

Análise Orientada a Objetos para a Classificação do Uso e Cobertura da Terra do Assentamento São José da Boa Morte, RJ



Empresa Brasileira de Pesquisa Agropecuária
Embrapa Solos
Ministério da Agricultura, Pecuária e Abastecimento

BOLETIM DE PESQUISA
E DESENVOLVIMENTO
265

Análise Orientada a Objetos para a
Classificação do Uso e Cobertura da Terra do
Assentamento São José da Boa Morte, RJ

Teule Lemos Branco
Elaine Cristina Cardoso Fidalgo
Cristiane Nunes Francisco
Ricardo de Oliveira Dart
Rachel Bardy Prado

Embrapa Solos
Rio de Janeiro, RJ
2018

Exemplares desta publicação podem ser adquiridos na:

Embrapa Solos
Rua Jardim Botânico, 1024, Jardim Botânico
CEP 22460-000, Rio de Janeiro, RJ
Fone: +55 (21) 2179-4500
www.embrapa.br
www.embrapa.br/fale-conosco/sac

Comitê Local de Publicações
da Embrapa Solos

Presidente
Vinicius de Melo Benites

Secretária-Executiva
Jacqueline Silva Rezende Mattos

Membros
*Ademar Barros da Silva, Adriana Vieira de
Camargo Moraes, Bernadete da Conceição
Carvalho Gomes Pedreira, Enyomara Lourenço
Silva, Evaldo de Paiva Lima, Joyce Maria
Guimarães Monteiro, Luciana Sampaio de
Araujo, Maria Regina Capdeville Laforet,
Maurício Rizzato Coelho, Moema de Almeida
Batista, Ricardo de Oliveira Dart, Wenceslau
Geraldes Teixeira.*

Supervisão editorial
Jacqueline Silva Rezende Mattos

Revisão de texto
Marcos Antônio Nakayama

Normalização bibliográfica
Enyomara Lourenço Silva

Projeto gráfico da coleção
Carlos Eduardo Felice Barbeiro

Editoração eletrônica
Moema de Almeida Batista

Foto da capa
Elaine Cristina Cardoso Fidalgo

1ª edição
On-line (2018)

Todos os direitos reservados.

A reprodução não autorizada desta publicação, no todo ou em parte,
constitui violação dos direitos autorais (Lei nº 9.610).

Dados Internacionais de Catalogação na Publicação (CIP)

Embrapa Solos

Análise orientada a objetos para a classificação do uso e cobertura da terra do assentamento
São José da Boa Morte, RJ / Teule Lemos Branco ... [et al.]. – Dados eletrônicos. – Rio de
Janeiro, RJ : Embrapa Solos, 2018.
36 p.: il. - (Boletim de Pesquisa e Desenvolvimento / Embrapa Solos, ISSN 1678-0892;
265).

Sistema requerido: Adobe Acrobat Reader.

Modo de acesso: <<https://www.embrapa.br/solos/publicacoes>>.

Título da página da Web (acesso em 30 ago 2018).

1. Solo-Uso. 2. Sensoriamento remoto. 3. Mata Atlântica. I. Branco, Teule Lemos. II.
Fidalgo, Elaine Cristina Cardoso. III. Francisco, Cristiane Nunes. IV. Dart, Ricardo de Oliveira.
V. Prado, Rachel Bardy. VI. Embrapa Solos. VII. Série.

CDD 631.47

Sumário

Resumo	5
Abstract	7
Introdução.....	9
Material e Métodos	13
Resultados e Discussão	26
Considerações Finais.....	32
Agradecimentos.....	33
Referências	33

Análise Orientada a Objetos para a Classificação do Uso e Cobertura da Terra do Assentamento São José da Boa Morte, RJ

Teule Lemos Branco¹

Elaine Cristina Cardoso Fidalgo²

Cristiane Nunes Francisco³

Ricardo de Oliveira Dart⁴

Rachel Bardy Prado⁵

Resumo – O uso de técnicas de sensoriamento remoto para a classificação do uso e cobertura das terras tem crescido e acompanhado o avanço tecnológico nessa área, devido à oferta de sensores de alta resolução espacial e métodos para a classificação digital das imagens. Nesse contexto, a análise de imagem orientada a objetos geográficos (GEOBIA) possibilita explorar atributos da imagem como forma e textura, ao mudar o elemento de classificação, que passa do pixel para uma região homogênea de pixels, aumentando a precisão da classificação. O objetivo deste trabalho foi aplicar a GEOBIA em uma imagem de alta resolução espacial para classificar o uso e cobertura da terra em uma área de Mata Atlântica, o Assentamento Rural São José da Boa Morte, RJ. A segmentação e a classificação da imagem foram aplicadas às quatro bandas multiespectrais do satélite World-View II e aos seus principais componentes. O método aplicado permitiu identificar os atributos que mais contribuíram para a classificação, sendo eles: as médias dos PC 2, 3 e 4; o Índice de Vegetação por Diferença Normalizada; e a Matriz de Co-ocorrência

¹ Bacharel em Engenharia Ambiental, bolsista Pibic da Embrapa Solos em 2016-2017, Rio de Janeiro, RJ.

² Engenheira-agrônoma, doutora em Engenharia Agrícola, pesquisadora da Embrapa Solos, Rio de Janeiro, RJ.

³ Bacharel em Geografia, doutora em Geociências, professora adjunta da Universidade Federal Fluminense, Niterói, RJ.

⁴ Geógrafo, mestre em Geografia, analista da Embrapa Solos, Rio de Janeiro, RJ.

⁵ Bióloga, doutora em Ciências da Engenharia Ambiental, pesquisadora da Embrapa Solos, Rio de Janeiro, RJ.

de Níveis de Cinza. As áreas não classificadas totalizaram 20%, mostrando a necessidade de prever novos procedimentos para seu melhor desempenho.

Termos para indexação: sensoriamento remoto, processamento digital de imagens, imagens orbitais de alta resolução, análise de imagem orientada a objetos geográficos.

Object-Oriented Analysis for the Classification of Land Use and Coverage of the Seating São José da Boa Morte, RJ

Abstract – The use of remote sensing techniques for the classification of land use and coverage has grown and accompanied the technological advance in this area, due to the availability of high spatial resolution sensors and methods for the digital classification of images. In this context, geographic-object-based image analysis (GEOBIA) allows to explore image attributes as shape and texture, by changing the classification element, from pixel to homogeneous region of pixels, increasing the accuracy of the classification. The objective of this work was to apply GEOBIA in a high spatial resolution image to classify land use and cover in an area of Atlantic Forest, the rural settlement São José da Boa Morte, RJ. The segmentation and image classification were applied to the four multispectral bands of the World-View II satellite and to its main components. The applied method allowed to identify the attributes that contributed most to the classification: the PC 2, 3 and 4 averages; the Normalized Difference Vegetation Index; and the Matrix of Co-occurrence of Gray Levels. The unclassified areas totaled 20%, showing the need to predict new procedures for their best performance.

Index terms: remote sensing, digital image processing, high resolution orbital images, geographic-object-based image analysis (GEOBIA).

Introdução

O mapeamento do uso e cobertura da terra é muito utilizado para avaliar a dinâmica da paisagem e dos seus usos. De acordo com Foody (2002), o sensoriamento remoto é uma fonte fundamental para geração de mapas temáticos, como os que descrevem o uso e cobertura da terra, uma vez que provém uma representação contínua e altamente consistente da superfície da terra, e seus produtos podem ser disponibilizados em várias escalas espaciais e temporais. Anderson et al. (1976) destacam que mapas de uso e cobertura da terra provenientes de aplicação de técnicas de sensoriamento remoto são necessários nas análises de processos e problemas ambientais. Eles permitem conhecer a distribuição e a área de agricultura, florestas e ocupação urbana, entre outros, bem como a informação sobre as suas mudanças. Esse conhecimento é fundamental para os tomadores de decisão implantarem políticas de uso da terra, identificarem os futuros pontos sob pressão e planejarem o desenvolvimento regional.

O mapeamento temático de dados de sensores remotos é baseado na classificação de imagens, que pode ser realizada tanto por análise visual como por algoritmos computacionais. Com o avanço dos sistemas de sensoriamento remoto que, atualmente, são capazes de fornecer dados constantes e consistentes da superfície da Terra, o volume de informações cresceu muito. As imagens multiespectrais e multitemporais apresentam grande quantidade de informações a serem processadas em uma cena, o que torna insuficiente a inspeção visual, dando espaço à análise digital por conta do avanço computacional e sua rapidez em processar dados (Meneses; Almeida, 2012; Novo, 2010).

