



Boletim de Ciências Geodésicas

ISSN: 1413-4853

bcg_editor@ufpr.br

Universidade Federal do Paraná

Brasil

NUNES FRANCISCO, CRISTIANE; DE ALMEIDA, CLÁUDIA MARIA
AVALIAÇÃO DE DESEMPENHO DE ATRIBUTOS ESTATÍSTICOS E TEXTURAIS EM
UMA CLASSIFICAÇÃO DE COBERTURA DA TERRA BASEADA EM OBJETO
Boletim de Ciências Geodésicas, vol. 18, núm. 2, abril-junio, 2012, pp. 300-326
Universidade Federal do Paraná
Curitiba, Brasil

Disponível em: <http://www.redalyc.org/articulo.oa?id=393937724008>

- Como citar este artigo
- Número completo
- Mais artigos
- Home da revista no Redalyc

redalyc.org

Sistema de Informação Científica

Rede de Revistas Científicas da América Latina, Caribe, Espanha e Portugal

Projeto acadêmico sem fins lucrativos desenvolvido no âmbito da iniciativa Acesso Aberto

AVALIAÇÃO DE DESEMPENHO DE ATRIBUTOS ESTATÍSTICOS E TEXTURAIS EM UMA CLASSIFICAÇÃO DE COBERTURA DA TERRA BASEADA EM OBJETO

*Evaluating the performance of statistical and textural attributes for an object-based
land cover classification*

CRISTIANE NUNES FRANCISCO¹
CLÁUDIA MARIA DE ALMEIDA²

¹ Universidade Federal Fluminense
Instituto de Geociências - Departamento de Análise Geoambiental
Campus da Praia Vermelha, Boa Viagem, Niterói - RJ – 24210-310
crisnf@vm.uff.br

² Instituto Nacional de Pesquisas Espaciais
Av. dos Astronautas, Caixa Postal 515 – 12245-970
São José dos Campos - SP, Brasil
almeida@dsr.inpe.br

RESUMO

Este artigo tem como objetivo avaliar o desempenho de duas redes semânticas geradas por mineração de dados para a classificação de cobertura da terra por meio de análise de imagens baseada em objetos geográficos (*GEographic Object-Based Image Analysis* – GEOBIA). Para isto, uma rede utilizou-se de descritores estatísticos e texturais, e a outra, apenas de descritores estatísticos. A base de dados foi constituída de imagens ALOS/AVNIR fusionadas com imagens ALOS/PRISM e dados de relevo provenientes do banco de dados TOPODATA. A área de estudo corresponde ao município de Nova Friburgo, com 933 km², localizado na região serrana do estado do Rio de Janeiro. O índice *Kappa* alcançado pela classificação baseada em árvore de decisão composta por descritores estatísticos e texturais foi de 0,81, enquanto que este valor para a classificação derivada apenas de descritores estatísticos foi de 0,84. Considerando os índices alcançados, conclui-se que ambos os resultados apresentam excelente qualidade quanto à acurácia da classificação. O teste de hipótese entre os dois índices mostra, com nível de significância de 5%, que não há diferenças entre as duas classificações quanto à acurácia.

Palavras-Chave: Redes Semânticas; Classificação de Imagens; Mineração de Dados; ALOS.

ABSTRACT

This paper aim at evaluating the performance of two semantic networks generated by data mining for classifying land cover using GEographic Object-Based Image Analysis (GEOBIA). The first one used statistical and texture attributes, and the second network employed only statistical attributes. The attributes were extracted from ALOS/AVNIR images pan-sharpened with ALOS/PRISM. Relief information provided by the TOPODATA geomorphometric database was also used as input data. The studied area is Nova Friburgo County, with an extension of 933 km², located in the mountainous region of Rio de Janeiro State. The Kappa index obtained by the classification based on statistical and texture attributes was 0.81, while the result for the classification derived only from statistical attributes achieved 0.84. These values corroborate the excellent accuracy of both results. The statistical hypothesis test between the two indices at 95% confidence interval demonstrated that there is no difference between the two classification accuracies.

