



ISSN:1984-2295

Revista Brasileira de Geografia Física

Homepage: www.ufpe.br/rbgfe



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. Autor correspondente. 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

Artigo submetido em 06/05/2015 e aceite em 28/12/2015.

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. 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.

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 (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 selecionadas 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.

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).

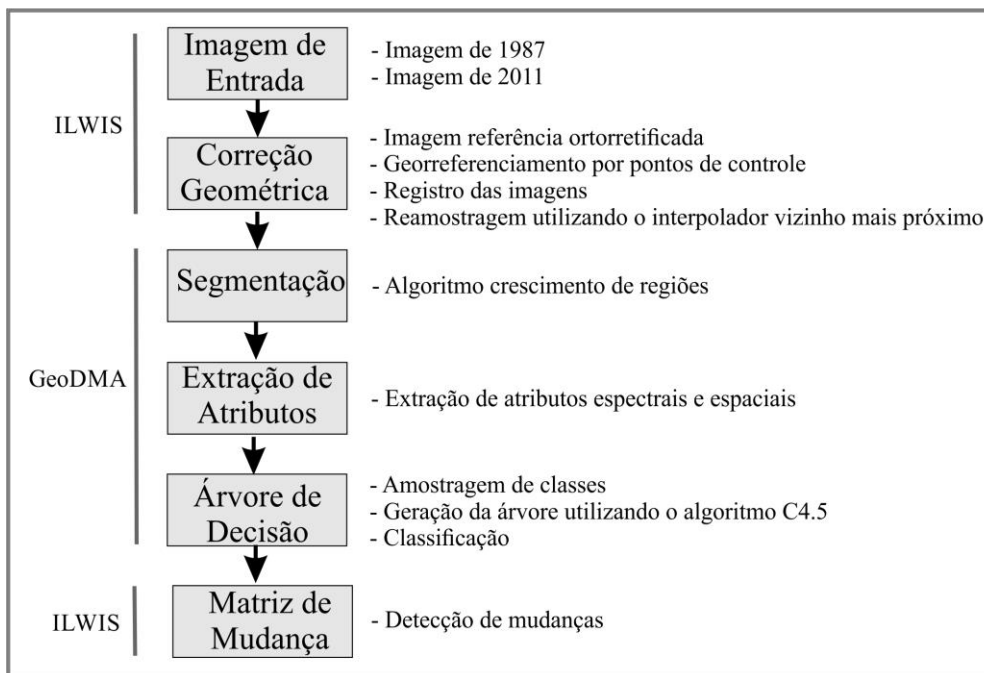


Figura 1. Fluxograma dos procedimentos adotados em diferentes softwares ao longo da execução do trabalho.

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° 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, como indicado na Figura 2.

