

**INTERPRETAÇÃO DE IMAGENS ORBITAIS POR MEIO DE SISTEMA ESPECIALISTA PARA O  
MAPEAMENTO DE COBERTURA DA TERRA EM REGIÃO MONTANHOSA**  
**Orbital images interpretation by means of an expert system for land cover mapping in highlands**

*Cristiane Nunes Francisco*

Profa. Adjunto do Depto. de Análise Geoambiental do Instituto de Geociências da Universidade Federal  
Fluminense (UFF)  
Niterói/RJ - Brasil  
crisnf@vm.uff.br

*Cláudia Maria de Almeida*

Pesquisadora Titular da Divisão de Sensoriamento Remoto do  
Instituto Nacional de Pesquisas Espaciais (INPE)  
São José dos Campos/SP - Brasil  
almeida@dsr.inpe.br

Artigo recebido em 23/02/2012 e aceito para publicação em 28/05/2012

**RESUMO:** Mapas de cobertura da terra constituem uma importante fonte de dados para a elaboração de diagnóstico, ordenamento e gestão do território, sendo fundamentais em projetos de zoneamentos, estudos de impactos ambientais, mapeamentos de áreas de riscos, entre outras aplicações. Em geral, são elaborados com base na interpretação de imagens aerotransportadas ou orbitais e/ou na análise de documentos cartográficos, conjugadas a trabalhos de campo. As técnicas tradicionais de classificação de imagens baseiam-se na análise pixel a pixel ou por regiões, enfocando as diferenças espectrais para extração de informações. A abordagem de análise de imagens baseada em objeto (OBIA), embora se utilize de regiões, representa um avanço em relação às classificações tradicionais por regiões, pois pressupõe necessariamente a existência de um modelo de conhecimento (rede semântica) atrelado ao processo de interpretação da cena, que explicita o conhecimento do intérprete, aproximando-se dos processos cognitivos humanos de interpretação. Este artigo tem como objetivo analisar a classificação de cobertura da terra feita a partir de imagens orbitais por meio de OBIA. Foram utilizados atributos estatísticos e texturais extraídos de imagens ALOS/AVNIR fusionadas com imagens ALOS/PRISM e de dados de relevo do banco de dados geomorfométricos TOPODATA. A área de estudo foi o município de Nova Friburgo, situado na região serrana do Rio de Janeiro. Para a validação da classificação, foi utilizado o índice *Kappa*, que confronta amostras classificadas com a verdade de campo. O valor do *Kappa* obtido neste trabalho alcançou 0,85, sendo superior aos encontrados em trabalhos similares que utilizam técnicas tradicionais de classificação. **Palavras chaves:** sensoriamento remoto, classificação de imagens, análise de imagens baseada em objeto, cobertura da terra, ALOS.

**ABSTRACT:** Land cover maps are an important data source for land planning and management, and hence, are crucial in zoning projects, environmental impact assessment, risky areas mapping, among other applications. They are usually derived from the interpretation of airborne or orbital images and/or the analysis of cartographic products, associated with field work. The traditional methods of remote sensing images classification consist either in pixel-per-pixel or region-based analyses, focusing on spectral differences for information extraction. The object-based image analysis (OBIA), although also based on the use of regions, represents an advance in relation to the traditional region-based classification approaches, for it relies on a knowledge model (semantic network) appended to the scene interpretation process, which

renders the interpreter's knowledge explicit, in a way to resemble the human cognitive processes. This paper aims to analyze land cover mapping resulting from the interpretation of remote sensing images using OBIA. Statistical and textural attributes extracted from ALOS/AVNIR images pan-sharpened with ALOS/PRISM image as well as relief data from the TOPODATA geomorphometric database were used as input data. The study area is Nova Friburgo County, with an area of 933 km<sup>2</sup>, located in the mountainous region of Rio de Janeiro State. The land cover map was validated by the *Kappa* index, which relates classified samples with field data. The *Kappa* value obtained in this paper was 0.85, which showed to be greater than the ones found in similar works that used traditional classification techniques.

**Keywords:** remote sensing, images classification, object-based image analysis, land cover, ALOS.

---

## INTRODUÇÃO

Mapas de cobertura da terra correspondem a uma representação espacial dos alvos que cobrem a superfície terrestre. A escala do mapeamento define o detalhamento das classes de cobertura. Estas podem abranger classes de cobertura da terra mais genéricas no caso de mapeamentos em pequena escala ou de resolução espacial mais grosseira, como, por exemplo, a classe urbana, e coberturas mais específicas no caso de mapeamentos em grande escala ou de resolução mais refinada, como, por exemplo, o asfalto. Os mapas de cobertura da terra constituem uma fonte de dados para a elaboração de diagnóstico, ordenamento e gestão do território, sendo, assim, fundamentais em projetos de zoneamentos, estudos de impactos ambientais, mapeamentos de áreas de riscos, aplicação e desenvolvimento de políticas ambientais e observância à legislação ambiental, entre outras aplicações (CREPANI *et al.*, 1996; METTERNICHTA *et al.*, 2005; MASCARENHAS *et al.*, 2009).

O mapeamento de cobertura da terra é feito em geral com base na interpretação de imagens aerotransportadas ou orbitais e/ou na análise de documentos cartográficos, conjugadas a trabalhos de campo. As técnicas tradicionais de classificação de imagens baseiam-se na análise pixel a pixel ou por regiões, enfocando as diferenças espectrais para extração de informações. Os métodos utilizados para a classificação das imagens abrangem desde procedimentos exclusivamente de interpretação visual a aqueles totalmente automatizados, que independem da intervenção do intérprete, baseados em recursos de processamento digital. O uso exclusivo da interpretação visual para

a classificação de cobertura da terra, dependendo da dimensão da área de estudo e da escala de análise, pode consumir uma grande quantidade de horas de trabalho, no entanto, dependendo do conhecimento do intérprete sobre a área de estudo, pode gerar mapas mais fidedignos. Por outro lado, métodos totalmente automatizados que não recorrem à intervenção do intérprete, conhecidos como classificações não-supervisionadas, podem despendar menos tempo de trabalho, contudo, requerem grande esforço de intérpretes para a realização de ajustes pós-classificação. Desta forma, os métodos mais adequados para a classificação de imagens visando ao mapeamento de cobertura da terra mostraram-se ser aqueles que conjugam a automação do processo, utilizando processamentos digitais de imagens, e a intervenção do intérprete, o qual detém o conhecimento prévio acerca das feições existentes na imagem, sendo denominados como classificações supervisionadas.

O surgimento de novas tecnologias de coleta de dados da superfície terrestre, principalmente aquelas baseadas na aquisição por sensores transportados em plataformas orbitais, tem ampliado a disponibilidade e variedade de imagens. Os avanços tecnológicos resultaram no advento de imagens de altíssima resolução espacial e espectral, bem como de dados até então coletados por veículos aerotransportados, como os altimétricos, aumentando, assim, a disponibilidade de informações sobre a superfície terrestre. Desta forma, é inevitável a necessidade do desenvolvimento de técnicas de classificação supervisionada de imagens mais eficientes, fato apontado por diversos trabalhos (BLASCHKE, 2003; BIAN, 2007; LANG, 2008), e vários comprovaram o melhor desempenho

da classificação por análise de imagem baseada em objeto (*object-based image analysis* - OBIA) sobre a tradicional, quando os dois métodos de classificação são comparados por meio de índices de acurácia. Essa abordagem, embora se utilize de regiões, representa um avanço em relação às classificações tradicionais por regiões, pois a OBIA pressupõe necessariamente a existência de um modelo de conhecimento (rede semântica) atrelado ao processo de interpretação da cena, que explicita o conhecimento do intérprete, aproximando-se dos processos cognitivos humanos de interpretação. Por este motivo, a OBIA insere-se no domínio de sistemas especialistas, que são aqueles que empregam estratégias de armazenamento e replicação do conhecimento humano (MOORE, 2000).

