

ANÁLISE DE IMAGEM BASEADA EM OBJETO PARA CLASSIFICAÇÃO DAS FISIONOMIAS DA VEGETAÇÃO EM IMAGENS DE ALTA RESOLUÇÃO ESPACIAL

Luiz Felipe de Almeida FURTADO¹, Cristiane Nunes FRANCISCO², Cláudia Maria de ALMEIDA¹

(1) Divisão de Sensoriamento Remoto - DSR, Instituto Nacional de Pesquisas Espaciais / INPE. Av. dos Astronautas, Caixa Postal 515. CEP 12245-970. São José dos Campos, SP. Endereço eletrônico: {luizfelipe, almeida}@dsr.inpe.br

(2) Instituto de Geociências, Departamento de Análise Geoambiental, Universidade Federal Fluminense / UFF. Campus da Praia Vermelha – Boa Viagem. CEP 24210-310. Niterói, RJ. Endereço eletrônico: crisnf@vm.uff.br

Introdução
Material e Métodos
 Processamento dos dados
 Classificação da fisionomia da vegetação por OBIA
 Avaliação da acurácia da classificação de cobertura da terra
Resultados e Discussão
Conclusões
Agradecimentos
Referências Bibliográficas

RESUMO – Este artigo tem como objetivo avaliar o desempenho da análise de imagem baseada em objeto (*Object-Based Image Analysis* - OBIA) na discriminação de fisionomias da vegetação em imagem de altíssima resolução espacial. A área de estudo, com 16 km², está localizada em Nova Friburgo, região serrana do estado do Rio de Janeiro. A rede semântica, gerada de modo heurístico, foi composta por descritores espectrais, texturais e topológicos extraídos das imagens *QuickBird-2* e de Modelos Digitais de Elevação (MDE) originários de levantamento aerofotogramétrico. Foram utilizadas quatro classes para o mapeamento da fisionomia: gramínea rala, gramínea, herbácea-arbustiva e arbórea. O índice *Kappa* alcançado na classificação foi de 0,73, considerado de muito boa qualidade quanto à acurácia. Todas as classes obtiveram valor de *Kappa* condicional acima de 0,5, sendo que o melhor desempenho coube à classe gramínea rala, por apresentar resposta espectral distinta das outras classes de vegetação.

Palavras-chave: sensoriamento remoto, classificação de vegetação, análise de imagem baseada em objeto (OBIA).

ABSTRACT – L.F.A. Furtado, C.N. Francisco, C.M. Almeida - *Object-based image analysis for vegetation physiognomies classification in high spatial resolution images*. This paper aims to evaluate the performance of object-based image analysis (OBIA) to discriminate vegetation physiognomies using high spatial resolution images. The study area, with 16 km², is located in Nova Friburgo county, in the mountainous region of Rio de Janeiro state. The heuristically generated semantic network, was composed of spectral, textural, and topological attributes extracted from *QuickBird-2* images and Digital Elevation Models (DEM) derived from an aerophotogrammetric survey. Four classes were adopted for mapping the vegetation physiognomies: sparse grasslands, grasslands, shrub-herbaceous vegetation, and forest. The Kappa index obtained in the classification was 0.73, indicating a good accuracy. All classes obtained conditional Kappa above 0.5. The sparse grasslands class achieved the best performance, because its spectral behavior is very dissimilar in relation to the one observed for the remaining vegetation classes.

Keywords: remote sensing, vegetation classification, object based image analysis (OBIA)

INTRODUÇÃO

O mapeamento da vegetação combina o uso de documentos cartográficos e imagens de sensoriamento remoto (SR) juntamente com a realização de trabalhos de campo. As imagens podem ser interpretadas visualmente ou a partir da aplicação de técnicas de processamento digital de imagens. O método visual consiste na interpretação direta do usuário, baseado em elementos de reconhecimento, como cor, forma, textura, entre outros, que examinados em conjunto pelo intérprete possibilitam a identificação dos alvos.

No mapeamento por processamento digital, algoritmos computacionais são utilizados na identificação automática dos alvos baseados em

classificadores pixel a pixel ou por regiões. A classificação pixel a pixel pode ser executada de modo não-supervisionado ou supervisionado. No não-supervisionado, a classificação é feita utilizando métodos estatísticos de análise de agrupamento e, durante o procedimento, não há intervenção direta do usuário na definição das classes pertinentes à cena. O modo supervisionado, por sua vez, é baseado na coleta de amostras, denominadas como áreas de treinamento, referentes a classes definidas pelo usuário. Os algoritmos de classificação, determinísticos ou probabilísticos, utilizam-se das amostras, geradas pelo usuário, para rotular os pixels

como pertencente a uma determinada classe (Novo, 2011).

A classificação por regiões é executada em duas etapas: a segmentação da imagem e a classificação propriamente dita. Segmentar uma imagem consiste em determinar agrupamentos de pixels adjacentes, similares entre si, através de algoritmos de agrupamentos de dados que examinam a textura e a resposta espectral dos pixels adjacentes e, em alguns casos, a forma do objeto. Após a segmentação, a classificação é executada de modo não supervisionado ou supervisionado, de maneira semelhante aos métodos pixel a pixel, considerando somente a resposta espectral dos alvos.

A diferença, assim, entre as duas metodologias de classificação consiste no tratamento dado ao pixel. Enquanto na pixel a pixel, estes são avaliados isoladamente, a classificação por regiões avalia os segmentos, ou seja, pixels agrupados em compartimentos homogêneos da cena. O segmento corresponde a uma região discreta de uma imagem que é internamente coerente e diferente do seu entorno (Castilla & Hay, 2008).

A década de 2000 é marcada pelo lançamento de satélites com sensores capacitados à aquisição de dados de alta a altíssima resolução espacial (Jensen, 2009). Como os pixels passam a apresentar resolução submétrica, os métodos de classificação tradicionais, quando aplicados a essas imagens, não resultam em produtos de acurácia aceitável. Desta forma, metodologias de análise de imagens baseada em objeto (*Object-Based Image Analysis* – OBIA) são pesquisadas e disseminadas a partir da sua incorporação a sistemas comerciais, com destaque para o eCognition (Blaschke, 2009). Desde então, ampliou-se o acesso a essa inovação conceitual e tecnológica, até então restrita exclusivamente à comunidade científica (Castilla & Hay, 2008).