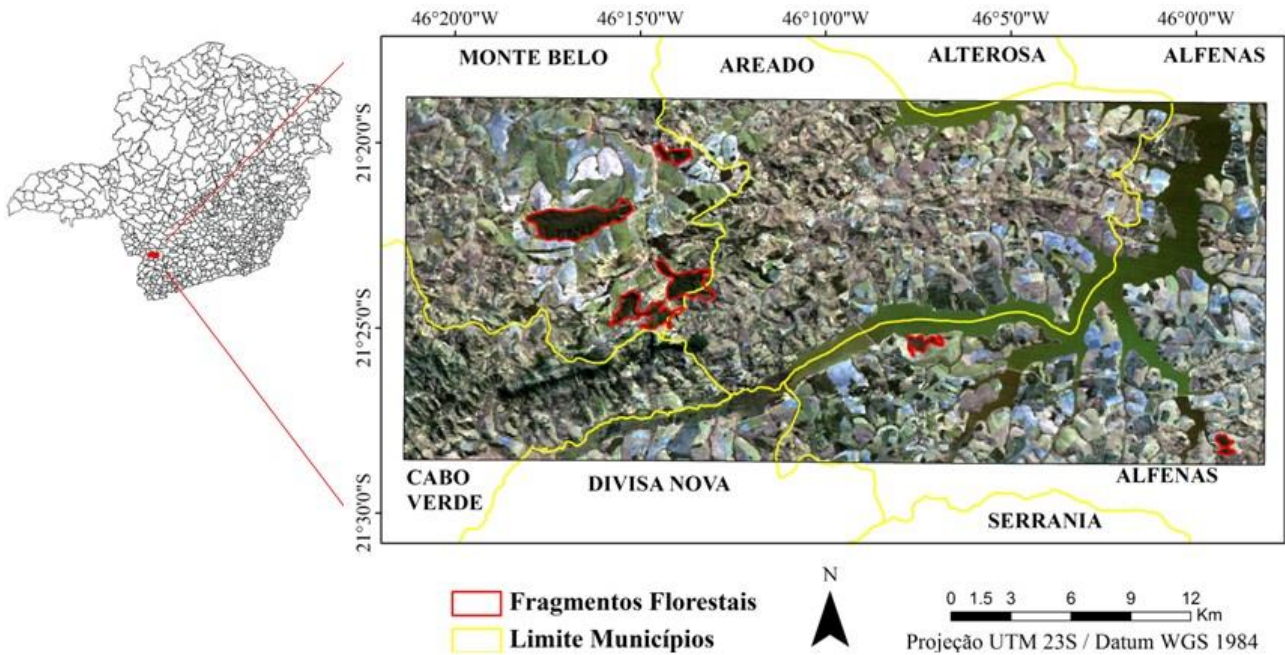


Figura 2. Localização da área de estudo no sul de Minas Gerais. A imagem corresponde a uma composição colorida 3R2G1B do satélite Landsat-5 TM de 27/08/2011, órbita/ponto 219/75.

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 Vizinheiro 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 (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. 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 particionamento 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.

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.

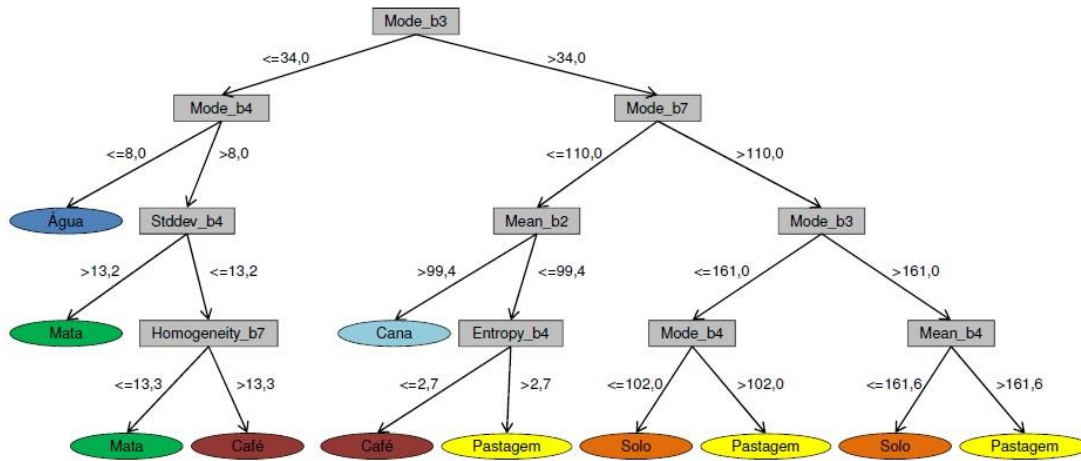


Figura 3. Árvore de decisão resultante do processo de classificação aplicado à imagem Landsat-5 TM de 09/08/1987.

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.