A fim de auxiliar a extração de informações das imagens digitais obtidas por meio dos sensores remotos, são empregadas técnicas de processamento digital de imagens, como realce de contraste, correção atmosférica, classificação, entre outras. As técnicas de classificação de imagens buscam gerar mapas temáticos por meio de complexos modelos estatísticos e probabilísticos (Jensen, 2009).

Com o avanço tecnológico, novos sensores remotos foram lançados, fornecendo imagens com melhor resolução, especialmente espacial. Com a necessidade de obter informações geográficas com técnicas de extração mais

rápidas e eficientes, surgiu o desafio de buscar novos métodos para explorar o conteúdo dessas imagens de forma mais inteligente (Lang, 2008).

A tradicional classificação de imagens por *pixel* utiliza a informação espectral dos pixels de forma isolada, classificando-os por meio de algoritmos probabilísticos ou determinísticos (Meneses; Almeida, 2012; Moreira, 2003). Essa abordagem tradicional explora as diferenças espectrais de vários atributos para extrair as informações temáticas de interesse e classifica cada *pixel* na imagem sem considerar os *pixels* vizinhos.

Blaschke et al. (2014) destacam que a classificação com o foco no *pixel* é compreensível quando os objetos de interesse são menores ou semelhantes em tamanho à resolução espacial. Uma vez que a resolução espacial se torna mais fina do que o objeto de interesse (por exemplo, árvores simples e campos de cultivo de bosques), ou seja, os objetos são compostos por muitos pixels, surge a demanda pela análise dos padrões espaciais que eles criam e não apenas dos pixels isolados. Nesses casos, especialmente em imagens de alta resolução, quando aplicada a classificação tradicional *pixel a pixel*, o resultado apresenta aparência salpicada e de baixa acurácia (Gao; Mas, 2008).

Com o avanço na tecnologia computacional e o fato de as metodologias de classificação de imagens convencionais não conseguirem explorar suficientemente a quantidade e qualidade dos dados fornecidos pelas imagens de alta resolução, uma nova abordagem foi desenvolvida: a análise orientada a objetos, ou análise geográfica de imagens baseada em objetos (*Geographic Object Based Image Analysis*, GEOBIA). Nesse caso, o elemento de classificação deixa de ser o *pixel*, passando a ser uma região de *pixels* que apresenta homogeneidade em suas propriedades espectrais. Essa nova abordagem possibilitou explorar outros atributos da imagem, como forma e textura, aumentando a precisão da classificação (Zhong et al., 2005; Hay; Castilla, 2008; Blaschke et al., 2014).

A abordagem orientada a objetos busca simular a maneira como humanos interpretam a imagem (Hay; Castilla, 2008), pois o cérebro tem capacidade de interpretar diversos aspectos da informação da cena e identificar objetos de forma intuitiva, reconhecendo num mesmo objeto diferentes orientações, cores, tamanhos e texturas, além da capacidade de explorar o conhecimento já armazenado e convertê-lo facilmente em uma base de regras para a

interpretação da imagem (Navalur, 2006). Os “objetos de imagem” representam componentes da cena que são distinguíveis dentro de uma imagem (por exemplo, uma casa), gerados perceptivamente a partir de grupos de *pixels* de alta resolução, onde cada grupo é composto de valores digitais semelhantes e possui um tamanho intrínseco, forma e relação geográfica com o componente da cena no mundo real (Benz et al., 2004; Blaschke et al., 2014; Hay et al., 2001).

O desafio da GEOBIA está em tornar explícito o modo como lidamos com a informação da imagem, conseguimos relacionar os objetos uns com os outros com facilidade e entendemos o conteúdo da cena, ou seja, trata-se de traduzir esse conhecimento cognitivo em um conjunto de regras. Segundo Hay e Castilla (2008), a GEOBIA é uma subdisciplina da Ciência de Informação Geográfica (*Geographic Information Science – GIScience*) dedicada ao desenvolvimento de métodos automatizados para segmentar imagens de sensoriamento remoto em objetos de imagem e avaliar suas características espaciais, espectrais e temporais, de modo a gerar novas informações geográficas no formato pronto para os sistemas de informação geográfica (SIG).

A GEOBIA recai em dois pilares metodológicos interligados, o primeiro é a segmentação, e o segundo corresponde à classificação baseada em regras, que tornam explícitas as propriedades espectrais e geométricas, bem como as relações espaciais (Lang, 2008).

A segmentação corresponde à partição da imagem em um conjunto de regiões que são mais uniformes interiormente do que as regiões adjacentes (Castilla; Hay, 2008). A partição da imagem é uma série de medidas com base na homogeneidade, na qual se divide uma imagem ou informação no formato *raster*, em regiões espacialmente contínuas, disjuntas e homogêneas, chamadas de “segmentos”. Na classificação de segmentos, atributos como tamanho, forma, localização absoluta/relativa, textura, condições de borda e relações topológicas podem ser utilizados junto com suas informações espectrais, assemelhando-se à forma como atuam os fotointérpretes (Blaschke et al., 2014; Zhong et al., 2005).

Outro aspecto que distingue a GEOBIA da abordagem por *pixels* é a possibilidade de criar uma segmentação hierárquica em múltiplas escalas, ou seja, é possível criar um conjunto de segmentações de imagens em diferentes

níveis de detalhes, sendo a segmentação mais grosseira obtida pela união de regiões de uma segmentação mais detalhada (Blaschke et al., 2014; Navalur, 2006; Zhong et al., 2005).

A definição de um conjunto de atributos (características) significativos é o passo mais difícil na categorização das informações das imagens. Os atributos espectrais, texturais e contextuais são os três elementos de padrão usados na interpretação humana de imagens coloridas. Os atributos espectrais descrevem a variação estatística dos valores das diversas bandas espectro eletromagnético. Atributos contextuais contêm informação derivada da relação da informação ao seu redor, enquanto os texturais correspondem a uma propriedade inata de todas as superfícies presentes na Terra, por exemplo o padrão de uma cultura no campo, sendo extraídos por diversos algoritmos (Haralick et al., 1973).

Para traduzir as características dos objetos de imagem, a GEOBIA usa redes semânticas baseadas em análise e conhecimento descritivo, ou seja, incorpora a *expertise* do usuário (Blaschke et al., 2014). Os processos são embasados em redes cognitivas, que controlam um sistema de classes alvo e as definições de classes, bem como o modo de sua representação, em um ou mais níveis de segmentação (Lang, 2008).

Segundo Francisco e Almeida (2012), atualmente o modelo de conhecimento em GEOBIA evoluiu de rede semântica para árvore de processos, que explicita toda a operação realizada para interpretar a cena, incluindo tanto as etapas de segmentação como a classificação (construção da rede semântica propriamente dita), bem como as etapas de pós-classificação. A construção da rede semântica é uma das tarefas mais importantes na classificação dos objetos, porém, é uma das mais trabalhosas, devido à dificuldade de encontrar os atributos que melhor descrevem as respectivas classes dos objetos, podendo ser gerada de forma heurística⁶ pelo usuário, ou seja, por meio de testes interativos dos descritores de classes, suas funções de pertinência e seus limiares, ou de forma automática, por meio da mineração de dados.

⁶ Heurística é um método interativo de análise, que, por tentativa e erro, busca resolver problemas científicos e encontrar soluções.

Tradicionalmente, a classificação na GEOBIA é realizada pelo analista, definindo regras e funções de pertinência aos atributos, de forma visual do tipo “tentativa e erro”. Por um lado, isso permite que GEOBIA seja eficiente para a interpretação de imagem com resolução espacial alta já que possibilita integrar o conhecimento do especialista no processo, considerando que a acurácia da classificação depende muito do analista (Arvor et al., 2013). A função de pertinência permite definir a relação entre os valores dos atributos e o grau de pertencimento a uma classe.

Face ao desenvolvimento das técnicas de GEOBIA na interpretação de imagens de alta resolução espacial, a sua aplicação pode trazer bons resultados na identificação do uso e cobertura da terra em condições de paisagem fragmentada de Mata Atlântica. Com base nessa hipótese, o presente trabalho foi desenvolvido com o objetivo de aplicar a abordagem GEOBIA em uma imagem de alta resolução espacial para classificar o uso e cobertura da terra no Assentamento Rural São José da Boa Morte, no Município de Cachoeiras de Macacu, Estado do Rio de Janeiro, no bioma Mata Atlântica.