Gao *et al.* (2006), ao compararem uma classificação por OBIA em relação a outra baseada em pixel, obtiveram um aumento de 37% no índice de exatidão global para o mapeamento de cobertura da terra em áreas afetadas por fogo com imagens ASTER. Leonardi *et al.* (2009) avaliaram comparativamente uma classificação supervisionada por regiões e outra baseada em objeto para imagens de alta resolução espacial e obtiveram, para a classificação tradicional, índice *Kappa* de 0,54, enquanto que para a classificação por OBIA, este valor alcançou 0,71. Por sua vez, os resultados de um estudo feito por Whiteside *et al.* (2011) mostraram uma significativa diferença entre a acurácia de dois mapeamentos de cobertura da terra, em áreas de savana, com o uso de dados do satélite ASTER: o índice *Kappa* alcançado pela classificação baseada em pixel foi de 0,65, ao passo que por OBIA, este valor foi de 0,74.

Outros trabalhos também 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 de laser na rede semântica para a classificação de cobertura do solo urbano em imagens de alta resolução. Gao e 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 por OBIA de cobertura da terra utilizando dados do satélite MODIS.

Assim, diante dos bons resultados recentemente alcançados com a classificação por sistemas especialistas e a introdução de novos dados para a classificação de imagens da superfície terrestre, este artigo tem como objetivo analisar o mapeamento de cobertura da terra feito a partir de interpretação de imagens orbitais por um sistema especialista de análise de imagens de sensoriamento remoto baseada em objeto. Utilizou-se, para isto, além das bandas multiespectrais dos sensores ALOS/AVNIR, dados auxiliares, como imagens derivadas de operações matemáticas sobre as bandas multiespectrais e dados de relevo, a partir dos quais foram extraídos atributos estatísticos e texturais.

## FUNDAMENTAÇÃO TEÓRICA DE OBIA

Em OBIA, os pixels são agrupados em segmentos ou objetos de acordo com as suas propriedades não somente espectrais, mas também espaciais, através da técnica de segmentação, e estes passam a ser utilizados como unidades primitivas para a classificação (NAVULUR, 2006). De maneira diversa dos classificadores tradicionais, que utilizam somente a informação espectral para identificar a classe provável a ser atribuída ao elemento de análise, a OBIA baseia-se em informações extraídas de objetos que possuem identidade própria. Assim, além das propriedades espectrais, os objetos apresentam numerosos atributos (descritores), associados à forma, textura, relações contextuais e semânticas, que podem ser utilizados para a análise de imagens, aproximando-se dos processos cognitivos humanos de interpretação de imagens (NAVULUR, 2006; CAMARGO *et al.*, 2009).

A OBIA consiste basicamente na aplicação de dois procedimentos metodológicos: (1) segmentação/regionalização, técnica primária usada para conversão de uma cena ou imagem em múltiplos objetos; e (2) classificação baseada em regras de decisão que explicitam as propriedades dos objetos expressas pelos atributos (NAVULUR, 2006; LANG, 2008). Os algoritmos de segmentação subdividem uma imagem formada por pixels em regiões ou segmentos, diminuindo o nível de detalhe e a complexidade da imagem, que passa a ser formada por objetos (LANG, 2008). A imagem segmentada é constituída por um conjunto de pixels contíguos, onde cada pixel é ro-

tulado como pertencente estritamente a um objeto. O objeto corresponde a uma região discreta de uma imagem que é internamente coerente e diferente do seu entorno (HAY; CASTILLA, 2008).

Após a segmentação, segue-se a fase de criação da base de conhecimento orientada a objeto, que é estruturada em uma rede semântica hierárquica, responsável por armazenar o conhecimento do intérprete sobre a área de estudo e com base na qual os objetos são classificados. A rede semântica é uma forma de representar o conhecimento através de um grafo direcionado formado por vértices, que representam conceitos, e por arestas, que correspondem às relações semânticas entre os conceitos (TÖNJES *et al.*, 1999). Durante a construção da base do conhecimento, devem ser considerados os seguintes pontos: (a) definição de classes e subclasses apropriadas para o nível de segmentação; (b) determinação dos atributos dos objetos (espectrais, texturais, morfológicos, espaciais) que os classificam e são herdados pelas subclasses; e (c) determinação das funções de pertinência (tipo de função e limiares) (MAVRANTZA; ARGIALAS, 2008). Blaschke *et al.* (2008) sugerem que o foco de OBIA deva estar na incorporação e desenvolvimento de bases geográficas inteligentes, ou seja, informações apropriadas dentro de um contexto geográfico.

A construção da base de conhecimento, representada pela rede semântica, é uma das tarefas mais importantes para a classificação dos objetos e, no entanto, uma das mais trabalhosas, devido à dificuldade para selecionar, entre uma grande quantidade de atributos fornecida pelos objetos, quais descrevem melhor as classes às quais pertencem. A rede semântica pode ser gerada de forma heurística pelo usuário, testando iterativa e interativamente os descritores, as funções e os seus limiares para a discriminação adequada das classes.

O poder de OBIA está no fato de os objetos fornecerem uma base de dados ampla para a classificação, pois, como correspondem a um agrupamento de pixels contíguos, é possível calcular, para cada objeto, parâmetros estatísticos e outros coeficientes relacionados às suas propriedades. Assim, a cada objeto está associado um conjunto de atributos que, no caso das propriedades espectrais, corresponde ao tratamento estatístico dado aos valores dos pixels pertencentes a

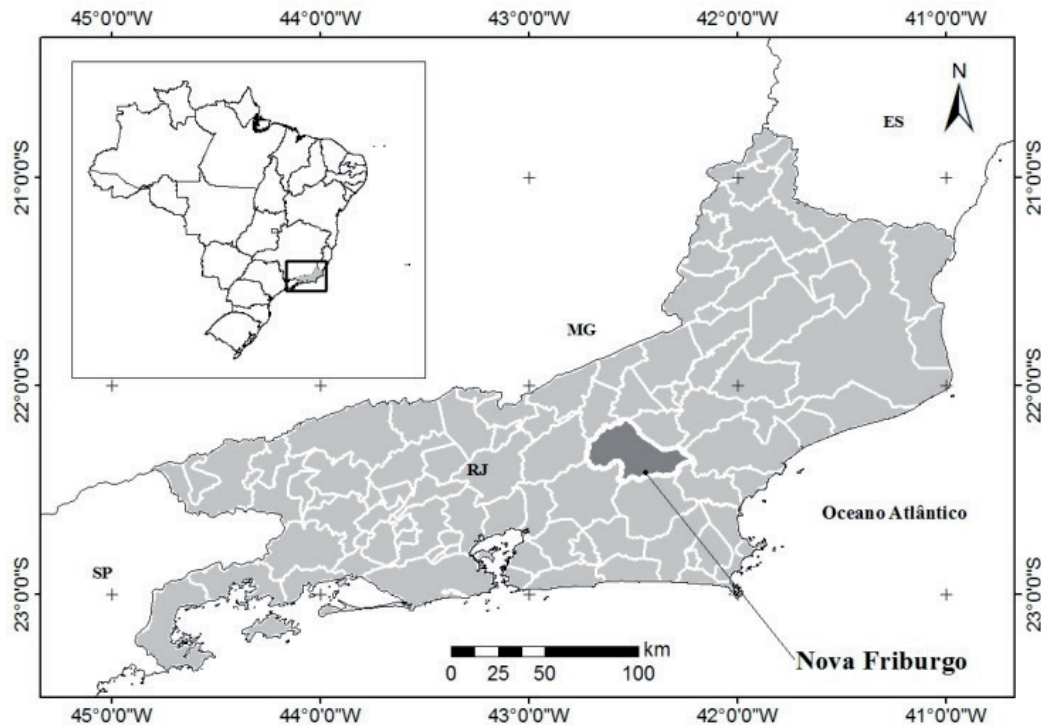
este objeto, e das texturais, ao tratamento matemático da distribuição espacial dos valores do pixel no respectivo objeto. Detalhes acerca dos atributos estatísticos e texturais utilizados neste trabalho, bem como dos métodos empregados para classificação de cobertura da terra na área de estudo, encontram-se descritos na próxima seção.