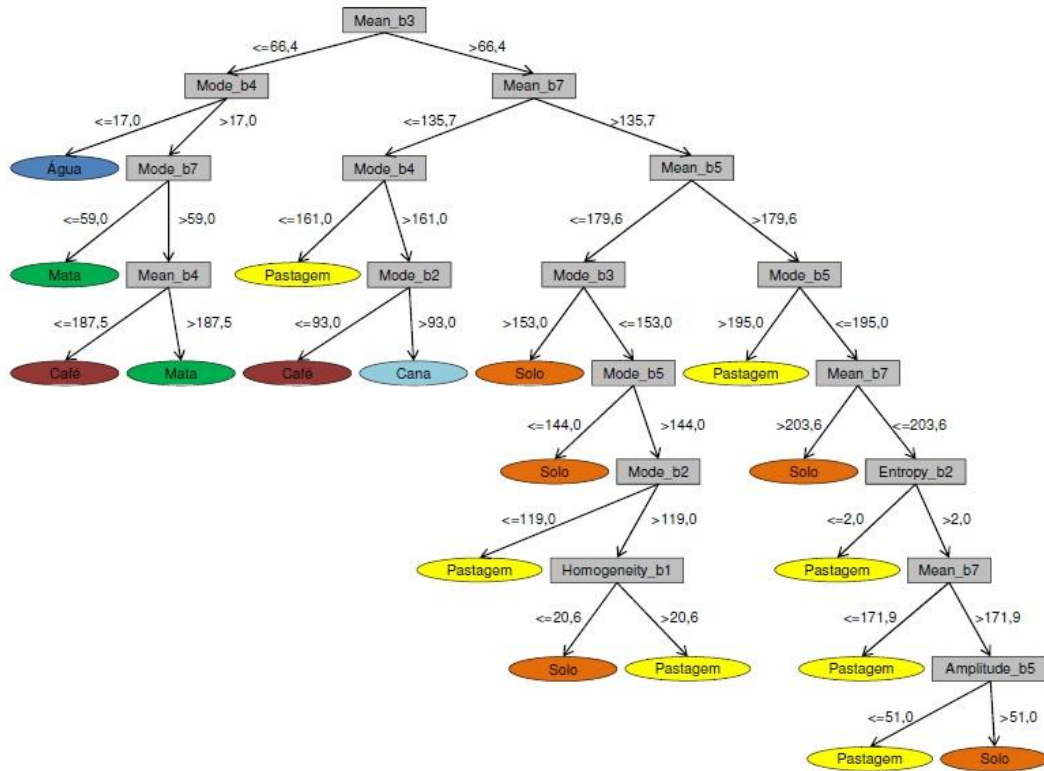


Figura 4. Árvore de decisão resultante do processo de classificação aplicado à imagem Landsat-5 TM de 27/08/2011.

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.

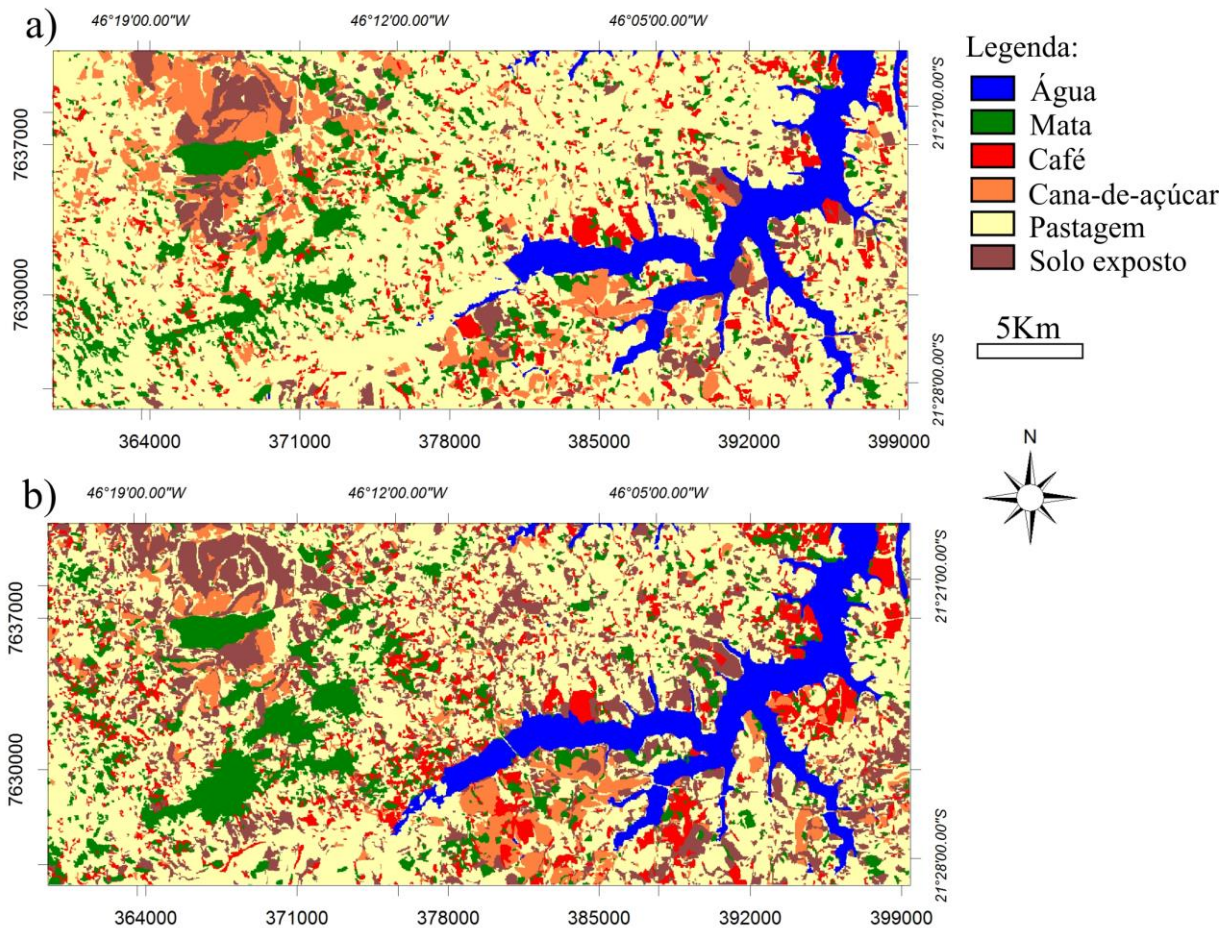
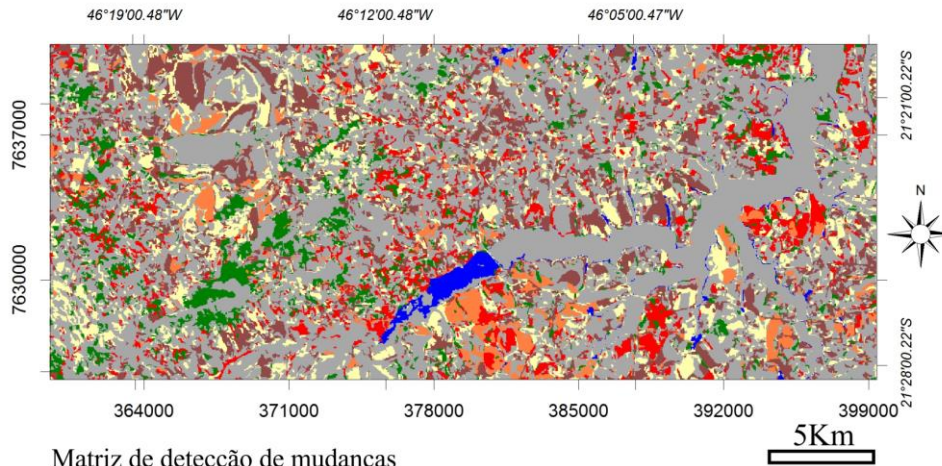