Keywords: Semantic Networks; Images Classification; Data Mining; ALOS.

1. INTRODUÇÃO

As primeiras classificações automáticas de imagens de sensoriamento remoto consideravam o valor digital observado em cada pixel. No início da década de 1980, foram concebidos métodos de classificação de imagens baseados em regiões, isto é, agrupamentos rotulados de pixels contíguos, também denominados segmentos, segundo critérios de semelhança do valor digital e obedecendo a limiares de área.

Passadas duas décadas, no início de 2000, surge uma nova abordagem para a interpretação de imagens de sensoriamento remoto ancorada no paradigma de Orientação a Objeto: a análise de imagem orientada a objeto, ou, como preferem alguns autores mais recentemente, a análise de imagem geográfica baseada em objeto (*GEographic Object-Based Image Analysis* - GEOBIA). Os procedimentos supervisionados (em que o usuário seleciona as amostras de treinamento) e não-supervisionados (em que não ocorre a interferência do usuário) de classificação automática pixel a pixel ou baseado em regiões até então se utilizavam de métodos estatísticos ou não-paramétricos para a interpretação de alvos, ao passo que a análise de imagem baseada em objeto, sempre fundamentada em um método supervisionado não-paramétrico de classificação, pressupõe necessariamente a existência de um modelo de conhecimento atrelado ao processo de interpretação da cena, o qual explicita o conhecimento do intérprete, tornando-o passível de reaplicação em outras áreas com características semelhantes às observadas quando de sua elaboração. Métodos não paramétricos são aqueles que não pressupõem nenhuma distribuição estatística conhecida para descrever o comportamento dos dados, não operando, portanto, com parâmetros estatísticos, a exemplo de média e

variância.

No paradigma de Orientação a Objeto (OO), o objeto pode ser entendido como a instância de uma classe, sendo que a classe representa um conjunto de objetos com características afins. As características de um objeto são denominadas atributos, e as funções para manipulá-los ou retratar seu comportamento são chamadas de métodos. Há ainda outros conceitos importantes, como o de herança (ou generalização), que se refere a um mecanismo pelo qual uma classe (subclasse) pode herdar de outra classe (superclasse) seus comportamentos (métodos) e variáveis possíveis (atributos) (DALL'OGGIO, 2009). Um exemplo disto é o fato de que uma superclasse de vegetação lega para as subclasses vegetação arbórea e vegetação rasteira os seus altos valores de NDVI.

Outros conceitos fundamentais em OO dizem respeito ao encapsulamento, que consiste na separação de aspectos internos e externos de um objeto. Este mecanismo é utilizado amplamente para impedir o acesso direto ao estado de um objeto (seus atributos), disponibilizando externamente apenas os métodos que alteram estes estados. Por exemplo, o usuário não precisa conhecer em detalhe os valores digitais de cada pixel referente a cada um dos atributos utilizados no processo de interpretação para manipulá-lo e classificá-lo. Há ainda o conceito de abstração, que representa a habilidade de se concentrar nos aspectos essenciais de um contexto qualquer, ignorando características menos importantes ou acidentais. E, por fim, há o conceito de polimorfismo, segundo o qual classes derivadas de uma mesma superclasse possuem métodos iguais (com mesma nomenclatura e parâmetros), mas comportamentos diferentes, redefinidos em cada uma das classes-filha (DALL'OGGIO, 2009).