Diferentemente dos classificadores tradicionais, que apenas utilizam a resposta espectral, a OBIA possibilita a construção de um modelo de conhecimento que é responsável por armazenar o conhecimento do intérprete sobre a área de estudo e com base na qual os objetos são classificados.

A OBIA consiste também em duas etapas (segmentação e classificação), porém nesta nova metodologia para interpretação de imagens, o segmento passa a ser denominado

como objeto, em vista da incorporação de preceitos do paradigma de Orientação a Objeto (Dall’Oglio, 2009). Após a segmentação, segue-se a fase de criação do modelo de conhecimento baseado em objeto, estruturado em uma rede semântica hierárquica. Como as imagens estão estruturadas em objetos, é possível extrair atributos (ou descritores) como textura, forma, relações topológicas, relação hierárquica entre os níveis de segmentação, entre outros, aproximando-se dos processos cognitivos humanos de interpretação de imagens (Navulur, 2007; Camargo et al., 2009).

Alguns dos fatores que limitam o mapeamento de vegetação, a partir de dados de SR, são inerentes à própria vegetação, como a estrutura física, o arranjo espacial dos indivíduos e a arquitetura de dossel. Fatores biofísicos da vegetação também influenciam no comportamento espectral da vegetação, bem como a quantidade de umidade presente nas folhas das plantas, a idade da vegetação e a orientação da encosta onde se localiza (Ponzoni & Shimabukuro, 2010). Por outro lado, a relação entre aspectos do relevo e a vegetação pode e deve ser explorada como dado auxiliar para o seu mapeamento (Corradini et al., 2008).

No caso das florestas tropicais, a elevada complexidade estrutural, devido ao elevado número de espécies com dossel volumoso e irregularmente estratificado, bem como a distribuição aleatória dos indivíduos aumentam a complexidade das respostas espectrais, o que acarreta na dificuldade em discriminar a vegetação de acordo com a sua fisionomia (Albuquerque et al., 2011).

Outras limitações são relativas às características dos produtos de SR. Nas imagens de altíssima resolução espacial, especificamente, há uma grande heterogeneidade das respostas espectrais nos dosséis. Como os pixels apresentam resolução submétrica, os alvos são representados por um conjunto de elementos, fazendo com que eles representem apenas uma pequena porção descontextualizada do alvo na cena (Blaschke, 2009). Uma árvore, por exemplo, é representada por um conjunto de pixels que corresponde a parcelas menores que o alvo com uma grande variação de respostas espectrais. Além da heterogeneidade da resposta, que se traduz na imagem em uma superfície muito

rugosa, os fatores que determinam a presença de sombra são potencializados (Gao & Mas, 2008). As sombras estão presentes no próprio indivíduo, no dossel, nas regiões com relevos acidentados e nas encostas sem ou com reduzida iluminação.

Por conta dessas características, os métodos de classificação pixel a pixel, quando aplicados a imagens de altíssima resolução, onde apenas a resposta espectral de cada pixel é analisada de maneira individualizada, apresentam menor acurácia, além de resultarem em uma imagem ruidosa, com a aparência salpicada de pixels isolados fora de contexto (Gao & Mas, 2008). Blaschke (2009) mostra que a aplicação de OBIA na classificação de imagens apresenta avanços tanto na classificação de fisionomias de vegetação quanto na extração de informações quantitativas sobre a vegetação.

Desta forma, o presente trabalho tem como objetivo avaliar, através de índices de acurácia,

o desempenho de OBIA na discriminação da fisionomia da vegetação em imagem de altíssima resolução espacial. Como os estágios sucessionais da vegetação devem ser determinados também em função de índices biofísicos, como diâmetro da altura do peito (DAP) e índice de área foliar (IAF), e de informações sobre a composição florística, optou-se por classificar as fisionomias da vegetação, que correspondem, de acordo com Metzger (2001), à forma da vegetação e de seu estrato - herbáceas, arbustos e árvores, a seu grau de perturbação antrópica, ou à combinação destes.

A área de estudo compreende um recorte de uma cena *QuickBird-2* com aproximadamente 16 km², localizada no município de Nova Friburgo, na região serrana do estado do Rio de Janeiro (Figura 1), com a presença de fisionomias vegetais diversas em diferentes níveis de intervenção antrópica.

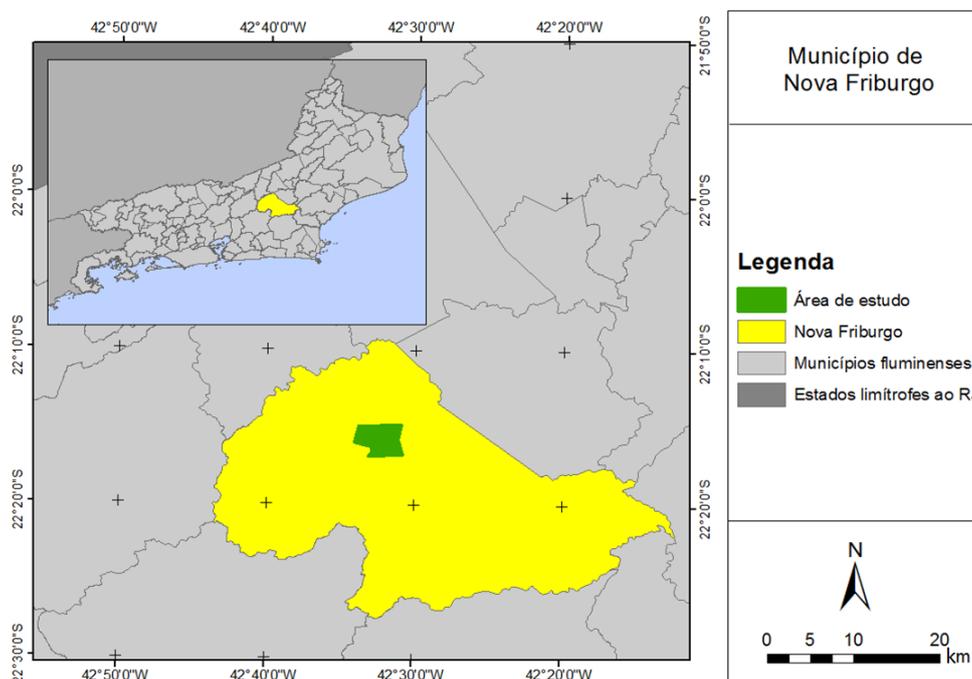


Figura 1. Localização da área de estudo.

