



ANTONIO CARLOS DE SOUSA COUTO JUNIOR

**MONITORAMENTO DO CERRADO EM MINAS
GERAIS USANDO ANÁLISES ESTATÍSTICAS
BASEADAS EM OBJETOS:
UMA ABORDAGEM EM DIFERENTES ESCALAS**

LAVRAS - MG

2011

ANTONIO CARLOS DE SOUSA COUTO JUNIOR

**MONITORAMENTO DO CERRADO EM MINAS GERAIS USANDO
ANÁLISES ESTATÍSTICAS BASEADAS EM OBJETOS: UMA
ABORDAGEM EM DIFERENTES ESCALAS**

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

Orientador

Dr. Luis Marcelo Tavares de Carvalho

Coorientador

Prof. Fausto Weimar Acerbi Junior

LAVRAS – MG

2011

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

Couto Junior, Antonio Carlos de Sousa.

Monitoramento do Cerrado em Minas Gerais usando análises estatísticas baseadas em objetos : uma abordagem em diferentes escalas / Antonio Carlos de Sousa Couto Junior. – Lavras : UFLA, 2011.

87 p. : il.

Dissertação (mestrado) – Universidade Federal de Lavras, 2011.

Orientador: Luis Marcelo Tavares de Carvalho.

Bibliografia.

1. Bioma cerrado. 2. Análises baseadas em objetos. 3. Detecção de mudanças. 4. Sensoriamento remoto. I. Universidade Federal de Lavras. II. Título.

CDD – 526.982

ANTONIO CARLOS DE SOUSA COUTO JUNIOR

**MONITORAMENTO DO CERRADO EM MINAS GERAIS USANDO
ANÁLISES ESTATÍSTICAS BASEADAS EM OBJETOS: UMA
ABORDAGEM EM DIFERENTES ESCALAS**

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

APROVADA em 5 de agosto de 2011.

Prof. Lucas Rezende Gomide

UFLA

Prof. Gilson Alexandre Ostwald Pedro da Costa

PUC - RIO

Dr. Luis Marcelo Tavares de Carvalho

(Orientador)

Fausto Weimar Acerbi Junior

LAVRAS – MG

2011

AGRADECIMENTOS

Agradeço a todos os Deuses, por todas as oportunidades que me foram proporcionadas.

A minha mãe, Maria José (Zezé), que me ensinou a ver o mundo de outra forma e que sempre me estimulou a pensar e a acreditar de uma maneira diferente e única. Ao meu pai, por ter me apoiado, mesmo estando um pouco distante. A minha apaixonante companheira, Ana Cecilia, por sempre estar do meu lado, compartilhando muitos momentos ótimos. Ao meu amigo e orientador Luis Marcelo (Passarinho), por sempre ter aprovado minhas ideias. Aos meus grandes amigos de noites letivas, Faustinho e Pedro, pelo tanto que discutimos sobre análises baseadas em objetos. Aos meus amigos e professores do LEMAF e DCF, que me proporcionaram grandes ensinamentos. Ao grande mestre Ricardo Cravícola, que ainda preserva suas ideias e batalha para mantê-las vivas. Aos bolsistas do Laboratório de Geo (LEMAF) por, juntos, conseguirmos entender cada vez mais essa ciência. Ao professor Greg McDermid que, com poucas reuniões, conseguiu solucionar algumas de minhas dúvidas. Aos amigos do F3GISCI, Canadá e a todos aqueles amigos que, de alguma forma, passaram pela minha vida e, mesmo fazendo críticas, me ensinaram algo sobre a vida.

Um especial agradecimento ao LEMAF, à CAPES e ao governo do Canadá, pelas bolsas de estudos durante a graduação e o mestrado.

RESUMO

COUTO JUNIOR, Antonio Carlos de Sousa. **Monitoramento do cerrado em Minas Gerais usando análises estatísticas baseadas em objetos**: uma abordagem em diferentes escalas. 2011. 78 p. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Lavras, Lavras, Minas Gerais.

O Cerrado brasileiro é um dos principais tipos de vegetação dentre os biomas brasileiros, considerado um hot spot mundial, por sua rica biodiversidade. Além da ocorrência de uma sazonalidade da vegetação, este bioma está sob intensa pressão antropogênica, tendo mais de 50% da cobertura original já sido transformada pelas atividades humanas. Por meio destes processos dinâmicos, está se formando um complexo mosaico de remanescentes de cerrado, plantações de eucalipto, campos agrícolas e áreas degradadas, dificultando a caracterização e o monitoramento da paisagem quando são utilizadas abordagens tradicionais baseadas em pixels. Portanto, este trabalho foi realizado com o objetivo de desenvolver um sistema de monitoramento capaz de detectar e caracterizar as alterações devido à perda de vegetação, queimadas, crescimento da vegetação e sazonalidade da vegetação, utilizando uma abordagem estatística baseada em objetos para a detecção dessas alterações e aplicadas em duas diferentes escalas. Foram utilizadas imagens do sensor de satélite Landsat TM (30m) das datas 02/08/2008 (T1), 14/03/2009 (T2), 05/08/2009 (T3) e 25/11/2009 (T4). A etapa de pré-processamento consistiu de correções geométricas e radiométricas das imagens. Foram gerados parâmetros estatísticos de todos os objetos, em todas as imagens. Após o pré-processamento, foram calculados NDVI para cada imagem para, posteriormente, produzir duas imagens NDVI-diferença (T2-T1 e T4-T3). Assim, essas imagens diferença foram utilizadas para calcular os parâmetros estatísticos, como média e desvio padrão de cada objeto. Utilizando-se análises estatísticas baseadas em objetos, áreas com ocorrência de mudanças foram separadas das áreas de não mudança e categorizadas. Os resultados mostraram que todas as áreas (objetos) de perda e crescimento da vegetação observadas em campo foram detectadas e apenas alguns objetos que tinham fogo em sua fase inicial não foram detectados, mostrando a necessidade de utilizar séries temporais maiores de imagens. O método foi eficiente para detectar e separar as áreas alteradas de acordo com o tipo de mudança, demonstrando a capacidade dos conjuntos de regras desenvolvidas até agora para discriminar objetos da paisagem e formar classes semânticas.

Palavras-chave: Sensoriamento remoto. Detecção de mudanças. Bioma Cerrado. Análises baseadas em objetos.

ABSTRACT

COUTO JUNIOR, Antonio Carlos de Sousa. **Brazilian Savanna monitoring system using object-based statistical analysis**: an approach at different scales. 2011. 78 p. Dissertation (Master's degree in Forest Engineering) – Universidade Federal de Lavras, Lavras, Minas Gerais.

Brazilian savannas are the main vegetation types within the Cerrado Biome, a recognized biodiversity hot spot. Besides the pronounced seasonality, they are under intense pressure and more than 50% of the original cover has already been transformed by human activities. These dynamic processes are forming a complex mosaic of savanna remnants, eucalyptus plantations, agricultural fields, and degraded areas, which is difficult to characterize using traditional pixel based approaches. Therefore, the objective of this work was to develop a monitoring system capable of detecting and labeling changes due to deforestation, fire, re-growth, and vegetation seasonality using an object based approach for change detection applied at two scales. Landsat TM images (30 m) from 2008/08/02 (T1), 2009/03/14 (T2), 2009/08/05 (T3) and 2009/11/25 (T4) were used. The pre-processing step comprised both geometric and radiometric corrections. Statistical parameters of all objects and all scales in the scene were derived. First, the NDVI was calculated for each image in order to produced two NDVI difference image (T2-T1 and T4-T3). Then, these difference images were used to derive statistical parameters such as the mean and the standard deviation of each object. Based on a object-based statistical analysis, changed objects from unchanged ones were separated and categorized. Results showed that all the objects observed in the field representing changes of deforestation and re-growth were included, and only a few objects that had fire in its early stages were not detected, showing the need to use a larger series of temporal images. The method was efficient to detect and separate the changed areas according to the type of change and demonstrating the ability of the rule sets developed so far, to discriminate objects and form semantic classes.

Keywords: Remote sensing. Change detection. Brazilian savanna. Object-based statistical analysis.

SUMÁRIO

1 INTRODUÇÃO.....	01
2 OBJETIVOS.....	03
3 REFERENCIAL TEÓRICO.....	03
3.1 O Cerrado mineiro.....	03
3.2 Mapeamento e monitoramento do Cerrado no Brasil e em Minas Gerais.....	06
3.3 Questão de escala.....	07
3.4 Segmentação de imagens.....	10
3.5 Detecção de mudanças.....	12
3.5.1 Aquisição de dados.....	16
3.5.2 Pré-processamento.....	17
3.5.3 Análise.....	18
3.5.4 Avaliação.....	19
4 MATERIAIS E MÉTODOS.....	20
4.1 Área de estudo e dados.....	20
4.2 Pré-processamento.....	21
4.3 Dados de referência.....	23
4.4 Processamento de imagens baseado em objetos.....	26
4.4.1 Segmentação de imagens.....	26
4.4.2 Assinatura espectro-temporal dos objetos.....	29
4.4.3 Detecção de mudanças.....	30
5 RESULTADOS E DISCUSSÃO.....	33
5.1 Pré-processamento dos dados de satélite.....	33
5.2 Avaliação da segmentação das imagens.....	36
5.3 Detecção de mudanças.....	41
5.3.1 Detecção de áreas onde houve crescimento e perda da vegetação.....	52
5.3.2 Detecção de áreas em que houve ocorrência de queimadas.....	56
5.3.3 Detecção de áreas nas quais houve ocorrência de sazonalidade da vegetação.....	58
5.3.4 Detecção de áreas de não mudança e análise global das mudanças.....	60
6 CONSIDERAÇÕES.....	61

8 RECOMENDAÇÕES E POTENCIALIDADES DA METODOLOGIA.....	62
REFERÊNCIAS.....	64

LISTA DE FIGURAS

Figura 1 Imagens com diferentes resoluções espaciais (tamanho de pixel ou grão) (TURNER; GARDNER; O'NEILL, 2001).....	8
Figura 2 Áreas com diferentes extensões em uma mesma imagem (TURNER; GARDNER; O'NEILL, 2001).....	9
Figure 3 Localização da área de estudo e detalhamento das áreas analisadas LS, SSA1 e SSA2.	20
Figure 4 Demonstração das etapas do pré-processamento.....	23
Figure 5 Mapa de áreas de ocorrência de mudanças para T21 como referência.	24
Figure 6 Mapa de áreas de ocorrência de mudanças para T43 como referência.	25
Figure 7 Fluxograma da detecção de mudanças baseada em objetos	26
Figure 8 Rede hierárquica de objetos obtidos na segmentação bottom-up (DEFEINIENS IMAGING, 2003)	27
Figure 9 Níveis de segmentação obtidos por meio do algoritmo bottom-up	28
Figure 10 Assinatura espectro-temporal dos objetos, mostrando o conjunto de pontos considerados outliers e a região dos objetos próximos da média (média e desvio padrão)	30
Figure 11 Teste estatístico para identificar os objetos de mudança e a elipse representada pelo limiar T com um nível de confiança 1-alpha.....	32
Figure 12 Cálculo da distância de Mahalanobis e limiar T (qui-quadrado).....	32
Figure 15 Imagem NDVI-diferença LS, SSA1 e SSA2 para T21	35
Figure 16 Imagem NDVI-diferença LS, SSA1 e SSA2 para T43	36
Figure 17 Imagem Landsat TM original da área de estudo	37
Figure 18 Avaliação da segmentação, tendo como base a imagem original.....	38
Figure 19 Imagem segmentada com atribuição de um nível de cinza para cada segmento, correspondendo à média dos valores dos pixels	39
Figure 20 Avaliação da segmentação, tendo como base a média de cores RGB	40
Figure 21 Pontos de mudança para LS T21 (1-alpha = 0,95).....	41
Figure 22 Pontos de mudança para LS T21 (1-alpha = 0,99).....	42
Figure 23 Pontos de mudança para LS T43 (1 - alpha = 0,95).....	43
Figure 24 Pontos de mudança para LS T43 (1-alpha = 0,99).....	44
Figure 25 Pontos de mudança para SSA1 T21 (1-alpha = 0,95).....	45
Figure 26 Pontos de mudança para SSA1 T21 (1-alpha = 0,99).....	46
Figure 27 Pontos de mudança para SSA1 T43 (1-alpha = 0,95).....	47
Figure 28 Pontos de mudança para SSA1 T43 (1-alpha = 0,99).....	48
Figure 29 Pontos de mudança para SSA2 T21 (1-alpha = 0,95).....	49

Figure 30 Pontos de mudança para SSA2 T21 (1-alpha = 0,99).....	50
Figure 31 Pontos de mudança para SSA2 T43 (1-alpha = 0,95).....	51
Figure 32 Pontos de mudança para SSA2 T43 (1-alpha = 0,99).....	52
Figura 33 Exemplo de áreas com ocorrência de crescimento da vegetação detectadas.....	54
Figura 34 Exemplo de objetos com áreas de perda da vegetação detectadas	55
Figura 35 Exemplo de áreas de perda da vegetação detectadas.....	56

LISTA DE TABELAS

Tabela 1 Métodos de detecção de mudança. Adaptação de Hall e Hay (2003) e Singh(1989).....	13
Tabela 2 Número de objetos de crescimento de vegetação nos dados de referência, bem como o número de objetos detectados em diferentes níveis de confiança e em diferentes áreas de análise	52
Tabela 3 Número de objetos de perda de vegetação nos dados de referência, bem como o número de objetos detectados em diferentes níveis de confiança e em diferentes áreas de análise	53
Tabela 4 Acurácia da classe crescimento da vegetação para diferentes níveis de confiança e diferentes áreas de análise.....	53
Tabela 5 Acurácia da classe perda de vegetação para diferentes níveis de confiança e diferentes áreas de análise.....	55
Tabela 6 Número de objetos de áreas de ocorrência de queimadas nos dados de referência, bem como o número de objetos detectados em diferentes níveis de confiança e em diferentes áreas de análise	56
Tabela 7 Acurácia da classe queimada para diferentes níveis de confiança e diferentes áreas de análise.....	57
Tabela 8 Número de objetos de áreas de ocorrência de sazonalidade da vegetação nos dados de referência, bem como o número de objetos detectados em diferentes níveis de confiança e em diferentes áreas de análise.....	59
Tabela 9 Acurácia da classe sazonalidade da vegetação para diferentes níveis de confiança e diferentes áreas de análise.....	59
Tabela 10 Número de objetos de não mudança nos dados de referência, bem como o número de objetos detectados em diferentes níveis de confiança e em diferentes áreas de análise erroneamente como mudança	60
Tabela 11 Índices globais da performance do método de detecção de mudanças para todas as áreas de análise e diferentes níveis de confiança.....	60

1 INTRODUÇÃO

Várias regiões, em todo o mundo, estão sofrendo rápidas mudanças na cobertura florestal, ocasionadas por atividades antropogênicas. Essas atividades estão relacionadas, principalmente, a agricultura, pecuária e degradação das florestas, resultado de extração ilegal de madeira e do aumento da frequência de queimadas.

Extensivas pesquisas e projetos de monitoramento sobre o uso e a cobertura terrestre atual, como o projeto Past Global Changes, o PAGES; o projeto BIOME 300; o Land-Use Land-Cover Change, ou LUCC (LAMBIN; GEIST; RINDFUSS, 2006); o Global Forest Resources Assessment, FRA (FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS - FAO, 2010), bem como os projetos nacionais Programa de Cálculo do Desmatamento da Amazônia 9 PRODES), Detecção de Desmatamento em Tempo Real (DETER), Monitoramento de Queimadas nos Biomas Brasileiros (QUEIMADAS) e Monitoramento da Degradação na Amazônia (DEGRAD) (INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE, 2008), tem mostrado a grande força de transformação da cobertura da Terra em todas as regiões do mundo.

Na Índia e também em Sri Lanka, Bangladesh, Myanmar, Tailândia, Laos, Cambodia, Vietnam, Malásia, Brunei, Singapura, Indonésia e Filipinas, em torno de 131 milhões de hectares (47% de uma área de 8 milhões de km²) de áreas de floresta e terras alagadas tiveram um declínio em um período de cem anos e, no mesmo período, a área cultivada para agropecuária teve um incremento de 106 milhões de hectares (LAMBIN; GEIST; RINDFUSS, 2006). Na África, em torno de 3,4 milhões de hectares de floresta foram perdidos, anualmente, entre os anos de 2000 e 2010, seguida da Oceania, que também reportou uma taxa de perda de área florestal em torno de 700 000 hectares por

ano, no mesmo período (entre 2000 e 2010) (FAO, 2010). Mas a maioria do declínio de áreas florestadas pode ser encontrada na América do Sul, a qual sofreu a maior taxa de perda de florestas entre 2000 e 2010, aproximadamente de 4 milhões de hectares por ano, uma grande perda na comparação com os primeiros cinco anos deste século (entre 2000 e 2005), quando houve uma redução de 4.251.000 hectares de áreas florestadas (FAO, 2009, 2010).

O desflorestamento em áreas tropicais tem atraído a atenção para potenciais efeitos de erosão do solo, aumento de enchentes e enxurradas, aumento da concentração de CO₂, mudanças no clima e perda da biodiversidade (MYERS, 1988). O bioma Cerrado está particularmente ameaçado por esses efeitos, uma vez que tem áreas relativamente mais adequadas para a implementação de sistemas produtivos agrícolas.

Até a década de 1950, os Cerrados mantiveram-se quase inalterados. A partir da década de 1960, com a interiorização da capital e a abertura de uma nova rede rodoviária, largos ecossistemas deram lugar à pecuária e à agricultura extensiva, como soja, arroz e trigo. Tais mudanças se apoiam, sobretudo, na implantação de novas infraestruturas viárias e energéticas, bem como na descoberta de novas vocações desses solos regionais, permitindo novas atividades agrárias rentáveis, em detrimento de uma biodiversidade até então pouco alterada. Durante as décadas de 1970 e 1980, houve um rápido deslocamento da fronteira agrícola, com base em desflorestamentos, queimadas, uso de fertilizantes químicos e agrotóxicos, que resultou em 67% de áreas do Cerrado “altamente modificadas”, como voçorocas, assoreamento e envenenamento dos ecossistemas (INSTITUTO BRASILEIRO DO MEIO AMBIENTE E DOS RECURSOS SUSTENTÁVEIS - IBAMA, 2001).

O monitoramento efetivo do Cerrado torna-se essencial, pois continuam-se causando grandes danos ambientais, apontados por Klink e Machado (2005), como fragmentação de habitats, extinção da biodiversidade, invasão de espécies

exóticas, erosão dos solos, poluição de aquíferos, degradação de ecossistemas, alterações nos regimes de queimadas, desequilíbrios no ciclo de carbono e, possivelmente, modificações climáticas regionais.

Neste contexto configuram-se as oportunidades para a execução do presente trabalho, por meio da adequação de um novo procedimento para a detecção de mudanças na cobertura do solo de Minas Gerais usando imagens de sensoriamento remoto.

2 OBJETIVOS

O presente estudo foi realizado com os seguintes objetivos: (a) avaliar a performance do método de detecção de mudanças baseado em objetos (BONTEMPS et al., 2008; DESCLÉE et al., 2006; DUVEILLER et al., 2008) em detectar mudanças da vegetação no bioma Cerrado do estado de Minas Gerais; (b) separar os objetos detectados por classe de mudança ocasionada por perda de vegetação (desflorestamento e culturas agrícolas), queimadas, crescimento de vegetação (regeneração e culturas agrícolas) e sazonalidade da vegetação e (c) avaliar o comportamento do método em duas escalas diferentes.