Em GEOBIA, o modelo de conhecimento é expresso, a princípio, por uma rede semântica, constituída por uma estrutura hierárquica de classes, às quais estão associados objetos da imagem. Redes semânticas são grafos que formalizam e representam o conhecimento humano por meio de um conjunto de nós conectados por arcos. De modo geral, os nós representam conceitos, e os arcos, as relações entre eles (TÖNJES et al., 1999). O pixel não poderia atuar como objeto em GEOBIA, pois não possui relação direta, ou semântica propriamente dita, com alvos de interesse na cena, e ademais, o pixel não permite a extração de atributos, ao passo que o segmento ou região sim. Por este motivo, o segmento ou região passa a ser denominado como "objeto" em GEOBIA, constituindo a unidade primitiva para a classificação (NAVULUR, 2006). Em termos gerais, o objeto corresponde a uma região discreta de uma imagem que é internamente coerente e diferente do seu entorno (CASTILLA; HAY, 2008).

Em suma, o pixel não atende aos requisitos conceituais de "objeto" segundo o paradigma de OO, ao contrário do segmento, o qual possui tratabilidade para a extração de atributos, a partir dos quais é construído o modelo de conhecimento expresso fundamentalmente pela rede semântica de interpretação da imagem.

A abordagem GEOBIA permitiu outros avanços em interpretação de imagens, como: i) a utilização de parâmetros 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; MARPU, 2009; CAMARGO et al., 2009a); ii) a possibilidade de se operar com mais de um nível de segmentação, que podem ou não estar associados a classificações; e iii) a sofisticação dos algoritmos de segmentação, que passaram a incorporar parâmetros de forma, como compactidade (*compactness*) e suavidade (*smoothness*).

É importante salientar, contudo, que GEOBIA não necessariamente pressupõe múltiplos níveis de segmentação, e tampouco todos os níveis de segmentação precisam estar classificados. No caso de haver múltiplos níveis de segmentação, todos eles se relacionam entre si por meio do algoritmo *Fractal Net Evolution Approach* – FNEA, denominado na plataforma Definiens Developer simplesmente como algoritmo de segmentação multirresolução. Isto quer dizer que as fronteiras que já existem no banco de dados da análise baseada em objeto serão sempre respeitadas com a inclusão de novos níveis de segmentação, sejam eles de escala mais grosseira (objetos maiores) ou mais refinada (objetos menores). Por este motivo, diz-se que um objeto possui identidade própria (PINHO, 2005), pois o sistema armazena em sua memória quem são seus vizinhos no nível em que se encontra tal objeto, os superobjetos a que pertence em níveis superiores de segmentação e, da mesma forma, quem são seus subobjetos em níveis inferiores. Atualmente, o modelo de conhecimento em GEOBIA extrapolou a rede semântica e evoluiu para o que se convencionou chamar árvore de processos, a qual explicita toda e qualquer operação realizada para a interpretação de uma cena, incluindo as etapas de segmentação, classificação (rede semântica propriamente dita) e rotinas de pós-processamento ou pós-classificação.

A construção da base de conhecimento em GEOBIA, representada fundamentalmente 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 quais atributos descrevem melhor as classes às quais os objetos 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, ou de forma automática, através da aplicação de técnicas de mineração de dados. Estas consistem na extração de conhecimento de uma base com grande volume de dados por meio de métodos inteligentes. O modelo derivado da mineração pode ser representado de várias formas, entre elas, as árvores de decisão, representadas por um fluxograma com estrutura de árvore e que são facilmente convertidas em regras de classificação (HAN; KAMBER, 2006).

O poder de GEOBIA está no fato de os objetos fornecerem uma base de dados

ampla para a classificação (MARPU, 2009), pois, conforme exposto anteriormente, correspondem a um agrupamento de pixels contíguos, sendo possível calcular, para cada um deles, 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.

No caso de imagens geradas por operações matemáticas aplicadas a imagens multiespectrais, como componentes principais e índices de vegetação, ou de quaisquer outros dados em formato matricial que não correspondem às imagens multiespectrais, como grades numéricas discretas (mapas temáticos) e contínuas (p.ex., Modelos Digitais de Elevação (MDE), declividade, temperatura etc.), o valor do pixel não representa as propriedades espectrais, mas o valor resultante de uma operação matemática, ou então o valor associado a uma classe temática, ou ainda, o valor correspondente à grandeza do evento representado. Desta forma, os atributos originários do tratamento estatístico do valor do pixel serão denominados como estatísticos, podendo, assim, corresponder à média, desvio-padrão ou variância de valores espectrais, índices e grandezas, dependendo do tipo de base tratada estatisticamente.