Material e Métodos

O desenvolvimento do trabalho para a classificação do uso e cobertura da terra do assentamento de São José da Boa Morte, no Município de Cachoeiras de Macacu, Estado do Rio de Janeiro, seguiu as etapas resumidamente apresentadas na Figura 1 e descritas no texto a seguir, após a descrição da área de estudo.

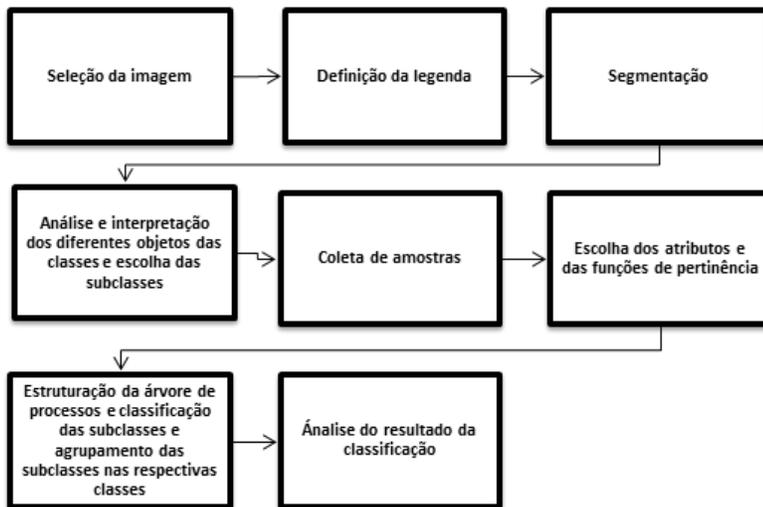


Figura 1. Etapas da classificação.

Área de Estudo

O assentamento rural São José da Boa Morte (SJBM) está localizado no Município de Cachoeiras de Macacu, Rio de Janeiro, entre as coordenadas 42°54'40" e 42°48'48" Oeste e 22°33'46" e 22°38'32" Sul, inserido na Bacia Hidrográfica do Rio Guapi-Macacu (BHRGM) (Figura 2), na região de Baixadas Litorâneas. Segundo Pedreira et al. (2011), a história de ocupação dessa bacia é antiga e gerou um quadro de degradação, como o acréscimo de áreas erodidas e o assoreamento de rios, devido ao uso inadequado e sem planejamento das terras que promoveu a remoção de grande parte da cobertura vegetal original. O mapeamento do uso e cobertura da terra da BHRGM, realizado por Fidalgo et al. (2008), mostrou o predomínio de áreas de pastagem, seguidas pelas áreas de vegetação natural em estágio avançado de regeneração (floresta densa). Entretanto, praticamente a metade da área da bacia (51,4%) encontrava-se sob proteção legal em Unidades de Conservação de Proteção Integral e de Uso Sustentável.

Segundo Abreu (2007), o assentamento SJBM foi criado pelo Instituto Nacional de Colonização e Reforma Agrária (Incra) no início dos anos 1980, sendo caracterizado pela presença de agricultura familiar, onde se destaca a produção de olerícolas.

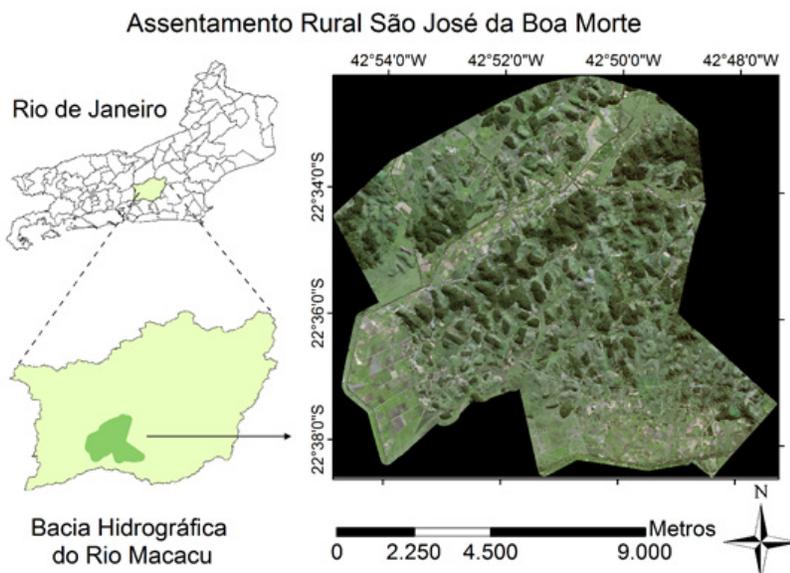


Figura 2. Localização do assentamento rural São José da Boa Morte.

Fonte: elaborada com imagem WorldView 2, da Digital Globe, por Elaine Cristina Cardoso Fidalgo.

Seleção da Imagem

Para a classificação do uso e cobertura da terra, foi selecionada e adquirida a imagem do sensor WorldView 2, da Digital Globe, de 01 de julho de 2012, composta pelas bandas das faixas do azul, verde, vermelho e infravermelho, com resolução de dois metros (Tabela 1). O produto utilizado nas análises descritas a seguir foi a imagem original, produto nível LV2A (ortorretificada).

Tabela 1. Características espectrais e resolução espacial do sensor WorldView 2.

Bandas	Faixa espectral (nm)	Resolução espacial
Azul (B)	450 – 510	2 metros
Verde (G)	510 – 580	
Vermelho (R)	630 – 690	
Infravermelho próximo 1 (Nir)	770 – 895	

Fonte: DIGITAL GLOBE (<https://www.digitalglobe.com/resources/satellite-information>).

A imagem original foi recortada de forma a integrar uma área correspondente à área do assentamento (Figura 3), totalizando uma área de estudo de 10,22 ha, na projeção UTM fuso 23 Sul com referencial geodésico WGS-1984.

A segmentação e a classificação orientada a objetos foram realizadas utilizando o programa eCognition Developer 9.2 (TRIMBLE, 2017).

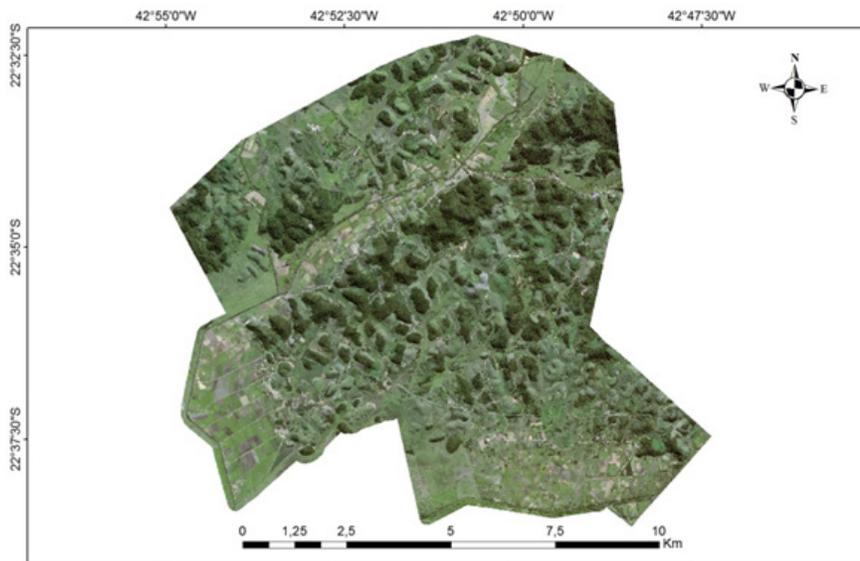


Figura 3. Imagem da área de estudo, do satélite Word View-2 de 01 de julho de 2012, na composição RGB. Projeção UTM fuso 23 Sul com referencial geodésico WGS-1984.