3 REFERENCIAL TEÓRICO

3.1 O Cerrado mineiro

O bioma Cerrado está localizado entre a zona equatorial e 23º de latitude sul e faz limite com a floresta Amazônica na região norte, a floresta Atlântica nas regiões sul e sudeste e a Caatinga (vegetação decídua xerófila) na região do semiárido no nordeste (MOTTA; CURI; FRANZMEIER, 2002).

A diversidade do Cerrado pode ser evidenciada por meio da existência de variados tipos de vegetação como parte do bioma. Segundo o sistema Brasileiro de Classificação da Vegetação Brasileira do IBGE (BRASIL, 2010), o bioma é subdividido em quatro subgrupos de formação, que são: Savana Florestada (Sd), Savana Arborizada (Sa), Savana Parque (Sp) e Savana Gramíneo-Lenhosa (Sg). Comparativamente ao sistema de classificação proposto por Ribeiro e Walter (2008), a Savana Arborizada corresponde ao tipo fitofisionômico denominado “cerrado sentido restrito” e, em especial, aos subtipos “cerrado denso” e “cerrado típico”. Nos terrenos bem drenados, a Savana Parque equivale aos subtipos definidos como “cerrado ralo”, “cerrado rupestre” e, às vezes, como “campo sujo” e “campo rupestre”. Nos terrenos mal drenados, a equivalência se dá com o “parque de cerrado” e, eventualmente, com “vereda”, “campo sujo úmido” e “campo sujo com murundus”.

Essa alta diversidade de ambientes resulta em uma alta riqueza de espécies, com plantas herbáceas, arbustivas, arbóreas e cipós, cerca de 12.356 espécies que ocorrem espontaneamente e 11.627 espécies pteridófitas e fanerógamas, sendo aproximadamente 44% da flora endêmica (BRASIL, 2010; MENDONÇA et al., 2008).

O fato é que o Cerrado e as florestas podem ocorrer na mesma região, na mesma latitude e nas mesmas condições climáticas. Estas observações geraram tipos de hipóteses sobre a origem dos Cerrados, como (1) a origem da vegetação por meio da indução humana baseada em observações de espécies adaptadas ao fogo, as quais sugerem que os Cerrados poderiam ser resultado do desenvolvimento de florestas secas com influência do fogo (LEDRU, 2002) e (2) estas hipóteses suportam a origem natural dos Cerrados baseada na ocorrência dos mesmos em áreas apenas recentemente colonizadas por humanos, e a descoberta da extinção dos grandes mamíferos que viviam em paisagens florestais no final do Pleistoceno (LEDRU, 2002; WARMING; FERRI, 1973).

Desde os anos de 1950, as áreas de Cerrado quase não sofreram mudanças. A partir do final dos anos de 1950, com a internacionalização da capital do país, estradas atravessaram o Bioma, conectando Brasília com São Paulo, Rio de Janeiro e Belo Horizonte, na região sudeste e Belém, na região Amazônica (KLINK; MOREIRA, 2002; LUCARELLI et al., 1989). Este fato resultou na transformação de grandes ecossistemas em extensivas fazendas de pecuária e cultivo agrícola, como culturas de soja, arroz e trigo. Essas alterações eram baseadas, principalmente, na construção da nova infraestrutura rodoviária e energética, do crescimento populacional e de urbanização, resultado da migração interna, com a qual a população cresceu, passando de cerca de 221 mil, em 1871, para cerca de 18 milhões de habitantes em 2000. Também contribuiu para essa mudança a descoberta de novas vocações regionais do solo, permitindo que novas e rentáveis atividades agrícolas se estabelecessem com extrema rapidez. Durante os anos de 1970, 1980 e até 2008, houve um rápido deslocamento da fronteira agrícola, baseada no desflorestamento e no uso de fertilizantes químicos, pesticidas e queimadas, o qual resultou em 47,84% das áreas de Cerrado altamente modificadas (BRASIL, 2010; IBAMA, 2001). Em se tratando de queimadas, nem sempre o fogo foi considerado um fenômeno maléfico para este bioma.

O fogo exerce importante papel no estabelecimento de comunidades da fauna e da flora do bioma Cerrado, por meio de adaptações às condições adversas deste fenômeno há 32.400 anos antes do presente, ou ap (MIRANDA; BUSTAMANTE; MIRANDA, 2002; PEREIRA, 2009; VICENTINI, 1993). Entretanto, as queimadas são uma prática presente e constante, desde a ocupação humana no Cerrado brasileiro. Os povos indígenas da região utilizavam o fogo para a caça, para estimular a produção de frutos, para o controle de espécies indesejáveis e na guerra tribal (COUTINHO, 1990; MIRANDA; BUSTAMANTE; MIRANDA, 2002; MISTRY, 1998). Hoje em dia, a principal

causa de incêndios no Cerrado é agrícola. Seu propósito pode ser para transformar Cerrado em campos de cultivo ou para o manejo da vegetação nativa ou pastagem plantada (COUTINHO, 1990).

As alterações que ocorrem no Cerrado acarretam um aumento significativo na dificuldade de distinção de suas fisionomias. Até mesmo em condições naturais, devido aos ecótonos formados nas transições das mesmas, os próprios especialistas botânicos têm problemas para padronizar os diferentes critérios e as escalas que são utilizadas para abordar a nomenclatura dos variados tipos fitofisionômicos encontrados nas regiões Savânicas. Essa dificuldade pode ser observada no histórico da classificação da vegetação brasileira de Veloso et al. (1991 citados por OLIVEIRA, 2004).

Assim, o monitoramento efetivo desse bioma torna-se de extrema importância, pois essas mudanças em sua cobertura continuam causando grandes danos ambientais, entre os quais podem-se citar: fragmentação de habitats, extinção da biodiversidade, intensa invasão de espécies exóticas, erosão dos solos e aumento das voçorocas, poluição dos aquíferos, alterações nos regimes de queimadas, desequilíbrios no ciclo de carbono e, possivelmente, modificações climáticas regionais.

3.2 Mapeamento e monitoramento do Cerrado em Minas Gerais

Desde 2003, a cada dois anos, a Universidade Federal de Lavras (UFLA), em parceria com o Instituto Estadual de Florestas (IEF) e a Secretaria de Meio Ambiente e Desenvolvimento Sustentável do Estado de Minas Gerais, vem trabalhando no mapeamento e no monitoramento da flora nativa e dos reflorestamentos do Estado, buscando superar as deficiências que sempre marcaram o gerenciamento do patrimônio natural, notadamente dos recursos florestais e dos ecossistemas que lhes são associados.

Até hoje, estes trabalhos foram executados a uma resolução espacial de 30 m – com imagens dos sensores Landsat ETM+ e TM –, possibilitando conhecer a situação florestal de Minas Gerais e as tendências de uso da terra, em escalas cartográficas de, no máximo, 1:150.000. Porém, a partir de novos convênios entre governo e empresas, do aumento da oferta e da diminuição de custos das imagens de alta resolução espacial, bem como da busca por um maior detalhamento das informações já levantadas, o governo do estado vem adquirindo imagens de diferentes sensores. Para atingir essas metas, são necessárias modificações metodológicas que atendam às necessidades de monitoramento do estado.

Por fim, o estado vem monitorando apenas mudanças ocasionadas pela remoção da vegetação, sem considerar as áreas de regeneração da mesma. O monitoramento do processo de regeneração da vegetação nativa é fundamental na avaliação e no planejamento dos fomentos florestais e dos incentivos à recuperação de áreas degradadas.

Existem, ainda, dificuldades de monitoramento dos tipos fisionômicos que apresentam deciduidade, pois estes se confundem com mudanças relacionadas com a perda de vegetação devido à perda de folhas nos períodos de seca.

3.3 Questão de escala

Um dos maiores problemas em se definir “escala” está relacionado com a variedade de significados existentes entre diversas disciplinas e comunidades científicas. Para um ecólogo, escala está relacionada com “grão”, uma medida de tamanho de manchas em uma paisagem fragmentada dentro de habitats. Para um cartógrafo, escala é definida simplesmente como uma razão entre a distância no mapa e a distância real - o uso é muitas vezes qualificado como uma “escala métrica” (GOODCHILD; QUATTROCHI, 1997).

O termo “grão” (*grain*, em inglês) é utilizado quando o estudo refere-se ao tamanho do menor objeto. Já o termo extensão (ou dimensão, *extent*, em inglês) refere-se ao tamanho total da área de estudo. Diferentes dados de satélites têm tamanhos variados de pixel, ou resolução espacial, como imagens Quickbird, com 2,5 por 2,5 m de pixel; Landsat TM, com 30 por 30 m de pixel; Spot, com 10 por 10 m de pixel, etc. A escolha da escala de uma área de estudo pode ser independente da resolução espacial (tamanho do pixel), como se pode observar nas Figuras 1 e 2, mas tem certo grau de correlação, como quando se opta por analisar uma área com pequena extensão em uma imagem, podendo-se também obter mais detalhes, caso essa imagem possua uma melhor resolução espacial.

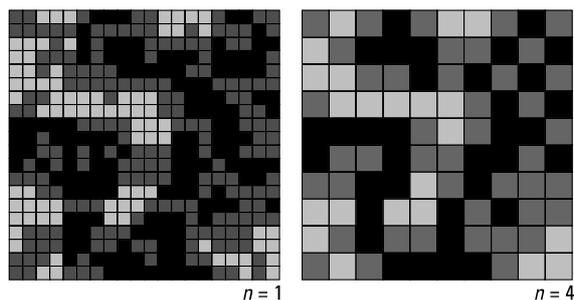


Figura 1 Imagens com diferentes resoluções espaciais (tamanho de pixel ou grão)
(TURNER; GARDNER; O'NEILL, 2001)

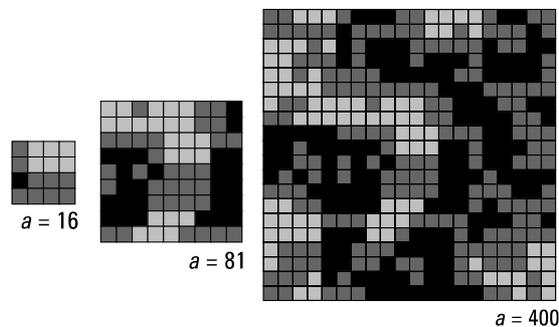


Figura 2 Áreas com diferentes extensões em uma mesma imagem (TURNER; GARDNER; O'NEILL, 2001)

O fato é que o termo escala pode estar relacionado com escala geográfica (escala espacial), escala temporal e muitos outros tipos de dimensões, dependendo do tipo de pesquisa.

Turner, Gardner e O'Neill (2001) descrevem algumas definições de escala relacionadas com alguns conceitos e terminologias, da seguinte forma:

- (1) escala absoluta - refere-se a distância atual, direção, forma e geometria;
- (2) escala cartográfica - refere-se ao grau de redução espacial, indicando a extensão utilizada para representar uma maior unidade de medida, refere-se à razão de distância no mapa para a distância na superfície da Terra que é representada por mapas (exemplo 1:10.000);
- (3) limiar crítico - refere-se a um ponto que representa uma mudança abrupta na qualidade, propriedade ou fenômeno;
- (4) extensão - refere-se ao tamanho da área de estudo ou à duração do tempo considerado;
- (5) grão - refere-se a menor unidade de um objeto de análise encontrado em um conjunto de dados;
- (6) hierarquia - refere-se a um sistema de interconexões ou organizações;
- (7) nível de organização - lugar dentro de uma hierarquia biótica (por exemplo, organismo, população, etc.);

- (8) escala relativa - transformação da escala absoluta em uma escala que descreve uma distância relativa, direção ou geometria;
- (9) resolução - precisão de uma medida, ou seja, o tamanho do grão, se espacial;
- (10) escala - dimensão espacial e temporal de um objeto de processo, caracterizados, ambos, por grão e extensão.

As imagens de sensoriamento remoto são uma ótima maneira de coletar dados espaciais em múltiplas escalas de forma hierárquica, podendo fornecer uma cobertura sobre grandes áreas, permitindo que as investigações à escala da paisagem, ou imagens mais detalhadas, podendo ser coletados dados que representam áreas menores, a maioria praticamente por meio de alguma forma de amostragem (LINKE et al., 2007).

A escala apropriada a ser escolhida é função do tipo de ambiente e o tipo de informação que se deseja analisar (WOODCOCK; STRAHLER, 1987).

No presente estudo, o termo escala fez referência ao tamanho da área de estudo (extensão geográfica) e a menor unidade de análise não será um pixel, mas, sim, um objeto ou um segmento, formado por um conjunto de pixels.

3.4 Segmentação de imagens

O termo segmentação de imagens refere-se à delimitação de objetos de interesse por similaridade ou por descontinuidade.

Então, por que segmentar as imagens em objetos ou regiões para analisá-las? **Primeiro**, para decompor a imagem em partes (objetos ou segmentos) para as posteriores análises, podem-se segmentar apenas partes da imagem as quais serão necessárias para analisar; **segundo**, para efetuar uma mudança na representação dos dados (SHAPIRO; STOCKMAN, 2000) - os pixels são agrupados com base em critérios de homogeneidade e forma; **terceiro**, as limitações das abordagens de análises baseadas em pixels que devem ser

suprimidas; **quarto**, as cenas podem ser analisadas em uma abordagem em multiescala, com objetos de diferentes tamanhos, formas e localizações espaciais (HAY; CASTILLA, 2008) - em diversos casos, os objetos gerados não proporcionam uma informação relevante em função do objetivo do estudo. Para isso, adéqua-se a segmentação em diferentes escalas e análises, ambas dentro de uma hierarquia de níveis e entre níveis; **quinto**, para integrar diferentes técnicas de processamento, recuperação e análise de dados em multirresolução de diferentes sensores (LANG, 2008) e **sexto**, para obter uma maior integração com softwares de SIG, em que são incorporadas algumas das funcionalidades dos mesmos, como informações auxiliares para uma classificação temática, medidas de distância, etc. (NAVULUR, 2007).

Em geral, as seguintes vantagens são provenientes das análises de imagens baseadas em objetos (BENZ et al., 2004; BOCK et al., 2005; HAY; CASTILLA, 2008; HAY et al., 2005; NAVULUR, 2007; NEUBERT; HEROLD; MEINEL, 2008):

- (1) particionar uma imagem em objetos é similar à maneira pela qual seres humanos conceitualmente organizam a paisagem para compreendê-la;
- (2) o reconhecimento de que pixels individuais não são verdadeiros objetos geográficos, o que significa objetos de imagem possuem uma relação intuitiva espacial entre objetos do mundo real;
- (3) vantagens nos cálculos estatísticos e de textura;
- (4) a fácil integração entre SIG e sensoriamento remoto (para classificações temáticas, incluindo o uso de informações auxiliares, medidas de distâncias, etc.);
- (5) aumentam as possibilidades de análises, uma vez que uma quantidade maior de características e atributos do sensoriamento remoto pode ser contemplada, como, por exemplo, espectral (bandas multiespectrais incluindo a banda pancromática), espacial (área, direção, distância, largura), morfológica

(parâmetros de forma e textura), contextual (relacionado com vizinhos, análises de proximidade) e temporal (séries temporais);

- (6) permite a incorporação de atuais métodos e técnicas utilizados para análise de imagens como métodos de classificações supervisionadas, lógica fuzzy e classificações baseadas e regras;
- (7) permite a extração de características de uma mesma cena em diferentes resoluções ou escalas;
- (8) o número softwares livres e proprietários disponíveis com análises baseadas em objetos está aumentando de forma constante. Como exemplos têm-se: Interimage, Edge Detection and Image Segmentation System (EDISON), Extended Water Shed (EWS), eCognition, HalconSEG, InfoPACK, Recursive Hierarchical Segmentation (RHSEG), Size-Constrained Region Merging (SCRM), Erdas Imagine extension (Imagine WS), PARBAT, SEGEN e SegSAR.

Com todas as vantagens abordadas anteriormente, a segmentação de imagens será incorporada nos processamentos e análises de detecção de mudanças do uso e cobertura da Terra.

3.5 Detecção de mudanças

Técnicas de detecção de mudanças utilizando dados de sensoriamento remoto têm sido aplicadas com êxito para o mapeamento e o monitoramento da vegetação, além de possibilitarem a avaliação de grandes extensões territoriais com custos menores, se comparados à mesma avaliação realizada totalmente em campo (FAO, 2009). Neste contexto, detecção de mudanças pode ser definida como o processo de identificar diferenças no estado de um objeto ou fenômeno sobre a superfície da Terra, utilizando observações feitas em épocas diferentes (SINGH, 1989).

Em vários estudos têm sido demonstrada a estreita relação entre a reflectância observada em dados de imagens de sensoriamento remoto e as características dos diferentes tipos de vegetação. Essas constatações justificam seu uso para o monitoramento da cobertura da Terra, uma vez que a mudança no status de um objeto resulta em uma mudança nos valores de reflectância. Sendo assim, mudanças na vegetação ocasionam alterações nos sinais captados pelos sensores remotos (DESCLÉE, 2007). Para isso, qualquer abordagem de detecção de mudanças da vegetação exige um conjunto de dados bem preparado e um conjunto específico de observações do terreno para calibrar as mudanças de um tipo de condição de vegetação ou outra (FRANKLIN, 2001).

Com base nesses pressupostos, métodos de detecção de mudança visam analisar duas ou mais imagens de sensores remotos adquiridas em datas diferentes para a identificação dessas modificações na cobertura da Terra.

Diferentes métodos de detecção de mudança têm sido desenvolvidos para estudar a cobertura da Terra (COPPIN et al., 2004; LU et al., 2004), como se observa na Tabela 1.

Tabela 1 Métodos de detecção de mudança. Adaptação de Hall e Hay (2003) e Singh (1989)

Método usado para detecção de mudanças	Autores
Razão de imagens (Image Rationing)	Howarth, Wickware (1981), Nelson (1983), Singh (1984, 1986), Todd (1977) e Wilson, Blackman e Spann (1976)
Índice de vegetação por diferença (Vegetation index difference)	Angelici, Bryntin e Friwmasn (1977), Banner e Lynham (1981), Coiner (1980), Coppin e Bauer (1994), Howarth, Boasson (1983), Lyon et al. (1998), Nelson (1983) e Singh (1984, 1986)

Imagem diferença (Image differencing)	Anutae Bauer (1973), Gong, Ledrew e Miller (1992), Ingram, Knapp e Robinson (1981), Jenson e Toll (1982), Manavalan, Kesavasamy e Adiga (1995), Miller, Nualchawee e Tom (1978), Nelson (1983), Singh (1984, 1986), Toll, Royal e Davis (1980) e Weismiller et al. (1977)
Regressão (Image Regression)	Hanaizumi, Okumura e Fujimura (1991), Ingram, Knapp e Robinson (1981), JhaeUnni (1994) e Singh (1984, 1986)
Análise de mudança de vetor (Change vector analysis)	Colwell e Weber (1981), Johnson e Kasischke (1998), Lambin (1996), Lambine Strahler (1994), Malila (1980) e Virage Colwell (1987)
Componentes principais (Principal Components)	Byrne, Crapper e Mayo (1980), Collins e Woodcock (1996), Deer e Longmore (1994), Fung e Ledrew (1987), Lodwick (1979), Siljstrom-Ribede Moreno-Lópes (1995), Singh (1984, 1986), Singh e Harrison (1985) e Toll, Royal e Davis (1980)
Análise de forma (Shape analysis)	Choo, Pham e Maeder (1989)
Ondaleta (Wavelet)	Carvalho (2001) e Collins e Woodcock (1994)
Textura local (Local texture)	Lazaroff e Brennan (1992)
Endmember analysis	Adams et al. (1995) e Kressler e Steinnocher (1999)
Inteligência Artificial (Artificial intelligence)	Matsuyama (1987)
Redes neurais (Artificial neural networks)	Chan, Chan e Yeh (2001), Dai e Khorram (1997) e Gopale Woodcock (1996)
Classificação em multiclasse direta (Direct multiclass classification)	Hoffer e Lee (1989) e Weismiller et al. (1977)
Expert system	Stefanov, Ramsey e Christensen (2001)
Fuzzy post-classification comparison	Deer (1998), Deer e Eklund (2001), Eklund, You e Deer (2000), Fisher e Pathirana (1993) e Foody (2001)

Comparação pós-classificações (Post-classification comparison)	Gordon (1980), Howarth e Wickware (1981), Jensen et al. (1995), Joyce, Ivey e Burns (1980), Munyati (2000), Riordan (1980), Singh (1984, 1986), Swain (1978) e Weismiller et al. (1977)
Detecção de mudanças baseada em objetos (Object-based change detection)	Bontemps et al. (2008), Chirici et al. (2011), Conchedda, Durieux e Mayaux (2008), Desclée, Bogaert e Defourny (2006), Duveiller et al. (2008), McDermid et al. (2008), Niemeyer et al. (2006) e Radoux e Defourny (2008)

Esses métodos variam em termos de refinamento, robustez e complexidade (HALL; HAY, 2003) e podem ser agrupados em três categorias: interpretações visuais, análises baseadas em pixel e análises baseadas em objetos (DESCLÉE, 2007).

