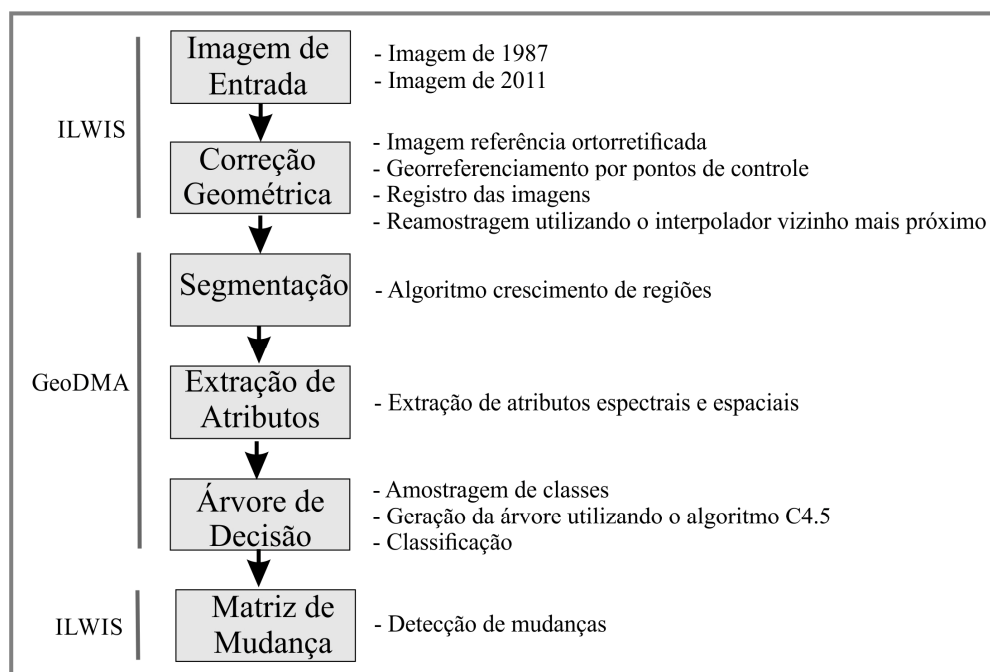


Figura 1. Fluxograma dos procedimentos adotados em diferentes softwares ao longo da execução do trabalho.

Área de Estudo - Corresponde a área do entorno da região sul do Reservatório da Usina Hidrelétrica de Furnas, sul de Minas Gerais, delimitada pelas coordenadas $21^{\circ} 18' 55''$ e $21^{\circ} 28' 31''$ S e $45^{\circ} 58' 08''$ e $46^{\circ} 21' 23''$ W, cobrindo parte dos Municípios de Alfenas, Alterosa, Areado, Cabo Verde, Divisa Nova e Monte Belo, como indicado na Figura 2.