Figura 5. Mapas finais de uso e ocupação do solo nas datas de 09/08/1987 (a) e 27/08/2011 (b), gerados através do GeoDMA.

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.

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.

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.

Referências

- Almeida, A. Batista, J. L. Damascena, L. S., Franca Rocha, W. de J. S. 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* 2, 31-43.
- Blaschke, T. 2010. Object based image analysis for remote sensing. *Journal of Photogrammetry and Remote Sensing* 65, 2-16.
- 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* 2, 161-173.
- Crosta, A. P. 1992. *Processamento digital de imagens de sensoriamento remoto*. Ed. rev. Campinas, SP: IG UNICAMP.
- Fayyad, U., Piatetsky-Shapiro, G., Smyth, P. 1996. From data mining to knowledge discovery in databases. *AI Magazine*, v.17, 37-54.
- Filho, B. C., Andrade, A. G., Polivanov, H., Guerra, A. J. T., Ramalho Filho, A. 2009. Diagnóstico geoambiental da área do entorno do reservatório da usina hidrelétrica de Tombos, para fins de recuperação de áreas degradadas. *Caminhos da Geografia* 10, 118-134.
- Friedl, M. A.; Brodley, C. E. (1997). Decision tree classification of land cover from remotely sensed data. *Remote Sensing of Environment* 61, 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* 29, 141-169.
- Jensen, J. R. 2005. *Introductory digital image processing: a remote sensing perspective*. 3ª ed. EUA: Pearson Education, Inc.
- Kawakubo, F. S., Morato, R. G., Midaglia, C. L., Gomide, M. L. C., Luchiari, A. 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* 24, 165-175. DOI:10.1080/10106040802488534
- 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* 34, 5452-5467.
- Korting, T. S., Garcia Fonseca, L. M., Camara, G. 2013. GeoDMA - Geographic Data Mining Analyst. *Computers & Geosciences* 57, 133-145.
- Martins M. L. 2013. Plantar, pasturar e fiar na Vila Formosa de Alfenas, MG: décadas de 1850-1890. *Estudos Econômicos* 43, 397-429.
- Mello, C. R., Sá, M. A. C., Curi, N., Mello, J. M., Viola, M. R. Silva, A. M. 2007. Erosividade mensal e anual da chuva no Estado de Minas Gerais. *Pesquisas agropecuárias brasileiras* 42, 537-545.
- Pascoal, I. 2007. Economia e trabalho no sul de Minas no século XIX. *Economia e Sociedade* 16, 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., Duarte, V. Santos, J. R., Melo, E. M. K., Moreira, J. C. 1999. Levantamento de áreas desflorestadas na Amazônia através de processamento digital de imagens orbitais. *Floresta e Ambiente* 6, 38-44.
- Vieira, M. A., Formaggio, A. R., Rennó, C. D. Atzberger, C., Aguiar, D. A. Mello, M. P. 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* 123, 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. Li, X., Song, D. 2013. A study on coastline extraction and its trend based on remote sensing image data mining. *Abstract and Applied Analysis*. <http://dx.doi.org/10.1155/2013/693194>