No primeiro método, as regiões com alterações na cobertura terrestre podem ser detectadas por analistas qualificados, por meio da comparação visual de imagens multitemporais, delineando as zonas afetadas pelas mudanças. Porém, nesse caso, além de o analista ter que ser experiente, o método só é aplicável a pequenas áreas, não sendo apropriado para o monitoramento de mudanças em escalas geográficas regionais.

O segundo método, mais utilizado atualmente, consiste em empregar técnicas baseadas em pixel para análise digital de mudanças nas imagens, ou seja, são comparados apenas os valores dos pixels de imagens multitemporais, independentemente de seus vizinhos. Esse método, apesar de ser amplamente empregado, tem se mostrado pouco eficiente e com aumento significativo dos erros quando imagens com alta resolução espacial constituem o objeto de análise.

Já no terceiro método, baseado em objetos, a mínima unidade de análise é um objeto - um conjunto de pixels homogêneos - o qual pode variar em função da escala de análise e, conseqüentemente, da gama de detalhes que se deseja

extrair dos resultados. Além de as análises também serem baseadas nos valores dos pixels que compõem cada objeto, ainda são levados em consideração outros parâmetros relacionados a forma, textura e vizinhança de objetos.

Estudos de detecção de mudanças por sensoriamento remoto envolvem uma série de etapas sequenciais, incluindo aquisição de dados, pré-processamento e/ou aprimoramento dos dados e análises e avaliação das informações (CIHLAR, 2000; COOPS; WULDER; WHITE, 2007; KENNEDY et al., 2009; LUNETTA, 1998; SCHOTT, 1997).

3.5.1 Aquisição de dados

A seleção de dados de satélites apropriados, crucial para o mapeamento e monitoramento, é altamente dependente da escala espacial e temporal (DESCLÉE, 2007; LINKE et al., 2007). Recentes observações da Terra por meio de sensores de satélites possibilitaram uma consistência espacial e temporal do estado da sua cobertura (RAMANKUTTY, 2006). Estas observações são função de uma demanda cada vez maior por um acompanhamento anual, semestral, trimestral, bimestral e até mensal das mudanças da cobertura terrestre, a preços mais acessíveis e resoluções espaciais, espectrais e temporais variadas. Assim, quatro características que devem ser consideradas para a escolha correta dos dados satélites em projetos de sensoriamento remoto para o monitoramento da paisagem são: tempo, tipo, qualidade e custo das imagens (KENNEDY et al., 2009).

Estas características estão relacionadas com o objetivo de cada projeto. Por exemplo, mudanças em tamanho e forma de manchas de tipos vegetacionais, mudanças lentas no tipo de cobertura da Terra ou na composição de espécies, mudanças abruptas na cobertura terrestre, mudanças abruptas em um único tipo vegetacional e mudanças no tipo e extensão de processos sazonais podem requerer imagens de sensores de diferentes resoluções espaciais, temporais e

preços variados, como fotos aéreas, imagens Quickbird, Ikonos, WorldView, Formosat, etc. (alta resolução com altos custos), imagens Landsat, Aster, Spot, etc. (resolução moderada com baixo custo ou sem custo) e imagens MODIS, Spot Vegetation, etc. (baixa resolução com baixo custo ou sem custo).

Tempo e qualidade de imagem devem ser escolhidos para minimizar a influência de efeitos indesejáveis sobre o espaço espectral, uma vez que tais efeitos podem obscurecer ou produzir desde mudanças reais a falsas mudanças. Assim, questões chave para a escolha dos dados, como o estado fenológico da paisagem, a angulação do sol, as condições atmosféricas e a qualidade geométrica e radiométrica das imagens, devem ser consideradas (KENNEDY et al., 2009).

Note que o maior custo, em muitos estudos de sensoriamento remoto, não é o da aquisição de imagens, mas o do trabalho necessário para processar as imagens, obter informação e avaliar os resultados (KENNEDY et al., 2009; LUNETTA, 1998).

3.5.2 Pré-processamento

O sucesso na identificação de mudanças e distúrbios na paisagem depende de um robusto pré-processamento das imagens (COOPS; WULDER; WHITE, 2007; LU et al., 2004; TRIETZ; ROGAN, 2004). Esta é uma etapa especialmente crítica em estudos de mudança, pois os métodos de detecção de mudança assumem que as propriedades espectrais de áreas de não mudança são estáveis e o pré-processamento inadequado pode aumentar o erro, fazendo com que ocorra detecção de falsas mudanças no espaço espectral (COOPS; WULDER; WHITE, 2007; KENNEDY et al., 2009; LUNETTA, 1998; LU et al., 2004; PEDDLE; TEILLET; WULDER, 2003; SCHOWENGERDT, 1997).

É importante ressaltar que cada etapa no pré-processamento modifica a posição e ou as propriedades espectrais de cada pixel na imagem, o que significa que em cada uma dessas etapas pode ocorrer a introdução de um erro potencial.

Na teoria, se o pré-processamento proceder-se perfeitamente bem sucedido, todas as alterações no valor espectral em um determinado pixel, entre duas imagens, poderão ser atribuídas a mudanças reais nas condições da superfície representada por esse pixel. Porém, na prática, em nenhuma etapa de pré-processamento, todos os efeitos são realizados perfeitamente. Assim, uma parte da mudança espectral observada em um pixel ao longo do tempo é pouco informativa e as técnicas de análise na próxima fase do projeto devem levar isso em conta (KENNEDY et al., 2009).

Uma vez que o pré-processamento tenha sido aplicado com sucesso, os dados estarão prontos para o início das análises.

3.5.3 Análise

Uma ampla variedade de algoritmos de detecção de mudanças e abordagens de séries temporais tem sido desenvolvida para detectar alterações e distúrbios na paisagem, como mostrado na Tabela 1 e a seleção e a implementação do método mais adequado são um processo importante em estudos de detecção dessas alterações (COOPS; WULDER; WHITE, 2007). Apesar dessa variedade de métodos, as abordagens de detecção de mudanças têm uma fase de modelagem (ou algoritmo funcional) e uma fase de subtração (ou diferença), na qual a fase de modelagem refere-se ao desenvolvimento ou implementação de algoritmos no conjunto de dados espectrais, enquanto a subtração refere-se ao processo de comparação entre datas via matemática de bandas ou outros métodos (GONG; XU, 2003; KENNEDY et al., 2009; YUAN; ELVIDGE; LUNETTA, 1998).

O maior desafio nas abordagens de análise encontra-se na etapa de subtração ou diferença das imagens, em que a correção radiométrica deve ser robusta e os dados de referência devem ser adquiridos.

3.5.4 Avaliação

Uma análise da literatura indica que diferentes métodos de detecção de mudança podem produzir distintos mapas de mudanças na cobertura da Terra (SINGH, 1989). Técnicas padrões foram desenvolvidas para avaliar a precisão desses mapas (CONGALTON; GREEN, 2009; GOPAL; WOODCOCK, 1994; KENNEDY et al., 2009), em que o erro é normalmente quantificado estatisticamente, comparando o mapa obtido com os dados de referência independentes amostrados no local da área de estudo e ou dados já avaliados (com seus próprios erros), obtidos de estudos anteriores.

Para realizar uma adequada avaliação da acurácia, os dados independentes devem ser considerados como "verdade" (CONGALTON; GREEN, 2009; KENNEDY et al., 2009). Na prática, os dados de referência possuem erros tanto no local de coleta como no mapa gerado, em que as medidas coletadas não capturam todas as condições representadas nos valores de reflectância e vice-versa. Reconhecendo que alguns erros existem nos dados de referência, os valores são, muitas vezes, considerados verdadeiros quando eles são conhecidos na precisão substancialmente maior do que os valores mapeados.

4 MATERIAIS E MÉTODOS

4.1 Área de estudo e dados

A área de estudo está localizada ao norte da bacia do rio São Francisco, no estado de Minas Gerais, Brasil, contemplando parte dos municípios de Cônego Marinho, Itacarambi, Miravânia e Januária, como mostrado na Figura 3. Esta região é sujeita a uma variedade de processos de mudança da paisagem, tanto naturais, como os relacionados à sazonalidade marcante da vegetação nativa e à ocorrência de queimadas naturais seguidas de regeneração, quanto os antropogênicos, como os relacionados ao desflorestamento para a produção agrossilvopastoril e a extração de carvão vegetal.

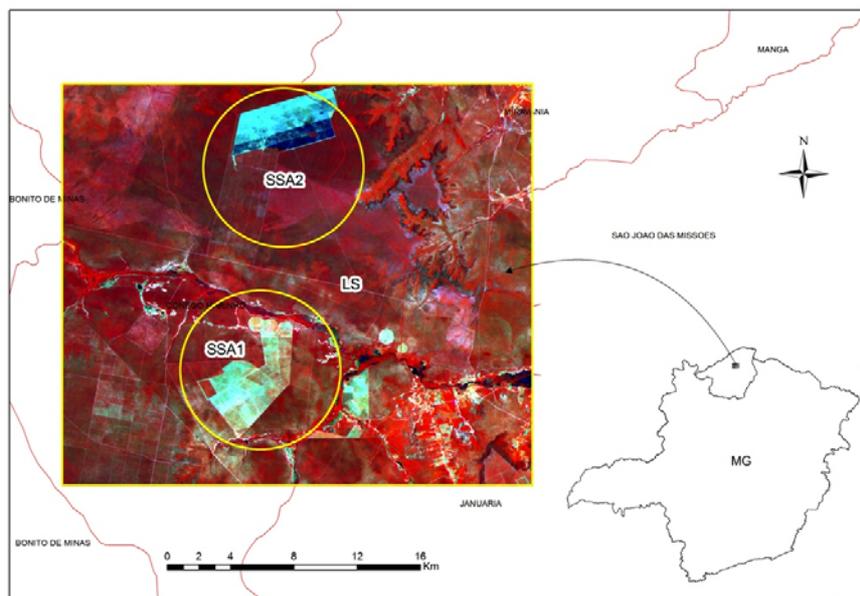


Figure 3 Localização da área de estudo e detalhamento das áreas analisadas LS, SSA1 e SSA2.

As fisionomias vegetacionais predominantes são Cerrado senso restrito e campo Cerrado interceptado por manchas de vereda.

Para esta área, foi selecionado um conjunto de 4 cenas Landsat TM adquiridas nas datas 02/08/2008, 14/03/2009, 05/08/2009 e 25/11/2009, para o monitoramento da perda e do crescimento da vegetação, queimadas e sazonalidade da vegetação. A partir destas quatro cenas Landsat TM, foram extraídas três áreas com diferentes extensões, uma extensão com maior área imageada (LS, como mostrado na Figura 3) e outras duas com menor área imageada (SSA1 e SSA2, como mostrado na Figura 3). As áreas SS (A1 e A2) foram escolhidas por terem focos de diferentes tipos de mudanças e com a finalidade de analisar o comportamento do método de detecção de mudanças em áreas com os mesmos focos, porém, com tamanhos diferentes.

4.2 Pré-processamento

O pré-processamento das imagens foi realizado em quatro etapas, (Figura 4), que foram:

- (1) correção da distorção geométrica das imagens para georreferenciá-las em um sistema de coordenadas comum;
- (2) conversão dos números digitais das imagens para valores de reflectância aparente, para melhorar as análises da vegetação durante o período analisado;
- (3) cálculo do Índice de Vegetação da Diferença Normalizada (Normalized Difference Vegetation Index - NDVI), para todas as quatro cenas Landsat TM. O NDVI é a razão da diferença das bandas do infravermelho próximo (NIR) e do vermelho (R) e da soma do infravermelho próximo e do vermelho, como mostrado na fórmula:

$$NDVI = \frac{(NIR - R)}{(NIR + R)} \quad (1)$$

O NDVI é um índice importante, pois possibilita o monitoramento de mudanças sazonais e interanuais no desenvolvimento e na atividade da vegetação, e a redução dos ruídos decorrentes de condições atmosféricas (como diferenças de iluminação solar, sombras de nuvens, variações topográficas e mudanças atmosféricas) presentes nas múltiplas bandas das imagens de múltiplas datas (JENSEN, 2006);

- (4) geração das imagens NDVI-diferença para cada par de imagem e cada banda por meio da subtração dos valores e comparando-se cena a cena, pixel por pixel. Valores próximos de zero na imagem diferença significam áreas em que não há mudanças na cobertura vegetal; valores positivos significam áreas nas quais houve redução significativa da cobertura da vegetação e valores negativos significam que houve crescimento significativo da vegetação durante o período em consideração (CARVALHO, 2008; CARVALHO; SCOLFORO, 2008).

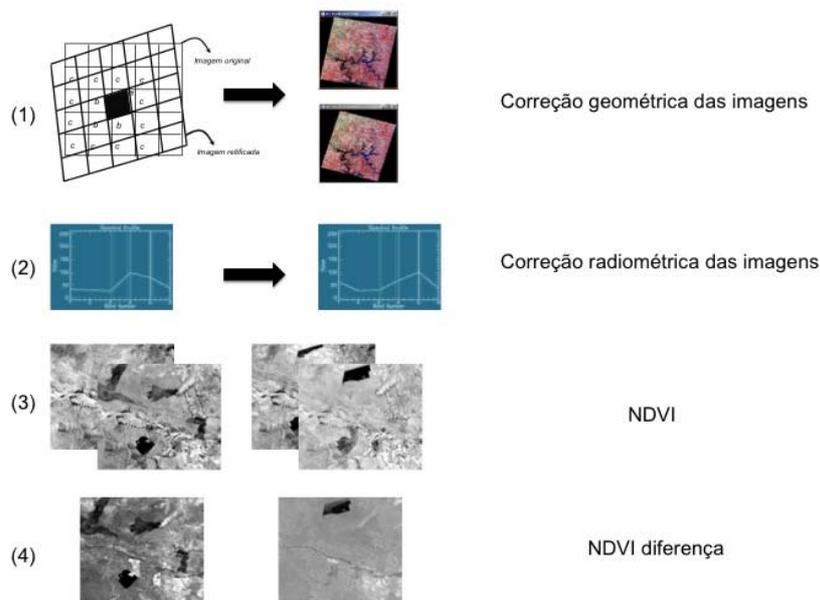


Figure 4 Demonstração das etapas do pré-processamento

4.3 Dados de referência

Como referência para as áreas detectadas, foram coletados pontos em campo nas áreas com ocorrência de mudança em crescimento e perda de vegetação fazendo-se uma análise prévia da imagem nos meses de maio e novembro de 2009. Com isso, foram gerados dois mapas para o tempo T21 e T43, como mostrado nas Figuras 4 e 5. E, como referência para as áreas de ocorrência de sazonalidade, utilizaram-se os estudos de Silveira (2007) e Toneli (2008), realizados na mesma área com focos em períodos sazonais.

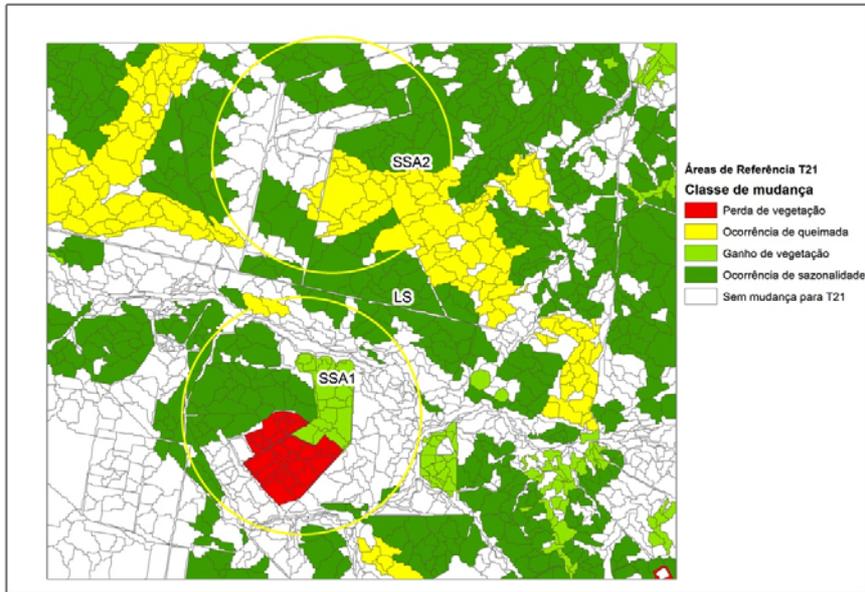


Figure 5 Mapa de áreas de ocorrência de mudanças para T21 como referência

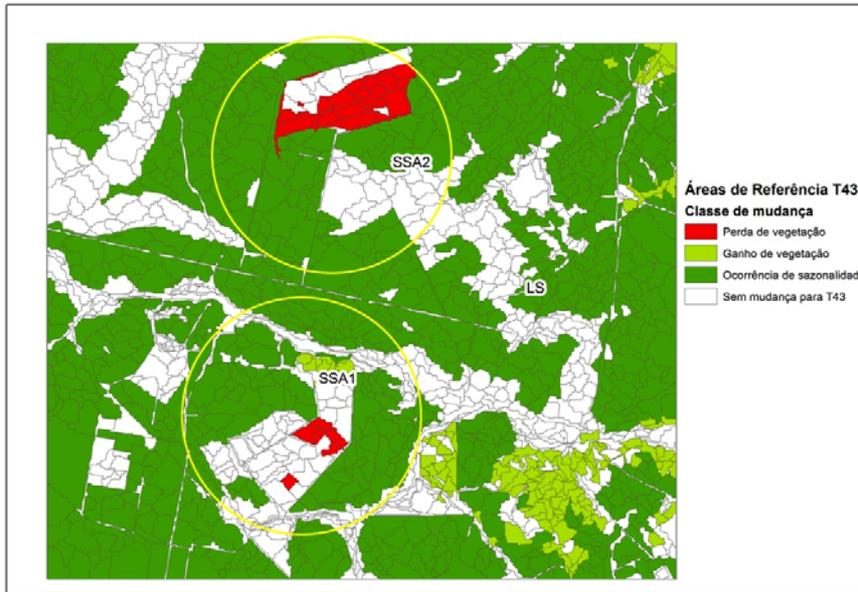


Figure 6 Mapa de áreas de ocorrência de mudanças para T43 como referência

4.4 Processamento de imagens baseado em objetos

Todo o processamento das imagens, desde a segmentação até a detecção dos objetos de mudança, está ilustrado no fluxograma da Figura 7.