A textura dos alvos terrestres, correspondente à distribuição espacial da variação de valores digitais 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; MARPU, 2009). As vantagens da aplicação da informação textural para dados de observação da superfície terrestre de média resolução já foi demonstrada em vários estudos (DEKKER, 2003; DELL'ACQUA; GAMBA, 2003; RIEDEL et al., 2008). Haralick et al. (1973) propuseram o cálculo de métricas texturais através de matrizes de coocorrência do valor digital (*Gray Level Cooccurrence Matrix* - GLCM) e determinaram 14 parâmetros característicos da textura. Este método extrai a textura pela relação espacial existente entre os valores digitais ao longo de diferentes direções. Segundo Ito et al. (2011), devido à sua simplicidade e eficácia, é considerado por muitos autores como método de referência.

Considerando o fato de que a textura ainda é pouco explorada em GEOBIA e dada a ausência de trabalhos na literatura indexada nacional e internacional comparando redes semânticas com e sem a inclusão de atributos texturais, este artigo tem como objetivo avaliar o desempenho de ambas as categorias de descritores para a classificação de cobertura da terra por GEOBIA. Para isto, uma rede utilizou-se de descritores estatísticos e texturais, e a outra, apenas de descritores estatísticos. O material e os métodos utilizados para a execução desta avaliação comparativa encontram-se descritos na próxima seção.

2. MATERIAL E MÉTODOS

A área de estudo é o município de Nova Friburgo, com extensão de 933 km² 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 na região (DANTAS, 2001). Os recentes deslizamentos de terra ocorridos na região serrana fluminense em janeiro de 2010 exemplificam as proporções catastróficas que podem adquirir esses eventos, que somaram um prejuízo superior a R\$ 600 milhões, deixando 837 mortos, dos quais 404 em Nova Friburgo, mais de 500 desaparecidos e 26.000 desabrigados (DANTAS, 2011).

O mapeamento do uso e cobertura da terra de Nova Friburgo baseou-se na aplicação de GEOBIA a partir da utilização da plataforma Definiens Developer 7.04. O algoritmo de segmentação FNEA ou 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 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) 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 (BAATZ; SCHÄPE, 2000). 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 (BAATZ; SCHÄPE, 2000).

Para a mineração de dados, foi utilizado o programa WEKA 3.6.4, desenvolvido pela Universidade de Waikato, Nova Zelândia. Este programa de código aberto apresenta uma coleção de algoritmos de aprendizagem, constituída por ferramentas de pré-processamento, classificação, regressão, agrupamento e regras de associação, que também podem ser aplicadas diretamente no conjunto de dados (HALL et al., 2009).

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 geomorfológicos 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 a interpolação dos dados altimétricos, resultando em Modelos Digitais de Elevação (MDE) com resolução espacial de 30 m (VALERIANO, 2005).