## REALIZAÇÃO DO EXPERIMENTO

### *Área de Estudo*

A área de estudo é o município de Nova Friburgo (Figura 1), com área de 933 km<sup>2</sup> e população de 182 mil habitantes (IBGE, 2011a), localizado na região serrana fluminense, na unidade geomorfológica denominada como Planalto Reverso da Região Serrana (DANTAS, 2001), apresentando relevo montanhoso a escarpado, com altitude variando entre 400 e 2.300 m. Os terrenos mais íngremes e elevados, devido à difícil acessibilidade, mantêm a cobertura florestal preservada, representando cerca de 70% do seu território (CIDE, 2003). Os principais sítios urbanos estão instalados em alvéolos intramontanos, e os núcleos agrícolas concentram-se nos fundos de vales e baixas encostas de relevo menos acidentado. Essa unidade geomorfológica apresenta alta vulnerabilidade a eventos erosivos e movimentos de massa, devido à declividade elevada das encostas associada à expansão das atividades econômicas (DANTAS, 2001), sendo uma das regiões mais atingidas pelos eventos catastróficos ocorridos no início de 2011.

Figura 1. Localização da área de estudo: município de Nova Friburgo



Org. das autoras.

### Material e Métodos

O mapeamento de cobertura da terra de Nova Friburgo baseou-se na aplicação de OBIA com a utilização da plataforma Definiens Developer 7.04. Nela, estão contidos algoritmos de segmentação, entre eles o de multirresolução, e de classificação, abrangendo 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. 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 existentes, o que possibilita a construção de uma rede hierárquica entre os níveis de segmentação.

Os critérios de homogeneidade utilizados na segmentação multirresolução são estabelecidos a partir da combinação das propriedades espectrais (cor)

dos pixels e de forma 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.

Por fim, deve ser atribuído também 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.

O banco de dados foi composto por imagens orbitais e dados de relevo. As imagens foram obtidas em agosto de 2009 pelo sensor ALOS/AVNIR-2, com resolução espacial de 10 m, correspondendo a três bandas do visível e uma do infravermelho próximo, fusionadas com a imagem pancromática do sensor ALOS/PRISM, com resolução espacial de 2,5 m. Os dados de relevo foram obtidos do banco de dados geomorfométricos TOPODATA, elaborado a partir do processamento dos dados SRTM (*Shuttle Radar Topography Mission*) disponibilizados pelo USGS (*United States Geological Survey*). Este processamento teve como objetivo o preenchimento de falhas e refinamento dos dados, resultando em Modelos Digitais de Elevação (MDE) com resolução espacial de 30 m (VALERIANO, 2005).

A SRTM teve como objetivo a obtenção de dados topográficos da Terra com base em um sistema de radar de abertura sintética interferométrico, instalado a bordo do ônibus espacial *Endeavour*, o qual sobrevoou o planeta durante 11 dias em fevereiro de 2000. Essa missão foi liderada conjuntamente pela Agência Nacional de Geointeligência Espacial (*National Geospatial-Intelligence Agency - NGA*) e pela Agência Nacional de Aeronáutica e Espaço dos

EUA (*National Aeronautics and Space Administration - NASA*). Os MDE gerados pela missão SRTM são distribuídos gratuitamente com resolução de 30m, para os Estados Unidos, e 90m, para o resto do mundo.

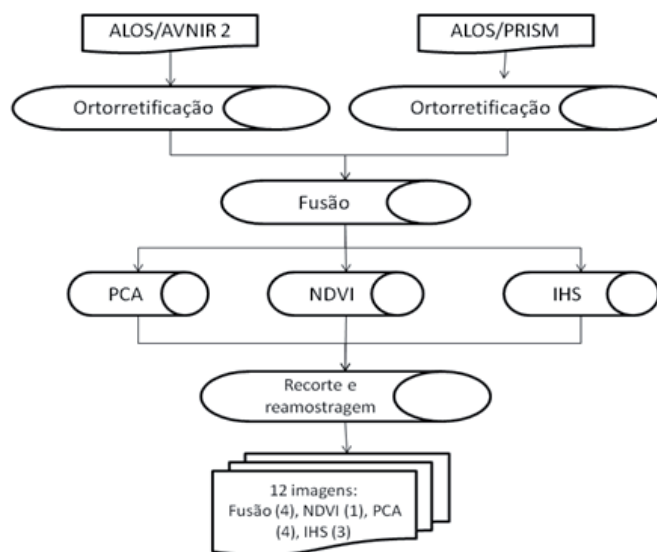
As etapas gerais do trabalho, abaixo descritas, consistiram na preparação da base de dados, segmentação das imagens, criação da rede semântica, classificação das imagens e validação da classificação.

### Preparação da base de dados

A preparação do banco de dados consistiu no processamento das imagens ALOS e do MDE TOPODATA. Para as imagens multiespectrais e pancromática, foram efetuadas as operações de ortorretificação e fusão e a geração de imagens por operações de transformações matemáticas (Figura 2).

Como os coeficientes polinomiais racionais (*rational polynomial coefficients - RPC*) das imagens ALOS são fornecidos apenas para dados obtidos no continente asiático, foram coletados 40 pontos de controle nas ortofotos 1:25.000 (IBGE, 2011b) com 1 m de resolução espacial para ortorretificar as cenas AVNIR (70 x 70 km). A altitude foi extraída dos dados do SRTM. Para a imagem PRISM (70 x 35 km), foram utilizados 20 pontos. A ortorretificação foi executada no programa ENVI 4.7.

Figura 2. Etapa de preparação da base de dados.



Org. das autoras.

O passo seguinte foi a fusão de imagens AV-NIR-2 e PRISM utilizando o método Gram-Schmidt, disponível no ENVI 4.7. Este método, criado por Laben e Bover em 1998 e patenteado pela Eastman Kodak, encontra-se disponível no ENVI (AIAZZI *et al.*, 2006), sendo particularmente aplicável nos casos de fusão de dados multiespectrais de alta resolução espacial. Inicialmente, simula-se uma banda pancromática a partir das bandas multiespectrais de resolução mais baixa. Em seguida, a transformação Gram-Schmidt é aplicada sobre a banda pancromática simulada e as bandas multiespectrais, na qual a banda pancromática simulada é empregada como a primeira banda. Feito isso, a primeira banda resultante da transformação Gram-Schmidt é substituída pela banda pancromática original. Por fim, a transformação Gram-Schmidt inversa é novamente aplicada, para gerar as bandas multiespectrais fusionadas (ENVI, 2009). Este método apresenta maior acurácia do que o de Análise das Principais Componentes (*Principal Components Analysis* - PCA), já que utiliza a função da resposta espectral do sensor para simular a banda pancromática (ITT, 2009). Em trabalho realizado por Pinho *et al.* (2005), objetivando a avaliação de métodos de fusão aplicados às imagens QuickBird, concluiu-se que os métodos “Principais Componentes e Gram-Schmidt, quando aplicados em fusões com as quatro bandas multiespectrais, apresentam os melhores resultados”. Neste trabalho, os autores também constataram a fidelidade espectral da imagem sintética com relação à imagem multiespectral original.

A partir das bandas fusionadas, foram criadas novas imagens resultantes da aplicação PCA e da 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). Também foi calculado o Índice de Vegetação por Diferença Normalizada (*Normalized Difference Vegetation Index* - NDVI). Ao final, as imagens foram recortadas pelo limite da área de estudo e reamostradas para que todas apresentassem resolução espacial de 2,5 m. Todo o processamento foi executado no sistema ENVI 4.7.

O passo seguinte foi a geração da grade de declividade utilizando o MDE TOPODATA e o interpolador TOPOTORASTER, disponível na extensão 3D Analyst do ArcGIS 9.0. Ao final, as bases topo-

gráficas foram igualmente recortadas pelo limite da área de estudo e reamostradas para 2,5 m.

No total, o banco de dados foi composto por 14 planos de informação assim distribuídos: quatro bandas multiespectrais do sistema ALOS (azul, verde, vermelho e infravermelho próximo) fusionadas, quatro principais componentes (PC), três componentes IHS, NDVI, MDE e grade de declividade.