Definição da Legenda

A definição da legenda teve como referência as classes de uso e cobertura da terra propostas pelo Instituto Brasileiro de Geografia e Estatística (IBGE, 2013) e presentes na área de estudo. Foram estabelecidas as seguintes classes:

- água: inclui todas as classes de água, como cursos de água e canais, e reservatórios artificiais e naturais;
- solo exposto: refere-se a áreas sem cobertura vegetal ou outros tipos de cobertura que não o solo, tanto em ambientes naturais quanto antrópicos;

- estradas: correspondem a vias de tráfego de veículos;
- sombra: corresponde a áreas de onde a luz solar não é refletida e, portanto, não apresentam resposta espectral, por exemplo, áreas sob a sombra de nuvens;
- floresta: considera formações arbóreas, incluindo áreas de remanescentes florestais em estágio médio a avançado de sucessão florestal;
- vegetação arbustiva: inclui fragmentos que diferem fisionalmente da floresta por apresentar menor porte, comum a estádios iniciais de sucessão; e
- área antrópica agrícola: terras utilizadas para a produção agrícola. Estão inseridas nesta categoria as culturas permanentes e temporárias, como também pastagem e silvicultura.

Segmentação

O algoritmo de segmentação utilizado foi o Multirresolução (*Multiresolution segmentation*), desenvolvido por Baatz e Schape (2000). Pelo princípio da multirresolução, objetos de interesse geralmente aparecem em uma imagem em diferentes escalas simultaneamente. A extração de objetos da imagem deve levar em consideração a escala do problema a ser resolvido e ser adaptável para atender a essa diversidade de escalas. O procedimento para a segmentação de imagens em várias escalas pode ser descrito como uma técnica de fusão de região. Começa com cada pixel formando um objeto ou região da imagem. Em cada etapa, um par de objetos de imagem é reunido formando um objeto maior. A decisão para essa fusão de objetos baseia-se em critérios de homogeneidade local, descrevendo a semelhança de objetos adjacentes. Para uma possível fusão de regiões, os critérios de análise da homogeneidade são avaliados. O procedimento termina quando não há mais fusões possíveis. Critérios de homogeneidade mais rígidos permitem menor número de fusões, gerando objetos menores, e vice-versa, relacionando-se, portanto, à escala.

O processo inicia-se a partir de um “pixel-semente” que vai agrupando vizinhos que satisfazem a um critério de similaridade ou homogeneidade estabelecido. O crescimento continua até que sejam encontrados pixels que não satisfazem a esse critério (Almeida Filho et al., 1998). O critério de homogeneidade é definido como a combinação de homogeneidade espectral e de

forma. No programa eCognition (TRIMBLE, 2016), pode-se influenciar a homogeneidade ao se modificar o parâmetro escala. Este, ajustado no processo de segmentação, é um termo abstrato que determina o máximo de heterogeneidade para os objetos resultantes da imagem e tem influência no tamanho final dos objetos. Por exemplo, o mesmo valor de escala resultará em objetos menores em dados heterogêneos e objetos maiores em dados homogêneos. Outro parâmetro disponível no programa eCognition (TRIMBLE, 2016), que é ajustado no processo de segmentação, denominado “composição de homogeneidade”, é internamente calculado por três critérios: cor, suavidade (das bordas) e compacidade (tendo o círculo como modelo de compacidade), sendo que a suavidade e a compacidade contribuem para a definição da forma dos objetos. A suavidade está relacionada ao desenho das bordas, e a compacidade tem como máxima expressão a forma de um círculo.

O processo de segmentação baseou-se no estudo desenvolvido por Castro et al. (2017), onde diferentes parâmetros de segmentação foram testados. No presente trabalho, novos testes foram realizados utilizando as quatro bandas do sensor WorldView 2, e seus resultados, analisados visualmente, a fim de selecionar os valores dos parâmetros apropriados para a obtenção da segmentação que melhor delimitou os segmentos correspondentes às classes da legenda.

Análise e Interpretação dos Diferentes Objetos das Classes e Escolha das Subclasses

Objetos pertencentes a uma mesma classe podem ter comportamentos espectrais diferentes, devido à geometria de aquisição da imagem (posição fonte, superfície do objeto e sensor) e a fatores relacionados à natureza e à composição do alvo (Novo, 2010). Dessa forma, foi necessário dividir as classes em subclasses (Rolim, 2003) de forma a identificar os atributos das subclasses pertencentes à mesma classe de uso e cobertura da terra. Na Tabela 2, são apresentadas as classes selecionadas, suas respectivas subclasses, uma breve descrição de suas principais características e ilustração.

Tabela 2. Descrição e ilustração das subclasses e classes em recortes da imagem WorldView 2.

Classe	Subclasse	Descrição	Exemplo (bandas 4, 2, 1 em RGB)
Água	Água clara	Água com tonalidade mais clara	
	Água escura	Água com tonalidade mais escura	
Solo exposto	Solo exposto 1	Solo muito claro e exposto	
	Solo exposto 2	Solo com cor amarelada a alaranjada	
	Solo exposto 3	Solo com tonalidade intermediária com presença de vegetação rala	
	Solo exposto 4	Solo com cores acinzentadas e tom escuro	
	Solo exposto 5	Solo escuro	
	Solo exposto 6	Solo escuro e úmido ou com influência de sombra.	

Solo exposto	Solo exposto encharcado	Solo exposto encharcado	
Estradas	Estradas	Vias de tráfego de veículos	
Sombra	Sombra 1	Sombra sem resposta espectral	
	Sombra 2	Vegetação na sombra	
Floresta	Floresta 1	Floresta densa	
	Floresta clara	Floresta com resposta mais clara	
	Floresta escura	Floresta com influência de sombra	
Vegetação arbustiva	Vegetação arbustiva	Vegetação arbustiva, em regeneração	

Área antrópica	Área antrópica agrícola 1	Área menos vegetada e mais clara	
	Área antrópica agrícola 2	Pastos vegetados e verdes	
	Área antrópica agrícola 3	Áreas mais escuras, pasto com sombra	

Coleta de Amostras

A partir do conhecimento prévio da área a ser classificada, foram coletadas dez amostras para cada subclasse utilizando duas ferramentas. A primeira ferramenta, “*Select Sample*”, tem a função de coletar as amostras escolhidas pelo operador. Após cada amostra coletada, a escolha da seguinte, de mesma subclasse, foi realizada com o emprego da ferramenta “*Sample Selection Information*”. Essa ferramenta apresenta informações sobre o objeto selecionado e seu nível de pertencimento a cada subclasse de acordo com as amostras coletadas anteriormente. Essa ferramenta auxiliou na escolha das amostras, pois permitiu selecionar as que apresentavam semelhanças espectrais entre si, tornando o grupo mais homogêneo.

Escolha dos Atributos e das Funções de Pertinência

A ferramenta “*Sample Editor*” foi utilizada para auxiliar na escolha dos atributos que melhor descreveram a subclasse e sua respectiva função de

pertinência. Essa ferramenta exibe o histograma de cada atributo baseado no conjunto de amostras selecionadas e, assim, permite comparar os histogramas de diferentes atributos e classes. Dentre os atributos disponíveis, há os derivados das propriedades espectrais, geométricas e das texturais dos objetos. Esse último é baseado em método proposto por Haralick et al. (1973), *Gray Level Cooccurrence Matrix* (GLCM), que consiste no cálculo das métricas texturais a partir de matrizes de co-ocorrência do valor digital, com base na relação espacial existente entre os valores digitais em diferentes direções.

Foram identificados os atributos que permitiram discriminar diferentes subclasses, ou seja, que apresentaram homogeneidade interna e diferenciação entre subclasses. A Figura 4 apresenta um exemplo da comparação entre atributos de duas classes, com indicação de pontos do histograma em que se observa homogeneidade interna e diferenciação entre as classes.

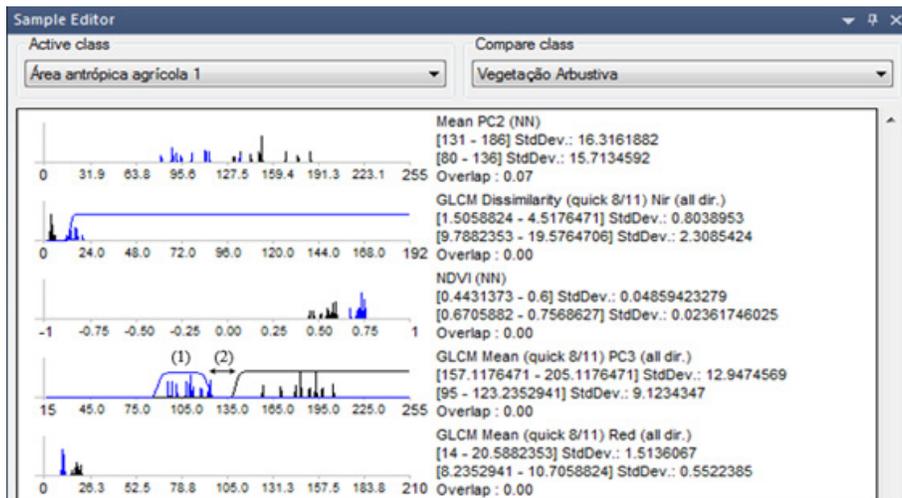


Figura 4. Tela do programa eCognition Developer 9.2 (TRIMBLE, 2017) mostrando os atributos das classes Área antrópica agrícola e Vegetação arbustiva, indicando (1) homogeneidade interna da classe Vegetação arbustiva relativa a um atributo de textura e (2) a diferenciação entre as duas classes no mesmo atributo.