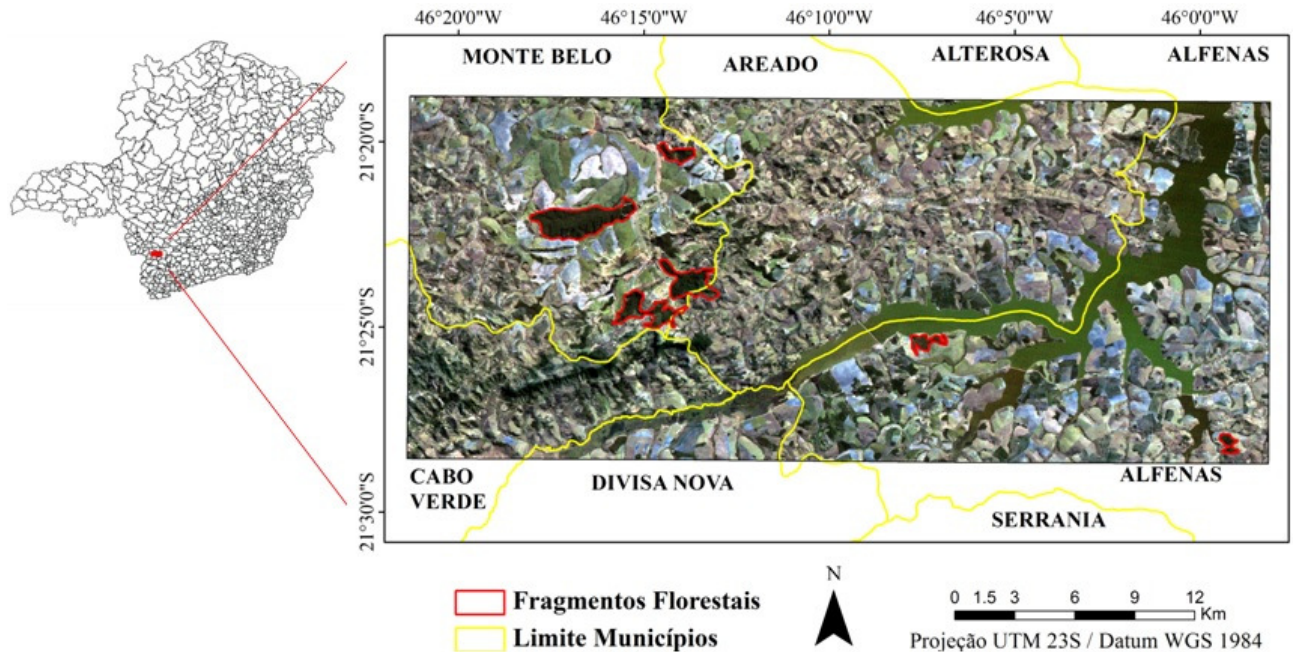


Figura 2. Localização da área de estudo no sul de Minas Gerais. A imagem corresponde a uma composição colorida 3R2G1B do satélite Landsat-5 TM de 27/08/2011, órbita/ponto 219/75.

A região se encontra no Cinturão Orogênico Brasília com litologias datadas entre 670 e 530 Ma (Hasui, 2010). Segundo Ross (2006), a região pertence à unidade dos Planaltos e Serras de Goiás–Minas, o relevo é de serras e morros alongados e estreitos, com altitudes médias entre 800 e 1000 m, e solos predominantes do tipo latossolo vermelho e argissolo vermelho-amarelo. O clima predominante na região sul de Minas Gerais é o Cwa (temperado úmido) pela classificação de Köppen, com estações bem definidas, inverno seco e frio e verão quente e chuvoso. As chuvas se concentram entre outubro e março, média mensal de 110 mm, sendo que nos meses de novembro e dezembro, as médias excedem os 210 mm (Mello et al., 2007). A vegetação original predominante da região era a Floresta Tropical Atlântica, caracterizada por ser uma floresta semi-decidual e de encosta, havendo presença de trechos com vegetação típica de cerrado, pois a região se encontra próxima à transição entre os dois biomas (Ross, 2006).

A ocupação da região se deu por volta do séc. XVIII, com pequenas propriedades que utilizavam técnicas rudimentares e pequenos roçados para agricultura de

subsistência. No século XIX, teve início o cultivo do café, que logo se tornou predominante, influenciando diretamente a economia sulmineira. A cana-de-açúcar e o milho também eram cultivados, fornecendo produtos derivados destinados ao comércio com localidades vizinhas, outra fonte de renda à época era a criação de gado (Pascoal, 2007; Martins, 2013). Ao longo dos anos, mais florestas nativas foram derrubadas para o plantio do café. Algumas áreas de cultivo abandonadas se tornaram áreas de pastagens. A partir do século XX, os cultivos tradicionais começaram a ser substituídos por sistemas desenvolvidos, utilizando técnicas modernas de cultivo e diversas variedades de café (Ross, 2006).

Imagens Landsat-5 TM - Para a realização do presente estudo foram utilizadas imagens do satélite Landsat-5 TM bandas 1 a 5 e 7 datadas de 09/08/1987 (ângulo de elevação solar: 35,86 e de azimute: 49,0) e 27/08/2011 (ângulo de elevação solar: 44,58 e de azimute: 48,6) correspondentes a órbita 219/75. As duas cenas utilizadas foram adquiridas em datas próximas para evitar as diferenças de brilho das imagens causadas por fatores de iluminação e mudanças nos estágios fenológicos dos cultivos. O período seco foi escolhido para evitar confusões espectrais principalmente entre as classes pastagem e cana-de-açúcar. Estas imagens foram adquiridas gratuitamente no sítio do INPE (<http://www.dsr.inpe.br/>).

Correção Geométrica - A correção geométrica tem como objetivo compatibilizar a imagem a uma base cartográfica. Em aplicações multitemporais a correção geométrica é um passo essencial, uma vez que permite por meio do registro das imagens, posicionar os pixels das imagens adquiridas em datas diferentes a uma mesma localidade, permitindo assim a comparação das mudanças na paisagem. Para realizar a correção geométrica, foi utilizada como referência uma composição colorida do satélite Landsat-5 TM ortorretificada de 03/05/2004 adquirida gratuitamente no sítio do *Global Land Cover Facility* (GLCF) (<http://glcf.umd.edu/>). Esta imagem foi recortada e utilizada como base cartográfica para identificação de pontos de controle. Nas imagens Landsat de 1987 e 2011 foram distribuídos 35 pontos de controle. O valor de ajuste polinomial após a definição dos pontos de controle foi abaixo do valor médio recomendado de 1 *pixel* (Crosta, 1992). O interpolador utilizado na reamostragem foi o Vizinho Mais Próximo. Este interpolador foi utilizado porque não altera o valor do pixel da imagem original: critério este importante na classificação de imagens.