### *Segmentação das imagens*

Foram efetuados três níveis de segmentação consecutivos, com a diminuição do fator de escala na execução de cada novo procedimento, originando, assim, um novo nível com maior número de objetos de tamanho reduzido.

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 (BAATZ; SCHÄPE, 2000). 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).

Devido à resolução espacial e à configuração morfométrica e de distribuição espacial dos alvos de interesse nas imagens utilizadas para classificação de cobertura da terra neste trabalho, o fator espectral ou cor tende a ser mais importante na segmentação do que a forma. Por isto, nas três segmentações efetuadas, ao parâmetro forma foi atribuído o valor 0,1, e por conseguinte, a cor assumiu o fator 0,9 (Tabela 1). Os parâmetros compacidade e suavidade foram estabelecidos de forma heurística em consonância com a diversidade de classes da cena. Como foram observados alvos de geometria mais regular, como áreas urbanas, queimadas, talhões agrícolas e de reflorestamento, e outros de fronteiras mais irregulares, como floresta, herbácea e herbácea rala, afloramento rochoso, atribuiu-se o valor 0,5 para o parâmetro compacidade, e assim, o fator suavidade assumiu o mesmo valor, visto que é complementar de 1.

Tabela 1 - Parâmetros dos três níveis de segmentação.

Nível	Fator de escala	Imagens com peso 1	Peso da cor	Peso da compacidade
3	500 N	DVI	0,9	0,5
2	250 N	DVI	0,9	0,5
1	160	4 bandas multispectrais	0,9	0,5

Org. das autoras

Para o segundo e terceiro níveis de segmentação, foi atribuído o peso 1 apenas para a imagem de NDVI, objetivando separar os objetos com vegetação daqueles sem vegetação. No primeiro nível de segmentação, foram utilizadas as quatro bandas multispectrais, visando discriminar os diversos tipos de alvos presentes na cena.

#### Geração da rede semântica

A rede semântica hierárquica, gerada de forma heurística, foi obtida diretamente no programa Definiens 7.04. A rede é constituída por descritores capazes

de discriminar as classes e, para estes, são definidos as funções e seus limiares, que, neste trabalho, foram estabelecidos iterativa e interativamente através da análise da distribuição espacial dos valores médios dos descritores e dos histogramas da função de pertinência dos objetos para cada classe.

As classes foram estabelecidas com base na análise visual das imagens fusionadas, sendo posteriormente ajustadas de forma iterativa com os resultados preliminares da classificação. Por fim, foram definidas sete classes de cobertura: afloramento rochoso, floresta, vegetação herbácea, queimada, reflorestamento, sombra e área urbana (Quadro 1).

Quadro 1 - Classes de cobertura da terra

Classes	Definição	Chave de interpretação	ALOS (Banda 2)
Afloramento rochoso	Rocha exposta com presença de pouca ou nenhuma vegetação.	<ul style="list-style-type: none"> <li>•Tonalidade – clara/escuro</li> <li>•Textura – intermediária</li> <li>•Forma – arredondada</li> <li>•Localização – encostas íngremes</li> <li>•Padrão – listrado</li> </ul>	
Floresta	Vegetação arbórea, em estágio médio e avançado de regeneração, e arbórea-arbustiva, em estágio inicial e médio.	<ul style="list-style-type: none"> <li>•Tonalidade – escura</li> <li>•Textura – intermediária a rugosa</li> </ul>	
Herbácea	Vegetação predominantemente composta por gramíneas e ervas.	<ul style="list-style-type: none"> <li>•Tonalidade - intermediária</li> <li>•Textura – lisa</li> </ul>	
Queimada	Área atingida por fogo.	<ul style="list-style-type: none"> <li>•Tonalidade - escura</li> <li>•Textura – lisa</li> </ul>	
Reflorestamento	Vegetação predominantemente arbórea e composta por eucaliptos.	<ul style="list-style-type: none"> <li>•Tonalidade - escura</li> <li>•Textura – lisa</li> </ul>	
Sombra	Áreas sem informação devido à ausência de incidência solar.	<ul style="list-style-type: none"> <li>•Tonalidade - escura</li> <li>•Textura - lisa</li> <li>•Localização – encostas</li> </ul>	
Urbana	Predominância de construções.	<ul style="list-style-type: none"> <li>•Tonalidade – clara/intermediária</li> <li>•Textura – rugosa</li> <li>•Padrão – reticulado</li> </ul>	

Org. das autoras.



A rede foi composta por descritores estatísticos e texturais. Os primeiros referem-se àqueles baseados no tratamento estatístico (média e desvio-padrão, no caso deste trabalho) dos valores dos pixels de cada objeto, enquanto os descritores texturais correspondem à distribuição espacial dos valores do pixel no respectivo objeto. A textura dos alvos terrestres, correspondente à distribuição espacial da variação de tons de cinza da imagem, é uma das mais importantes características utilizadas para a identificação de objetos em uma imagem e, no entanto, difícil de ser descrita (HARALICK et al., 1973).

Para o cálculo dos descritores texturais, feito pelo Definiens 7.04, são utilizadas as matrizes de co-ocorrência do nível de cinza (Gray Level Cooccurrence Matrix - GLCM) propostas por Haralick et al. (1973). Este método extrai a textura pela relação espacial existente entre os níveis de cinza ao longo de diferentes direções, comumente utilizando como vizinhança uma janela de tamanho 3x3, isto é, 3 pixels por 3 pixels. Devido à sua simplicidade e eficácia, é considerada por muitos autores como referência (ITO et al., 2011). Entre os 14 parâmetros de textura criados por Haralick et al. (1973), quatro são considerados de maior relevância (ITO et al., 2011): (1) segundo momento angular ou energia – mede a uniformidade da textura, ou seja, a quantidade de repetição de pares de pixels; (2) entropia – mede a desordem da imagem, ou seja, corresponde a uma medida inversamente proporcional ao segundo momento angular; (3) contraste – corresponde à diferença entre os valores de níveis de cinza mais altos e mais baixos; e (4) homogeneidade – mede a homogeneidade da imagem, isto é, valores elevados correspondem a pequenas diferenças tonais entre os pixels vizinhos. O contraste foi a única métrica textural utilizada neste trabalho.

#### *Avaliação da acurácia da classificação de cobertura da terra*

Para a avaliação da acurácia das classificações, foram coletadas cerca de 700 amostras de referência, correspondendo a segmentos, localizadas aleatoriamente e estratificadas pela área esperada das sete classes. As amostras de referência foram identificadas com base nas ortofotos geradas por le-

vantamento aerofotogramétrico realizado em 2005, com resolução espacial original de 0,7 m e escala aproximada de 1:30.000, e foram utilizadas para dirimir eventuais conflitos de interpretação. Não se prescindiu da informação visual extraída das imagens ALOS, a qual auxiliou na identificação das classes das amostras de referência.

Tentou-se obedecer ao número mínimo de 50 amostras por classe, definido por Congalton e Green (2009), para mapas cobrindo menos de um milhão de acres e com menos de 12 classes. No entanto, devido à reduzida área de algumas classes, não foi possível a observância deste número para todas elas. Congalton e Green (2009) também afirmam que a unidade da amostra deve ser um polígono, caso o mapa a ser avaliado tenha esta estrutura, como aqueles oriundos de processos de segmentação.

A seguir, foram construídas as matrizes de erros, também denominadas como matrizes de confusão, compostas, nas colunas, pelas amostras de referência e, nas linhas, pelas classes obtidas na classificação. As matrizes expressam os erros de omissão e erros de comissão. Os primeiros correspondem às amostras que não foram classificadas de acordo com as classes de referência, e estão representados nas linhas da matriz. Por sua vez, os erros de comissão correspondem às amostras de referência classificadas erroneamente como pertencentes a outras classes, e estão representados nas colunas da matriz. 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, o 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, o qual representa a relação entre o número de amostras classificadas corretamente da classe  $k$  e o número total de amostras classificadas da classe  $k$ ; (d) índice Kappa ( $K$ ) (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 resultado do índice *Kappa* varia de -1 a 1, e quanto mais próximo de 1, maior a acurácia da classificação. De acordo com Landis e Koch (1977), a qualidade da classificação pode ser definida em função dos seguintes intervalos de índice *Kappa*: [ $<0,00$ ]: muito ruim; [ $0,00 - < 0,20$ ]: ruim; [ $0,20 - < 0,40$ ]: aceitável; [ $0,40 - < 0,60$ ]: bom; [ $0,60 - < 0,80$ ]: muito bom; [ $0,80 - 1,00$ ]: excelente.