A partir da análise dos histogramas dos atributos escolhidos, foram selecionados as funções de pertinência e os limites máximo e mínimo de cada subclasse. A Figura 5a apresenta uma função de pertinência para o atributo de textura *GLCM* Dissimilaridade (*quick 8/11*), aplicado à banda infravermelho próximo em todas as direções. Essa função tem como limites os valores 9 e 10,

sendo que os valores abaixo de nove não representam a subclasse e os acima de 10 representam totalmente, enquanto os valores intermediários apresentam diferentes probabilidades de pertinência conforme definido pela curva. A Figura 5b apresenta uma função de pertinência para o atributo da média da banda PC3, com intervalo fixo de pertinência entre 30 e 70.

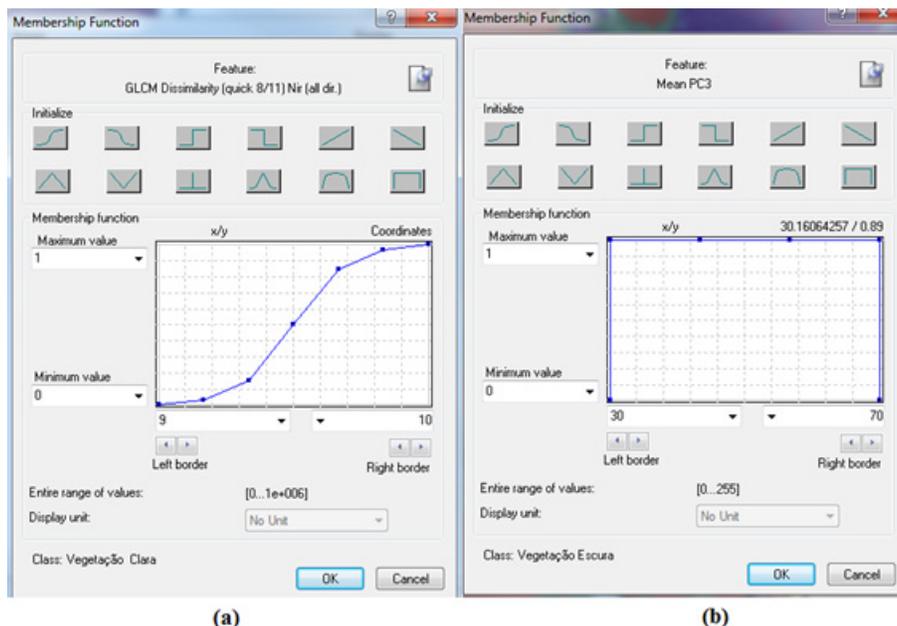


Figura 5. Telas do programa eCognition Developer 9.2 (TRIMBLE, 2017) mostrando exemplos de funções de pertinência.

A fim de auxiliar na classificação da imagem, foram inseridas quatro bandas derivadas do processamento dos principais componentes (PC) das bandas multiespectrais originais, e obtidos atributos derivados desses PC para análise. Segundo Novo (2010), a transformações por PC é uma técnica de realce feita a partir do cálculo da matriz de covariância entre as bandas. Por meio dessa matriz, é possível gerar novas bandas, tal que o valor de nível digital é a combinação linear dos valores de todas as bandas que contribuem para aquele eixo. Dessa forma, o número de PC é igual ao número de bandas, sendo que cada componente está associado a uma dada variância dos níveis digitais, onde o primeiro componente tem a maior variância, sendo reduzido sucessivamente. Os PCs foram obtidos utilizando o programa ENVI 5.3 (Harris Corp, Bloom-field, CO).

Estruturação da Árvore de Processos, Classificação e Agrupamento das Subclasses

A construção de uma rede semântica se baseia na análise de atributos e definição de um grupo de regras (algoritmos baseados nas funções de pertinência), organizadas em uma sequência para ser aplicada sobre o conjunto de objetos obtidos pela segmentação visando discriminar a classe correspondente. A execução de um algoritmo representa um único processo, ou seja, um conjunto de regras que fornece uma solução para um problema específico da análise da imagem. Um conjunto de regras é uma sequência de processos que são executados em uma ordem definida. A sequência de processos estabelecida para a classificação é denominada árvore de processos (*tree process*).

A árvore de processos elaborada permitiu a realização dos procedimentos em etapas. A cada etapa, uma subclasse foi analisada, e os objetos que pertenciam a ela foram classificados. Na etapa subsequente, a análise e a classificação da subclasse seguinte foram realizadas considerando apenas o conjunto de objetos ainda não classificados nas etapas anteriores. Ao final da classificação, as subclasses foram agrupadas em suas respectivas classes, utilizando-se a ferramenta “*Class Hierarchy*”, que possibilitou o agrupamento das subclasses em uma estrutura hierárquica.

Análise do Resultado da Classificação

Ao longo do processo, os resultados preliminares foram analisados visualmente para verificação da qualidade da classificação, considerando o conhecimento existente sobre o uso e cobertura da terra da área de estudo. O desempenho da classificação final foi analisado comparando-o a dados de referência obtidos em campo em agosto de 2013, verificando a relação da área classificada com a área de referência, ou seja, observando a correspondência das classes geradas na classificação às classes observadas em campo. A diferença entre as datas da imagem e o trabalho de campo ocorreu porque não foi possível obter imagem com data mais próxima ao trabalho realizado em campo. Embora alterações possam ocorrer ao longo desse período, pelo que conhecemos da área, seu uso não sofre muitas alterações. Sendo essa a melhor referência que temos disponível, que pode indicar eventuais erros, decidiu-se utilizá-la com esse fim, e não

para estabelecer a exatidão de mapeamento ou outras medidas estatísticas com rigor. Os dados de campo foram classificados de acordo com o uso e cobertura da terra, sendo identificadas as áreas de reflorestamento com eucalipto, pastagem, floresta (representando diversos estádios de sucessão), solo exposto e os tipos de culturas agrícolas presentes, incluindo sistemas diversificados como os sistemas agroflorestais. Esses dados foram agrupados nas seguintes categorias a fim de estabelecer uma relação com as classes utilizadas na classificação: cultura anual, cultura perene, reflorestamento de eucalipto, pastagem, solo exposto, sistema agroflorestal, floresta e outras áreas antrópicas. As classes Água e Sombra não foram comparadas porque não havia dados de campo sobre essas classes.

O agrupamento foi necessário porque a identificação dos diferentes tipos de uso e cobertura da terra na imagem possibilitou um nível de detalhamento diferente do realizado em campo. As classes e subclasses utilizadas neste trabalho foram escolhidas de maneira que fosse possível identificá-las na imagem, de acordo com as resoluções espacial, temporal e espectral disponíveis. Dessa forma, a legenda escolhida foi generalizada e aplicada a toda a imagem. Por outro lado, os dados de campo permitiram especificar, para alguns pontos visitados, o uso da terra e detalhar o tipo de cultura.

Foi utilizado o programa ArcGis 10 (ESRI) para sobrepor a classificação realizada aos dados de campo, que compreendem um plano de informação (PI) contendo polígonos das áreas identificadas visitadas e classificadas. Embora a amostragem não seja aleatória nem distribuída por toda a área de estudo para a realização de uma análise sem viés, os dados de campo foram usados como uma referência para uma análise preliminar dos acertos e erros da classificação. Seu uso justifica-se pela qualidade, apresentando um fiel retrato da realidade. Ao final, foi realizada a comparação pixel a pixel de 35 áreas e gerada uma matriz com os resultados.