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

2.1 Preparação da base de dados

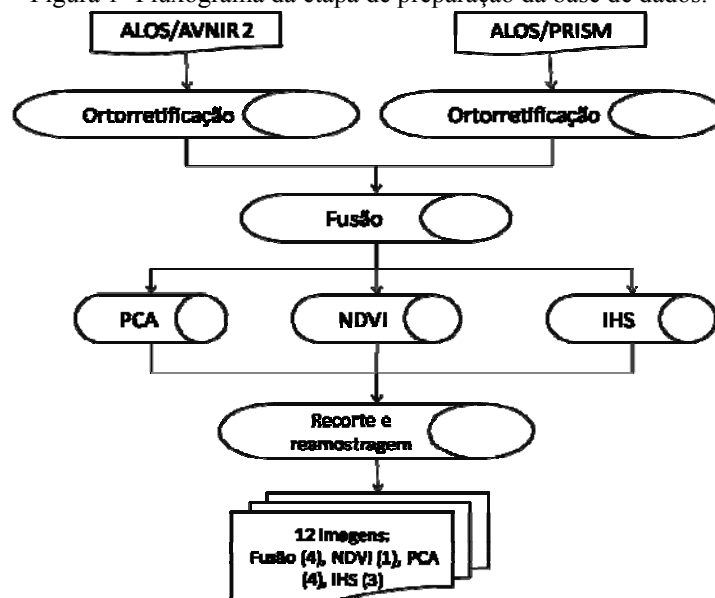
A preparação do banco de dados consistiu no processamento das imagens ALOS e do MDE TOPODATA. Para as imagens multiespectrais e pancromática, foram efetuadas as operações de ortorretificação e fusão e a geração de imagens por operações de transformações matemáticas (Figura 1).

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 (70x70 km). A altitude foi extraída dos dados do SRTM (JACOBSEN, 2005; RICHTER; TEICHERT, 2008). Para a imagem PRISM (70x35 km), foram utilizados 20 pontos. A ortorretificação foi executada no programa ENVI 4.7, utilizando dados de posição e atitude do sensor obtidos junto à equipe de suporte do ALOS.

O passo seguinte foi a fusão de imagens AVNIR-2 e PRISM utilizando o método *Gram-Schmidt*, disponível no ENVI 4.7. Este método consiste na simulação de uma banda pancromática com as multiespectrais, aplicando, então, a transformação de *Gram-Schmidt* sobre as multiespectrais e a pancromática

simulada. Ao final, uma transformação inversa é efetuada, com a substituição da primeira banda pela pancromática. O método *Gram-Schmidt* apresenta maior acurácia do que o de Análise das Componentes Principais (*Principal Components Analysis* - PCA), já que utiliza a função da resposta espectral do sensor para simular a banda pancromática (ENVI, 2009), preservando, de modo eficiente, o conteúdo espectral da imagem original. Neste trabalho, constatou-se a fidelidade espectral da imagem sintética com relação à imagem multiespectral original.

Figura 1- Fluxograma da etapa de preparação da base de dados.



A partir das bandas fusionadas, foram criadas novas imagens resultantes da aplicação PCA e da conversão do sistema RGB 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. Esta rotina interpola valores de elevação em uma grade regular, a partir de restrições que se baseiam em uma rede de drenagem totalmente interconectada e uma correta representação de cumeeiras e cursos d'água nos dados altimétricos de entrada. Apenas quatro valores de entrada são usados para a

definição da célula de saída, e o método utiliza uma técnica de interpolação baseada na diferença finita iterativa, que otimiza a eficiência computacional da interpolação local sem perder a continuidade da superfície de interpolação global.

Por fim, as bases topográficas 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 fusionadas do sistema ALOS, quatro componentes principais (*Principal Components* - PC), três componentes IHS, NDVI, MDE e grade de declividade.

2.2 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.

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 (Tabela 1). 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. 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 atribuídos aos três níveis de segmentação.

Nível	Fator escala	Imagens com peso 1	Peso forma	Peso compacidade
3	500	NDVI	0,1	0,5
2	250	NDVI	0,1	0,5
1	160	4 bandas multiespectrais	0,1	0,5

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 multiespectrais, visando discriminar os diversos tipos de alvos presentes na cena.

2.3 Geração da Rede Semântica

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 oito classes de cobertura: afloramento rochoso, floresta, vegetação herbácea, vegetação herbácea rala, queimada, reflorestamento, sombra e área urbana (Quadro 1).