## RESULTADOS E DISCUSSÃO

### *Cobertura da terra de Nova Friburgo*

Foram gerados três níveis de segmentação, dando origem a objetos com diferentes tamanhos

de acordo com o seu nível hierárquico (Figura 3). O terceiro nível de segmentação, gerado com fator de escala 500 e peso 1 para a camada NDVI, apresenta menor detalhamento e a delimitação de objetos com e sem vegetação. No segundo nível, gerado com fator de escala 250 e peso 1 para a camada NDVI, os segmentos delimitam objetos de vegetação de acordo com a iluminação das encostas. Por fim, o primeiro nível apresenta maior detalhamento e foi gerado com fator de escala 160 e peso 1 para as bandas multiespectrais; observa-se neste nível a maior discriminação de alvos da cena tanto na área urbana como nos segmentos de vegetação.

Figura 3. Níveis de segmentação por fator de escala: 500 (3), 250 (2) e 160 (1).



Org. das autoras.

A classificação de cobertura da terra de Nova Friburgo foi gerada através de rede semântica heurística constituída por três níveis de segmentação. A rede foi composta por descritores estatísticos e texturais utilizando as bandas multiespectrais, as imagens originárias de operações aritméticas entre bandas multiespectrais, as imagens oriundas de operações de transformação sobre bandas multiespectrais e a grade de declividade.

No terceiro nível da rede semântica, correspondente à segmentação com fator de escala 500

(Figura 4), o brilho foi utilizado para discriminar as áreas de sombra e não-sombra. A classe sombra apresenta baixa reflectância nas três bandas do visível, correspondente às encostas orientadas para o quadrante sul/oeste, entre os azimutes  $180^\circ$  a  $270^\circ$ , que recebiam pouca ou nenhuma iluminação solar direta no momento da passagem do satélite. Nestas encostas, não é possível identificar a cobertura da terra.

Figura 4. Rede semântica hierárquica correspondente ao terceiro nível de segmentação.



Org. das autoras.

O segundo nível utilizou a segmentação com fator de escala 250 (Figura 5), e a classe arbórea-arbustiva foi discriminada a partir dos descritores referentes à soma das médias das bandas 2 (verde) e 3 (vermelho), produzindo um descritor customizado resultante da operação aritmética de adição entre tais bandas (Figura 6). Como o afloramento rochoso, situado em encosta menos iluminada, confundia-se com esta classe, foi utilizada a média da segunda componente principal. Segundo Eastman (2006), a segunda componente principal é a mais importante para detectar variações na cobertura vegetal. Ela apresenta valores elevados para respostas no infravermelho próximo, e negativos na porção do visível do espectro eletromagnético. Daí, ela ter sido utilizada para diferenciar as classes de vegetação mais densas (classe arbórea-arbustiva, a qual contém as subclasses floresta e reflorestamento) das demais classes.

No primeiro nível com fator de escala 160 (Figura 7), as classes floresta e reflorestamento, pertencentes à classe arbórea-arbustiva, foram discriminadas a partir da soma das médias da segunda e quarta componentes principais. Conforme exposto anteriormente, a segunda componente principal é importante para detectar variações na cobertura vegetal, de forma geral. Por outro lado, a quarta componente principal realça o contraste entre as bandas do visível e do infravermelho, e este é justamente o caso da classe

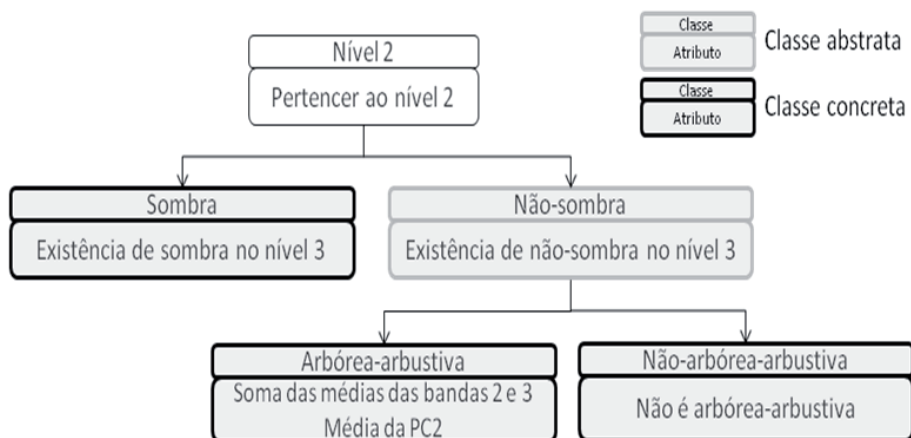
reflorestamento, que possui alta correlação entre as bandas do visível, em média com baixa resposta, e elevada resposta na banda do infravermelho próximo, maior inclusive do que a apresentada por floresta. A soma dessas duas componentes realça, portanto, as classes floresta e reflorestamento.

Devido à confusão entre o afloramento rochoso e outras classes, foram utilizados três descritores para discriminá-lo: NDVI, soma das médias das bandas 2 (verde), 3 (vermelho) e 4 (infravermelho próximo), e a declividade. O NDVI auxiliou na diferenciação de alvos com vegetação e sem vegetação. Solos e rochas apresentam resposta elevada nas bandas 2, 3 e 4, e sua soma acaba por realçar a classe afloramento rochoso. A declividade auxiliou na discriminação dos afloramentos, pois estes se encontram situados em encostas íngremes. A queimada foi discriminada a partir da média da segunda componente principal e média da banda 4 (infravermelho próximo), visto que essas bandas realçam vegetação, a qual é inexistente na classe queimada, e por este motivo, permitem identificá-la com facilidade em vista dos baixos valores a ela associados. Para a classe urbana, foram utilizados os descritores GLCM contraste da banda 4 (infravermelho próximo), desvio-padrão da terceira componente principal, bem como a soma das médias da primeira e terceira principais componentes, da componente intensidade I (IHS) e da banda 1 (azul).

Tanto o desvio-padrão quanto o contraste são descritores que expressam textura, sendo assim importantes para a discriminação de áreas urbanas devido à sua rugosidade. A primeira componente principal concentra a maior variância da informação contida no conjunto de componentes, típica de áreas urbanas, que compreendem uma grande heterogeneidade de alvos. Por sua vez, a terceira componente usualmente contém

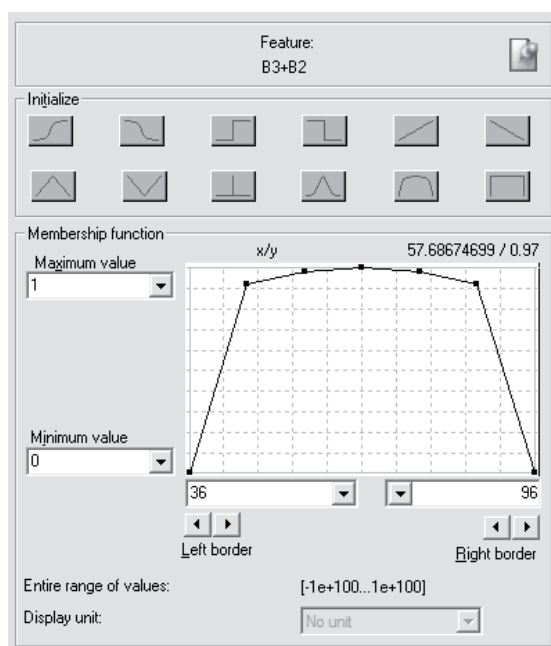
variação aleatória ou ruído, o que também caracteriza as áreas urbanas, dada a enorme variabilidade de seus materiais constituintes e respectivas respostas espectrais. Por fim, a classe herbácea foi identificada por exclusão, correspondendo à não-existência de todas as outras classes.