Segmentação e Extração de Atributos - A segmentação pode ser entendida como um processo no qual a imagem é particionada em diferentes regiões com o intuito de discriminar *pixels* que apresentem determinadas características predefinidas pelo usuário, como níveis de cinza, propriedades texturais ou valores médios. Algoritmos baseados na similaridade entre os valores de intensidade dos *pixels* são mais adequados para identificar diferentes classes de uso do solo, uma vez que os comportamentos espectrais de *pixels* vizinhos tendem a apresentar valores semelhantes (Gonzalez & Woods, 2010). Esse processo é conhecido como segmentação baseada na região e possui três tipos principais: segmentação usando *watersheds*, divisão e fusão de regiões e crescimento de regiões.

Os tipos de dados e a área em questão são fundamentais para determinar qual tipo de segmentação deve ser implementada. Na segmentação baseada em regiões, os agrupamentos de *pixels* apresentam limites interligados, é de simples execução e muito eficaz nos resultados. A desvantagem dessa técnica é a associação de *pixels* de borda às regiões vizinhas devido principalmente à presença de ruídos nas imagens (Bins et al., 1996; Jensen, 2005).

A técnica de crescimento de regiões vem sendo amplamente utilizada em estudos de cunho ambiental (Shimabukuro et al., 1999; Kawakubo et al., 2009). Gonzalez e Woods (2010) entendem este processo de segmentação como o agrupamento de *pixels* ou conjuntos destes em regiões maiores de acordo com características pré-estabelecidas. A ideia é iniciar o processo com um conjunto de *pixels* base, que recebem o nome de "semente", e então anexar a cada semente os *pixels* vizinhos que possuem propriedades semelhantes estabelecidas pelos valores de limiares. Caso a diferença entre o valor do *pixel* semente e o *pixel* vizinho esteja dentro do limiar estabelecido, agrega-se o *pixel* vizinho formando uma região. Após concluir a segmentação, os segmentos ou regiões podem ser submetidos a mesma rotina de classificação tradicional.

A segmentação das imagens de 1987 e 2011 foi feita utilizando o algoritmo de crescimento de regiões apresentado por Bins et al. (1996). Dois parâmetros são definidos na segmentação: o critério de similaridade e o de área. O critério de similaridade define a distância espectral entre os valores das médias de intensidade de duas regiões e o critério de área define o tamanho mínimo da região a ser definida. Os limiares de segmentação para cada conjunto de imagem foram definidos de maneira visual a partir

de testes de diferentes valores até alcançar um particionado considerado adequado, ou seja, um resultado de segmentação que apresentasse nem excesso de segmentos (*over-segmentation*) e nem falta de segmentos (*under-segmentation*).

Finalizada a etapa de segmentação, iniciou-se a etapa de extração de atributos. Todos os atributos espectrais e espaciais disponíveis no GeoDMA foram utilizados (Körting et al., 2013). Os atributos espectrais consistem das medidas de amplitude, dissimilaridade, entropia, homogeneidade, média, moda e desvio padrão. Já os atributos espaciais são representados pelo ângulo, área, área caixa, círculo, ajuste elíptico, dimensão fractal, comprimento, perímetro, razão de área do perímetro, ajuste retangular e largura.

Mineração de Dados – Seguindo a definição de Fayyad et al. (1996), mineração de dados é entendido como a aplicação de algoritmos específicos para a extração de padrões de dados. A mineração de dados se insere dentro de um contexto maior denominado de *Knowledge Discovery in Databases* (KDD) cujo objetivo primordial é a descoberta de conhecimento útil a partir de volumosos bancos de dados.

No campo do SR, a grande vantagem da mineração de dados em aplicações relacionadas ao mapeamento do uso da terra é a possibilidade de contemplar uma ampla gama de atributos sejam espectrais, espaciais ou texturais. Além disto, possibilita a geração automática da estrutura do conhecimento que por meio da árvore de decisão é possível ter a exata noção dos critérios adotados no processo de classificação.

Foram definidas 6 classes de uso da terra: Água, Café, Cana-de-açúcar, Mata, Pastagem e Solo Exposto. A classe Mata engloba principalmente os remanescentes florestais, incluindo também regiões de mata ciliar, e pequenos trechos com vegetação mais densa. A classe Café inclui os cultivos em produção e os cafezais velhos. A classe Cana-de-açúcar inclui as áreas de cultivos de cana-de-açúcar em diferentes estágios de desenvolvimento. As classes Solo Exposto e Pastagem apresentam grande diversidade espectral, sendo a primeira composta principalmente por solos que estão sendo preparados para cultivos. Já a classe Pastagem inclui tanto os pastos secos quanto os pastos sujos e os banhados, encontrados principalmente nas regiões onde a Represa de Furnas apresenta variação de nível de acordo com o regime das chuvas.

A amostragem foi feita visualmente utilizando os critérios da fotointerpretação (Ceron & Diniz, 1966), visitas em campo e com o auxílio das imagens de alta resolução do *Google Earth*. Após a seleção das amostras, todos os atributos extraídos na etapa

anterior foram selecionados para a geração da árvore de decisão. O GeoDMA utiliza o algoritmo C4.5 desenvolvido por Quinlan (1993) para a geração da árvore de decisão. A escolha dos atributos é baseada em uma métrica de entropia denominada de ganho de informação. Assim, os atributos com maiores ganhos de informação são selecionados na construção da árvore de decisão.