Foram levantadas 225 amostras para o treinamento da árvore de decisão, correspondentes às oito classes de cobertura da terra, ou seja, 30 amostras por classe, com exceção da classe queimada, pois apresenta área reduzida e, consequentemente, reduzido número de objetos.

O conjunto inicial de dados para mineração, composto por atributos estatísticos e texturais extraídos do primeiro nível de segmentação, foi gerado no Definiens Developer 7.04. Após os procedimentos de importação e limpeza dos dados (para remoção de ruídos e inconsistências), executados no Weka 3.6.4, este conjunto constituiu-se de 130 descritores estatísticos e texturais (Tabela 2). Métodos não-paramétricos, como a árvore de decisão utilizada nesta abordagem orientada a objeto, são tolerantes à redundância, a qual chega a ser desejável para a identificação de certas classes na cena. Embora possa haver correlação entre bandas de entrada, há especificidades em cada uma delas que são imprescindíveis para a discriminação de certos alvos.

Tabela 2 - Descritores utilizados na mineração de dados.

Descritor	Tipo	Total
Média	Estatístico	16
Desvio-padrão		12
GLCM 2º Momento Angular*	Textural	27
GLCM Contraste*		28
GLCM Entropia*		30
GLCM Homogeneidade*		17

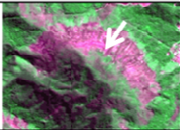
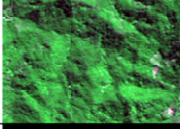
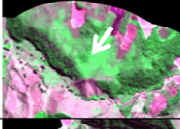
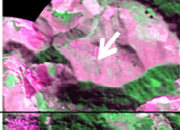
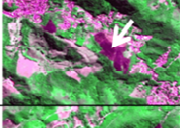
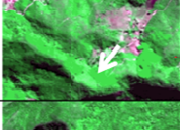
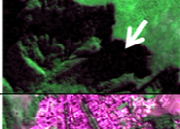

* Os atributos texturais baseados na GLCM foram calculados a partir de uma janela de tamanho 3x3.

Para o cálculo dos descritores texturais, feito pelo Definiens Developer 7.04, são utilizadas as matrizes de coocorrência do valor digital (GLCM) propostas por Haralick et al. (1973). Esta abordagem extrai a textura pela relação espacial existente entre os valores digitais ao longo de diferentes direções. Entre os 14 parâmetros de textura disponíveis, foram utilizados quatro considerados de maior relevância (BARALDI; PARMIGGIANI, 1995; ITO et al., 2011):

- Segundo momento angular ou energia – mede a uniformidade da textura, ou seja, a quantidade de repetição de pares de pixels. Valores elevados significam que a distribuição do valor digital é constante, isto é, ocorre grande repetição na variação dos valores digitais. Para uma matriz normalizada, os valores são positivos e menor ou igual a 1.

- Entropia – mede a desordem da imagem, ou seja, corresponde a uma medida inversamente proporcional ao segundo momento angular. Valores elevados indicam que a imagem não possui textura uniforme.


Quadro 1 - Classes de cobertura da terra.

Classes	Definição	Chave de interpretação	ALOS/AVNIR 3R_4G_2B
Afloramento rochoso	Rocha exposta com presença de pouca ou nenhuma vegetação.	<ul style="list-style-type: none"> • Cor – magenta • Textura – intermediária • Forma – arredondada • Localização – encostas íngremes • Padrão – listrado 	
Floresta	Vegetação arbórea, em estágio médio e avançado de regeneração, e arbórea-arbustiva, em estágio inicial e médio.	<ul style="list-style-type: none"> • Cor – verde escuro • Textura – intermediária a rugosa 	
Herbácea	Vegetação predominantemente composta por gramíneas e ervas.	<ul style="list-style-type: none"> • Cor – verde claro • Textura – lisa 	
Herbácea rala	Vegetação muito rala composta por gramíneas e associada a solo exposto.	<ul style="list-style-type: none"> • Cor – magenta claro • Textura – lisa 	
Queimada	Área atingida por fogo.	<ul style="list-style-type: none"> • Cor – roxo escuro • Textura – lisa 	
Reflorestamento	Vegetação predominantemente arbórea e composta por eucaliptos.	<ul style="list-style-type: none"> • Cor – verde intermediário • Textura – lisa 	
Sombra	Áreas sem informação devido à ausência de incidência solar.	<ul style="list-style-type: none"> • Cor – preta • Textura - lisa • Localização – encostas 	
Urbana	Predominância de construções.	<ul style="list-style-type: none"> • Cor – magenta • Textura – rugosa • Padrão – reticulado 	