MATERIAL E MÉTODOS

Para o mapeamento da fisionomia da vegetação por OBIA, fez-se uso da plataforma Definiens Developer 7.04 (Definiens, 2007). Entre os algoritmos de segmentação nela contidos está o de multirresolução ou FNEA (*Fractal Net Evolution Approach*), enquanto os de classificação abrangem classificadores

baseados na regra do vizinho mais próximo e em lógica *fuzzy* ou nebulosa.

O algoritmo de segmentação multirresolução gera um nível de imagem com objetos criados a partir da fusão de pixels de acordo com critérios de homogeneidade (Baatz & Schäpe, 2000). Quando aplicado a um banco de dados com um

nível de segmentação existente, irá fundir objetos em superobjetos em níveis superiores, ou então, subdividi-los em subobjetos em níveis inferiores, em ambos os casos, respeitando as fronteiras dos níveis previamente existentes.

Os critérios de homogeneidade utilizados na segmentação multirresolução são estabelecidos a partir da combinação das propriedades espectrais (cor) e de forma dos pixels ou dos objetos. Os parâmetros cor e forma somam 1,0 e determinam, respectivamente, o quanto da informação de cor e forma é usada no processo de segmentação. O parâmetro forma é subdividido em compacidade e suavidade. Um alto valor de compacidade produz segmentos menores e mais compactos, tipicamente relativos a alvos antrópicos, como construções. Por outro lado, um alto valor de suavidade gera segmentos com bordas suaves, características de alvos naturais (Kressler & Steinnocher, 2006).

O parâmetro escala é um importante valor utilizado pelo algoritmo de segmentação multirresolução e determina a média do tamanho do objeto a ser criado. Quanto mais alto o valor atribuído ao parâmetro, maiores serão os objetos e, com isto, menor a quantidade de objetos criados.

Deve ser atribuído, ainda, peso às imagens de acordo com o seu grau de importância no processo de segmentação. O peso varia entre 0 e 1, e quanto maior o valor, maior o grau de importância conferida à respectiva imagem de entrada, sendo que o valor 0 implica a desconsideração da respectiva imagem no processo de segmentação.

Para a composição do banco de dados, foram utilizadas imagens de SR orbitais e dados de relevo. As imagens *QuickBird-2*, obtidas em julho de 2008, apresentam resolução espacial de 2,62 m no modo multiespectral, constituído por três bandas do visível e uma do infravermelho próximo, e foram fusionadas à pancromática com resolução espacial de 0,65 m. Os dados altimétricos foram obtidos nos Modelos Digitais de Elevação (MDE), com resolução de 20 m, do Projeto RJ-25 MDE, gerados por processamento fotogramétrico analítico a partir de fotografias aéreas com escala aproximada de 1:30.000 (IBGE, 2011). Com base nos modelos, foi gerada a grade de declividade no 3D Analyst no ArcGIS 9.2 (ESRI, 2006).

As etapas gerais do trabalho, descritas a seguir, consistiram no processamento da base de dados, classificação da fisionomia da vegetação por OBIA e validação da classificação.

Processamento dos dados

O tratamento inicial dado à base de dados consistiu na execução das seguintes operações: conversão dos valores digitais ou níveis de cinza (NC) para valores de radiância e correção atmosférica.

Nos estudos que utilizam comparação entre bandas ou entre imagens de diferentes sensores, é fundamental a conversão dos NC para valores de radiância, pois, apesar de representarem o comportamento espectral dos alvos da cena, os NC não possuem uma unidade escalar que permita a comparação entre diferentes produtos (Ponzoni & Shimabukuro, 2010). Nestes casos, a radiância torna-se a unidade radiométrica mais precisa para ser empregada em SR (Jensen, 2009). A radiação registrada pelo sensor, conhecida como radiância de topo de atmosfera, corresponde uma medida aparente, já que sofre interferência atmosférica, não representando a resposta espectral pura dos alvos da superfície terrestre. Os parâmetros para a transformação dos NC para radiância de topo de atmosfera, neste trabalho, foram obtidos em Digital Globe (2003).

Para fazer a correção atmosférica, foi utilizado o método DOS (*Dark Object Subtraction*), proposto por Chavez (1988), que consiste na subtração, de todos os pixels, do menor nível de cinza presente na imagem. Este método baseia-se no pressuposto de que em uma cena deva haver pixels onde a radiância é nula, considerando assim como influência atmosférica o menor valor de NC presente na cena (Ponzoni & Shimabukuro, 2010).

Posteriormente ao tratamento inicial, visando realçar os dados contidos nas bandas originais, foram executadas as seguintes operações: (a) Análise das Principais Componentes (APC), (b) conversão do sistema de cores aditivo RGB (*Red* ou Vermelho, *Green* ou Verde, *Blue* ou Azul) para o IHS (*Intensity* ou Intensidade – I, *Hue* ou Matiz – H, *Saturation* ou Saturação – S) utilizando duas composições de bandas (RGB321 e RGB423); e (c) cálculo de índices de vegetação por Razão

Simples (RS) e Índice de Vegetação por Diferença Normalizada (IVDN), gerados diretamente no Definiens Developer 7.04.