Edição de Erros - Os erros gerados na classificação (erros de omissão e comissão) foram corrigidos manualmente com base em informações de campo e com auxílio das imagens do *Google Earth*. As confusões de rotulação das classes foram corrigidas por meio da edição de polígonos. Já os erros de fronteira de classes resultantes da segmentação foram corrigidos por meio da edição matricial.

Matriz de Detecção de Mudanças - A matriz de detecção de mudanças (MDM) é um método quantitativo muito utilizado em SR. Neste método, dois mapas são comparados por meio de uma tabulação de base *pixel-a-pixel*. A MDM é construída confrontando um mapa com as suas respectivas classes na linha da matriz (classificação de 1987) e outro mapa na coluna da matriz (classificação de 2011). Na diagonal principal desta matriz encontram-se discriminados os números de *pixels* que não sofreram alterações. Fora da diagonal principal são registrados os números de *pixels* que correspondem às mudanças (Jensen, 2005).

Ao utilizar MDM é importante que cada mapa a ser analisado esteja adequadamente classificado, pois caso um dos mapas contenha alguma imprecisão, esta estará contida no mapa de detecção de mudanças. Além disto, é importante que os mapas de entrada estejam perfeitamente registrados, pois caso haja erro de posicionamento, as mudanças identificadas na matriz não expressarão as mudanças registradas na paisagem.

3. Resultados e Discussão

Após a realização de vários testes de segmentação, os limiares que resultaram em uma segmentação mais adequada foram 25 para similaridade e 10 para área mínima. Estes limiares foram adotados para as duas datas analisadas. Foram gerados neste processo 24729 segmentos para a imagem de 1987 e 22469 segmentos para a imagem de 2011.

A árvore de decisão gerada para o ano de 1987 é ilustrada na Figura 3. Apenas atributos espectrais foram selecionados na árvore de decisão de 1987, indicando a importância do comportamento espectral dos objetos na determinação de sua classificação. Os parâmetros de moda e média determinaram a rotulação das classes Água e Cana-de-açúcar, respectivamente. Para as classes Mata e Café, os atributos desvio padrão, homogeneidade e entropia (atributos texturais), determinaram a classificação dos objetos. Objetos rotulados como Mata apresentam em geral textura mais grosseira em relação aos outros objetos, embora o seu comportamento espectral seja similar ao Café. A classe Café apresenta grande diversidade espectral em razão do manejo adotado no cultivo. Nos estágios iniciais de desenvolvimento, por exemplo, o café formação apresenta comportamento espectral similar à pastagem verde.

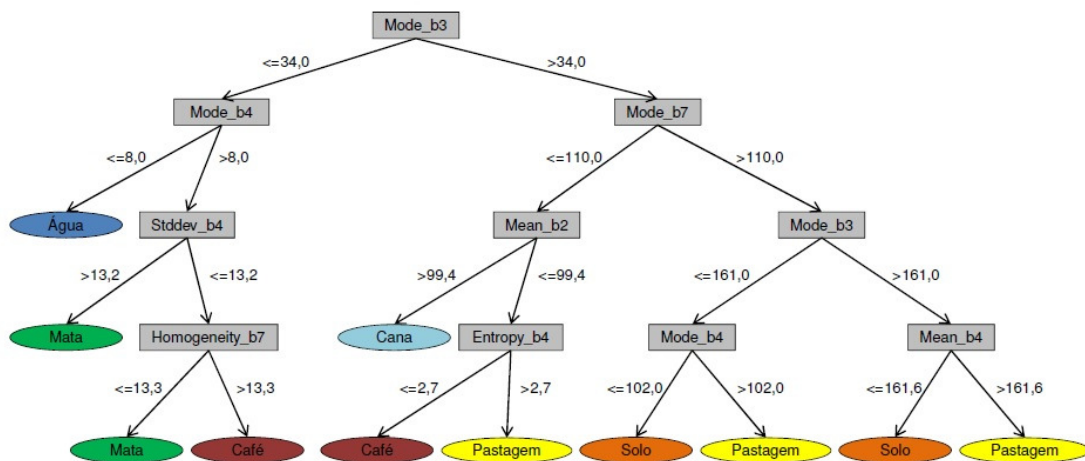


Figura 3. Árvore de decisão resultante do processo de classificação aplicado à imagem Landsat-5 TM de 09/08/1987.