- **Contraste** – corresponde à diferença entre os valores mais altos e mais baixos de um conjunto de pixels contíguos. Elevados valores de contraste correspondem a imagens compostas por valores digitais de grande amplitude, ou seja, com textura rugosa.
- **Homogeneidade** – mede a homogeneidade da imagem. Valores elevados correspondem a pequenas diferenças tonais entre os pixels vizinhos. Este parâmetro é inversamente proporcional ao contraste e à energia.

As regras de classificação por mineração de dados foram estabelecidas pelo algoritmo C4.5, criado por Quinlan (1993) e implementado como classificador *tree.J48* no programa Weka 3.6.4. Este algoritmo constrói árvores de decisão a partir de amostras de treinamento. As árvores são expressas por um fluxograma, onde o nó interno denota um teste com o atributo, o ramo representa o resultado do teste, e o nó externo (folha) exibe a classe esperada (Figura 2). Para cada nó, o algoritmo escolhe o melhor atributo para separar os dados em classes individuais. Os atributos que não aparecem na árvore são considerados irrelevantes (HAN; KAMBER, 2006). O algoritmo apresenta como objetivo a construção de árvores menores, por serem mais facilmente compreendidas e apresentarem bom desempenho. Para isto, utiliza a entropia para medir o quanto o nó é informativo. Quanto menor a entropia, menos informação será utilizada para descrever os dados (SILVA, 2006).

Figura 2 – Esquema estrutural de uma árvore de decisão gerada pelo algoritmo C4.5.



2.4 Classificação de cobertura da terra

As árvores de decisão geradas no Weka 3.6.4 para a classificação de cobertura da terra foram implementadas na plataforma Definiens Developer 7.04, através da conversão das regras de decisão fornecidas pelas árvores em limiares *crisp* das redes semânticas. Foram geradas classificações baseadas em árvores de decisão contendo descritores estatísticos e texturais e em árvores contendo apenas os descritores estatísticos. Em ambos os casos, foi selecionada para posterior validação a árvore de

decisão que apresentou simultaneamente uma estruturação lógica e um bom resultado de classificação.

2.5 Avaliação da acurácia da classificação de cobertura da terra

Para a avaliação da acurácia das classificações, foram coletadas cerca de 1,4 mil amostras estratificadas pela área esperada das sete classes. 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. As amostras referem-se a pixels, justamente para se evitar o enviesamento que ocorreria caso fossem selecionados segmentos como amostras, haja vista a variabilidade observada no tamanho dos segmentos. No entanto, devido à reduzida área de algumas classes, não foi possível a observância deste número para todas elas. Foram criados dois conjuntos independentes de amostragem, sendo 720 pontos aleatórios para a classificação contendo atributos texturais e estatísticos, e outros 719 pontos aleatórios para a classificação baseada apenas em atributos estatísticos.

Na sequência, foram construídas as matrizes de erros compostas, nas colunas, pelas amostras de referência, identificadas com base nas ortofotos do projeto RJ-25 (IBGE, 2011b), e nas linhas, pelas classes obtidas na classificação. As ortofotos foram geradas por levantamento aerofotogramétrico realizado em 2005, com resolução espacial 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.

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); e (e) *Kappa* condicional (CONGALTON; GREEN, 2009). O índice *Kappa* é dado por (Equação 1):

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

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).