Figura 5. Rede semântica hierárquica correspondente ao segundo nível de segmentação.



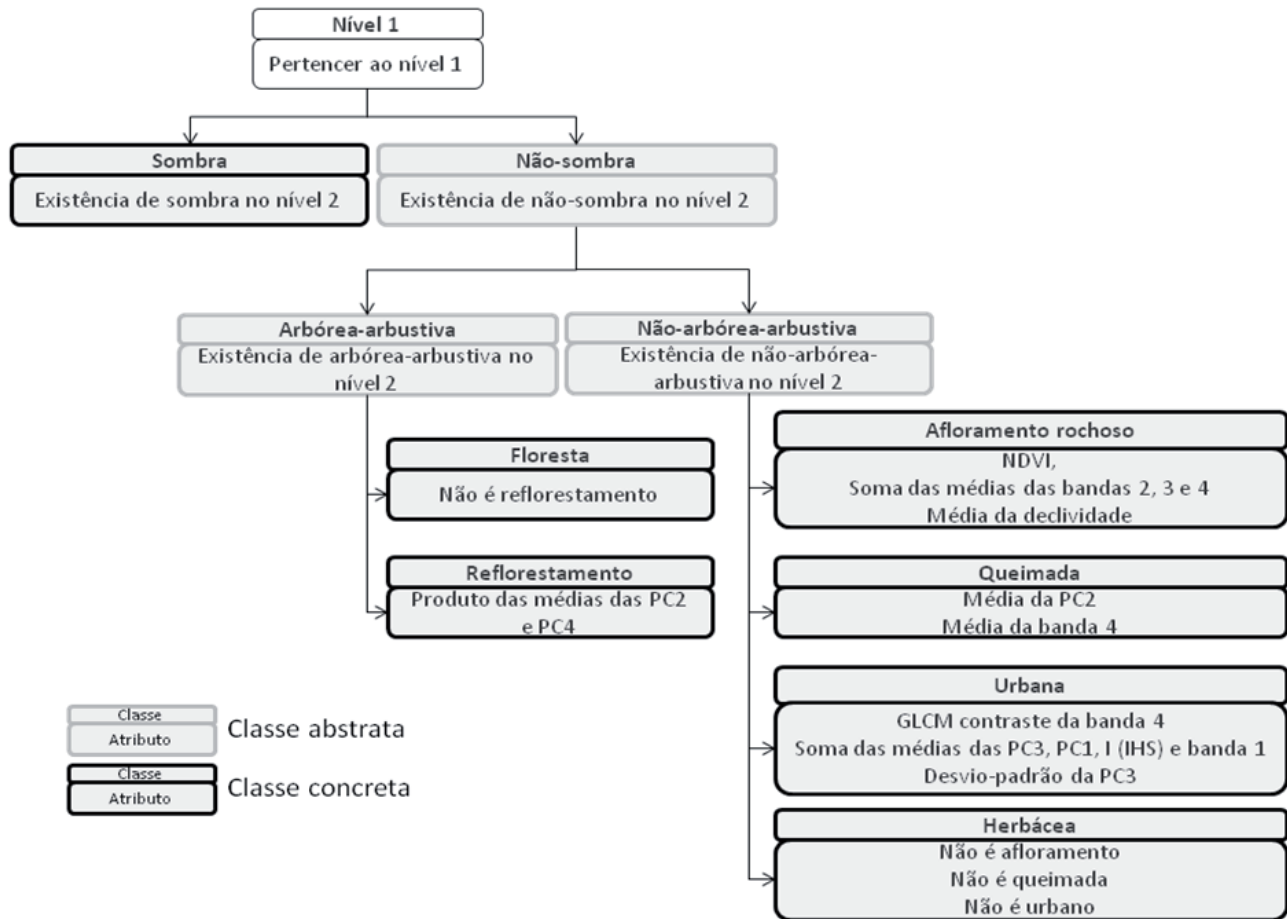
Org. das autoras.

Figura 6. Função de pertinência fuzzy do descritor “soma das médias das bandas 2 e 3”



Org. das autoras.

Figura 7. Rede semântica hierárquica correspondente ao primeiro nível de segmentação



Org. das autoras

O mapa de cobertura da terra de Nova Friburgo produzido neste trabalho abrange, além dos limites municipais, uma área de 1 km no entorno do município (Figura 8). Assim, de acordo com este mapeamento, aproximadamente 70% da área de estudo é coberta por florestas (Tabela 2). Como o município está situado na região serrana, este número expressa os remanescentes da Mata Atlântica localizados nas encostas íngremes e, portanto, de menor acessibilidade da Serra do Mar. A vegetação herbácea, representando cerca de 25% da área de estudo, corresponde a áreas desmatadas, bem como com uso agropecuário. A área urbana, localizada principalmente nos alvéolos e vales, corresponde a cerca de 4% da área de estudo e concentra-se ao longo do Rio Bengala, correspondendo à área urbana localizada no distrito-sede e em Conselheiro Paulino. O restante das classes de cobertura representa

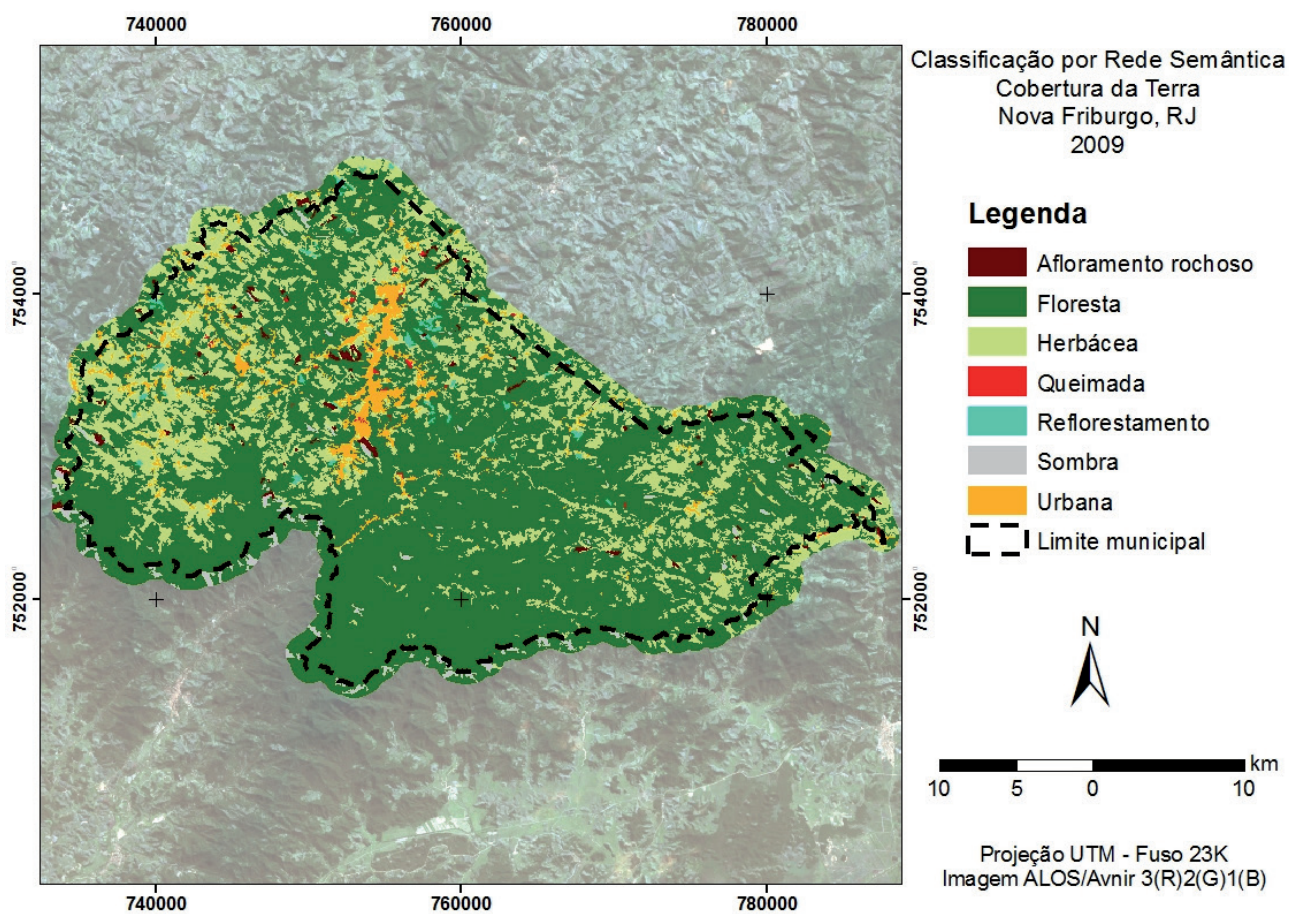
menos de 1% da área de estudo. Os afloramentos rochosos localizam-se em encostas muito íngremes, onde, devido à declividade, não há fixação do solo. O reforestamento corresponde ao plantio de eucalipto.