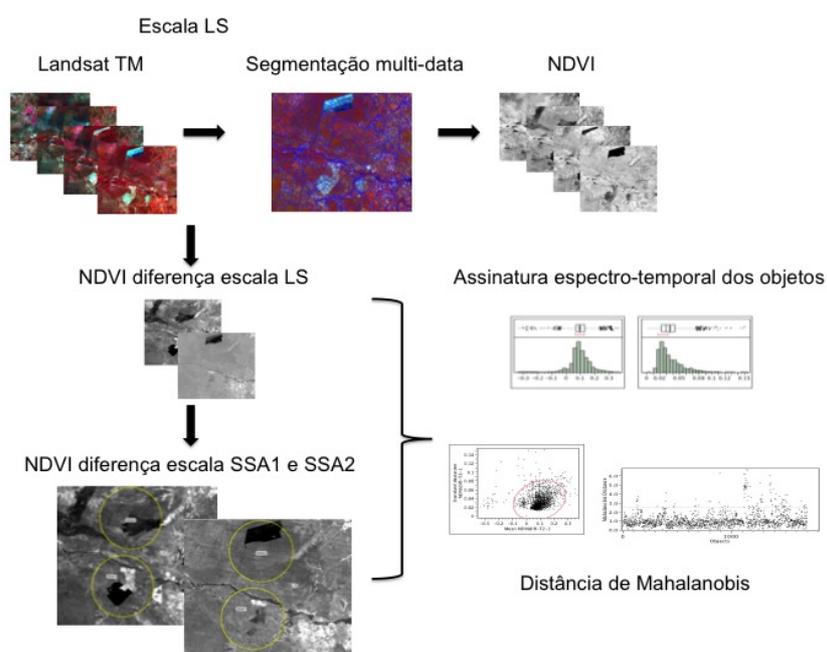


Figure 7 Fluxograma da detecção de mudanças baseada em objetos

4.4.1 Segmentação de imagens

Para as análises baseadas em objetos, a segmentação das imagens foi realizada por meio do algoritmo “Bottom-Up segmentation”, mais conhecido como “Multiresolution Segmentation, baseado na técnica de crescimento de regiões, vista na equação (2) (BAATZ; SCHAPE, 2000). Esse procedimento inicia-se com um único objeto na imagem de um pixel e utiliza critérios de homogeneidade para determinar o melhor vizinho para fazer a fusão entre ambos. Assim, repetidas fusões com objetos adjacentes são realizadas e o

algoritmo finaliza quando o parâmetro de homogeneidade é excedido. O critério de homogeneidade é definido como a combinação da homogeneidade espectral e homogeneidade da forma, ambas influenciadas pelo parâmetro de escala h_{scale} . O parâmetro de escala significa o número máximo de pixels heterogêneos contidos em um objeto, limitando a amplitude de variação no tamanho e no número dos objetos gerados, como pode ser observado nas Figuras 5 e 6.

$$w_{spectral} \cdot h_{spectral} + (1 - w_{spectral}) \cdot h_{spatial} \leq h_{scale} \quad (2)$$

em que $h_{spatial}$ caracteriza a forma do objeto; $w_{spectral}$ são os pesos inversos para $h_{spectral}$; $eh_{spatial}$ mede a variabilidade espectral do objeto (BONTEMPS et al., 2008).

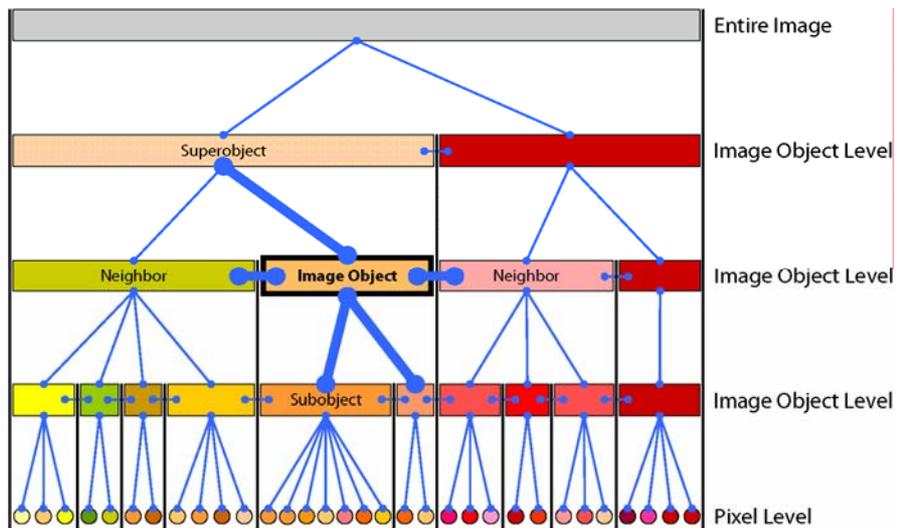


Figure 8 Rede hierárquica de objetos obtidos na segmentação bottom-up (DEFINIENS IMAGING, 2003)

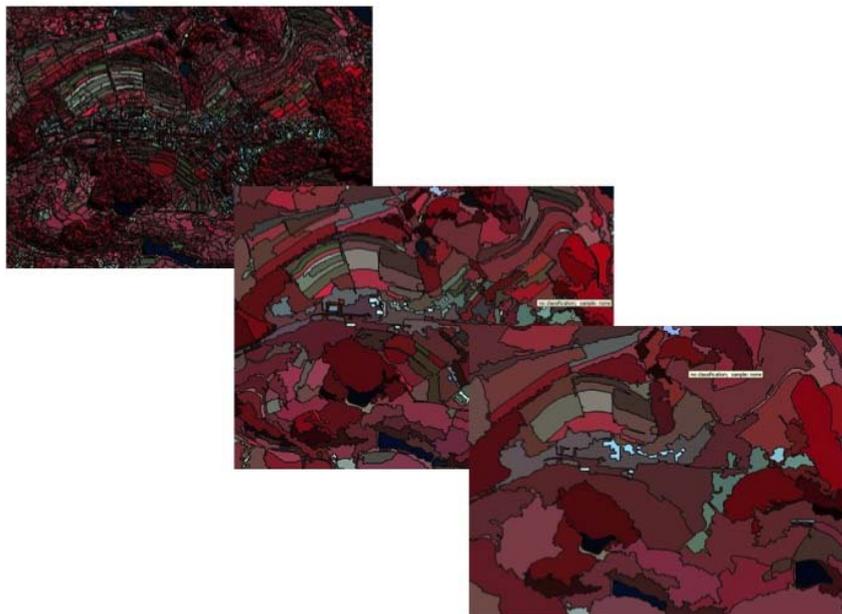


Figure 9 Níveis de segmentação obtidos por meio do algoritmo bottom-up

O processo de segmentação foi realizado em uma abordagem em multidata (ou multitemporal) (BONTEMPS et al., 2008; CHIRICI et al., 2011; CONCHEDDA; DURIEUX; MAYAUX, 2008; DESCLÉE, 2007; DESCLÉE; BOGAERT; DEFOURNY, 2006; DUVEILLER et al., 2008; GERRAND et al., 2009; LINDQUIST, 2010), que significa que cada objeto será delineado baseando-se em todas as imagens juntas.

Também foram utilizados no processo de segmentação parâmetros relacionados com assinatura espectral, suavidade ou compacidade, e relacionados com a escala de cada objeto. O primeiro parâmetro, relacionado com a assinatura espectral, relaciona-se com objetos espectralmente homogêneos. O parâmetro de suavidade é utilizado, segundo Baatze Shape (2000), para definir objetos que possuem bordas suaves, como, por exemplo, áreas de vegetação nativa ou fragmentos florestais, enquanto o parâmetro de

compacidade está relacionado com a geração de segmentos mais compactos, como, por exemplo, prédios, casas, plantios de eucalipto e áreas de agricultura. Já o parâmetro de escala controla o tamanho dos objetos, em que, dependendo da escala escolhida, podem-se obter diferentes níveis de segmentação, caracterizados pela média do tamanho de cada objeto.

4.4.2 Assinatura espectro-temporal dos objetos

Para cada objeto delineado previamente foram obtidos os valores de média (m) e desvio padrão (sd) da assinatura espectral dos conjuntos de dados em multidata, como no exemplo da Figura 7. Estes valores correspondem, respectivamente, à medida dos valores do NDVI-diferença e sua heterogeneidade (DESCLÉE; BOGAERT; DEFOURNY, 2006). Assim, os valores computados para cada imagem NDVI-diferença podem ser definidos como um “feature vector” (f_v)(vetor), obtido por meio da equação (3), que será utilizada nas análises de detecção de mudanças:

$$f_{v_{ij}} = (m_{ij1}, \dots, m_{ijsb}, sd_{ij1}, \dots, sd_{ijsb})' \quad (3)$$

em que i corresponde a cada objeto, j corresponde a cada imagem NDVI-diferença e sb corresponde ao número de bandas espectrais (no caso, sempre $sb = 1$, com cada NDVI-diferença relativa como uma banda).

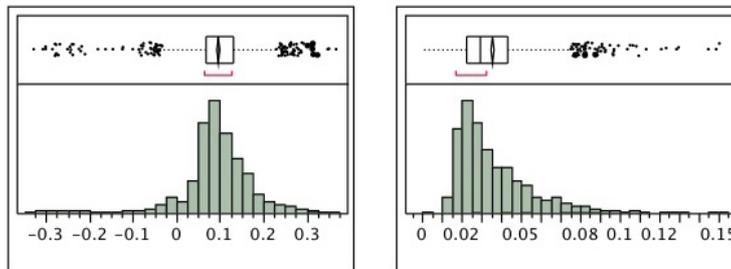


Figure 10 Assinatura espectro-temporal dos objetos, mostrando o conjunto de pontos considerados outliers e a região dos objetos próximos da média (média e desvio padrão)

4.4.3 Detecção de mudanças

Utilizando-se os valores obtidos a partir da assinatura espectro-temporal (os *featurevectors*) de cada NDVI-diferença, foram separados objetos de mudança e não-mudança, por meio de um procedimento estatístico baseado na remoção dos valores extremos, ou “outliers” (BONTEMPS et al., 2008; DESCLÉE, 2007; DESCLÉE; BOGAERT; DEFOURNY, 2006; RADOUX; DEFOURNY, 2008).

Esse procedimento estatístico consiste em computar a distância de Mahalanobis (D_M) para cada objeto em cada imagem NDVI-diferença. A distância de Mahalanobis é uma medida de distância entre pontos usados em problemas de classificação, problemas de reconhecimento de padrões ou análise discriminante. Considerando a assinatura espectral dos objetos de não-mudança, aproximada da média das assinaturas de todos os objetos contidos em cada área de estudo, como uma distribuição de Gauss, vista na Figura 7, pode-se avaliar a distância entre os objetos de mudança, que significa objetos com valores discrepantes e objetos de não-mudança, que significa objetos com valores próximos da média. A distância de Mahalanobis pode ser obtida por meio da equação (4).

$$D_M = \sqrt{(fv_{ij} - m_i)^T \Sigma_j^{-1} (fv_{ij} - m_j)} \quad (4)$$

em que fv_{ij} assume-se que seja uma distribuição de Gauss, anteriormente proposta, com o vetor média m_j e matriz de covariância Σ_j .

Os valores calculados com a distância de Mahalanobis em cada objeto serão identificados como objetos de mudança ou não mudança por meio de um limiar T, baseado na distribuição qui-quadrado com $2n$ graus de liberdade e um nível de probabilidade $1-\alpha$ (com $1-\alpha = 0,95$, por exemplo), representado na equação (5).

$$P(D_M \leq T) = P(D_M \leq \chi_{1-\alpha}^2(2n)) = 1 - \alpha \quad (5)$$

Quando os valores D_M calculados para os objetos excederem o limiar T (com $1-\alpha$ escolhido), estes serão considerados como objetos de mudança, como representado nas Figuras 10 e 11. Assim, esses objetos detectados como mudança serão primeiramente removidos, ou seja, a primeira remoção de objetos de mudança será aplicada. Com a assinatura dos objetos considerados como não-mudança (os objetos remanescentes) serão definidas novas análises de D_M e, assim, a segunda remoção será aplicada. Esse procedimento estatístico iterativo foi repetido e apenas obteve seu término quando novos objetos de mudança não mais foram detectados.

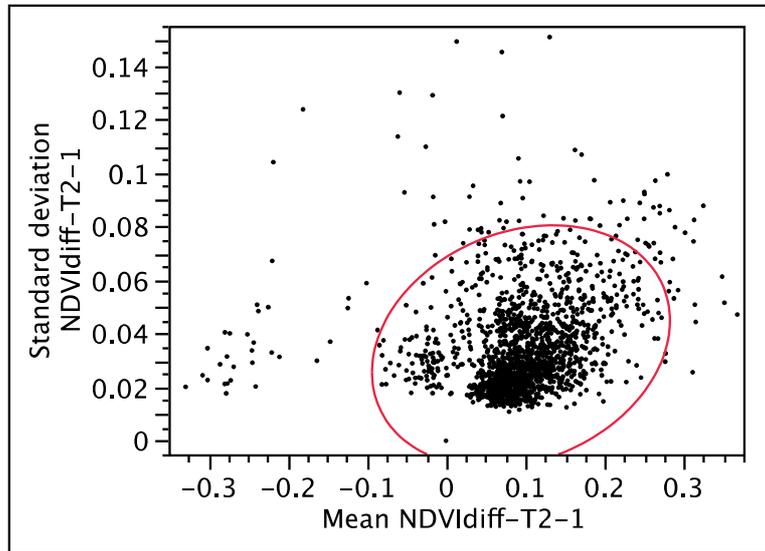


Figure 11 Teste estatístico para identificar os objetos de mudança e a elipse representada pelo limiar T com um nível de confiança 1-alpha.

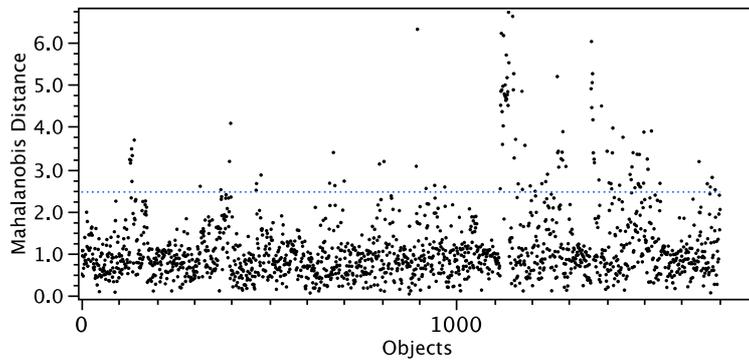


Figure 12 Cálculo da distância de Mahalanobis e limiar T (qui-quadrado)

Todos os objetos de mudança detectados para cada imagem nas áreas LS e SS foram categorizados por classe de mudança: (1) crescimento de vegetação,

(2) perda de vegetação, (3) ocorrência de queimada, (4) sazonalidade da vegetação e (5) não mudança (ou seja, os objetos que foram detectados erroneamente como mudança).

Para cada classe de mudança citada foi calculada a acurácia, adaptando-se o método proposto por KalenskyeScherk (1975), que propõe a acurácia de cada classe, como visto na equação (6).

$$M_i \% = N_i / (N_i + E_i) \quad (6)$$

em que M_i % é a acuracidade da classe de mudança i , N_i é o número de objetos corretamente detectados como pertencentes à de mudança classe i e E_i é o número de objetos erroneamente omitidos na classe de mudança i . Como os objetos detectados como mudança não foram classificados e, sim, categorizados, não houve ocorrência de objetos erroneamente incluídos na classe de mudança i nas análises de acuracidade da classe.

5 RESULTADOS E DISCUSSÃO

5.1 Pré-processamento dos dados de satélite

Para o registro das imagens, foram utilizados 38 pontos de controle identificados em cada uma das imagens de cada data analisada em relação à imagem de referência, com aproximadamente 0,48 pixels de erro, o que representa menos de meio pixel de erro de deslocamento.

As diferenças obtidas entre uma imagem em dados brutos e outra com os valores calibrados para reflectância aparente podem ser vistas nos gráficos das bandas espectrais nas Figuras 13 e 14.

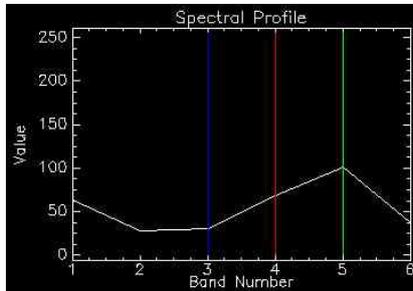


Figure 13 Imagem sem calibração dos números digitais para reflectância aparente

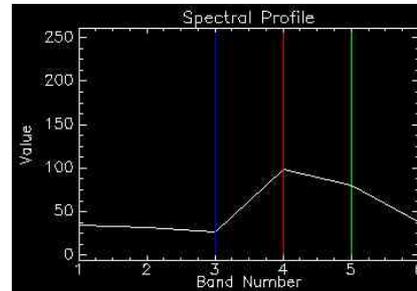


Figure 14 Mesma imagem com os valores calibrados para reflectância aparente

As imagens NDVI-diferença geradas podem ser vistas nas Figuras 15 e 16. Nestas imagens, valores próximos de zero indicam áreas onde não houve mudanças na cobertura da vegetação, valores negativos (pixels escuros) indicam áreas em que houve um decréscimo na cobertura da vegetação e valores positivos (pixels claros) indicam áreas nas quais houve um incremento na cobertura da vegetação.