A vegetação apresenta comportamento espectral antagônico nas bandas do vermelho e infravermelho próximo. Quanto maior a densidade da cobertura vegetal, menor é a reflectância na região do visível, devido à maior presença de pigmentos fotossintetizantes; por outro lado, maior é a reflectância verificada na região do infravermelho próximo, devido ao espalhamento múltiplo da radiação eletromagnética no dossel (Ponzoni & Shimabukuro, 2010). O índice RS, razão entre as bandas do infravermelho próximo e vermelho, é mais sensível a alvos de maior biomassa, possuindo, assim, intervalo mais largo para alvos desta natureza. Já o IVDN, por ser uma razão normalizada, apresenta um estreito intervalo para esses alvos, dificultando a distinção das fisionomias em formações vegetais densas. Assim, como o RS e IVDN apresentam comportamentos complementares (Jensen, 2009), optou-se por utilizar ambos os índices.

O banco de dados final foi então constituído pelas quatro bandas multiespectrais do sensor do *QuickBird-2*, quatro componentes principais (CP) e seis componentes IHS, além do MDE e da grade de declividade.

Classificação da fisionomia da vegetação por OBIA

A segmentação, primeira etapa da OBIA, foi gerada com base nas informações espectrais de todas as bandas, exceto as componentes matiz das imagens IHS e a banda azul, por apresentarem menos informação sobre a vegetação. Os dados de relevo também não foram considerados, pois, como seus valores correspondem à morfometria da superfície, não expressam os limites dos alvos.

Como a imagem não apresenta classes de cobertura da terra extensas e homogêneas, como massas d'água, optou-se por criar apenas um nível de segmentação com os seguintes parâmetros: escala 15, cor 0,9 e compacidade 0,5. O fator de escala foi escolhido a partir de testes empíricos, por apresentar a melhor relação entre tamanho dos objetos e a discriminação das classes.

As classes foram estabelecidas com base na interpretação visual das imagens fusionadas, sendo posteriormente ajustadas de forma iterativa com os resultados preliminares da classificação. Foram, assim, definidas sete classes de cobertura da terra:

1. Vegetação arbórea – composta predominantemente por indivíduos com porte arbóreo sob diversos graus de perturbação antrópica;
2. Vegetação herbácea-arbustiva - composta por ervas mescladas com arbustos;
3. Gramínea - vegetação rasteira dominante com predomínio de gramíneas e presença rara de ervas e arbustos;
4. Gramínea rala - vegetação rasteira com predomínio de gramíneas associada ao solo;
5. Afloramento rochoso - rochas expostas;
6. Antrópica - área urbana, solo exposto e queimadas muito recentes; e
7. Sombra - áreas sem informação espectral devido ao sombreamento do alvo.

A rede semântica foi gerada heurísticamente no programa Definiens Developer 7.04. As funções e seus limiares foram definidos iterativa e interativamente pelo usuário através da análise da distribuição espacial, por objeto, dos valores médios dos descritores em níveis de cinza e dos histogramas da função de pertinência, por atributo, dos objetos para cada classe.

Avaliação da acurácia de classificação da cobertura da terra

Para a avaliação da acurácia da classificação, foram coletadas 1,7 mil amostras estratificadas pela área esperada de cada classe. Considerando apenas as classes correspondentes à vegetação este valor foi de 1,2 mil amostras. Foi coletado o número mínimo de 50 amostras por classe, definido por Congalton & Green (2009), para mapas cobrindo menos de um milhão de acres e com menos de 12 classes. As amostras referem-se a pixels, justamente para se evitar o enviesamento que ocorreria caso fossem selecionados segmentos como amostras.

A seguir, foi construída a matriz de erros composta, nas colunas, pelas amostras de referência, identificadas nas imagens *QuickBird-2* por um intérprete especialista, e nas linhas, pelas classes obtidas na

classificação. Na matriz, são expressos os erros de omissão, ou seja, amostras que não foram classificadas de acordo com as classes de referência, e os erros de comissão, correspondentes a amostras de referência classificadas erroneamente como pertencentes a outras classes. A partir das matrizes, são calculados os seguintes índices: (a) exatidão global - relação entre o número de amostras classificadas corretamente sobre o número total de amostras de referência; (b) exatidão do produtor - relativa aos erros de omissão, a qual

representa a relação entre o número de amostras classificadas corretamente da classe k e o número total de amostras de referência da classe k, (c) exatidão do usuário - referente aos erros de comissão, a qual corresponde à relação entre o número de amostras classificadas corretamente da classe k e o número total de amostras classificadas da classe k; (d) *Kappa* (K) variando entre de -1 a 1; e (e) *Kappa* condicional (Congalton & Green, 2009). O índice *Kappa* é dado por (Equação 1):

$$K = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k (n_{i+} n_{+i})}{n^2 - \sum_{i=1}^k (n_{i+} n_{+i})} \quad (1)$$

n_{ii} - número total de amostras corretamente classificadas da classe k;

n_{i+} - número total de amostras classificadas da classe k;

n_{+i} - número total de amostras coletadas da classe k; e

n - número total de amostras.

O índice *Kappa* condicional avalia a acurácia de cada classe e é calculado com base

no mesmo princípio do índice *Kappa* utilizado para a avaliação global da classificação, assim como a interpretação dos resultados obedece aos mesmos princípios. O índice *Kappa* condicional do usuário avalia os erros de comissão (Equação 2), e o do produtor, os erros de omissão (Equação 3) (Rossiter, 2004).

$$K_p = \frac{nn_{ii} - n_{ii} n_{+i}}{nn_{i+} - n_{i+} n_{+i}} \quad (2)$$

$$K_u = \frac{nn_{ii} - n_{i+} n_{+i}}{nn_{i+} - n_{+i} n_{+i}} \quad (3)$$

RESULTADOS E DISCUSSÃO

Foram gerados 123 mil objetos no processo de segmentação. Valores maiores do fator de escala testados não delimitaram apropriadamente os alvos, ocorrendo mistura, principalmente, entre os alvos gramínea rala e herbácea, gramínea e floresta, e afloramento rochoso e vegetação rupestre.

A rede semântica gerada heurísticamente está apresentada na Figura 2, sendo composta pelos seguintes descritores: a primeira, a segunda e a terceira CP, os índices de vegetação RS e IVDN, a altimetria, descritores topológicos e a textura.