Convém mencionar que a informação extraída sobre a cobertura da terra em Nova Friburgo previamente à ocorrência dos deslizamentos em janeiro de 2011, quando conjugada às informações das respectivas cicatrizes (obtidas igualmente por imagens orbitais), constituem importante fonte de dados para determinar a extensão e magnitude desses eventos no município, e com isso, subsidiar o processo de tomada de decisão referente a ações preventivas da defesa civil, bem como a iniciativas de reordenamento territorial, buscando o reassentamento de populações e de usos rurais em áreas menos vulneráveis à incidência de movimentos de massa.

Tabela 2 - Área da classificação de cobertura da terra de Nova Friburgo e seu entorno.

Classe	Área	
	km <sup>2</sup>	%
Floresta	761,1	68,6
Herbácea	272,6	24,6
Urbana	42,6	3,8
Sombra	16,9	1,5
Afloramento rochoso	8,9	0,8
Reflorestamento	5,6	0,5
Queimada	1,9	0,2

Figura 8. Classificação de cobertura da terra de Nova Friburgo.



Org. das autoras.

### Acurácia das classificações de cobertura da terra

A Tabela 3 refere-se à matriz de erros da classificação de cobertura da terra de Nova Friburgo. O índice de exatidão global alcançado foi de 91%, e o índice *Kappa*, de 0,85. Este valor indica excelente qualidade da classificação quanto à acurácia, de acordo com Landis e Koch (1977).

Todas as classes apresentaram índice de exatidão do produtor acima de 60%, ou seja, com erros de

omissão abaixo de 40%, com exceção do afloramento rochoso, que apresentou uma alta confusão com a classe herbácea, a despeito da utilização de três descritores para discriminá-lo. Em relação aos erros de comissão, todas as classes apresentaram erros abaixo de 30%, ou seja, o menor índice de exatidão do usuário foi de 70%, correspondente à classe herbácea, confundindo-se, entre outras, com as classes afloramento rochoso e urbana. As classes restantes apresentaram índice acima de 96%, significando que as amostras classificadas correspondiam à classe das amostras coletadas.

Tabela 3 - Matriz de erros da classificação de cobertura da terra.

Classificadas	Amostras de Referência								
	Classes	Afloramento	Floresta	Herbácea	Queimada	Reflorestamento	Sombra	Urbana	Total classificadas
Afloramento	2								12
Floresta	24	22	26				7		439
Herbácea	16	39	01			11	08		129
Queimada					7				7
Reflorestamento						41			4
Sombra	12						82		9
Urbana			11					53	55
Total coletadas	31	4269	38			21	45	61	685
Exatidão do Produtor	39%9	9%	97%8		8%	67%6	2%	87%	91%
Exatidão do Usuário	100%9	6%	70%		100%	100%9	7%9	6%	

### CONCLUSÕES

Considerando o índice *Kappa* global, pode-se afirmar que o mapa de cobertura da terra apresentou excelente qualidade quanto à acurácia da classificação, sendo semelhante aos obtidos em outras classificações de cobertura da terra (REGO, 2003; KANJIR *et. al.*, 2010; KASS, 2010) utilizando OBIA e que possuíam número de classes e resolução espacial semelhantes aos adotados neste trabalho.

Em relação aos erros de omissão e comissão das classes de cobertura da terra, constatou-se que a qualidade da classificação quanto à acurácia é muito boa, pois todos os erros ficaram abaixo de 40%, com exceção da classe afloramento rochoso. O melhor desempenho coube à classe floresta, que obteve erros inferiores a 5%, seguida pelas classes queimada e urbana.

Com relação aos atributos empregados, a textura, que se constitui em um dos principais critérios utilizados para a interpretação de imagens, pode ser apenas matematicamente calculada quando os pixels estão agrupados em objetos. Desta forma, nas técnicas tradicionais de classificação pixel a pixel, este critério assim como outros critérios derivados de dados extraídos de segmentos, a exemplo da forma dos alvos, topologia, entre outros, não podem ser adotados. Neste trabalho, a textura auxiliou na discriminação da área urbana, a qual apresentou erros de comissão e omissão inferiores a 85%.

A introdução de dados auxiliares na base de conhecimento a ser utilizada na classificação de imagens é outro diferencial a ser destacado em OBIA. No presente trabalho, destacam-se a declividade, para a discriminação dos afloramentos rochosos, e as principais componentes, que auxiliaram na discriminação

entre a floresta e o reflorestamento com eucalipto. Ademais, cumpre salientar que o método de OBIA, ao semiautomatizar as rotinas de classificação de imagens, representa uma substancial economia de capital humano, visto que o procedimento para a interpretação visual de uma cena como a utilizada neste trabalho, com grande heterogeneidade de classes e fragmentação da paisagem, demandaria uma elevada quantidade de homens-hora para a sua realização.

No entanto, devem-se mencionar algumas limitações para a classificação decorrentes de características inerentes à cena. Uma delas refere-se à diferença de intensidade de incidência solar nas encostas em função da declividade e orientação das vertentes, principalmente em áreas montanhosas, dificultando principalmente a distinção dos estágios sucessionais da floresta.

Outra dificuldade foi a discriminação dos cultivos, que, por serem compostos predominantemente por plantações de porte rasteiro, características das lavouras temporárias, apresentam resposta espectral e textura semelhantes à vegetação herbácea, não sendo possível a discriminação de lavouras neste estudo. A utilização de índices de forma para a discriminação dos talhões, caracterizados por apresentar geometria regular, não foi possível, visto que a segmentação não os individualizou por completo.

Todas as dificuldades relatadas relacionam-se à ausência de informações na base de dados e/ou aos limites do método de classificação. A primeira será minimizada à medida que mais informações sejam adicionadas, como bandas espectrais de resolução mais fina, disponíveis em sensores hiperespectrais, bem como modelos digitais de altura, capazes de fornecer informações acerca do porte dos alvos. Em relação à limitação do método, destaca-se a segmentação, que neste trabalho não foi capaz de delimitar objetos puros, isto é, alvos de forma individualizada. No entanto, a comunidade científica de OBIA dedica-se atualmente à concepção de novos algoritmos destinados a refinar o procedimento de segmentação, no sentido de criar fronteiras mais próximas aos reais limites dos alvos presentes na cena.

## AGRADECIMENTOS

As autoras agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela bolsa de pós-doutorado, e à Fundação de Auxílio à Pesquisa do Rio de Janeiro (FAPERJ), pelo financiamento deste trabalho de pesquisa. As autoras gostariam igualmente de manifestar o seu agradecimento aos revisores, cujas críticas contribuíram para a melhora da qualidade final do artigo.

## REFERÊNCIAS

AIAZZI, B.; BARONTI, S.; SELVA, M.; ALPARONE, L. Enhanced Gram-Schmidt spectral sharpening based on multivariate regression of MS and pan data. In: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2006, Denver. *Proceedings...* Denver: IGARSS, 2006. p. 3806-3809.