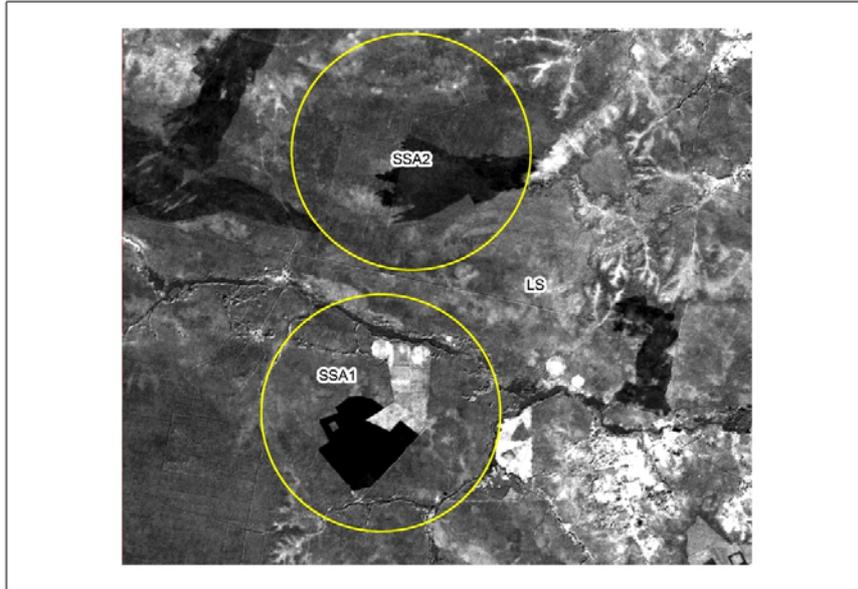


Figure 15 Imagem NDVI-diferença LS, SSA1 e SSA2 para T21

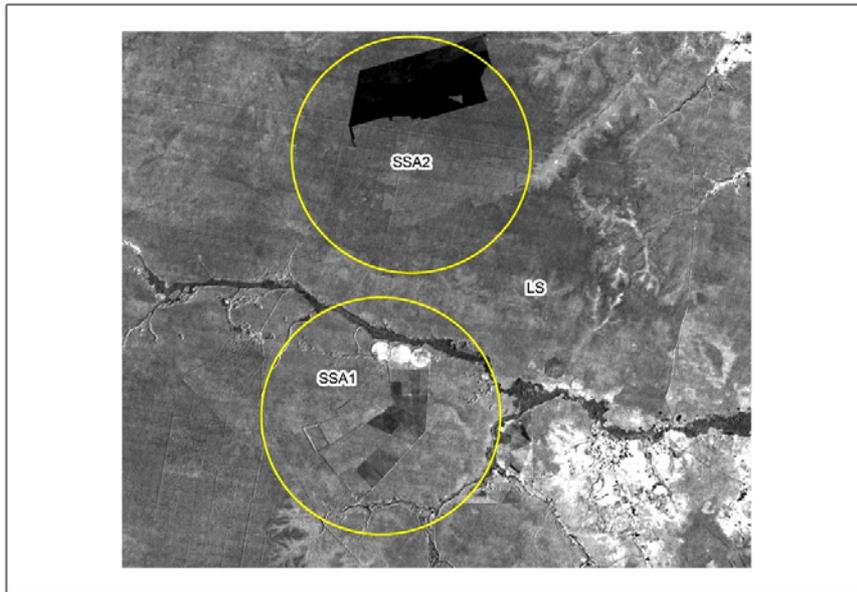


Figure 16 Imagem NDVI-diferença LS, SSA1 e SSA2 para T43

5.2 Avaliação da segmentação das imagens

Para a avaliação da segmentação em multidata das imagens, foi utilizado o método de avaliação visual em duas etapas, em que se obtiveram resultados satisfatórios, considerando que os objetos representaram cada região homogênea da imagem.

Na primeira etapa, foi realizada uma observação detalhada dos objetos, ou segmentos observados na Figura 18, baseando-se nas quatro datas das imagens Landsat TM e nas duas imagens NDVI-diferença geradas a partir das quatro imagens base. Obteve-se, assim, uma avaliação qualitativa da acurácia, baseada na distinção entre as diferentes regiões, particularmente aquelas em que ocorreram mudanças.

Na segunda etapa foi atribuído, para cada segmento, um nível de cinza, correspondendo à média dos valores de todos os pixels compostos a partir das

regiões (Figura 19) da imagem original (Figura 17). A Figura 19 mostra cada objeto representado pela média dos valores dos pixels que o compõe na composição RGB. Esta última representação foi feita para resolver parte do problema quando o olho humano não é capaz de distinguir entre duas regiões com os níveis de cinza muito próximos (ROSENBERGER et al., 2006).

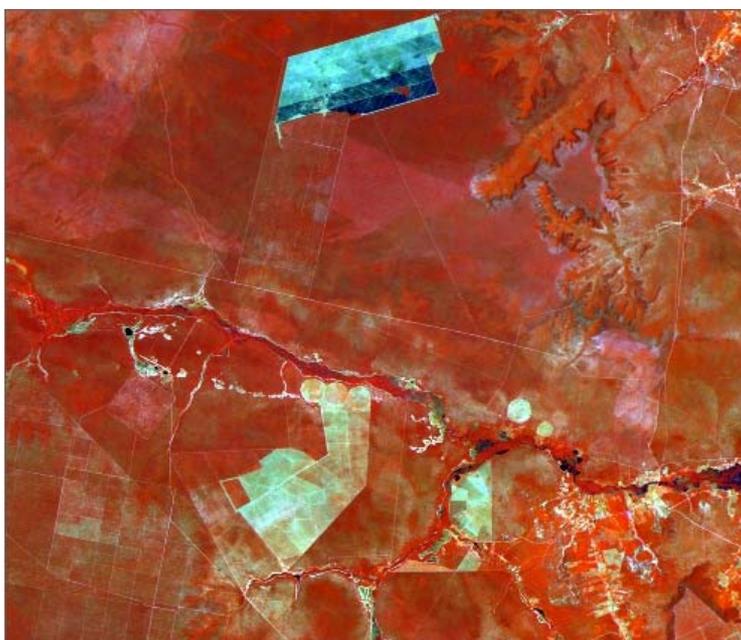


Figure 17 Imagem Landsat TM original da área de estudo

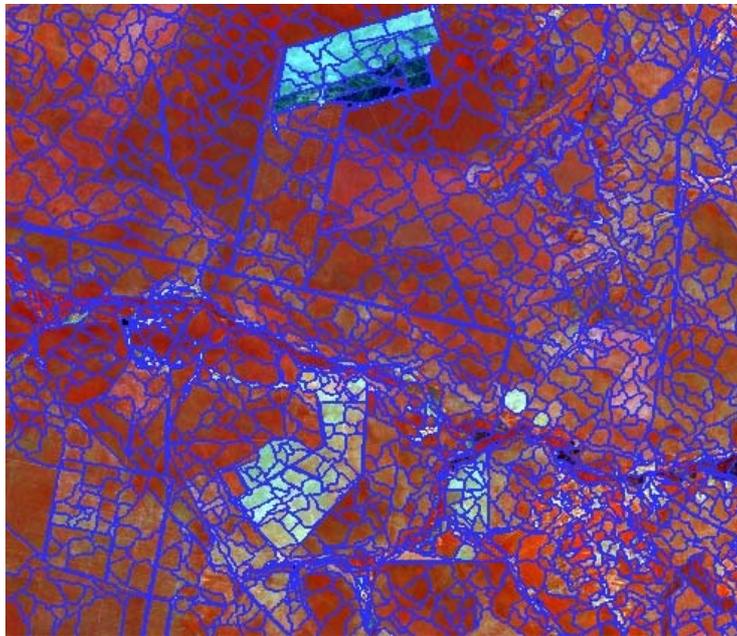


Figure 18 Avaliação da segmentação, tendo como base a imagem original



Figure 19 Imagem segmentada com atribuição de um nível de cinza para cada segmento, correspondendo à média dos valores dos pixels



Figure 20 Avaliação da segmentação, tendo como base a média de cores RGB

A avaliação visual da segmentação se justifica, pois a área em questão é pequena, fazendo parte de uma mesma região fitogeográfica. Porém, para análises utilizando-se da segmentação em áreas com grande diversidade da paisagem, como é o caso de um mapeamento ou monitoramento do estado de Minas Gerais, recomenda-se utilizar métodos supervisionados, nos quais se medem a dissimilaridade entre os resultados de segmentação e o grau de verdade (resultado de segmentação ideal), como, por exemplo, distância de Hausdorff, distância de Baddeley, distância de Vinte, medidas de Peli e Malha, critério de Odet, método Multicritério, medidas de qualidade de Ramon, dentre outros; e métodos não supervisionados, como, por exemplo, critério de uniformidade intrarregião, contraste inter-região, contraste intra e inter-região, dentre outros, para quantificar a qualidade dos resultados de segmentação. Mais detalhes sobre os métodos citados podem ser encontrados em Rosenberger et al. (2006).

5.3 Detecção de mudanças

Os pontos para cada objeto detectado como área de ocorrência de mudança para as datas T21 e T43 e áreas LS, SSA1 e SSA2 e nível de confiança $1-\alpha$ (0,95 e 0,99), estão representados nas Figuras 21 a 32.

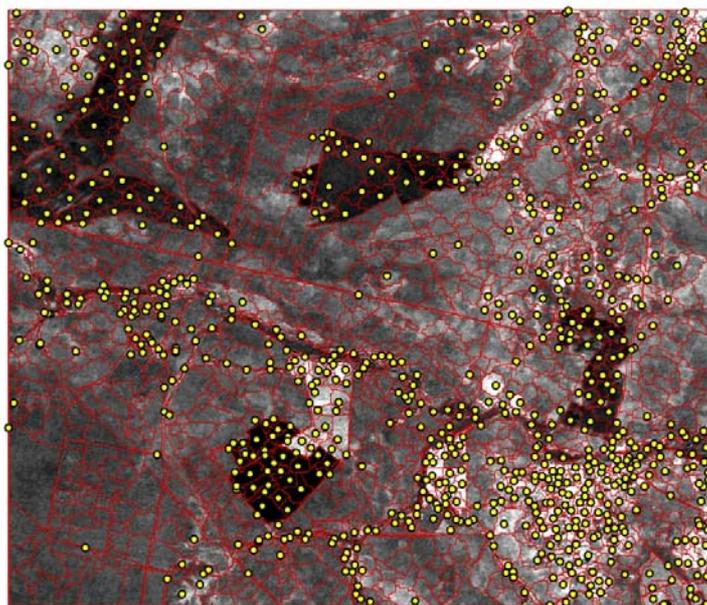


Figure 21 Pontos de mudança para LS T21 ($1-\alpha = 0,95$)

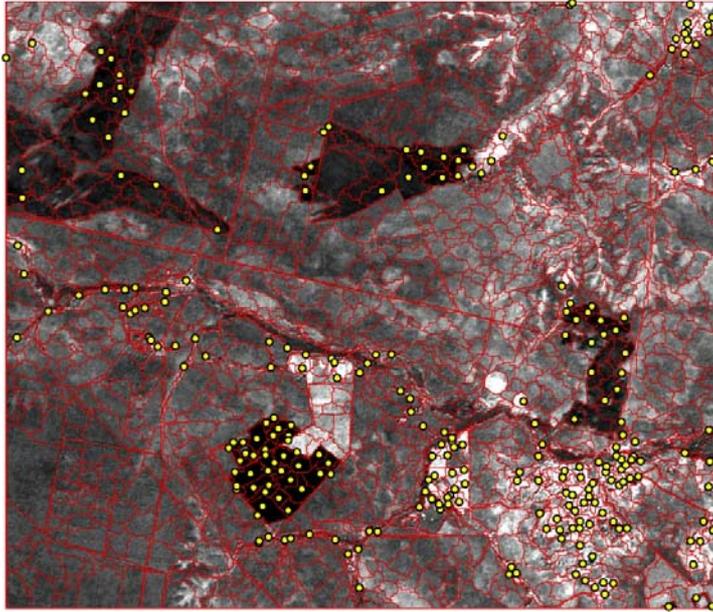


Figure 22 Pontos de mudança para LS T21 ($1-\alpha = 0,99$)

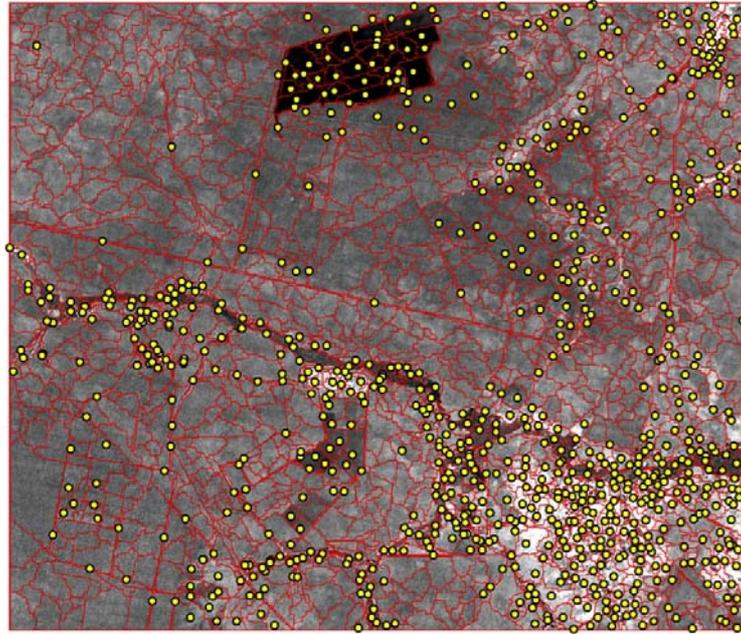


Figure 23 Pontos de mudança para LS T43 (1 - $\alpha = 0,95$)

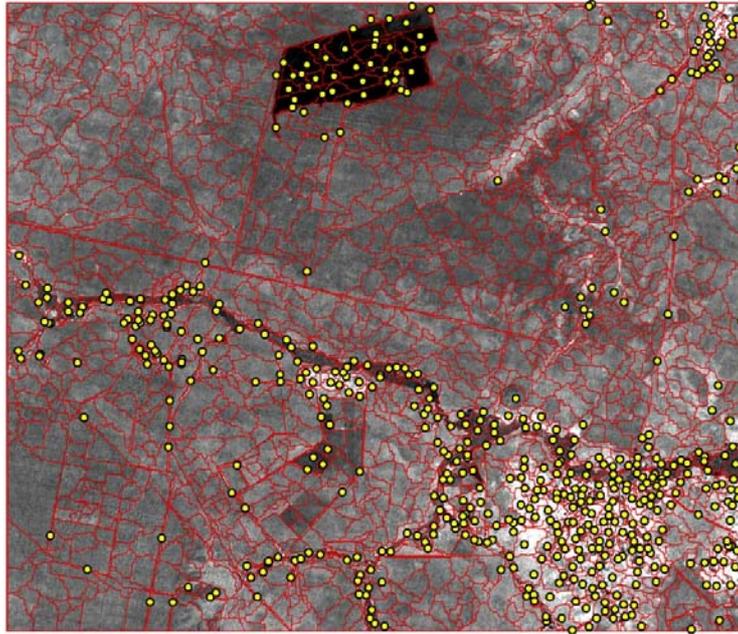


Figure 24 Pontos de mudança para LS T43 (1-alpha = 0,99)

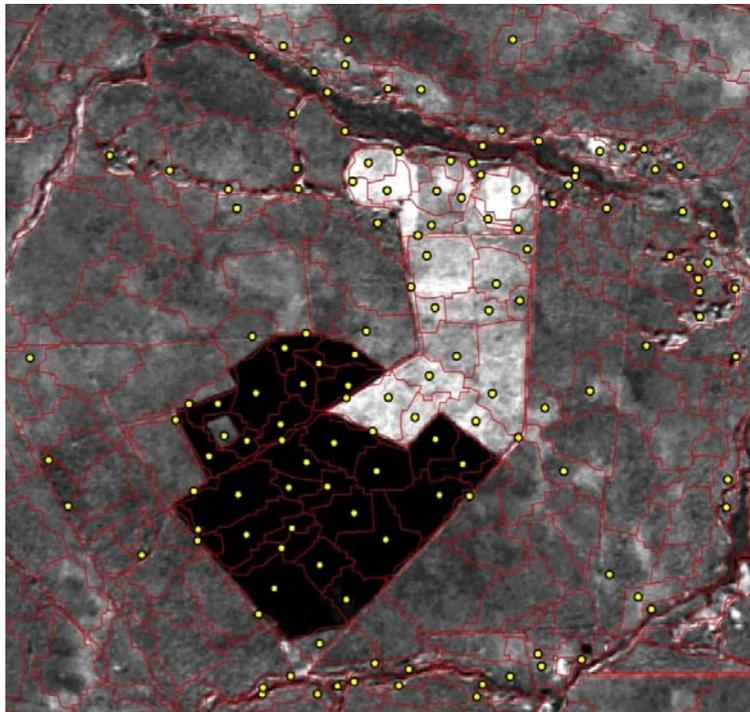


Figure 25 Pontos de mudança para SSA1 T21 ($1-\alpha = 0,95$)

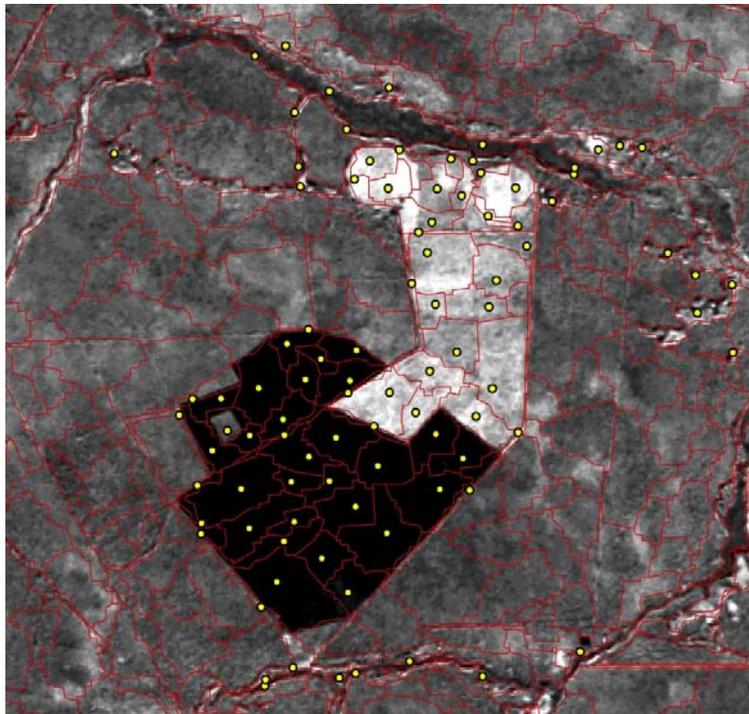


Figure 26 Pontos de mudança para SSA1 T21 ($1-\alpha = 0,99$)

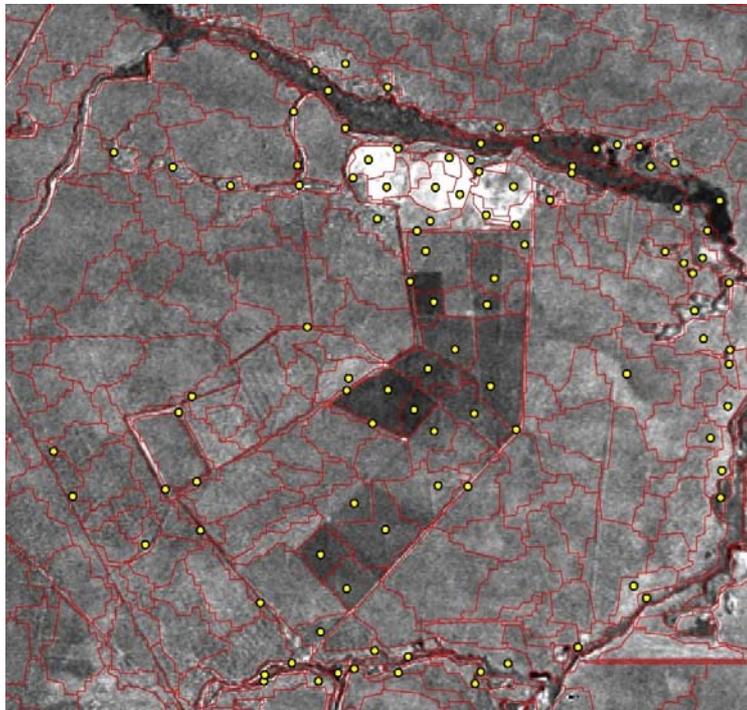


Figure 27 Pontos de mudança para SSA1 T43 ($1-\alpha = 0,95$)