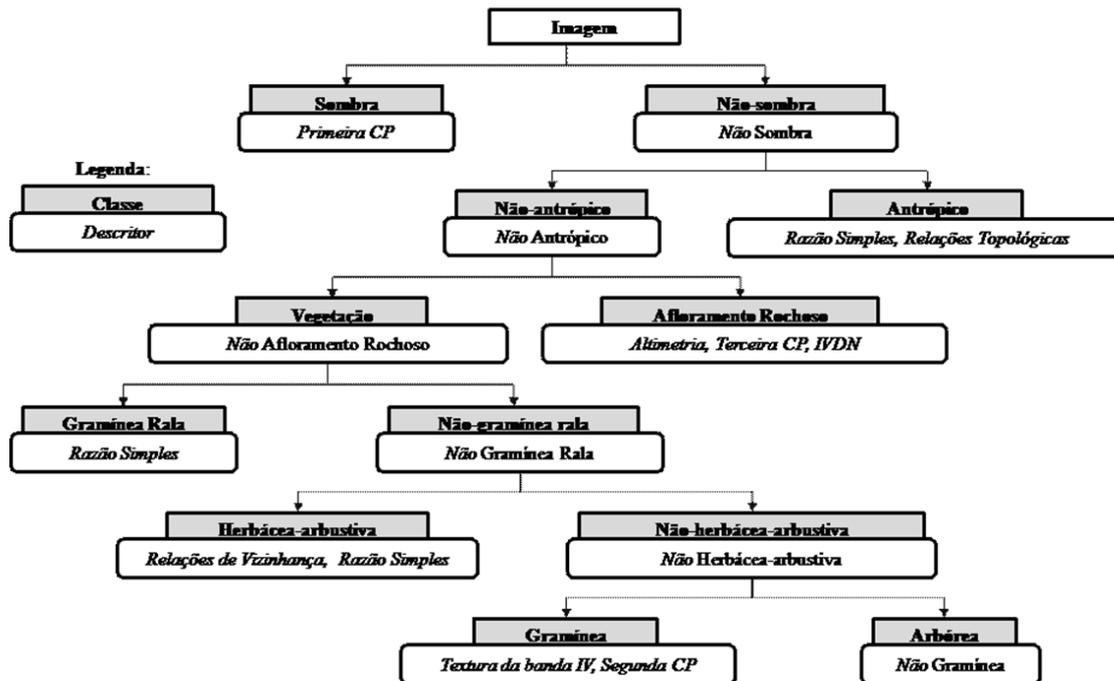


Figura 2. Rede semântica utilizada na classificação de fisionomia da vegetação.

Primeiramente, foi discriminada a classe sombra utilizando como descritor a primeira CP. Como esta componente possui a maior parte da variância total dos dados, apresenta a informação de brilho associada às sombras de topografia (Mather & Koch, 2011). Também foram incluídos os segmentos com sombreamento causado pelos dosséis. Os segmentos não classificados foram denominados como não-sombra.

A seguir, a classe antrópica foi discriminada tendo como descritor o índice RS, por apresentar alta saturação em alvos sem cobertura vegetal (Jensen, 2009). Foi aplicado, a seguir, o descritor topológico de encapsulamento (*enclosed by class*), que tem como função reclassificar os objetos cujos limites fazem contato com outros pertencentes a uma única classe. Como resultado, foram classificados, na classe antrópica, pequenos segmentos contidos no seu interior e que não tinham sido classificados. Os segmentos não classificados foram denominados como não-antrópico.

Para o afloramento rochoso, terceira classe a ser discriminada, os seguintes descritores foram utilizados: IVDN, altimetria e a terceira CP. O IVDN, por apresentar maior intervalo em alvos sem cobertura vegetal, auxiliou na separação do

afloramento das demais classes de vegetação, no entanto, ocorreu muita confusão com a gramínea rala. A utilização do descritor altimetria auxiliou na separação entre as duas classes, já que a gramínea rala se localiza predominantemente abaixo dos mil metros de altitude, situada em áreas próximas às atividades humanas. A utilização da terceira CP reduziu esta confusão. Os segmentos não classificados foram denominados como vegetação.

A classe gramínea rala, quarta a ser classificada, por apresentar influência do solo e menor densidade de cobertura vegetal, possui resposta espectral distinta das demais classes de vegetação. O índice RS foi, assim, utilizado na sua discriminação. Os segmentos não classificados foram denominados como não-gramínea rala.

Para a vegetação herbácea-arbustiva, quinta classe discriminada, também foi utilizado o índice RS. No entanto, segmentos de vegetação arbórea, que se encontravam em áreas sombreadas pelo dossel ou em encostas mal-iluminadas, foram classificados indevidamente. Desta forma, foi determinado, através da relação topológica de vizinhança, que todos os segmentos classificados como herbácea-arbustiva, que fossem vizinhos dos objetos já

classificados como sombra, seriam reclassificados como não-herbácea-arbustiva.

A vegetação gramínea, sexta classificada, apresenta um comportamento bastante semelhante à vegetação arbórea, com níveis altos de radiância no infravermelho próximo, resultando, assim, em valores elevados dos índices de vegetação. Isto pode ser explicado pelo dossel regular com presença reduzida de sombras, potencializada nos alvos localizados em vertentes contrárias ao ângulo de incidência do sol. Estas características criam uma superfície menos rugosa do que das demais classes de vegetação, fazendo com que os descritores texturais apresentem bom desempenho na discriminação da classe gramínea. A medida de textura utilizada foi baseada em Haralick et al. (1973), aplicada à média do infravermelho próximo em todas as direções. Verificou-se, no entanto, que este descritor incluía na classe gramínea segmentos de árvores isoladas que apresentavam iluminação diferenciada das demais, causada pela incidência solar direta. A utilização da segunda CP auxiliou na sua exclusão. Os segmentos não classificados foram denominados como vegetação arbórea.

Foram testados diversos descritores para diferenciar os objetos constituídos por araucária

e eucalipto da classe vegetação arbórea, entretanto, os testes não foram bem sucedidos. Como a araucária apresenta dossel esparsa e com folhas aciculares, ocorre a penetração da luz em seu sub-dossel e, ao mesmo tempo, um menor espalhamento no seu estrato. Logo, a resposta espectral é menos intensa na região do infravermelho próximo. Com isto, a vegetação arbórea sombreada foi confundida com os objetos de araucária.