Resultados e Discussão

Na etapa de segmentação, os resultados foram avaliados visualmente e foi selecionado o que melhor delimitou as áreas consideradas homogêneas (Figura 6). A melhor segmentação foi a realizada a partir das bandas originais das faixas do azul, verde, vermelho e infravermelho, aplicando-se escala = 30, forma = 0,3, cor = 0,7, compacidade = 0,5 e suavidade = 0,5.

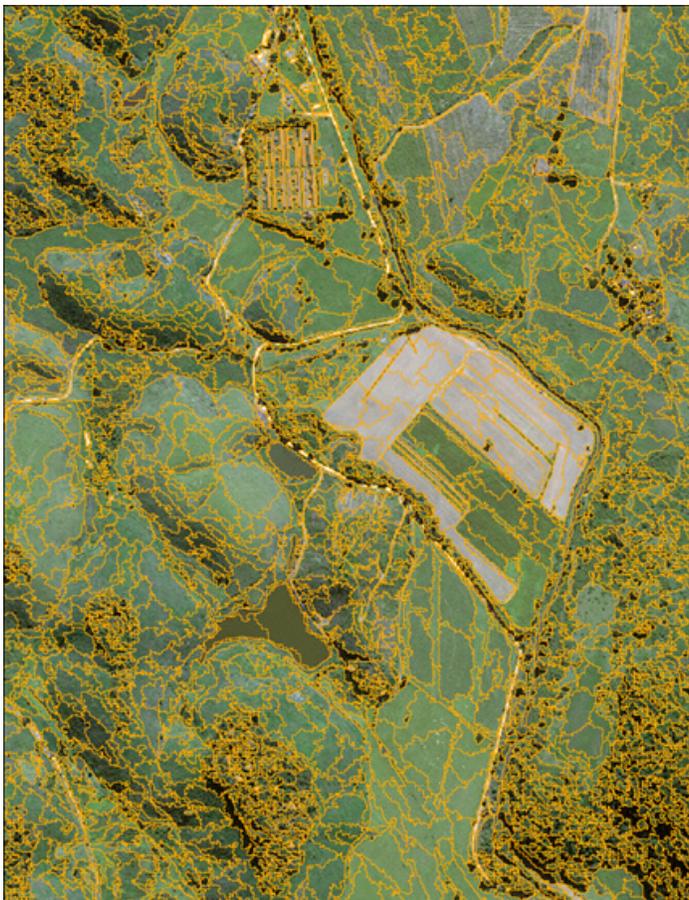


Figura 6. Resultado da segmentação da imagem WorldView 2, da Digital Globe.

Os atributos selecionados e utilizados para a classificação das subclasses são apresentados na Tabela 3.

Tabela 3. Atributos utilizados para a classificação de cada subclasse.

Subclasses	Atributos					
	Média	Menor Valor	NDVI*	Brilho	GLCM Dis-similaridade (quick 8/11) aplicado a	GLCM Média (quick 8/11) aplicado a
Água clara	PC2 e PC3	NIR	X	-	-	-
Água escura	PC2 e PC3	NIR	-	-	-	-
Solo exposto 1,2, 3, 4, 5, 6	PC3	-	X	X	-	-
Solo exposto encharcado	PC3	-	X	X	-	-
Estradas	PC3	-	X	-	Todas as bandas	-
Sombra 1	PC3 e PC2	-	-	X	-	-
Sombra 2	-	-	X	X	Banda NIR	-
Floresta 1	PC4	-	-	-	-	Banda do Vermelho
Floresta clara	PC4	-	X	-	Banda NIR	Banda PC3
Floresta escura	PC3	-	-	-	Banda NIR	Banda PC3
Vegetação arbustiva	-	-	-	-	Banda NIR	Banda PC3 e NIR
Área antrópica agrícola 1	-	-	-	X	-	Banda PC3
Área antrópica agrícola 2	PC3	-	-	-	Banda NIR	-
Área antrópica agrícola 3	-	-	X	-	Banda NIR	Banda PC3

* Índice de Vegetação por Diferença Normalizada (IVDN, ou NDVI, como é comumente utilizado) é a razão entre a diferença entre os valores das bandas do infravermelho próximo (NIR) e do vermelho (R), e a soma das bandas, ou seja, $NDVI = (NIR - R) / (NIR + R)$. Os valores computados variam de -1 a +1. (Meneses; Almeida, 2012).

O uso dos principais componentes 2, 3 e 4 mostrou-se eficaz para auxiliar na classificação da imagem. Pode-se dar destaque ao PC3, pela identificação da classe Solo exposto, como verificado no estudo realizado por Castro et al. (2017), bem como por ter sido utilizada ao menos uma vez, considerando-se seus valores de média ou textura GLCM, para descrever as subclasses, exceto Sombra 2 e Floresta 1.

O Índice de Vegetação por Diferença Normalizada (IVDN, ou NDVI, como é comumente utilizado) contribuiu para a identificação de 7 das 14 subclasses.

Os atributos de textura GLCM Média (*quick 8/11*) e GLCM Dissimilaridade (*quick 8/11*) aplicados a diversas bandas da imagem foram importantes para diferenciar as classes Floresta e Vegetação arbustiva, bem como as classes Vegetação arbustiva e Área antrópica agrícola, evidenciando que os atributos de textura propostos por Haralick et al. (1973) fornecem importantes informações para a classificação de imagens.

Os atributos de geometria não apresentaram bons resultados, pois a escala da segmentação, embora delimitasse bem os objetos conforme as classes definidas, resultou em formas irregulares, sem padrões que pudessem ser descritos por esses atributos.

Cada linha da árvore de processos (Figura 7) descreve uma etapa do processo de classificação, que ocorreu de maneira sequencial, considerando as funções de pertinência dos atributos de cada subclasse. As primeiras subclasses classificadas foram as que apresentaram a resposta espectral mais uniforme e, por isso, estão localizadas no topo da árvore. Conforme indicado no início de cada linha, toda a classificação foi realizada no “Level 1”, que corresponde ao único nível de segmentação realizado neste trabalho.



Figura 7. Cópia da tela do programa eCognition Developer 9.2 (TRIMBLE, 2017) mostrando a árvore de processos empregada na classificação.

Para ilustrar o resultado da classificação, na Figura 8, é apresentado um detalhe da área de estudo classificada ao lado da composição colorida da imagem utilizada. Na Figura 9, a classificação do uso e cobertura da terra da área de estudo é apresentada, sendo possível verificar o predomínio da classe Área antrópica agrícola.

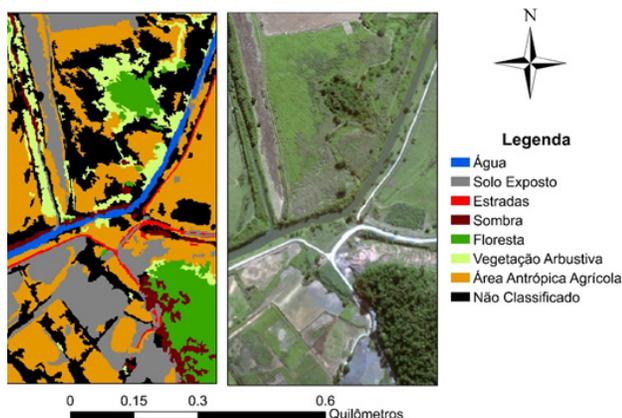


Figura 8. Parte da área do Assentamento São José da Boa Morte representada pela imagem classificada e a composição colorida das bandas do sensor WorldView-2, de 01 de julho de 2012.

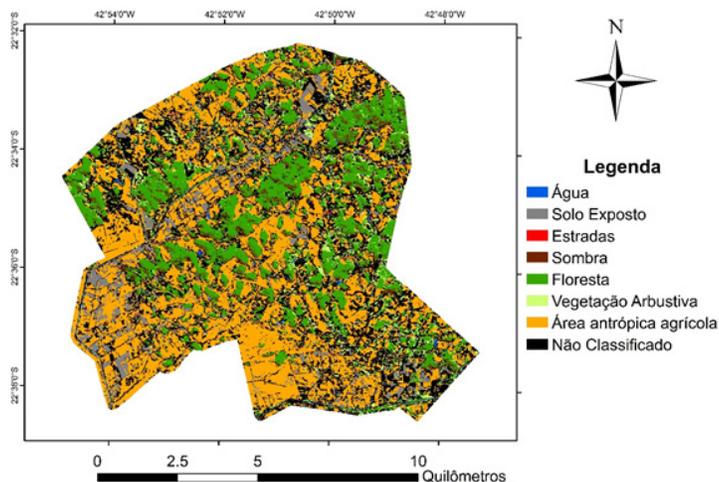


Figura 9. Classificação do uso e cobertura da terra do Assentamento São José da Boa Morte. Projeção UTM fuso 23 Sul com referencial geodésico WGS-1984.