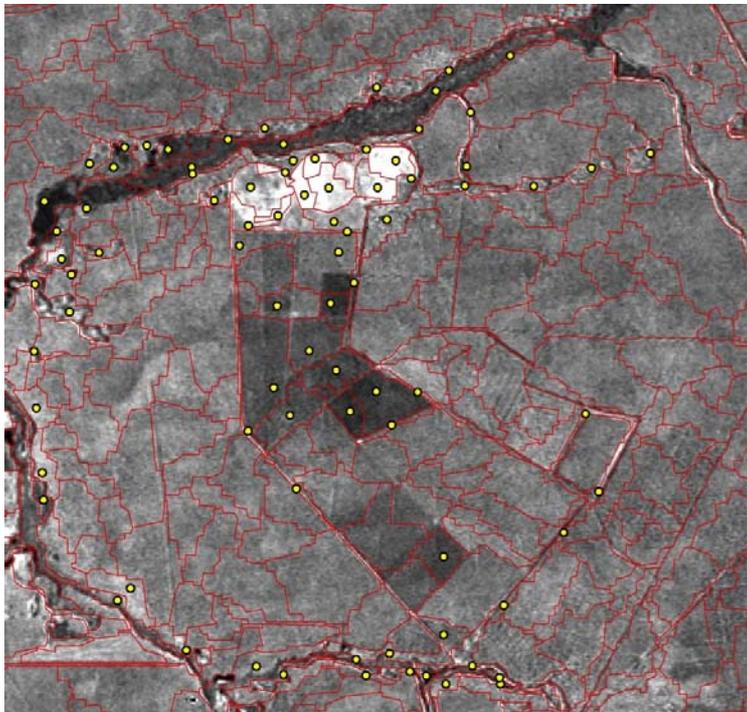


Figure 28 Pontos de mudança para SSA1 T43 (1-alpha = 0,99)

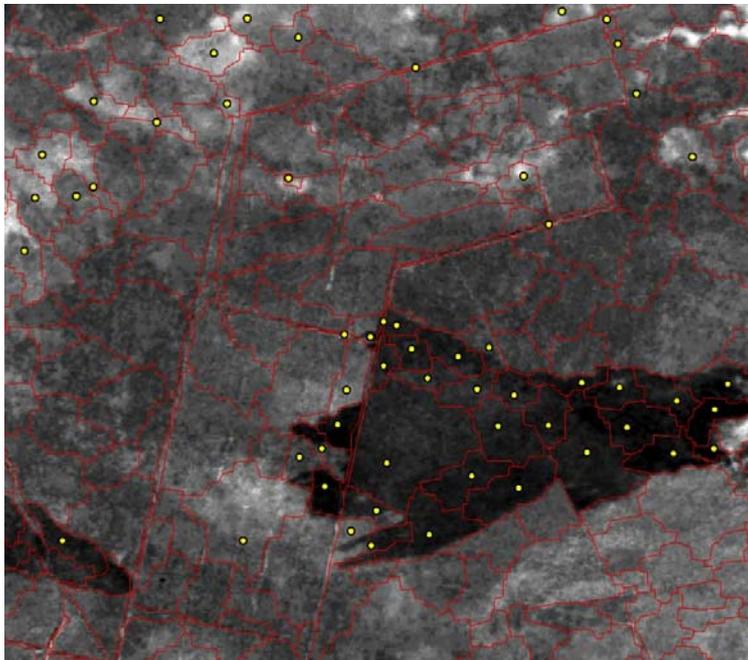


Figure 29 Pontos de mudança para SSA2 T21 ($1-\alpha = 0,95$)

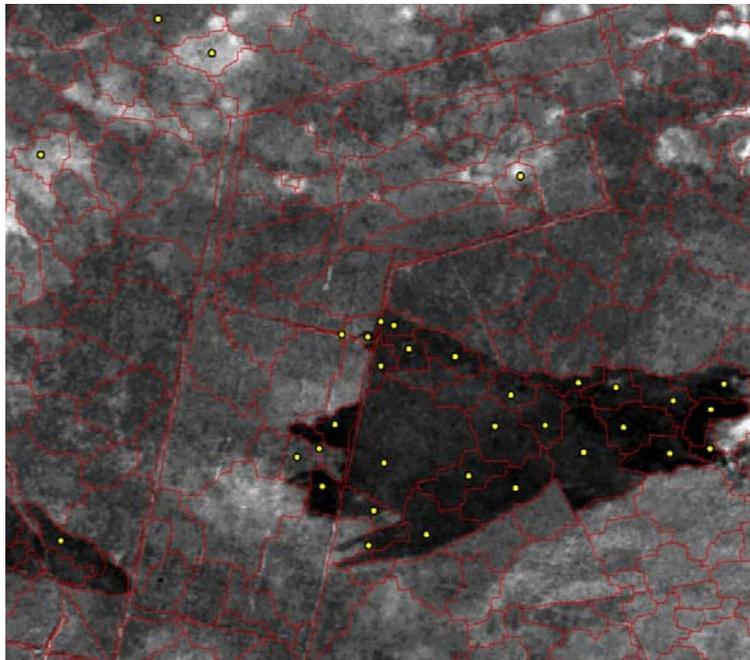


Figure 30 Pontos de mudança para SSA2 T21 ($1-\alpha = 0,99$)

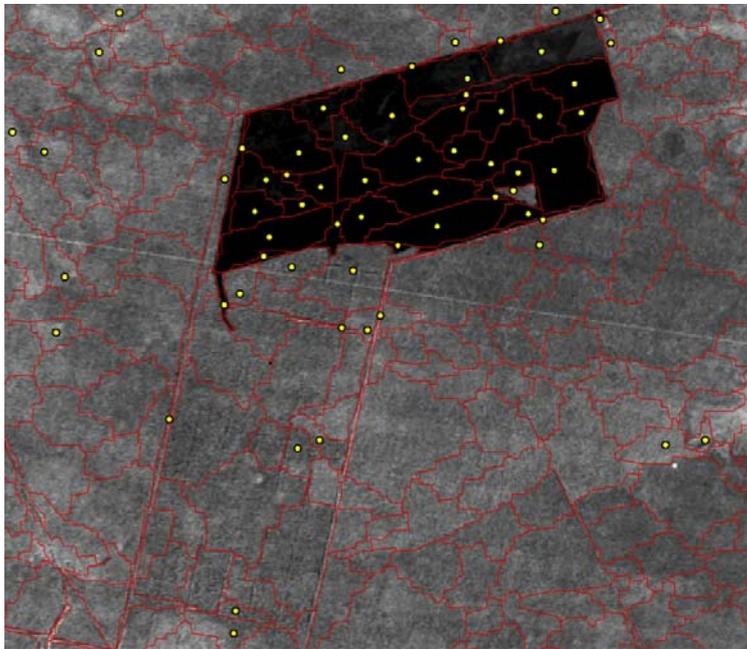


Figure 31 Pontos de mudança para SSA2 T43 ($1-\alpha = 0,95$)

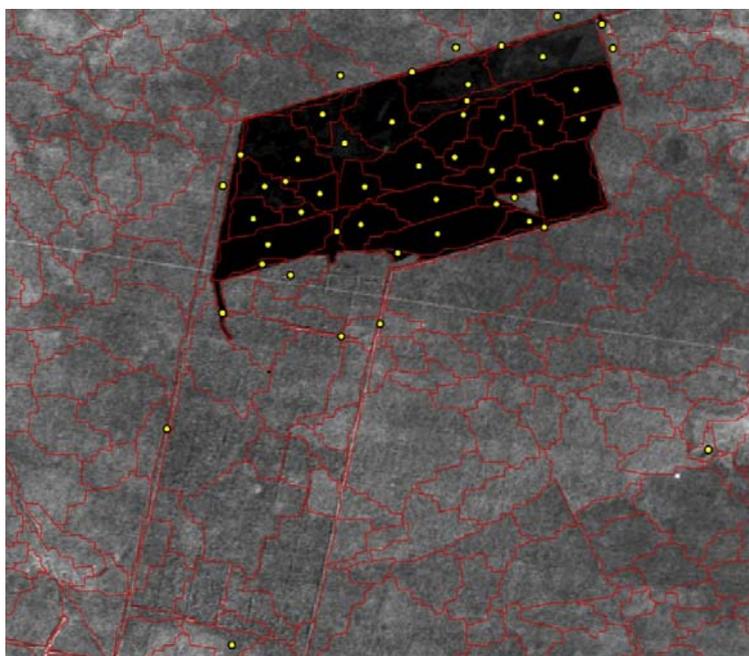


Figure 32 Pontos de mudança para SSA2 T43 ($1-\alpha = 0,99$)

5.3.1 Detecção de áreas onde houve crescimento e perda da vegetação

Para as duas diferentes escalas analisadas (LS e SSA1-2), os resultados relativos às classes de mudança de crescimento e perda da vegetação são mostrados nas Tabelas 2 e 3, respectivamente.

Tabela 2 Número de objetos de crescimento da vegetação nos dados de referência, bem como o número de objetos detectados em diferentes níveis de confiança e em diferentes áreas de análise

Classe de mudança	($1-\alpha$) 0,95	($1-\alpha$) 0,99	Referência	Área
Crescimento da vegetação	100	63	103	LS T21
	128	120	131	LS T43
	26	25	26	SSA1 T21
	10	10	10	SSA1 T43
	--	--	--	SSA2 T21
	--	--	--	SSA2 T43

Tabela 3 Número de objetos de perda da vegetação nos dados de referência, bem como o número de objetos detectados em diferentes níveis de confiança e em diferentes áreas de análise

Classe de mudança	(1- α) 0,95	(1- α) 0,99	Referência	Área
Perda da vegetação	36	36	36	LS T21
	30	28	31	LS T43
	34	34	34	SSA1 T21
	5	5	6	SSA1 T43
	--	--	--	SSA2 T21
	25	25	25	SSA2 T43

A performance do método de detecção de mudanças, comparando-se os diferentes processos, nas diferentes escalas, para crescimento de vegetação, mostrou resultados melhores para os testes estatísticos com o nível de confiança 1- α de 0,95 ($\alpha = 0,05$), para todos os processos, com acurácias de classe maiores que 97%, como mostrado na Tabela 4 e apenas com erros de omissão de 2,91 % e 2,29%, para as análises LS T21 e LS T43, respectivamente. Para os processos dos subsets SSA2 T21 e T43, com 173 objetos, não houve resultados, devido ao fato de não existirem, na área de abrangência, mudanças relacionadas a crescimento de vegetação, mostradas na Figura 33.

Tabela 4 Acurácia da classe crescimento da vegetação para diferentes níveis de confiança e diferentes áreas de análise

Classe de mudança	Área	Acuracidade da classe (%) - (1- α) 0,95	Acuracidade da classe (%) - (1- α) 0,99
Crescimento da vegetação	LS T21	97,08	61,16
	LS T43	97,70	91,60
	SSA1 T21	100	96,15
	SSA1 T43	100	100
	SSA2 T21	--	--
	SSA2 T43	--	--

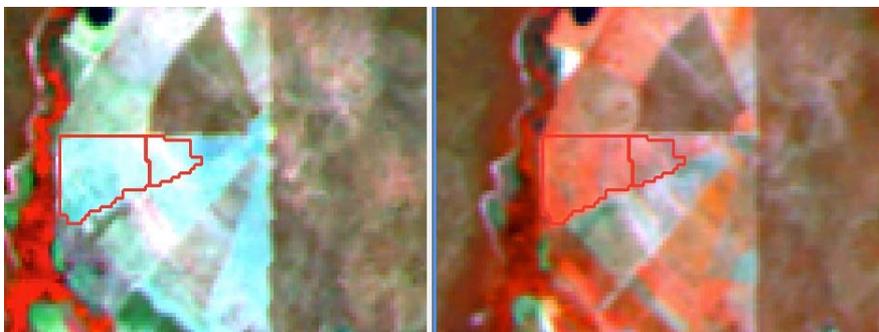


Figura 33 Exemplo de áreas com ocorrência de crescimento da vegetação detectadas

Porém, fazendo-se um análise de performance comparando-se as duas escalas LS e SSA1, os resultados para a classe de mudança crescimento de vegetação foram maximizados quando se trabalhou com uma menor área, não cometendo erros de comissão e apenas na análise SSA1 T21, com $1-\alpha$ de 0,99, ocorrendo erro de omissão de um objeto não detectado (em torno de 3,8%) e 100% de acurácias de classe para ambos, SSA1 T21 e T43. Isso significa que, para a detecção de mudanças na menor área (SSA1), todos os objetos que, na realidade, ocorreram ganho de vegetação, foram detectados. Para os processos LS, com 1.703 objetos, não ocorreram erros de comissão, mas com erros de omissão maiores quando analisados entre as datas T2-1, com $1-\alpha$ de 0,99, 40 objetos nos quais ocorreram, realmente, crescimento da vegetação foram omitidos (em torno de 38,83%).

Já para mudanças de perda da vegetação, o método de detecção de mudanças mostrou um incremento na performance em todos os testes estatísticos com níveis de confiança $1-\alpha$ de 0,95 ($\alpha = 0,05$) e $1-\alpha$ de 0,99 ($\alpha = 0,01$), em que não houve erros de comissão e apenas erros de omissão de 1 objeto (3,22%) e 3 objetos (9,67%), para LS T43 ($\alpha = 0,05$) e ($\alpha = 0,01$), respectivamente, e 1 objeto (16,66%) para SSA1 T43 ($\alpha = 0,01$). A acuracidade de classes foi de 100% para as análises LS T21, SSA1 T21 e SSA2 T43, de 96,77% para LS T43 e de 83,33% para SSA1 T43 (Tabela 5), indicando que o método detecta muito bem

mudanças relacionadas e perda da vegetação, como áreas de desflorestamento mostradas nas Figuras 34 e 35.

Tabela 5 Acurácia da classe perda da vegetação para diferentes níveis de confiança e diferentes áreas de análise

Classe de mudança	Área	Acuracidade da classe (%) - $(1-\alpha)$ 0,95	Acuracidade da classe (%) - $(1-\alpha)$ 0,99
Perda da vegetação	LS T21	100	100
	LS T43	96,77	90,32
	SSA1 T21	100	100
	SSA1 T43	83,33	83,33
	SSA2 T21	--	--
	SSA2 T43	100	100

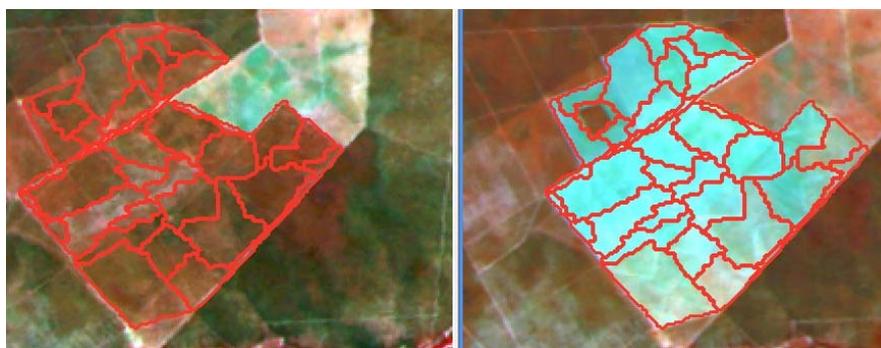


Figura 34 Exemplo de objetos com áreas de perda da vegetação detectadas

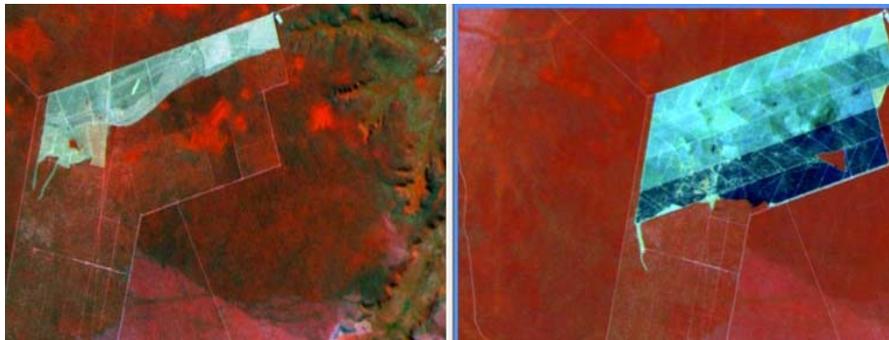


Figura 35 Exemplo de áreas de perda da vegetação detectadas

No presente estudo, fez-se a aquisição de imagens que mostrassem os efeitos da sazonalidade da vegetação, para, como dito anteriormente, verificar o comportamento do método de detecção em áreas de Cerrado com ocorrência fenológica.

5.3.2 Detecção de áreas em que houve ocorrência de queimadas

As áreas de queimada ocorreram apenas nas análises entre as datas T2-1, nas áreas LS e SSA2. Os resultados estão dispostos nas Tabelas 6 e 7.

Tabela 6 Número de objetos de áreas de ocorrência de queimadas nos dados de referência, bem como o número de objetos detectados em diferentes níveis de confiança e em diferentes áreas de análise

Classe de mudança	(1- α) 0,95	(1- α) 0,99	Referência	Área
Queimada	121	43	159	LS T21
	--	--	--	LS T43
	--	--	--	SSA1 T21
	--	--	--	SSA1 T43
	28	26	31	SSA2 T21
	--	--	--	SSA2 T43

Tabela 7 Acurácia da classe queimada para diferentes níveis de confiança e diferentes áreas de análise

Classe de mudança	Área	Acuracidade da classe (%) - (1- α) 0,95	Acuracidade da classe (%) - (1- α) 0,99
Queimada	LS T21	76,10	27,04
	LS T43	--	--
	SSA1 T21	--	--
	SSA1 T43	--	--
	SSA2 T21	90,32	83,87
	SSA2 T43	--	--

No caso da detecção das ocorrências de queimadas, o método apresentou performance mais baixa, comparada com a performance para as classes de crescimento e perda de vegetação, mesmo obtendo valores melhores de acuracidade da classe para o nível de confiança $1-\alpha$ de 0,95 ($\alpha = 0,05$), com 76,10% para LS T21 e 90,32% para SSA2 T21, do que $1-\alpha$ de 0,99 ($\alpha = 0,01$), com 27,04% para LS T21 e 83,87% para SSA2 T21.

Entretanto, observa-se um ganho na detecção de áreas de ocorrência de queimada para a área de menor escala (SSA2 T21), em que houve 9,67% ($1-\alpha$ de 0,95) e 16,12% ($1-\alpha$ de 0,99) de erros de omissão, contra 23,89% ($1-\alpha$ de 0,95) e 72,95% ($1-\alpha$ de 0,99) de erros de omissão para a área de maior escala (LS T21).

A detecção e a quantificação de áreas queimadas a partir de dados de sensoriamento remoto são abordadas sob pontos de vista distintos, como propõe Pereira (2009): (1) primeiro, refere-se à detecção dos focos de calor associados a fogos ativos (JUSTICE et al., 2006; PEREIRA, 2009; PHULPIN et al., 2002; SETZER; MORELLI; LOMBARDI, 2007); (2) segundo, linha está relacionada à cartografia das queimadas e concentra-se na quantificação e na espacialização das áreas afetadas por esse fenômeno (CHUVIECO; CONGALTON, 1988; HERDINIA-LACLAUSTRA et al., 2003; PEREIRA, 2009; PEREIRA et al., 2008).

Neste estudo, optou-se pela segunda abordagem, visando à detecção apenas das áreas afetadas pelo fogo. Assim, o ganho em performance na detecção de áreas de queimada deve ser intensificada e obter bons resultados, uma vez que auxilia na manutenção e no aprimoramento das atividades preventivas, gera informações para órgãos de fiscalização e serve de base para estudos de impactos ambientais, atmosféricos e de mudanças climáticas.