Os eucaliptos por se localizarem, na área de estudo, no interior das formações arbóreas, não geraram objetos puros. Na porção nordeste da imagem, há objetos delimitando pequena área com eucalipto de plantio recente, que possuem resposta espectral e textura semelhantes à classe gramínea, não sendo possível, assim, a sua discriminação.

Considerando todas as classes de cobertura da terra definidas (Figura 3), o índice de exatidão global obtido foi de 83%, e o índice *Kappa* de 0,78 (Tabela 1) O índice *Kappa* do produtor da classe antrópica alcançou valor de 0,81, e do usuário, 0,97. A classe afloramento rochoso obteve índice *Kappa* condicional de 0,94 e 0,83, respectivamente para produtor e usuário.

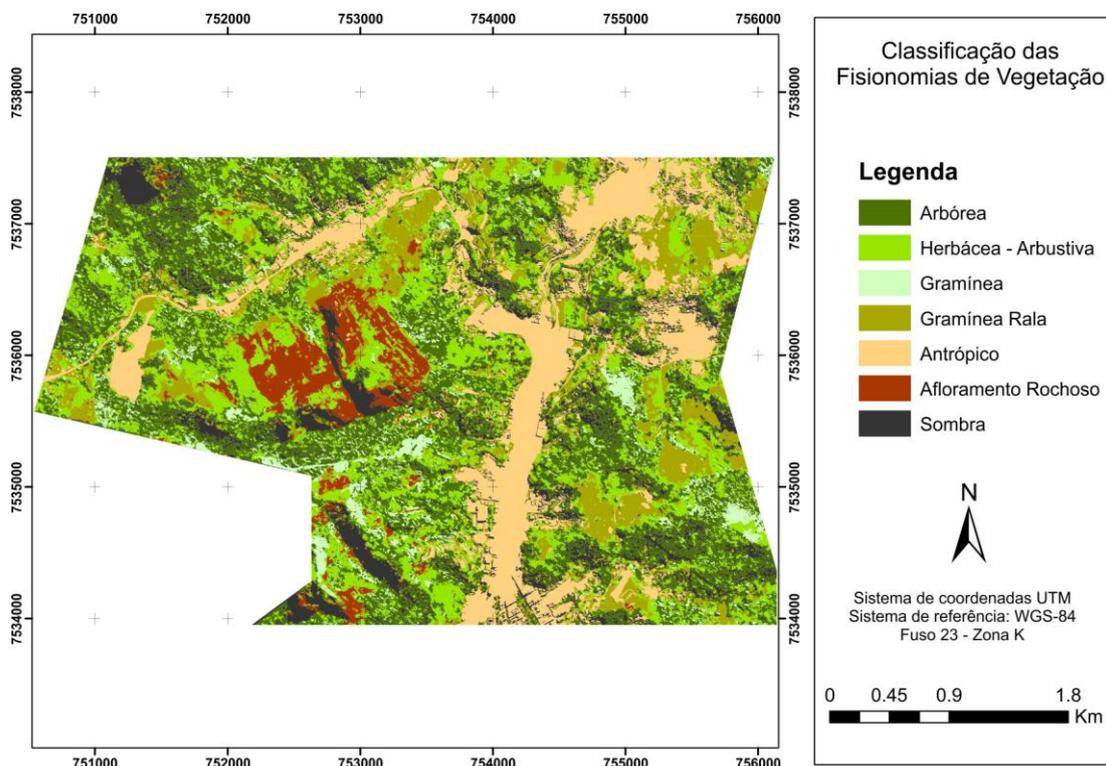


Figura 3. Classificação das fisionomias da vegetação.

Entre as classes de vegetação, a classe vegetação arbórea obteve maior valor do índice do usuário, alcançando 0,88 no *Kappa* condicional, seguida da gramínea rala, com valor de 0,77. Já as classes gramínea e herbácea-arbustiva apresentaram desempenho inferior. A gramínea, com *Kappa* do usuário 0,60, apresentou confusão com a vegetação arbórea, conforme foi apontado anteriormente. A vegetação herbácea-arbustiva, também com índice *Kappa* do usuário de 0,60, apresentou confusão com a classe arbórea.

O *Kappa* condicional do produtor apresentou melhor resultado, em média, alcançando valores entre 0,68 e 0,90 entre as classes de vegetação. O melhor resultado foi da classe herbácea-arbustiva, e o pior resultado coube à vegetação arbórea.

Considerando o *Kappa* global (0,78) das classes de cobertura da terra, pode-se afirmar que a qualidade da classificação é muito boa (Landis & Koch, 1977). Estes valores

demonstram que as classes de vegetação apresentaram, em geral, erros superiores aos apresentados pelas classes antrópica e afloramento rochoso. Yu et al. (2006) obtiveram resultados semelhantes na classificação por OBIA, com uso de fotografias aéreas multiespectrais realçadas de resolução espacial 1 m e dados de relevo, alcançando índice de exatidão para as classes de vegetação entre 40 e 60%, enquanto para as classes de não-vegetação estes valores situaram-se entre 75 e 85%. Além do comportamento espectral semelhante entre as diversas fisionomias de vegetação e da interferência do sombreamento do dossel, pode ser apontado, como razão das diferenças entre os índices, o fato de alvos de diferentes naturezas (urbana, queimada e solo exposto), neste trabalho, estarem agregados em uma única classe (antrópica), tornando-a mais abrangente e, assim, aumentando o valor do *Kappa*.

Tabela 1. Matriz de erros e índices de concordância obtidos para a classificação de fisionomias da vegetação.