A distribuição das classes na área de estudo mostrou o predomínio de áreas classificadas como antropizadas na paisagem, apresentando 21% de áreas de floresta. A Área antrópica agrícola, que reúne pastagem e culturas anuais e permanentes, totalizou 41,2% da área do assentamento. As áreas não classificadas totalizaram 19,4%, mostrando que o conjunto de classes e regras estabelecidos não foram suficientes para discriminar todos os objetos da imagem (Tabela 4).

Tabela 4. Área de cada classe e dos objetos não classificados.

Classe	Área (ha)	%
Água	59,53	0,6
Área antrópica agrícola	4.212,19	41,2
Estradas	80,46	0,8
Solo exposto	606,54	5,9
Sombra	464,78	4,5
Floresta	2.142,49	21,0
Vegetação arbustiva	672,28	6,6
Não classificado	1.984,05	19,4
Total	10.222,31	100,0

Uma análise visual das áreas não classificadas permitiu identificar que parte delas pertence às classes Vegetação arbustiva e Área antrópica agrícola. A classificação desses objetos requer, portanto, a seleção de amostras e de atributos representativos de suas classes ou subclasses.

Áreas com cobertura sazonal, como as áreas de culturas anuais, poderiam ser mais bem classificadas com emprego de análise de imagens de outros períodos ao longo do ano. Devido ao uso de imagem de apenas um período do ano, parte das áreas de culturas agrícolas que estava em período de descanso ou de preparo do solo pode ter sido classificada como Solo exposto.

Área de cultivo de espécies arbóreas e arbustivas, como eucalipto e goiaba, não puderam ser corretamente classificadas utilizando o procedimento adotado neste trabalho, pois os atributos não permitiram sua diferenciação de outras classes, como Floresta e Vegetação arbustiva.

Na matriz de comparação entre os dados de campo (referência) e a classificação gerada (Tabela 5), pode ser observada a razão, em percentagem, entre o número de pixels classificado e o número de pixels das amostras de campo de cada classe (referência).

Tabela 5. Matriz de comparação entre a classificação e os dados de campo.

Referência	Classificação					Total (%)
	Área antrópica agrícola (%)	Vegetação arbustiva (%)	Floresta (%)	Solo exposto (%)	Não classificado (%)	
Cultura anual	67,7	1,5	0,2	19,5	9,3	100
Cultura perene	28,7	16,0	4,1	8,5	42,3	100
Pastagem	87,0	0,8	0,4	2,1	9,6	100
Floresta	6,9	5,4	71,1	0,0	14,2	100
Solo exposto	23,3	0,0	0,0	71,7	3,9	100
Sistema agroflorestal	37,5	16,7	0,0	0,0	37,5	100
Reflorestamento de eucalipto	5,4	3,5	61,8	2,0	24,9	100
Outras áreas antrópicas	52,8	3,7	0,3	14,7	26,1	100

Na análise da tabela, que se restringe às áreas onde havia informações de campo, observa-se que a classe Área antrópica agrícola foi classificada em todas as categorias do dado de campo, mostrando sua heterogeneidade por ser uma classe que englobava pastagem e áreas de cultivo. A Cultura perene teve 16% de sua área classificada como Vegetação arbustiva, provavelmente devido à resposta espectral similar entre Vegetação arbustiva e Cultura perene, por exemplo, o cultivo de goiaba.

As áreas de Floresta observadas em campo foram, em sua maioria (71,1%), classificadas como Floresta. No entanto, a maioria das áreas de Reflorestamento de eucalipto foi classificada erroneamente como Floresta (61,8%). As áreas de Solo exposto foram classificadas predominantemente como solo exposto (71,7%), porém parte do solo exposto observado em campo foi classificado como Área antrópica, bem como parte das áreas de Cultura anual foi classificada como solo exposto. Essa confusão entre as classes pode ser devida à diferença de datas entre a imagem utilizada e o trabalho de campo e à alta sazonalidade das áreas de culturas anuais, que ficam temporariamente sem cobertura vegetal para renovação ou preparo do solo.

Considerando que a utilização de imagens de sensoriamento remoto para o mapeamento de culturas agrícolas se baseia no fato de que diferentes

coberturas apresentam padrões espectro-temporais distintos (Gleriani et al., 2005), entende-se que a delimitação e classificação de áreas agrícolas poderia ter maior nível de acerto se fossem disponibilizadas informações obtidas em séries temporais de imagens orbitais.

A Pastagem observada em campo apresentou 87% da área classificada como Área antrópica agrícola. Por outro lado, as áreas de Cultura perene observadas em campo, em sua maioria, não foram classificadas (42,3%). Dentre as áreas de Sistema agroflorestal, 37,5% foram classificadas corretamente como área antrópica agrícola, e 37,5% não foram classificadas. O baixo nível de acerto na classificação dessas duas últimas classes pode ser atribuído à heterogeneidade dos seus padrões, demonstrando a necessidade de selecionar descritores que as definam e as diferenciem das demais classes. Era esperada a confusão entre as classes que apresentam padrões heterogêneos e com semelhanças entre si, por exemplo, sistema agroflorestal, floresta e alguns tipos de cultura permanente, causando ainda lacunas na classificação. Esse tipo de resultado também é observado em outros trabalhos que empregaram a classificação orientada a objetos em imagem de uma única data (Marujo et al., 2013).

Considerações Finais

A metodologia empregada permitiu a delimitação das classes de uso e cobertura da terra definidas. Porém, 20% da área total não foi classificada, indicando que os atributos selecionados e as funções de pertinência não puderam englobar todas as respostas espectrais, texturais e geométricas presentes na imagem. Observa-se a necessidade de refinar a classificação a partir da identificação dos objetos não classificados e prever novos procedimentos para seu melhor desempenho, como definição de novas subclasses, identificação de atributos, ajuste nas funções de pertinência. Outra solução para a identificação desses objetos não classificados pode ser o emprego de mineração de dados, a fim de apoiar a seleção dos atributos e os limites das funções de pertinência.

A determinação de uma rede semântica de forma heurística necessita de tempo e conhecimento do intérprete. O emprego dessa metodologia requer que o operador tenha afinidade com o programa utilizado, bem como o conhecimento do comportamento dos atributos para fazer o devido uso das ferra-

mentas disponíveis, a fim de melhorar o processo de classificação. O conhecimento prévio da área estudada também se mostrou de grande importância para o resultado, facilitando a escolha das amostras e também as análises visuais realizadas para definir as funções de pertinência e seus limiares.

Para auxiliar na delimitação e classificação de áreas agrícolas, sugerem-se utilizar, de forma complementar a este trabalho, informações obtidas em séries temporais de imagens orbitais.

Agradecimentos

Este trabalho foi desenvolvido no âmbito do Projeto “Monitoramento participativo da resiliência de uma paisagem agrícola e o papel de práticas agroecológicas na conservação da biodiversidade”, financiado pela Embrapa, pelo qual foram adquiridas as imagens utilizadas e obtidas as informações de campo. Os autores agradecem ao Programa de Iniciação Científica Pibic/CNPq, pela bolsa oferecida à Teule Lemos Branco no período de agosto de 2016 até julho de 2017, e à Embrapa Solos pela infraestrutura disponibilizada para a realização do trabalho.

Referências

- ABREU, M. B. **Uso e cobertura da terra do Assentamento Rural São José da Boa Morte, Cachoeiras de Macacu – RJ**. 2007. 32 f. Monografia (Bacharelado em Geografia) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ.
- ALMEIDA FILHO, R.; NASCIMENTO, P. S. R.; BATISTA, G. T. Avaliação de técnicas de segmentação e classificação automática de imagens LANDSAT-TM no mapeamento do uso do solo na Amazônia. **Acta Amazonica**, v. 28, n. 1, p. 41-54, 1998.
- ANDERSON, J. R.; HARDY, E. E.; ROACH, J. T.; WITMER, R. E. **A land use and land cover classification system for use with remote sensor data**. Washington: US Government Printing Office, 1976. Disponível em: <<https://pubs.er.usgs.gov/publication/pp964>>. Acesso em: 06 nov. 2017.
- ARVOR, D.; SAINT-GEOURS, N.; DUPUY, S.; ANDRÉS, S.; DURIEUX, L. Identifying optimal classification rules for geographic object-based image analysis. In: Simpósio Brasileiro de Sensoriamento Remoto, 16, 2013, Foz do Iguaçu. **Anais...** São José dos Campos, SP: INPE, 2013. p. 2290 - 2297. Disponível em: <<https://hal.archives-ouvertes.fr/hal-00828025/document>>. Acesso em: 06 nov. 2017.