5.3.3 Detecção de áreas nas quais houve ocorrência de sazonalidade da vegetação

Para a avaliação da detecção de áreas de ocorrência de sazonalidade da vegetação, foram escolhidas imagens nas datas de agosto de 2008 (tempo 1) e março de 2009 (tempo 2) e nas datas de agosto de 2009 (tempo 3) e novembro de 2010 (tempo 4), para analisar o comportamento do método de detecção para períodos sazonais de diferentes intensidades. Porém, a detecção dessas áreas pode ter dois objetivos diferentes, os quais resultarão em distintas avaliações dos resultados de métodos de detecção de mudanças: (1) se o objetivo consistir em conhecer a localização assim como tamanho das áreas de ocorrência de sazonalidade ao longo de um período de tempo, a avaliação dos resultados deve considerar uma boa performance do método de detecção; (2) se o objetivo consistir em detectar mudanças de outros tipos, como, por exemplo, crescimento, perda e queimada da vegetação, e não detectar sazonalidade, pois sabe-se que é um tipo de mudança que ocorre naturalmente, a avaliação dos resultados deverá considerar uma boa performance do método, se não houver detecção da sazonalidade.

Para o presente estudo, utilizou-se a avaliação baseada no segundo objetivo, conhecendo-se previamente as áreas de sazonalidade da vegetação (mostradas nas Figuras 5 e 6). Os resultados do número de objetos detectados e a

acuracidade da classe em cada processo de detecção estão dispostos na Tabela 8 e 9, respectivamente.

Tabela 8 Número de objetos de áreas de ocorrência sazonalidade da vegetação nos dados de referência, bem como o número de objetos detectados em diferentes níveis de confiança e em diferentes áreas de análise

Classe de detecção	(1- α) 0,95	(1- α) 0,99	Referência	Área
Sazonalidade da vegetação	192	16	551	LS T21
	225	73	862	LS T43
	8	1	38	SSA1 T21
	8	3	101	SSA1 T43
	18	4	74	SSA2 T21
	22	9	106	SSA2 T43

Tabela 9 Acurácia da classe sazonalidade da vegetação para diferentes níveis de confiança e diferentes áreas de análise

Classe de detecção	Área	Acuracidade da classe (%) - (1- α) 0,95	Acuracidade da classe (%) - (1- α) 0,99
Sazonalidade da vegetação	LS T21	34,85	2,91
	LS T43	26,11	8,47
	SSA1 T21	21,06	2,64
	SSA1 T43	7,93	2,98
	SSA2 T21	24,33	5,41
	SSA2 T43	20,76	8,50

Os valores baixos de acurácia encontrados significam, de acordo com o objetivo de não detecção proposto, bons resultados para a performance do método de detecção para não detectar objetos com mudanças relacionadas com sazonalidade da vegetação para ambos os níveis de confiança 1- α de 0,95 e 1- α de 0,99, encontrando melhores resultados quando analisados nas áreas de menores escalas SSA1 e SSA2

5.3.4 Detecção de áreas de não mudança e análise global das mudanças

Além da avaliação do método de detecção para as áreas de mudança as quais foram objetivo deste estudo, observaram-se também as áreas onde não ocorreram mudanças, mas que foram detectadas como tal. Para isso, calcularam-se a acuracidade global de todas as classes de mudança e a classe não mudança, como se pode observar na Tabela 11. Foi também separado o número de objetos detectados erroneamente, por área de análise (LS e SSA1 e 2) e comparado com o número de objetos nos quais não ocorreram mudanças para as datas T21 e T43, mostrados na Tabela 10.

Tabela 10 Número de objetos de não mudança nos dados de referência, bem como o número de objetos detectados em diferentes níveis de confiança e em diferentes áreas de análise erroneamente como mudança

Classe de detecção	(1- α) 0,95	(1- α) 0,99	Referência	Área
Não mudança	363	105	854	LS T21
	428	299	679	LS T43
	72	35	138	SSA1 T21
	81	66	119	SSA1 T43
	11	4	68	SSA2 T21
	17	16	42	SSA2 T43

Tabela 11 Índices globais da performance do método de detecção de mudanças para todas as áreas de análise e diferentes níveis de confiança

Processo	Acurácia global (%) - (1- α) 0,95	Acurácia global (%) - (1- α) 0,99
LS T21	55,19	53,25
LS T43	37,22	35,29
SSA1 T21	56,77	69,06
SSA1 T43	25,84	30,08
SSA2 T21	59,53	54,33
SSA2 T43	41,61	34,68

Os resultados mostraram que, para apenas 3 processos, para o nível de confiança $1-\alpha$ de 0,95, a acuracidade global foi acima de 50%, com erros de comissão de 363 objetos (55,19%) para LS T21 (de 1.703 objetos totais, 854 são objetos de não mudança), 72 objetos (56,77%) para SSA1 T21 (de 236 objetos totais, 138 são não mudança), 11 objetos (59,53%) para SSA2 T21 (em que a imagem possui 173 objetos totais e 68 objetos de não mudança).

Já para o nível de confiança $1-\alpha$ de 0,99, três áreas de análise apresentaram acuracidade global acima de 50%, LS T21, SSA1 T21 e SSA2 T21, o que mostra que, para este nível de confiança, o método obteve melhor performance para o tempo T21.

Esta análise global mostra que o método de detecção de mudanças tem boa performance para detectar as mudanças que ocorreram realmente, porém, baixa performance para uma detecção independente do tipo de mudança, pois o mesmo detecta uma quantidade considerável de não mudanças.

6 CONSIDERAÇÕES

Em função dos objetivos propostos neste estudo e dos resultados observados para as escalas LS e SS (A1 e A2), nos tempos T21 e T43, concluiu-se que o método de detecção de mudanças proposto, aplicado a imagens NDVI-diferença, tem ótima performance para a detecção de crescimento e perda da vegetação, em que em quase todos os processos foram detectados próximos da totalidade dos objetos.

Para as análises de detecção de áreas de ocorrência de queimada, o método mostrou possuir melhor performance quando trabalhado em uma menor escala. Porém, não se pode concluir que é melhor, pois apenas uma data em uma área, tanto para o processo na escala LS como para a escala SS, tinha ocorrência do fenômeno. Assim, um estudo mais detalhado poderia ser feito para o método,

em diferentes áreas de focos de queimada no bioma Cerrado, aplicando esta metodologia e usando outros índices, mais adequados para este tipo de classe de mudança.

Para as análises de detecção de mudanças relacionadas à ocorrência de sazonalidade, o método mostrou boa performance de não detecção, principalmente para os processos da escala SS. Este resultado indica que, em ocasiões nas quais o objetivo seja monitorar mudanças de causas antrópicas em um menor período, como de 3 a 4 vezes ao ano (no caso de um órgão fiscalizador) e que a disponibilidade de imagens poderia ser uma limitante, o uso da metodologia proposta poderia proporcionar bons resultados, sem a ocorrência de falsas mudanças antrópicas, como comportamentos fenológicos da vegetação.

Já para a ocorrência de objetos que foram detectados erroneamente como mudança, e que na realidade não eram, a performance do método foi baixa em todos os processos (tanto em LS como SS).

8 RECOMENDAÇÕES E POTENCIALIDADES DA METODOLOGIA

Para a melhora e a adaptação da metodologia no intuito de aplicação para um mapeamento do bioma Cerrado em Minas Gerais, recomenda-se a realização de novos estudos focados em dois pontos principais do método de detecção: (1) melhorar o pré-processamento das imagens a serem trabalhadas, principalmente se as mesmas forem de altíssima resolução espacial, para eliminar o máximo de influências atmosféricas, erros de registro e problemas de ruídos nas imagens e (2) aplicação do método substituindo-se as imagens NDVI-diferença por imagens "Reflectância-diferença" (OB-reflectance) proposto por Desclée, Bogaert e Defourny (2006), em que foram encontrados bons resultados

para a detecção de objetos de perda e ganho da vegetação, e substituição pelas imagens em multiescala propostas por Carvalho (2001).

REFERÊNCIAS

ADAMS, J.B. et al. Classification of multispectral images based on fractions of endmembers: application to land cover change in Brazilian Amazon. **Remote Sensing of Environment**, New York, v. 52, n. 2, p. 137-154, May 1995.

ANGELICGI, L.; BRYNTN, A.; FRIWMASN, Z. Techniques for land use change detection using Landsat imagery. **Proceedings of the American Society of Photogrammetry**, Bethesda, v. 35, n. 4, p. 217-228, 1997.

ANUTA, P.; BAUER, M. **An analysis of temporal data for crop species identification and urban change detection**: LARS information note 110873. Purdue: Purdue University, 1973. 86 p.

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. **Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 58, n. 3/4, p. 12-23, Aug. 2000.

BANNER, A.V.; LYNHAM, T. Multitemporal analysis of Landsat data for forest cover mapping: a trial of two procedures. In: CANADIAN SYMPOSIUM ON REMOTE SENSING, 7., 1981, Winnipeg. **Proceedings...** Winnipeg: Canadian Remote Sensing Society, 1981. p. 233-240.

BENZ, U.C. et al. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 58, n.3/4, p. 239-258, Jan. 2004.

BOCK, M. et al. Object-oriented methods for habitat mapping at multiple scales: case studies from Northern Germany and Wye Downs. **Journal for Nature Conservation**, Kusterdingen, v. 13, n. 2/3, p. 75-89, July 2005.

BONTEMPS, S. et al. An object-based change detection method accounting for temporal dependences in time series with medium coarse spatial resolution. **Remote Sensing of Environment**, New York, v. 112, n. 6, p. 3181-3191, June 2008.

BRASIL. Ministério do Meio Ambiente. **Plano de ação para prevenção e controle do desmatamento e das queimadas no Cerrado**: conservação e desenvolvimento. Brasília, 2010. 159 p.

BYRNE, G. F.; CRAPPER, P. F.; MAYO, K. K. Monitoring land cover change by principal component analysis of multitemporal Landsat data. **Remote Sensing of Environment**, New York, v. 10, n. 3, p. 175-184, Nov. 1980.

CARVALHO, L. M. T. Detecção de modificações na cobertura do solo. In: CARVALHO, L. M. T.; SCOLFORO, J. R. (Ed.). **Inventário florestal de Minas Gerais: monitoramento da flora nativa 2005-2007**. Lavras: UFLA, 2008. p. 2-24.

_____. **Mapping and monitoring forest remnants: a multiscale analysis of spatio-temporal data**. 2001. 150p. Thesis (Ph.D. in Production Ecology and Resources Conservation) - Wageningen University, Wageningen, 2001.

CARVALHO, L. M. T.; SCOLFORO, J. R. S. **Inventário florestal de Minas Gerais: monitoramento da flora nativa 2005-2007**. Lavras: UFLA, 2008. 357 p.

CHAN, J.C.W.; CHAN, K.P.; YEH, A.G.O. Detecting the nature of change in an urban environment: a comparison of machine learning algorithms. **Photogrammetric Engineering Remote Sensing**, Falls Church, v. 67, n.2, p. 213-225, Feb. 2001.

CHIRICI, G. et al. Large-scale monitoring of coppice forest clearcuts by multitemporal very high resolution satellite imagery: a case study from central Italy. **Remote Sensing of Environment**, New York, v. 115, n. 4, p. 1025-1033, Apr. 2011.

CHOO, A.; PHAM, B.; MAEDER, A. J. Change detection in an image sequence using shape analysis. In: CONFERENCE ON IMAGE PROCESSING AND THE IMPACT OF NEW TECHNOLOGIES, 5., 1989, Canberra. **Proceedings...** Canberra: Canberra University, 1989. p. 111-114.

CHUVIECO, E.; CONGALTON, R. G. Mapping and inventory of Forest fires from digital processing of TM data. **Geocarto International**, Hong Kong, v. 4, p. 41-53, Dec. 1988.

CIHLAR, J. Land cover mapping of large areas from satellites: status and research priorities. **International Journal of Remote Sensing**, Basingstoke, v.21, n. 6/7, p.1093-1114, Sept. 2000.

COINER, J.C. Using Landsat to monitor changes in vegetation cover induced by desertification processes. In: INTERNATIONAL SYMPOSIUM OF REMOTE

SENSING OF ENVIRONMENT, 17., 1980, San José.**Proceedings...**Ann Arbor: Environmental Research Institute of Michigan, 1980. p. 1341-1351.

COLLINS, J. B.; WOODCOCK, C. E. An assessment of several linear change detection techniques for mapping forest mortality using multitemporal Landsat TM data. **Remote Sensing of Environment**, New York, v. 56, n. 1, p. 66-77, Apr. 1996.

_____. Change detection using the Gramm-Schmidt transformation applied to mapping forest mortality. **Remote Sensing of Environment**, New York, v. 50, n. 3, p. 267-279, Dec. 1994.

COLWELL, J. E.; WEBER, F. P. Forest change detection. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 15., 1981, Ann Arbor. **Proceedings...**Ann Arbor: Environmental Research Institute of Michigan, 1981. p. 839-852.

CONCHEDA, G.; DURIEUX, L.; MAYAUX, P. An object-based method for mapping and change analysis in mangrove ecosystems. **ISPRS Journal of Photogrammetry & Remote Sensing**, Amsterdam, v. 63, n. 5, p. 578-589, Sept. 2008.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. Boca Raton: CRC, 2009. 184 p.

COOPS, N.; WULDER, M. A.; WHITE, J. C. Identifying and describing forest disturbance and spatial pattern: data selection n.s and methodological implications. In: WULDER, M.A.; FRANKLIN, S.E. (Ed.). **Understanding forest disturbance and spatial pattern**. Boca Raton: CRC, 2007. p. 215-246.

COPPIN, P. R.; BAUER, M. E. Processing of multitemporal Landsat TM imagery to optimize extraction of forest cover change features. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 32, n. 4, p. 918-927, July 1994.

COPPIN, P.R. et al. Digital change detection methods in ecosystem monitoring: a review. **International Journal of Remote Sensing**, Basingstoke, v. 25, n. 9, p. 1565-1596, May 2004.

COUTINHO, L. M. Fire in the ecology of the Brazilian Cerrado. In: GOLDAMMER, J. G. (Ed.). **Fire in the tropical biota: ecosystem processes and global challenges**. Saint Paul: Springer-Verlag, 1990. p. 82-105.

DAI, X.; KHORRAM, S. Development of new automated land cover change detection system from remotely sensed imagery based on artificial neural networks. In: INTERNATIONAL GEOSCIENCE REMOTE SENSING SYMPOSIUM,9., 1997, Oxford.**Proceedings...** Oxford: IGARSS, 1997. p. 1029-1031.

DEER, P. **Digital change detection in remotely sensed imagery using fuzzy set theory**. 1998. 101 f. Thesis (Ph.D. in Computer Science) - University of Adelaide, Adelaide, 1998.

DEER, P.; EKLUND, P. **Fuzzy logic for change detection in classified images**. Berlin: Springer-Verlag, 2001.62 p. (Fuzzy Logic and Soft Computing Series).

DEER, P. J.; LONGMORE, M. E. The application of principal components analysis to monitoring the clearance of native forest stands on Kangaroo island, South Australia. In: AUSTRALASIAN REMOTE SENSING CONFERENCE, 7., 1994, Melbourne. **Proceedings...** Melbourne: ARS, 1994. 1 CD-ROM.

DEFINIENS IMAGING.**Ecognitionuser guide 3**. München, 2003.413p.

DESCLÉE, B. **Automated object-based change detection for forest monitoring by satellite remote sensing: applications in temperate and tropical regions**. 2007. 152 p. Thesis (Docteur en Sciences AgronomiquesetIngénierieBiologique) - UniversitéCatholique de Louvain, Geneva, 2007.

DESCLÉE, B.; BOGAERT, P.; DEFOURNY, P. Forest change detection by statistical object-based method.**Remote Sensing of Environment**, New York, v. 102, n. 1/2, p. 1-11, May 2006.

DUVEILLER, G. et al. Deforestation in Centra Africa: estimates at regional, nacional and landscape levels by advanced processing of systematically-distributed Landsat extracts. **Remote Sensing of Environment**, New York, v.112, n. 5, p.1969-1981, May 2008.

EKLUND, P.; YOU, J.; DEER, P. Mining remote sensing image data: an integration of fuzzy set theory and image understanding techniques for environmental change. **Proceedingsof SPIE**, Bellingham, v. 4057, n. 265,p. 66-67, Apr. 2000.

FISHER, P. F.; PATHIRANA, S. The ordering of fuzzy land cover information derived from Landsat MSS data. **Geocarto International**, Hong Kong, v. 3, n. 1, p. 5-14, 1993.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. **State of the world's forests 2009**. Rome, 2009. 152p.

_____. **State of the world's forests 2010**. Rome, 2010. 164p.

FOODY, G.M. Monitoring the magnitude of land cover change around the southern limits of the Sahara. **Photogrammetric Engineering Remote Sensing**, Falls Church, v. 67, n. 7, p. 841-847, July 2001.

FRANKLIN, S. E. **Remote sensing for sustainable forest management**. New York: Lewis, 2001. 407p.

FUNG, T.; LEDREW, E. The application of principal components analysis to change detection using various accuracy indices. **Photogrammetric Engineering Remote Sensing**, Falls Church, v. 53, n. 8, p. 1649-1658, Aug. 1987.

GERRAND, A. et al. The 2010 global forest resource assessment remote sensing survey. In: WORLD FOREST CONGRESS, 13., 2009, Buenos Aires. **Anales...** Buenos Aires: SWF, 2009. p. 1-7.

GONG, P.; LEDREW, E. F.; MILLER, J. R. Registration-noise reduction difference images for change detection. **International Journal of Remote Sensing**, Basingstoke, v. 13, n. 4, p. 773-779, Feb. 1992.

GONG, P.; XU, B. Remote sensing of forests over time. In: WULDER, M.A.; FRANKLIN, S.E. (Ed.). **Remote sensing of forest environments: concepts and case studies**. Boston: Kluwer Academic, 2003. p. 301-334.

GOODCHILD, M.F.; QUATTROCHI, D.A. Introduction: scale, multiscaling, remote sensing and GIS. In: QUATTROCHI, D.A.; GOODCHILD, M.F. (Ed.). **Scale in remote sensing and GIS**. Santa Barbara: CRC, 1997. p. 1-11.

GOPAL, S.; WOODCOCK, C. Remote sensing of forest change using artificial neural networks. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 34, n. 2, p. 398-404, Mar. 1996.

_____. Theory and methods for accuracy assessment of thematic maps using fuzzy sets. **Photogrammetric Engineering Remote Sensing**, Falls Church, v. 60, n. 2, p. 181-188, Feb. 1994.

GORDON, S. Utilizing Landsat imagery to monitor land use change A case study of Ohio. **Remote Sensing of Environment**, New York, v. 9, n. 2, p. 189-196, Apr. 1980.

HALL, O.; HAY, G. J. A multiscale object-specific approach to digital change detection. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 4, n. 4, p. 311-327, Nov. 2003.

HANAIZUMI, H.; OKUMURA, H.; FUJIMURA, S. Change detection from remotely sensed multitemporal images using spatial segmentation. In: INTERNATIONAL GEOSCIENCE REMOTE SENSING SYMPOSIUM, 39., 1991, Ann Arbor. **Proceedings...** Ann Arbor: IGARSS, 1991. p. 1079-1081.