As classes Pastagem e Solo Exposto apresentam certa confusão de associação de objetos, o que pode ser explicado pelo fato destas classes englobarem áreas de solo exposto em diferentes níveis de preparação para cultivo (cana-de-açúcar principalmente), bem como áreas de pasto sujo, pasto limpo e áreas de cultivo abandonadas que se transformaram em pastagem. Devido à grande diversidade espectral das classes Café, Pastagem e Solo Exposto, estas foram classificadas em diferentes partes da árvore de decisão. Percebe-se que as informações derivadas da banda 4, infravermelho próximo, foi determinante na delimitação de cinco das seis classes, confirmando a eficácia da informação do infravermelho próximo no mapeamento do uso da terra.

A Figura 4 ilustra a árvore de decisão gerada para a imagem de 2011. Assim como na árvore anterior, esta árvore selecionou somente atributos espectrais. O

parâmetro moda foi o mais utilizado, seguido pela média, enquanto a homogeneidade, entropia e amplitude foram utilizados somente uma vez cada. A classe Água foi atribuída a um nó distinto, já que objetos a ela associados possuem comportamento espectral singular. Como na árvore anterior, a classe Mata apresentou alguma confusão com a classe Café. O mesmo ocorreu com a classe Cana-de-açúcar (confusão com Café), podendo estar associado ao comportamento espectral de algumas áreas de cultivo de café e de cana-de-açúcar em estágios próximos de desenvolvimento.

As classes Pastagem e Solo Exposto apresentam confusão em dois momentos, sendo que em ambos o algoritmo selecionou atributos texturais (homogeneidade e amplitude). Isto pode ser explicado pela generalização de áreas durante o processo de amostragem, visto que áreas com diferentes tipos de solo exposto (solos preparados para cultivo de café ou cana) e de pastagens (pasto limpo, pasto sujo, cultivos abandonados) apresentam características espectrais próximas. Pastagem e Solo Exposto também foram definidos em nós distintos da árvore, sendo a moda o atributo espectral de maior relevância. É importante ressaltar que os valores de moda de cinco das seis bandas analisadas foram selecionados pelo algoritmo, comprovando a importância da complementaridade das informações espectrais de diferentes faixas do espectro.

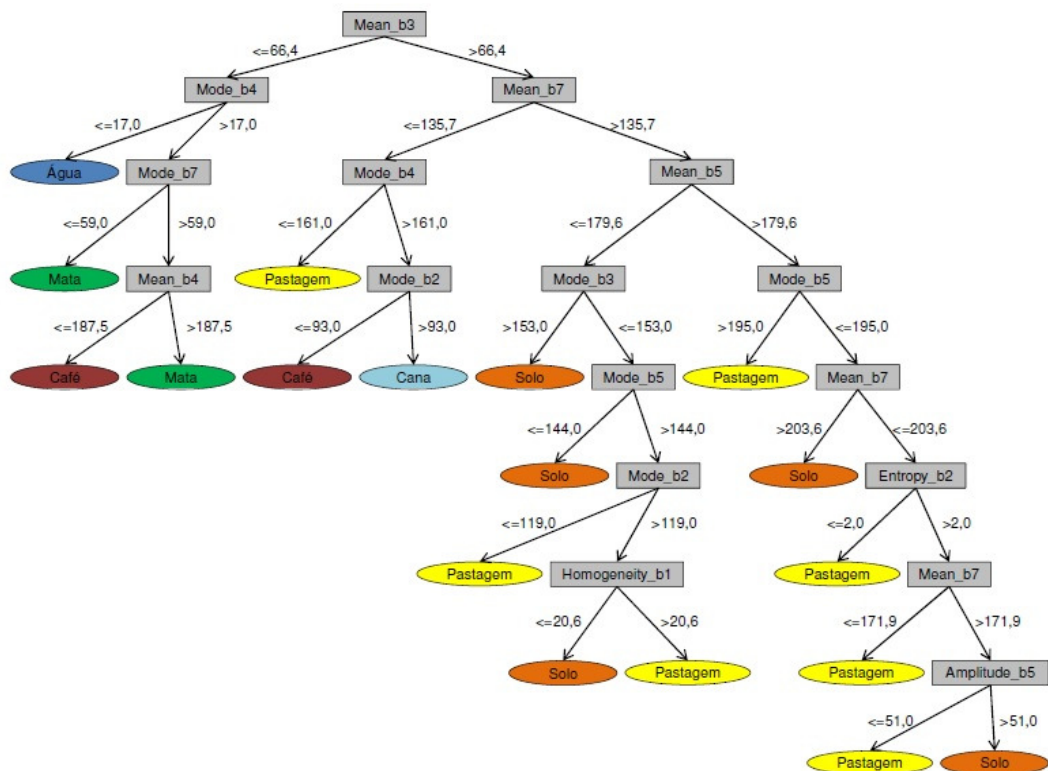


Figura 4. Árvore de decisão resultante do processo de classificação aplicado à imagem Landsat-5 TM de 27/08/2011.