Classes	Amostras de Referência							Total Classificadas
	Afloramento Rochoso	Antrópico	Sombra	Gramínea Rala	Herbácea-Arbustiva	Gramínea	Vegetação Arbórea	
Afloramento rochoso	52	2	3	5				62
Antrópico		232		2	3			237
Sombra		14	157	2			9	182
Gramínea Rala	3	27	1	198	12		4	245
Herbácea-Arbustiva		1		44	307	3	95	450
Gramínea						45	28	73
Vegetação Arbórea		2		11	13	11	420	457
Total Coletadas	55	278	161	262	335	59	556	1706
Total Corretas	52	232	157	198	307	45	420	1411
Exatidão do Usuário	95%	83%	98%	76%	92%	76%	76%	Exatidão Global
Exatidão do Produtor	84%	98%	86%	81%	68%	62%	92%	0,83
<i>Kappa</i> Condicional do Usuário	0,83	0,97	0,85	0,77	0,60	0,60	0,88	Índice <i>Kappa</i>
<i>Kappa</i> Condicional do Produtor	0,94	0,81	0,97	0,72	0,90	0,76	0,68	0,78

Amaral et al. (2009), comparando o desempenho dos classificadores por região e por pixel em imagens com resolução de 6 e 20

m para a classificação de estádios de sucessão florestal, obtiveram índice *Kappa* entre 0,21 a 0,54. Os autores apontam que as respostas

espectrais estreitamente semelhantes entre as classes utilizadas no mapeamento diminuem a acurácia. Os maiores erros ocorreram nas classes referentes aos estádios médios e avançados de sucessão, o que se assemelha ao encontrado no presente trabalho, com maiores erros de comissão (0,56) e omissão (0,64) para as classes arbórea e herbácea-arbórea,

respectivamente. Os autores apontam que para a distinção entre os estádios de sucessão florestal, em que o dossel já se encontra fechado, a estrutura da comunidade, a composição florística e a arquitetura das árvores são os principais critérios de diferenciação e devem ser levantados em campo.

CONCLUSÕES

Destaca-se, enfim, como avanços de OBIA: i) a utilização de atributos não somente estatísticos como nos métodos tradicionais, mas também geométricos, topológicos, contextuais e de relacionamento semântico entre classes, aproximando-se dos processos cognitivos humanos de interpretação de imagens (Navulur, 2006; Camargo et al., 2009); ii) a possibilidade de se operar com mais de um nível de segmentação; iii) a sofisticação dos algoritmos de segmentação, que passaram a incorporar parâmetros de forma, e iv) a possibilidade de se integrar dados de diversas fontes para a classificação. Os descritores que obtiveram melhor desempenho neste trabalho foram aqueles derivados de operações de transformação (CP e RS) e dos dados de relevo. Trabalhos indicam o aumento dos índices de acurácia ao se incluir dados auxiliares na base de dados para a classificação por OBIA, além das tradicionais bandas multiespectrais. Leonardi (2010) obteve aumento no índice *Kappa* de 0,53 para 0,73, quando introduziu dados altimétricos de laser na rede semântica para a classificação de cobertura do solo urbano em imagens de alta resolução. Gao & Mas (2008) obtiveram aumento da exatidão global de 57% para 62% ao introduzir o índice EVI (*Enhanced Vegetation Index* – Índice Realçado de Vegetação) para a classificação de cobertura da terra por OBIA, utilizando dados do satélite MODIS. Outros trabalhos sobre OBIA aplicados ao mapeamento da vegetação também se utilizaram de informações semelhantes (Yu

et al., 2006; Gergel et al., 2007; Dorren et al., 2003; Johansen et al., 2007; Sousa et al., 2011).

Outro ponto de destaque em OBIA, conforme exposto anteriormente, é a possibilidade de se utilizar outros atributos que não somente os estatísticos aplicados a dados exclusivamente espectrais, a exemplo dos texturais e topológicos, os quais foram utilizados neste trabalho para a discriminação das classes gramínea e vegetação arbórea. A aplicação da informação textural é apontada em vários estudos para melhor discriminação de classes de vegetação (Yu et al., 2006), bem como de classes antrópicas (Dekker, 2003; Dell'acqua & Gamba, 2003; Francisco & Almeida, 2012).

Por fim, cabe contudo salientar que o tamanho dos objetos gerados na segmentação atuam como um limitante para o uso de descritores texturais e topológicos. Em vista da altíssima resolução espacial da imagem empregada neste trabalho, houve a necessidade de se utilizar parâmetros de segmentação que permitissem a geração de objetos puros, ou seja, com a presença predominante de apenas um alvo, resultando em objetos muito pequenos. Por outro lado, a fim de que os atributos calculados para cada um dos objetos sejam representativos das respectivas classes consideradas, há a necessidade de que exista um número mínimo de pixels por segmento, o que representa um grande desafio ao usuário de OBIA quando aplicada a imagens de elevada resolução espacial.

AGRADECIMENTOS

Os autores agradecem às instituições de fomento à pesquisa CNPq e CAPES.

REFERÊNCIAS BIBLIOGRÁFICAS

1. ALBUQUERQUE, C.K.; CRUZ, C.B.M.; BARROS, R.S. Sensibilidades de índices de vegetação para classificação do estado de conservação da cobertura florestal. In: Simpósio

Brasileiro de Sensoriamento Remoto, 15, 2011. Curitiba, Brasil. *Anais...* São José dos Campos: INPE, 2011. p. 1652-1659.