HAY, G.J.; CASTILLA, G. Geographic Object-Based Image Analysis (GEOBIA): a new name for a new discipline. In: BLASCHKE, T.; LANG, S.; HAY, G.J. (Ed.). **Object-based image analysis spatial concepts for knowledge-driven remote sensing applications**. New York: Springer-Verlag, 2008. p. 75-90.

HAY, G.J. et al. An automated object-based approach for the multiscale image segmentation of forest scenes. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 7, n. 4, p. 339-359, Dec. 2005.

HEREDIA-LACLAUSTRA, A. et al. Comparación de distintas técnicas de análisis digital para la cartografía de áreas quemadas con imágenes LANDSAT ETM+. **GeoFocus**, Jacupiranga, v. 3, p. 216-234, nov. 2003.

HOFFER, R.M.; LEE, K. S. Forest change classification using SEASAT and SIR-B satellite SAR data. In: INTERNATIONAL GEOSCIENCE REMOTE SENSING SYMPOSIUM, 36., 1989, Ann Arbor. **Proceedings...** Ann Arbor: IGARSS, 1989. p. 1372-1375.

HOWARTH, I. P.; BOASSON, E. Landsat digital enhancements for change detection in urban environment. **Remote Sensing of Environment**, New York, v. 13, n. 2, p. 149-160, Apr. 1983.

HOWARTH, J. P.; WICKWARGE, M. Procedure for change detection using Landsat digital data. **International Journal of Remote Sensing**, Basingstoke, v. 2, n. 3, p. 277-291, Mar. 1981.

INGRAM, K.; KNAPP, E.; ROBINSON, J. W. **Change detection technique development for improved urbanized area delineation, technical memorandum CSC/TM-81/6087**. Silver Springs: Computer Sciences Corporation, 1981.

INSTITUTO BRASILEIRO DO MEIO AMBIENTE E DOS RECURSOS SUSTENTÁVEIS. **Ecosistemas brasileiros**. Brasília, 2001. 49 p.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Monitoramento da cobertura florestal da Amazônia por satélites: sistema PRODES, DETER, DEGRAD e QUEIMADAS 2007-2008**. São José dos Campos, 2008. 47 p.

JENSEN, J. R. **Remote sensing of the environment: an earth resource perspective**. 2nd ed. Chicago: Prentice Hall, 2006. 598 p.

JENSEN, J.R. et al. Inland wetland change detection in the Everglades water conservation area 2A using time series of normalized remotely sensed data. **Photogrammetric Engineering Remote Sensing**, Falls Church, v. 61, n. 2, p. 199-209, Feb. 1995.

JENSON, J. R.; TOLL, D. L. Detecting residential land use development at the urban fringe. **Photogrammetric Engineering and Remote Sensing**, Falls Church, v. 48, n. 4, p. 629-643, Apr. 1982.

JHA, C. S.; UNNI, N. V. M. Digital change detection of forest conversion of a dry tropical forest region. **International Journal of Remote Sensing**, Basingstoke, v. 15, n. 13, p. 2543-2552, July 1994.

JOHNSON, R.D.; KASISCHKE, E.S. Change vector analysis: a technique for the multispectral monitoring of land cover and condition. **International Journal of Remote Sensing**, Basingstoke, v. 19, n. 3, p. 411-426, Feb. 1998.

JOYCE, A. T.; IVEY, J. H.; BURNS, G. S. The use of Landsat MSS data for detecting land use changes in forest land. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 24., 1982, San José. **Proceedings...** Ann Arbor: Environmental Research Institute of Michigan, 1980. p. 979-988.

JUSTICE, C. O. et al. **The MODIS fire products**. Version 2.3. Washington: NASA, 2006. 34 p.

KALENSKY, Z. D.; SCHERK, L. R. Accuracy of forest mapping from Landsat CCTs. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 10., 1975, Ann Arbor. **Proceedings...** Ann Arbor: Environmental Research Institute of Michigan, 1975. p. 1159-1163.

KENNEDY, R.E. et al. Remote sensing change detection tools for natural resource managers: understanding concepts and tradeoffs in the design of landscape monitoring projects. **Remote Sensing of Environment**, New York, v. 113, n. 7, p. 1382-1396, July 2009.

KLINK, C. A.; MACHADO, R. B. A conservação do Cerrado brasileiro. **Megadiversidade**, São Paulo, v. 1, n. 2, p.147-155, out.2005.

KLINK, C.A.; MOREIRA, A.G. Past and current human occupation and land use. In: OLIVEIRA, P. S.; MARQUIS, R. J. (Ed.). **The Cerrados of Brazil: ecology and natural history of a neotropical savanna**. New York: Columbia University, 2002. p. 69-88.

KRESSLER, F.P.; STEINNOCHER, K.T. Detecting land cover changes from NOAA AVHRR data by using spectral mixture analysis. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 1, n. 1, p. 21-26, 1999.

LAMBIN, E.F. Change detection and multitemporal scales: seasonal and annual variations in landscape variables. **Photogrammetric Engineering Remote Sensing**, Falls Church, v. 62, n. 8, p. 931-938, Aug. 1996.

LAMBIN, E.F.; GEIST, H.; RINDFUSS, R.R. Introduction: local processes with global impacts. In: LAMBIN, E.F.; GEIST, H.J. (Ed.). **Land-use and land-cover change: local processes and global impacts**. Berlin: Springer-Verlag, 2006. p. 1-8.

LAMBIN, E.F.; STRAHLER, A.H. Change vector analysis in multitemporal space: a tool to detect and categorise land cover change processes using high temporal resolution satellite data. **Remote Sensing of Environment**, New York, v. 48, n. 2, p. 231-244, May 1994.

LANG, S. Object-based image analysis for remote sensing applications: modeling reality: dealing with complexity. In: BLASCHKE, T.; LANG, S.;

HAY, G.J. (Ed.). **Object-based image analysis spatial concepts for knowledge-driven remote sensing applications**. New York: Springer-Verlag, 2008. p. 3-28.

LAZAROFF, M.B.; BRENNAN, M.W. Multitemporal texture analysis of features computed from remotely sensed imagery. **Proceedings of SPIE**, Bellingham, v. 1819, n. 166, p. 166-175, Nov. 1992.

LEDRU, M.P. Late quaternary history and evolution of the Cerrados as revealed by palynological records. In: OLIVEIRA, P. S.; MARQUIS, R. J. (Ed.). **The Cerrados of Brazil: ecology and natural history of a neotropical savanna**. New York: Columbia University, 2002. p. 33-50.

LINDQUIST, E. **Estimation and analysis of forest cover change: the FAO global forest resource assessment 2010 remote sensing survey: monitoring tree cover and forest area change globally from 1990 to 2005**. Rome: FAO, 2010. 343 p.

LINKE, J. et al. Introduction: Structure, function and change of forest landscapes. In: WULDER, M.A.; FRANKLIN, S.E. (Ed.). **Understanding forest disturbance and spatial pattern**. Boca Raton: CRC, 2007. p. 1-30.

LODWICK, G.D. Measuring ecological changes in multitemporal Landsat TM data using principal components. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING ENVIRONMENT, 13., 1979, Ann Arbor. **Proceedings...** Ann Arbor: Environmental Research Institute of Michigan, 1979. p. 1131-1141.

LU, D. et al. Change detection techniques. **International Journal of Remote Sensing**, Basingstoke, v. 25, n. 12, p. 2365-2407, June 2004.

_____. Relationships between forest stand parameters and Landsat TM spectral responses in the Brazilian Amazon Basin. **Forest Ecology and Management**, Amsterdam, v. 198, n. 1, p. 149-167, Jan. 2004.

LUCARELLI, H. Z. et al. Impacto da construção de Brasília na organização do espaço. **Revista Brasileira de Geografia**, Rio de Janeiro, v. 51, n. 1, p. 99-138, jan./mar. 1989.

LUNETTA, R. S. Applications, project formulation, and analytical approach. In: LUNETTA, R.S.; ELVIDGE, C.D. (Ed.). **Remote sensing change detection**. New York: CRC, 1998. p. 1-19.

- LYON, J.G. et al. A change detection experiment using vegetation indices. **Photogrammetric Engineering Remote Sensing**, Falls Church, v. 64, n. 2, p. 143-150, Feb. 1998.
- MALILA, W.A. Change vector analysis: an approach for detecting forest change with Landsat. In: ANNUAL SYMPOSIUM ON MACHINE PROCESSING OF REMOTELY SENSED DATA, 6., 1980, Washington. **Proceedings...** Washington: IEEE, 1980. p. 326-336.
- MANAVALAN, P.; KESAVASAMY, K.; ADIGA, S. Irrigated crops monitoring through seasons using digital change detection analysis of IRD-LISS 2 data. **International Journal of Remote Sensing**, Basingstoke, v. 16, n. 4, p. 633-640, Feb. 1995.
- MATSUYAMA, T. Knowledge-based aerial image understanding systems and expert systems for image processing. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 25, n. 3, p. 305-316, May 1987.
- MCDERMID, G. J. et al. Object-based approaches to change analysis and thematic map update: challenges and limitations. **Canadian Journal Remote Sensing**, Ottawa, v. 34, n. 5, p. 462-466, Sept. 2008.
- MENDONÇA, R. C. et al. Flora vascular do Bioma Cerrado: checklist com 12.356 espécies. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. (Org.). **Cerrado: ecologia e flora**. Brasília: EMBRAPA Cerrados, 2008. v. 2, p. 213-228.
- MILLER, L. D.; NUALCHAWEE, K.; TOM, C. **Analysis of the dynamics of shifting cultivation in the tropical forests of northern Thailand using landscape modelling and classification of Landsat imagery, NASA technical memorandum 79545**. Greenbelt: Goddard Space Flight Centre, 1978.
- MIRANDA, S.H.; BUSTAMANTE, M.M.C.; MIRANDA, A.C. The fire factor. In: OLIVEIRA, P. S.; MARQUIS, R. J. **The Cerrados of Brazil: ecology and natural history of a neotropical savanna**. New York: Columbia University, 2002. p. 51-68.
- MISTRY, J. Fire in the Cerrado (savannas) of Brazil: an ecological review. **Progress in Physical Geography**, London, v. 22, n. 4, p. 425-448, Dec. 1998.
- MOTTA, P.E.F.; CURI, N.; FRANZMEIER, D.P. Relations of soil and geomorphic surfaces in the Brazilian Cerrado. In: OLIVEIRA, P. S.;

MARQUIS, R. J. (Ed.). **The Cerrados of Brazil: ecology and natural history of a neotropical savanna.** New York: Columbia University, 2002. p. 13-32.

MUNYATI, C. Wetland change detection on the Kafue Flats, Zambia, by classification of a multitemporal remote sensing image dataset. **International Journal Remote Sensing**, Basingstoke, v. 21, n. 9, p. 1787-1806, July 2000.

MYERS, N. Tropical forests: much more than stocks of wood. **Journal of Tropical Ecology**, Winchelsea, v. 4, n. 2, p.209-221, May 1998.

NAVULUR, K. **Multispectral image analysis using the object-oriented paradigm.** Boca Raton: CRC, 2007. 184p.

NELSON, R.F. Detecting forest canopy change due to insect activity using Landsat MSS. **Photogrammetric Engineering and Remote Sensing**, Falls Church, v. 49, n. 9, p. 1303-1314, Sept. 1983.

NEUBERT, M.; HEROLD, H.; MEINEL, G. Assessing image segmentation quality: concepts, methods and application. In: BLASCHKE, T.; LANG, S.; HAY, G.J. (Ed.). **Object-based image analysis spatial concepts for knowledge-driven remote sensing applications.** New York: Springer-Verlag, 2008. p. 769-784.

NIEMEYER, I. Object-based change detection: an unsupervised approach. In: INTERNATIONAL CONFERENCE ON OBJECT-BASED IMAGE ANALYSIS, 1., 2006, Salzburg. **Proceedings...** Salzburg: Salzburg University, 2006. 1 CD-ROM.

OLIVEIRA, L.T. de. **Fusão de imagens de sensoriamento remoto e mineração de dados geográficos para mapear as fitofisionomias do Bioma Cerrado.** Lavras: UFLA, 2004. 131p.

PEDDLE, D. R.; TEILLET, P. M.; WULDER, M. A. Radiometric image processing. In: WULDER, M.A.; FRANKLIN, S.E. (Ed.). **Remote sensing of forest environments.** Norwell: Springer, 2003. p. 181-208.

PEREIRA, A. A. **Uso de geotecnologia para detecção e análise de queimadas e focos de calor em unidades de conservação no norte de Minas Gerais.** Lavras: UFLA, 2009. 91p.

PEREIRA, A. A. et al. Procedimentos metodológicos para detecção e quantificação de áreas queimadas no programa de monitoramento integrado da

flora nativa de Minas Gerais. In: SEMINÁRIO DE ATUALIZAÇÃO EM SENSORIAMENTO REMOTO E SISTEMAS DE INFORMAÇÕES GEOGRÁFICAS APLICADOS À ENGENHARIA FLORESTAL, 8., 2008, Curitiba. **Anais...** Curitiba: UFPR, 2008. 1 CD-ROM.

PHULPIN, T. et al. Using SPOT-4 HRVIR and vegetation sensors to assess impact of tropical forest fires in Roraima, Brazil. **International Journal of Remote Sensing**, Basingstoke, v. 23, n. 10, p. 1943-1966, Oct. 2002.

RADOUX, J.; DEFOURNY, P. Image-to-map conflict detection using iterative trimming: application to forest change. **International Society for Photogrammetry and Remote Sensing**, Basingstoke, v. 38, n. 4, Aug. 2008. Disponível em: <http://www.isprs.org/proceedings/XXXVIII/4-C1/Sessions/Session6/6731_Radoux_pap.pdf>. Acesso em: 10 jul. 2011.

RAMANKUTTY, N. Global land-cover change: recent progress, remaining challenges. In: LAMBIN, E.F.; GEIST, H.J. (Ed.). **Land-use and land-cover change: local processes and global impacts**. Berlin: Springer-Verlag, 2006. p. 9-40.

RIBEIRO, J. F.; WALTER, B. M. T. As principais fitofisionomias do Bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. (Ed.). **Cerrado: ecologia e flora**. Planaltina: EMBRAPA Cerrados, 2008. p. 151-212.

RIORDAN, C.J. **Non-urban to urban land cover change using Landsat data**: summary report of the Colorado Agricultural Research Experiment Station. Fort Collins: Interweave, 1980.

ROSENBERGER, C. et al. Unsupervised and supervised image segmentation evaluation. In: ZHANG, Y. (Ed.). **Advances in image and video segmentation**. Edinburgh: Idea, 2006. p. 457-460.

SCHOTT, J. R. **Remote sensing: the image chain approach**. New York: Oxford University, 1997. 688 p.

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

SETZER, A. W.; MORELLI, F.; LOMBARDI, R. J. R. Estimativa quinzenal de áreas queimadas nas imagens MODIS do INPE. In: RUDORFF, B. F. T.; SHIMABUKURO, Y. E.; CEBALLOS, J. C. (Org.). **O sensor modis e suas aplicações ambientais no Brasil**. São José dos Campos: Bookimage, 2007. p.

403-417.

SILJESTRÖM-RIBED, P.; MORENO-LÓPES, A. Monitoring burnt areas by principal components analysis of multitemporal TM data. **International Journal Remote Sensing**, Basingstoke, v. 16, n. 9, p. 1577-1587, Sept. 1995.

SILVEIRA, E. M. O. **Mapping forests: a multitemporal analysis**. Lavras: UFLA, 2007. 75 p.

SINGH, A. Change detection in the tropical forest environment of northeastern India using Landsat. In: EDEN, M. J.; PARRY, J. T. (Ed.). **Remote sensing and tropical land management**. New York: J. Wiley, 1986. p. 237-254.

_____. Digital change detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, Basingstoke, v. 10, n. 6, p. 989-1003, Dec. 1989.

_____. **Tropical forest monitoring using digital Landsat data in northeastern India**. 1984. 225 f. Thesis (Ph.D. in Geography) - University of Reading, Reading, 1984.

SINGH, A.; HARRISON, A. Standardized principal components. **International Journal of Remote Sensing**, Basingstoke, v. 6, n. 6, p. 883-896, July 1985.

SHAPIRO, L.; STOCKMAN, G. **Computer vision**. Trenton: Prentice-Hall, 2000. 609 p.

STEFANOV, W.L.; RAMSEY, M.S.; CHRISTENSEN, P.H. Monitoring urban land cover changes: an expert system approach to land cover classification of semiarid to arid urban centers. **Remote Sensing Environment**, New York, v. 77, n. 1, p. 173-185, Feb. 2001.

SWAIN, P. H. Bayesian classification in a time-varying environment. **IEEE Transactions on Systems, Man and Cybernetics**, New York, v. 8, p. 879-883, 1978.

TODD, W. J. Urban and regional land use change detected by using Landsat data. **Journal of Research by the U.S. Geological Survey**, Washington, v. 5, p. 527-534, 1977.

TOLL, D. L.; ROYAL, J. A.; DAVIS, J. B. Urban area up-date procedures using Landsat data. In: FALL TECHNICAL MEETING OF THE AMERICAN

SOCIETY OF PHOTOGRAMMETRY HELD IN NIAGRA FALLS, 1., 1980, Ottawa. **Proceedings...** Ottawa: ASPH, 1980.p.1-17.

TONELI, C.A.Z. **Estimativa da cobertura arbóreautilizando a combinação de imagensIkonos e Landsat**. Lavras: UFLA, 2008. 81 p.

TRIETZ, P.; ROGAN, J. Remote sensing for mapping and monitoring land-cover and land-use change: an introduction. **Progress in Planning**, New York, v. 61, n. 4, p. 269-279,May 2004.

TURNER, M.G.; GARDNER, R.H.; O'NEILL, R.V. **Landscape ecology in theory and practice**.New York: Springer, 2001. 401 p.

VICENTINI, K. R. C. F. **Análise palinológica de uma vereda em Cromínia, Goiás**. 1993. 137 f. Dissertação (Mestrado em Ciências) - Universidade de Brasília, Brasília, 1993.

VIRAG, L. A.; COLWELL, J. E. An improved procedure for analysis of change in thematic mapper image-pairs. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING ENVIRONMENT, 21., 1987, Ann Arbor. **Proceedings...**Ann Arbor: Environmental Research Institute of Michigan, 1987. p. 1101-1110.

WARMING, E.; FERRI, M. G. **Lagoa Santa e a vegetação de Cerrados brasileiros**. São Paulo:EDUSP; Belo Horizonte: Itatiaia, 1973. 47 p.

WEISMILLER, R.A.et al. Change detection in coastal zone environments. **Photogrammetric Engineering and Remote Sensing**, Falls Church, v. 43, p. 1533-1539, 1977.

WILSON, J. R.; BLACKMAN, C.; SPANN, G. W. Land use change detection using Landsat data. In: ANNUAL REMOTE SENSING EARTH RESOURCES CONFERENCE, 5., 1976, Tullahoma. **Proceedings...**Tullahoma: University of Tennessee, 1976. p. 79-91.

WOODCOCK, C.E.; STRAHLER, A.H. The factor of scale in remote sensing. **Remote Sensing of Environment**, New York, v. 21, n. 3, p. 311-332, Apr. 1987.

YUAN, D.; ELVIDGE, C. D.; LUNETTA, R. S. Survey of multispectral methods for land cover change analysis. In: LUNETTA, R.S.; ELVIDGE, C.D.

(Ed.). **Remote sensing change detection**. Chelsea: Ann Arbor Press, 1998. p. 21-40.