Os resultados das classificações após as edições realizadas são ilustrados na Figura 5. Conforme pode ser observado, a Pastagem é a classe predominante na região constituindo a matriz da paisagem. Fragmentos de Mata se encontram principalmente na porção oeste, em áreas de relevo mais acidentado. As culturas de Café concentram-se nas proximidades da represa de Furnas. O cultivo de maior expressão espacial é a Cana-de-açúcar, localizada nas porções noroeste e centro-sul da área de estudo onde o terreno mais plano favorece a mecanização do cultivo. As manchas de Solo Exposto localizadas nas proximidades das lavouras de cana-de-açúcar correspondem às terras sendo preparadas para este mesmo cultivo.

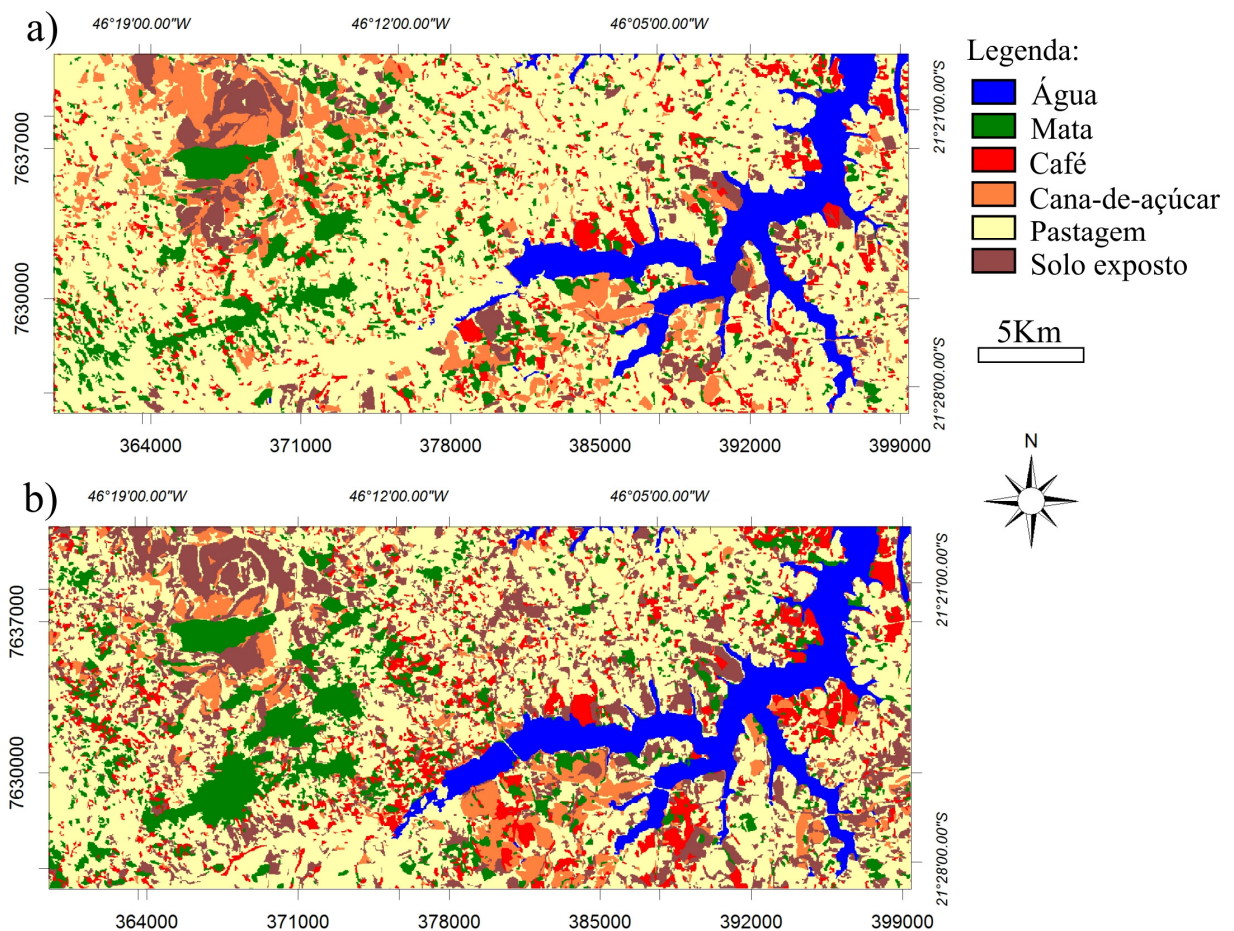
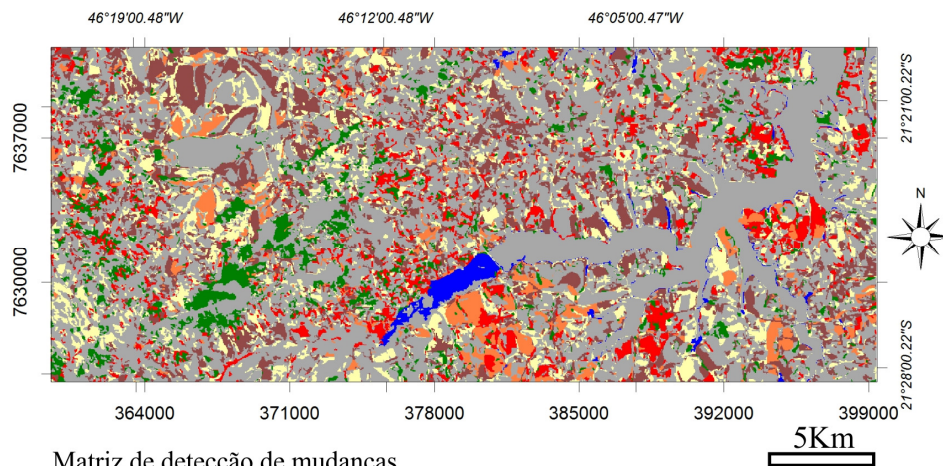