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: STROBL, J.; BLASCHKE, T.; GRIESEBNER, G. (Ed.). **Angewandte Geographische Informations Verarbeitung**. Heidelberg: Wichmann-Verlag, 2000. p. 12-23. Disponível em: <http://www.ecognition.com/sites/default/files/405_baatz_fp_12.pdf>. Acesso em: 20 nov. 2017.

BENZ, U. C.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I.; HEYNEN, M. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 58, n. 3, p. 239–258, 2004. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0924271603000601>>. Acesso em: 06 nov. 2017.

BLASCHKE, T.; HAY, G. J.; MAGGI, K.; LANG, S.; HOFMANN, P.; ADDINK, E.; FEITOSA, R. Q.; MEER, F. van der; WERFF, H. van der; COILLIE, F. van; TIEDE, D. Geographic object-based image analysis - towards a new paradigm. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 180–191, 2014. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0924271613002220>>. Acesso em: 06 nov. 2017.

CASTILLA, G.; HAY, G. J. Image objects and geographic objects. In: BLASCHKE, T.; LANG, S.; HAY, G. J. (Ed.). **Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 91–110.

CASTRO, L. F.; FIDALGO, E. C. C.; PRADO, R. B. Análise orientada a objetos aplicada a imagem de alta resolução para identificação de solo exposto em ambiente montanhoso de Mata Atlântica. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18., 2017, Santos, SP. **Anais...** [São José dos Campos, SP]. Disponível em: <<http://urlib.net/8JMKD3MGP6W34M/3PS4GRG>>. Acesso em: 06 jun. 2017.

FIDALGO, E. C.; PEDREIRA, B.; ABREU, M. B.; DE MOURA, I. B.; GODOY, M. D. P. **Uso e cobertura da terra na bacia hidrográfica do Rio Guapi-Macacu**. Rio de Janeiro, RJ: Embrapa Solos, 2008. 31 p. (Embrapa Solos. Documentos, 105). Disponível em: <http://ainfo.cnptia.embrapa.br/digital/bitstream/CNPS-2009-09/14026/1/doc105_208_guapi_macacu.pdf>. Acesso em: 06 nov. 2017.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote sensing of environment**, v. 80, n. 1, p. 185–201, 2002. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0034425701002954>>. Acesso em: 06 nov. 2017.

FRANCISCO, C. N.; ALMEIDA, C. Avaliação de desempenho de atributos estatísticos e texturais em uma classificação de cobertura da terra baseada em objeto. **Boletim de Ciências Geodésicas**, v. 18, n. 2, 2012. Disponível em: <<http://www.scielo.br/pdf/bcg/v18n2/08.pdf>>. Acesso em: 06 nov. 2017.

GAO, Y.; MAS, J. F. A comparison of the performance of pixel-based and object-based classifications over images with various spatial resolutions. **Online Journal of Earth Sciences**, v. 2, n. 1, p. 27–35, 2008. Disponível em: <<http://docsdrive.com/pdfs/medwelljournals/ojesci/2008/27-35.pdf>>. Acesso em: 06 nov. 2017.

GLERIANI, J. M.; EPIPHANIO, J. C. N.; SILVA, J. D. S. Classificação espectral-temporal de culturas agrícolas tropicais: tolerância de dois modelos de redes neurais a dados falhos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12, 2005, Goiânia, GO. **Anais...** São José dos Campos, SP: INPE, 2005. p. 151-158.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 3, n. 6, p. 610–621, 1973. Disponível em: <<http://haralick.org/journals/TexturalFeatures.pdf>>. Acesso em: 06 nov. 2017.

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.** Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 75–89.

HAY, G. J.; MARCEAU, D. J.; DUBÉ, P.; BOUCHARD, A. A multiscale framework for landscape analysis: object-specific analysis and upscaling. **Landscape Ecology**, v. 16, n. 6, p. 471–490, 2001. Disponível em: <http://people.ucalgary.ca/~gjhay/PDFs/Peer_reviewed/2002%20Hay_LSE_Full.pdf>. Acesso em: 06 nov. 2017.

IBGE. **Manual técnico de uso da terra.** 3. ed. Rio de Janeiro, RJ: IBGE, 2013. (IBGE. Manuais técnicos em Geociências, 7). Disponível em: <<https://biblioteca.ibge.gov.br/visualizacao/livros/liv81615.pdf>>. Acesso em: 05 abr. 2017.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos naturais.** São José dos Campos, SP: Parêntese, 2009.

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.** Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 3–27.

MARUJO, R. F. B.; VOLPATO, M. M. L.; VIEIRA, T. G. C.; ALVES, H. M. R.; RIBEIRO, M. B. P. Classificação orientada a objetos aplicada a cultivos cafeeiros em Três Pontas, MG. In: SIMPOSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu, PR. **Anais...** São José dos Campos, SP: INPE, 2013. p. 1338-1345.

MENESES, P. R.; ALMEIDA, T. (Org.). **Introdução ao processamento de imagens de sensoriamento remoto.** Brasília, DF: UNB, 2012. 266 p. Disponível em <<http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>>. Acesso em: 08 de nov. 2017.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação.** 2. ed. Viçosa, MG: UFV, 2003. 314 p.

NAVALUR, K. **Multispectral image analysis using the object-oriented paradigm.** Florida, EUA: CRC Press, 2006. Disponível em: <[ftp://nozdr.ru/biblio/kolxo3/Cs/Cslp/Navalur%20K.%20Multispectral%20image%20analysis%20using%20the%20object-oriented%20paradigm%20\(CRC.%202007\)\(ISBN%201420043064\)\(206s\)_Cslp_.pdf](ftp://nozdr.ru/biblio/kolxo3/Cs/Cslp/Navalur%20K.%20Multispectral%20image%20analysis%20using%20the%20object-oriented%20paradigm%20(CRC.%202007)(ISBN%201420043064)(206s)_Cslp_.pdf)>. Acesso em: 06 de nov. 2017.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações.** 4. ed. São Paulo, SP: Bucher, 2010.

PEDREIRA, B. C. C.; FIDALGO, E. C. C. F.; UZEDA, M. C.; COSTA, M. D. **Áreas prioritárias para recuperação na região da bacia hidrográfica do Rio Guapi-Macacu, RJ.** Rio de Janeiro, RJ: Embrapa Solos, 2011. 45 p. (Embrapa Solos. Boletim de Pesquisa e Desenvolvimento, 191). Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/77820/1/BPD-191-Recuperacao-Guapi.pdf>>. Acesso em: 04 nov. 2017.

ROLIM, F. A. **Classificação orientada a objeto em imagens de alta resolução para auxílio ao monitoramento ambiental em uma microbacia hidrográfica.** 2003. 107 p. Dissertação (Mestrado em Ciências Florestais) - Universidade Federal do Paraná, Paraná, PR.

TRIMBLE. **ECognition Developer 9.2:** reference book. Munich: TRIMBLE Germany GmbH, 2016.

TRIMBLE. **ECognition.** 2017. Disponível em: <<http://www.ecognition.com/>>. Acesso em: 25 de nov. 2017.

ZHONG, C.; ZHONGMIN, Z.; DONGMEI, Y.; RENXI, C. Multi-scale segmentation of the high resolution remote sensing image. In: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2005. Seoul, Coréia do Sul. **Anais...** Seoul: IEEE, 2005. Disponível em: <<http://www.ecognition.com/document/multi-scale-segmentation-high-resolution-remote-sensing-image>>. Acesso em: 04 abr. 2017.

Literatura Recomendada

VIANA, V. M.; PINHEIRO, L. A. F. V. Conservação da biodiversidade em fragmentos florestais. **Série Técnica IPEF**, v. 12, n. 32, p. 25–42, 1998. Disponível em: <<http://www.ipef.br/publicacoes/tecnica/nr32/cap03.pdf>>. Acesso em: 04 de abr. 2017.