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, 2000. p. 12-23.

BIAN, L. Object-oriented representation of environmental phenomena: Is everything best represented as an object? *Annals of the Association of American Geographers*, v. 97, n. 2, p. 267-281, 2007.

BLASCHKE, T. Object-based contextual image classification built on image segmentation. In: IEEE WORKSHOP ON ADVANCES IN TECHNIQUES FOR ANALYSIS OF REMOTELY SENSED DATA, 2003, Washington, D.C. *Proceedings...* Washington: IEEE, 2003. p. 113-119.

BLASCHKE, T.; LANG, S.; HAY, G. J. *Object-based image analysis spatial concepts for knowledge-driven remote sensing applications*. Berlin: Springer, 2008. 828p.



- 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, p. 6613-6620, 2009.
- 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.
- CIDE - FUNDAÇÃO CENTRO DE INFORMAÇÕES E DADOS DO RIO DE JANEIRO. *Índice de Qualidade de Municípios Verde II*. Rio de Janeiro: Secretaria de Estado de Planejamento, Desenvolvimento Econômico e Turismo, 2003. 154p.
- CONGALTON, R.; GREEN, K. *Assessing the accuracy of remotely sensed data: Principles and practices*. Boca Raton: CRC/Taylor & Francis, 2009. 183p.
- CREPANI, E.; MEDEIROS, J. S.; HERNANDEZ-FILHO, P.; FLORENZANO, T. G.; DUARTE, V. Uso de sensoriamento remoto no zoneamento ecológico-econômico. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador, BA. Anais ... São José dos Campos: INPE, 1996. p. 129-135.
- DANTAS, M. E. Geomorfologia do estado do Rio de Janeiro. In: SILVA, L. C.; CUNHA, H. C. S. *Geologia do Estado do Rio de Janeiro: texto explicativo do mapa geológico do Estado do Rio de Janeiro*. Brasília: CPRM, 2001.
- EASTMAN, J. R. *IDRISI Andes guide to GIS and image processing*. Worcester, USA: Clark Labs, 2006.
- ITT. *ENVI User's Guide - ENVI Version 4.7*. Boulder, CO: ITT Visual Information Solutions, 2009.
- GAO, Y.; MAS, J. F.; MAATHIUS, B. H. P.; XIANGMIN Z.; DIJK P. M. V. Comparison of pixel-based and object oriented image classification approaches – a case study of a coal fire area, Wuda, inner Mongolia, China. *International Journal of Remote Sensing*, v. 27, p. 4039-4055, 2006.
- GAO, Y.; MAS, J. F. MODIS EVI as an ancillary data for an object-based image analysis with multi-spectral MODIS data. In: GEOGRAPHIC OBJECT-BASED IMAGE ANALYSIS, 2., 2008, Alberta, Canada. *Proceedings...* Alberta: University of Calgary, 2008.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, v. 3, p. 610-620, 1973.
- 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. (Eds.) *Object-based image analysis spatial concepts for knowledge-driven remote sensing applications*. Berlin: Springer, 2008. p.75-89.
- IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. *Cidades @*. Disponível em: <<http://www.ibge.gov.br/cidadesat>>. Acesso em: 09 ago. 2011a.
- \_\_\_\_\_. *Ortofotos 1:25.000 - Rio de Janeiro*. Disponível em: <[ftp://geoftp.ibge.gov.br/mapas/ortofoto/Projeto\\_RJ25/TIF/](ftp://geoftp.ibge.gov.br/mapas/ortofoto/Projeto_RJ25/TIF/)>. Acesso em: 12 fev. 2011b.
- ITO, R. H.; KIM, H. Y.; SALCEDO, W. J. *Classificação de texturas invariante a rotação usando matriz de co-ocorrência*. Disponível em: <<http://www.lps.usp.br/~hae/Ito-Kim-Salcedo-Textura.pdf>>. Acesso em 20 jul. 2011.
- KANJIR, U.; VELJANOVSKI, T.; MARSETIÈ, A.; OŠTI, K. Application of object based approach to heterogeneous land cover/use. *The International Archives*

*of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. XXXVIII-4/C7, 2010.

KASS, S.; NOTARNICOLA, C.; ZEBISCH, M. Object-based approach to map semi-natural areas in mountain region with high spatial resolution images. In: GEOGRAPHIC OBJECT-BASED IMAGE ANALYSIS, 3., 2010, Ghent, Belgium. *Proceedings...* Ghent: University of Ghent, 2010.

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. *Proceedings...* Salzburg: University of Salzburg, Austria 2006.

LANDIS, J.; KOCH, G. The measurement of observer agreement for categorical data. *Biometrics*, v. 33, p. 159-174, 1977.

LANG, S. Object-based image analysis for remote sensing applications: modeling reality – dealing with complexity. 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. 3-28.

LEONARDI, F. *Abordagens cognitivas e mineração de dados aplicadas a dados ópticos orbitais e de laser para a classificação de cobertura do solo urbano*. 2010. 134 f. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010.

LEONARDI, F.; ALMEIDA, C. M.; FONSECA, L. M. G.; CAMARGO, F. F. Avaliação comparativa entre classificação supervisionada por regiões e orientada a objeto para imagens de alta resolução espacial: CBERS 2B-HRC e QuickBird. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal, RN. *Anais ...* São José dos Campos: INPE, 2009. p. 981-988.

MASCARENHAS, L. M. A.; FERREIRA, M. E.; FERREIRA, L. G. Sensoriamento remoto como ins-

trumento de controle e proteção ambiental: análise da cobertura vegetal remanescente na bacia do rio Araguaia. *Sociedade & Natureza*, v. 21, n. 1, p. 5-18, 2009.

MAVRANTZA, O.; ARGIALAS, D. An object-oriented image analysis approach for the identification of geologic lineaments in a sedimentary geotectonic environment. In: BLASCHKE, T.; LANG, S.; HAY, G. J. *Object-based image analysis spatial concepts for knowledge-driven remote sensing applications*. Berlin: Springer, 2008. p. 383-398.

METTERNICHTA, G.; HURNIB, L.; GOGU, R. Remote sensing of landslides: An analysis of the potential contribution to geo-spatial systems for hazard assessment in mountainous environments. *Remote Sensing of Environment*, v. 98, n. 2-3, p. 284-303, 2005.

MOORE, T. Geospatial expert systems. In: OPENSHAW, S.; ABRAHART, R. J. (Eds.). *Geocomputation*. London: Taylor & Francis, 2000. 436 p.

NAVULUR, K. *Multispectral image analysis using the object-oriented paradigm*. Boca Raton: Taylor & Francis Group, 2006. 165p.

PINHO, C. M. D.; RENNÓ, C. D.; KUX, H. J. H. Avaliação de técnicas de fusão aplicadas à imagem QuickBird. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia, GO. *Anais...* São José dos Campos: INPE, 2005. p. 4225-4232.

REGO, L. F. G. *Automatic land-cover classification derived from high-resolution IKONOS satellite image in the urban Atlantic Forest in Rio de Janeiro, Brazil, by means of an object-oriented approach*. 2003. 179f. Tese (Doutorado em Ciências Florestais). Albert-Ludwigs-Universität, Freiburg, 2003.

TÖNJES, R.; GROWE, S.; BÜCKNER, J.; LIEDTKE, C.-E. Knowledge-based interpretation of remote sensing images using semantic nets. *Photogrammetric Engineering & Remote Sensing*, v. 65, n. 7, p. 811-821, 1999.

VALERIANO, M. M. Modelo digital de variáveis morfométricas com dados SRTM para o território nacional: o projeto TOPODATA. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia, GO. *Anais ...* São José dos Campos: INPE, 2005. p. 1-8.

WHITESIDE, T. G.; BOGGS, G. S.; MAIER, S. W. Comparing object-based and pixel-based classifications for mapping savannas. *International Journal of Applied Earth Observation and Geoinformation*, v. 13, n. 6, p. 884-893, 2011.