Figura 5. Mapas finais de uso e ocupação do solo nas datas de 09/08/1987 (a) e 27/08/2011 (b), gerados através do GeoDMA.

O mapa com a matriz de detecção de mudanças é ilustrado na Figura 6. Os valores da diagonal principal correspondem ao número de pixels que não mudaram. A

última coluna e linha descrevem a porcentagem de mudança ocorrida para cada classe analisada. As classes que apresentaram maiores mudanças foram o Café, Cana-de-açúcar e Solo Exposto. Tal fato se deve ao incremento das atividades agrícolas na região. Em termos de números absolutos, a classe pastagem foi que apresentou maior perda de área em razão do incremento dos cultivos mencionados.

A classe Café apresentou mudanças consideráveis principalmente na porção leste. Nota-se um aumento da expansão da classe Cana-de-açúcar principalmente na porção sul. Já a classe Solo Exposto apresentou mudanças em toda a extensão, envolvendo principalmente áreas de solo que estão sendo ou já foram preparadas para cultivo de cana-de-açúcar (porção noroeste) e de café (centro, no entorno do reservatório). A classe Mata foi incrementada principalmente na porção centro-oeste, onde o terreno apresenta maior declividade, e também onde a vegetação consegue se desenvolver mais facilmente, seja por proteção legal ou por condições ambientais. Em razão da diferença no nível do reservatório, observou-se um incremento considerável da classe Água.



Matriz de detecção de mudanças

Classificações	2011						Totais	Mudanças (%)	
	Água	Café	Cana	Mata	Pastag.	Solo Exp.			
1987	Água	56303	366	246	662	1335	239	59151	4,8
	Café	359	9620	3427	6100	21797	6505	47808	80,6
	Cana	411	3354	13499	3280	26445	23208	70197	80,7
	Mata	258	7359	1731	40796	16231	2647	69022	40,8
	Pastag.	7164	38924	20598	33037	269370	73397	442490	39,1
	Solo Exp.	249	3889	7669	1024	22030	21059	55920	62,3
Totais	64744	63512	47170	84899	357208	127055	744588		
Mudanças (%)	13,0	84,8	71,3	51,9	24,5	83,4			

Figura 6. Mapa de mudanças produzido utilizando a lógica de matriz de detecção de mudanças aplicado as imagens Landsat-5 TM de 09/08/1987 e 27/08/2011. Cada *pixel* corresponde a uma área de 900 metros quadrados.

4. Conclusão

Conforme foi observado, nenhum atributo espacial foi considerado na geração das árvores de decisão. Tal resultado demonstra que neste estudo, o comportamento espectral foi mais decisivo que a distribuição e o arranjo espacial dos objetos. A utilização de árvores de decisão em classificação de imagens de satélite possui várias vantagens quando comparada com outros classificadores tradicionais, como o Maxver. Além de não requerer suposições com relação à distribuição das amostras, a árvore de decisão é de fácil interpretação, possibilita considerar variáveis categóricas e numéricas e permite incorporar relações não lineares entre classes. Tal característica explica o fato de classes com grande diversidade espectral serem alocadas em diferentes ramos da árvore de decisão. Os resultados mostraram que a paisagem se tornou mais fragmentada na classificação de 2011, sugerindo um maior aproveitamento da paisagem com maior diversidade de uso. A cana é o cultivo que mais se expande na região, favorecido pelo relevo plano e pelo desenvolvimento tecnológico da agricultura. Percebe-se que os principais fragmentos se encontram imersos em diferentes matrizes agrícolas, como café, cana-de-açúcar e pastagens, e cada uma dessas matrizes influenciam de formas distintas estes fragmentos, visto que cada uso apresenta características próprias. A composição e a diversidade de espécies dos fragmentos é influenciado pelo tipo de uso, portanto, o ganho de informações sobre o comportamento de diferentes usos ao longo dos anos, se traduz em uma excelente ferramenta para o direcionamento de alternativas para conservação e gestão de fragmentos.

5. Agradecimentos

Os autores expressam seus agradecimentos ao Grupo de Pesquisa ECOFRAG, que acreditou e apoiou este trabalho. Agradecimentos especiais a FAPEMIG pelo apoio financeiro concedido.