2. AMARAL, M.V.F.; SOUZA, A. L.; SOARES, V. P.; SOARES, C. P.; LEITE, H. G.; MARTINS, S.V.; FERNANDES FILHO, S.V.; LANA, E.I.J.M. Avaliação e comparação de métodos de classificação de imagens de satélites para o mapeamento de estádios de sucessão florestal. **Revista Árvore**, v. 33, n. 3, p. 575-582, 2009.
3. BAATZ, M.; SCHÄPE, A. Multiresolution segmentation - an optimization approach for high quality multi-scale image segmentation. In: STROBL, J.; BLASCHKE, T.; GRIESEBNER, G. (Eds.). **Angewandte Geographische Informations-Verarbeitung XII. Beiträge zum AGIT-Symposium Salzburg**. Karlsruhe: Herbert Wichmann Verlag, p. 12-23, 2000.
4. BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, p. 2-16, 2009.
5. CAMARGO, F.F.; FLORENZANO, T.G.; ALMEIDA, C.M.; OLIVEIRA, C.G. Geomorphological Mapping Using Object-Based Analysis and ASTER DEM in the Paraíba do Sul Valley, Brazil. **International Journal of Remote Sensing**, v. 30, n. 24, p. 6613-6620, 2009.
6. CASTILLA, G. & HAY, G. J. Image objects and geographic objects. In: BLASCHKE, T.; LANG, S.; HAY, G.J. (Eds.) **Object-Based Image Analysis Spatial Concepts for Knowledge-Driven Remote Sensing Applications**. Berlin: Springer, 2008. p. 91-110.
7. CHAVEZ JR., P.S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v. 24, n. 3, p. 459-479, 1988.
8. CONGALTON, R. & GREEN, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. Boca Raton: CRC/Taylor & Francis, 2009. 183p.
9. CORRADINI, F.A.; STEVAUX, J.C.; FACHINI, M.P. Geomorfologia e distribuição da vegetação ripária na Ilha Mutum, Rio Paraná - PR/MS. **Revista Geociências**, v. 27, n. 3, p. 345-354, 2008.
10. DALL'OGGIO, P. **Programando com Orientação a Objetos**. São Paulo: Novatec, 2009. 2. ed. 574 p.
11. DEKKER, R.J. Texture analysis and classification of ERS SAR images for map updating of urban areas in The Netherlands. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 9, p. 1950-1958, 2003.
12. DEFINIENS. **Definiens Developer 7.04**. Germany, 2007.
13. DELL'ACQUA, F. & GAMBA, P. Texture-based characterization of urban environments on satellite SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 1, p. 153-159, 2003.
14. DIGITAL GLOBE. **Radiance Conversion of QuickBird Data**. Technical Note. Longmont, Colorado, 2003.
15. DORREN, L.K.A.; MAIER, B.; SEIJMONSBERGEN, A.C. Improved landsat-based forest mapping in steep mountainous terrain using object-based classification. **Forest Ecology and Management**, v. 183, n. 1-3, p. 31-46, 2003.
16. ESRI. **ArcGIS 9.2**. California, USA, 2006.
17. FRANCISCO, C.N. & ALMEIDA, C.M. Avaliação de Desempenho de Atributos Estatísticos e Texturais em uma Classificação de Cobertura da Terra Baseada em Objeto. **Boletim de Ciências Geodésicas**, v. 18, p. 302-326, 2012.
18. GAO, Y. & MAS, J.F. A comparison of the performance of pixel based and object based classification over images with various spatial resolutions. **Online Journal of Earth Sciences**, v. 2, p. 27-35, 2008.
19. GERGEL, S.E.; STANGE, Y.; COOPS, N.C.; JOHANSEN, K.; KIRBY, K.R. What is the value of a good map? An example using high spatial resolution imagery to aid riparian restoration. **Ecosystems**, v. 10, n. 5, p. 688-702, 2007.
20. HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural Features for Image Classification. **IEEE Transactions on Systems, Man and Cybernetics**, v. SMC-3, n. 6, p. 610-620, 1973.
21. IBGE. **Ortofotos 1:25.000 - Rio de Janeiro**. Disponível em: ftp://geofp.ibge.gov.br/mapas/ortofoto/Projeto_RJ25/TIF/. Acessado em: 12fev2011.
22. JENSEN, J.R. **Sensoriamento remoto do ambiente: Uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese Editora, 672 p., 2009.
23. JOHANSEN, K.; COOPS, N.C.; GERGEL, S.E.; STANGE, Y. Application of high spatial resolution satellite image for riparian and forest ecosystem classification. **Remote Sensing of Environment**, v. 110, n. 1, p. 29-44, 2007.
24. KRESSLER, F. P. & STEINNOCHER, K. Image data and LIDAR – an ideal combination matched by object oriented analysis. In: **Geographic Object-Based Image Analysis**, 1, 2006. Salzburg University, Austria. **Proceedings...** Salzburg: Salzburg University 2006.
25. LANDIS, J. & KOCH, G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159 - 174, 1977.
26. LEONARDI, F. **Abordagens Cognitivas e Mineração de Dados Aplicadas a Dados Ópticos Orbitais e de Laser para a Classificação de Cobertura do Solo Urbano**. São José dos Campos, 2010. 134 p. Dissertação (Mestrado em Sensoriamento Remoto) – INPE, 2010.
27. LORENZZETTI, J. A. **Princípios Físicos de Sensoriamento Remoto - Notas de Aula de SER 333**. São José dos Campos: INPE, 2011.
28. MATHER, P. & KOCH, M. **Computer Processing of Remotely-Sensed Images: An Introduction**. New York: Wiley, 2011. 4. ed. 460 p.
29. METZGER, J.P. O que é ecologia de paisagens? **Revista Biota Neotropica**, v. 1, n. 1-2, p. 1-9, 2001.
30. NAVULUR, K. **Multispectral image analysis using the object-oriented paradigm**. Boca Raton: Taylor & Francis Group, 2006. 165 p.
31. NOVO, E.M.L.M. **Sensoriamento remoto: Princípios e aplicações**. São Paulo, SP: Editora Edgard Blücher LTDA, 2011. 4. ed. 388 p.
32. PONZONI, F.J. & SHIMABUKURO, Y.E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos, SP: Editora Parêntese, 144p., 2010.
33. ROSSITER, D.G. **Statistical methods for accuracy assesment of classified thematic maps**. Technical Note. Enschede: International Institute for Geo-information Science & Earth Observation (ITC), 2004.
34. SOUSA, A.M.O.; MESQUITA, P.; GONÇALVES, A.C.; MARQUES DA SILVA, J.R.; SILVA, L.L. **Deteção de vegetação arbórea através de segmentação e classificação orientada a objecto de imagens multispectrais de alta resolução (QuickBird)**. Disponível em: <http://hdl.handle.net/10174/2807>. Acessado em: 11dez2011.
35. YU, O.; GONG, P.; CLINTON, N.; BIGING, G.; KELLY, M.; SHIROKAUER, D. Object-based Detailed Vegetation Classification with Airborne High Spatial Resolution Remote Sensing Imagery. **Photogrammetric Engineering and Remote Sensing**, v. 72, n. 7, p. 799-811, 2006.

*Manuscrito recebido em: 27 de Junho de 2012
Revisado e Aceito em: 29 de Novembro de 2012*