6. Referências

Almeida, A. et al. (2010). Análise sobre a fragmentação dos remanescentes de Mata Atlântica na APA do Pratigi para identificar as áreas com maiores potenciais para a

- construção de corredores ecológicos baseados no método AHP. *Revista AGIR de Ambiente e Sustentabilidades Ibirapitanga*, v.2, n.3, pp.31-43.
- Bins, L. S. et al. (1996). Satellite imagery segmentation: a region growing approach. *Anais VIII Simpósio Brasileiro de Sensoriamento Remoto*, Salvador, Abril, INPE, p.677-680.
- Blaschke, T. (2010). Object based image analysis for remote sensing. *Journal of Photogrammetry and Remote Sensing*, v.65, n. 1, pp.2-16.
- Calderano Filho, B. et al. (2009). Diagnóstico geoambiental da área do entorno do reservatório da usina hidrelétrica de Tombos, para fins de recuperação de áreas degradadas. *Caminhos da Geografia*, v.10, n.30, pp.118-134.
- Ceron, A. O.; Diniz, J. A. F. (1966). O uso de fotografias aéreas na identificação das formas de utilização agrícola da terra. *Revista Brasileira de Geografia*. v.2, n. 28, pp.161-173.
- Crosta, A. P. (1992). *Processamento digital de imagens de sensoriamento remoto*. Ed. rev. Campinas, SP: IG UNICAMP.
- Fayyad, U. et al. (1996). From data mining to knowledge discovery in databases. *AI Magazine*, v.17, n.3, pp.37-54.
- Friedl, M. A.; Brodley, C. E. (1997). Decision tree classification of land cover from remotely sensed data. *Remote Sensing of Environment*, v.61, n.3, pp.399-408.
- Gonzalez, R. C.; Woods, R. C. (2010). *Processamento Digital de Imagens*. Tradução de Cristina Yamagami e Leonardo Piamonte. 3ª ed. São Paulo: Pearson Prentice Hall.
- Hasui, Y. (2010). A grande colisão pré-cambriana do sudeste brasileiro e a estruturação regional. *São Paulo, UNESP, Geociências*, v.29, n.2, p.141-169.
- Jensen, J. R. (2005). *Introductory digital image processing: a remote sensing perspective*. 3ª ed. EUA: Pearson Education, Inc.
- Kawakubo, F.S. et al. (2009). Land-use and vegetation-cover mapping of an indigenous land area in the state of Mato Grosso (Brazil) based on spectral linear mixing model, segmentation and region classification. *Geocarto International*, v.24, n.2, pp.165-175.
- Kawakubo, F. S. et al. (2013). Use of fraction imagery, segmentation and masking techniques to classify land-use and land-cover types in the Brazilian Amazon. In: *International Journal of Remote Sensing*. v.34, n15, p.5452-5467.
- Körting, T. S. et al. (2009). GeoDMA - Um sistema para mineração de dados de sensoriamento remoto. *Anais XIV Simpósio Brasileiro de Sensoriamento Remoto*, Natal, INPE, pp.7813-7820.

- Körting, T. S. et al. (2013). GeoDMA - Geographic Data Mining Analyst. *Computers & Geosciences*, v. 57, pp. 133-145.
- Martins M. L. (2013). Plantar, pasturar e fiar na Vila Formosa de Alfenas, MG: décadas de 1850-1890. *Estudos Econômicos*, v.43, n.2, pp.397-429.
- Mello, C. R. et al. (2007). Erosividade mensal e anual da chuva no Estado de Minas Gerais. *Pesquisas agropecuárias brasileiras, Brasília*, v.42, pp.537-545.
- Pascoal, I. (2007). Economia e trabalho no sul de Minas no século XIX. *Economia e Sociedade*, v.16, n.2, pp.259-287.
- Quinlan, J. R. (1993). *C4. 5: Programs for Machine Learning*. Morgan Kaufmann, San Francisco.
- Ross, J. L. S. (2006). *Ecogeografia do Brasil: subsídios para planejamento ambiental*. São Paulo: Oficina de textos.
- Shimabukuro, Y. E. et al. (1999). Levantamento de áreas desflorestadas na Amazônia através de processamento digital de imagens orbitais. *Floresta e Ambiente*, v.6, n.1, pp.38-44.
- Vieira, M. A. et al. (2012). Object based image analysis and data mining applied to a remotely sensed Landsat time-series to map sugarcane over large areas. *Remote Sensing of Environment*, v. 123, pp.553-562.
- Zanella, L. (2011). *Análise da interferência antrópica na fragmentação da mata atlântica e modelos de simulação da paisagem na microrregião da Serra da Mantiqueira do estado de Minas Gerais*. 117f. Dissertação (Mestrado em Ecologia Aplicada), UFLA, Lavras.
- Zhang, Y. et al. (2013). A study on coastline extraction and its trend based on remote sensing image data mining. *Abstract and Applied Analysis*, v.2013, pp.1-7.