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

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

Por fim, para testar a significância estatística da diferença entre os índices *Kappa*, calculados para a classificação por redes semânticas geradas por atributos estatísticos e texturais e somente por atributos estatísticos, foi utilizado o teste Z (CONGALTON; GREEN, 2009), de acordo a seguinte expressão (Equação 4):

$$z = \frac{K_1 - K_2}{\sqrt{\sigma_{K_1}^2 + \sigma_{K_2}^2}} \quad (4)$$


K_1 = índice *Kappa* da classificação 1;
 K_2 = índice *Kappa* da classificação 2; e
 σ = variância do índice *Kappa*.

3. RESULTADOS

3.1 Cobertura da Terra de Nova Friburgo

A Figura 3 apresenta os três níveis de segmentação efetuados para a elaboração da rede semântica. No nível 3, correspondente ao fator de escala 500 e peso 1 para a camada NDVI, verifica-se a delimitação de objetos com e sem vegetação. No nível 2, 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, no nível 1, a partir do qual foram efetivamente extraídas as amostras de treinamento para a produção das árvores de decisão, apresentando fator de escala 160 e peso 1 para as bandas multiespectrais, observa-se a maior discriminação de alvos da cena.

Figura 3 - Níveis de segmentação por fator de escala 500 (3), 250 (B) e 160 (C).



A Figura 4 apresenta a árvore de decisão treinada com base no conjunto de descritores texturais e estatísticos e utilizada para a classificação de cobertura da terra de Nova Friburgo (Figura 5). Dos 130 descritores, os seguintes foram utilizados pelo algoritmo de mineração de dados para descrever os padrões das classes de cobertura da terra: NDVI, quarta componente principal (PC4), segundo momento angular, homogeneidade, entropia e declividade.

A estrutura da árvore apresenta-se da seguinte forma:

- Inicialmente, a árvore divide-se em dois grandes ramos, tendo como base o NDVI.
- No ramo da esquerda, foram classificadas as classes com índice menor, ou seja, correspondendo àquelas sem vegetação ou com vegetação muito rala, além das áreas de sombra, incluindo: a área urbana, a queimada, a herbácea rala e o afloramento rochoso.
- No ramo da direita, com maior valor de NDVI, foram classificadas a floresta, o reflorestamento e a vegetação herbácea.
- No ramo esquerdo, o segundo momento angular foi utilizado para a classificação da área urbana. Este descritor mede a uniformidade da textura, sendo que os valores próximos a 1 indicam alvos homogêneos ou com textura uniforme (BARALDI; PARMIGGIANI, 1995). Isto explica o baixo limiar estabelecido para a extração de área urbana.
- No terceiro nível deste mesmo ramo, a sombra foi classificada com base na entropia, cujos valores correspondem a texturas uniformes quando baixos.
- No nível seguinte, o NDVI foi utilizado para a classificação da queimada, diferenciando-se da herbácea rala e do afloramento por apresentar menor valor de NDVI, explicado pela total ausência de vegetação no terreno recém queimado. No caso dos afloramentos, é comum a presença de vegetação rupestre, o que explica o fato de seus valores de NDVI serem superiores aos da classe queimada.
- No total, 19 amostras da classe herbácea rala foram classificadas pelo maior valor de homogeneidade do NDVI, enquanto as amostras restantes separaram-se dos afloramentos por apresentarem menor valor de declividade, o que indica a localização dos afloramentos rochosos em encostas de maior declive.

- No ramo da direita, os valores maiores de homogeneidade do NDVI classificam a vegetação herbácea.
- No nível imediatamente inferior, o reflorestamento é discriminado da floresta pela quarta componente principal, cujos coeficientes encontram-se na Tabela 3. Segundo Mather e Koch (2011), a última 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.

Figura 4 - Árvore de decisão com descritores texturais e estatísticos.

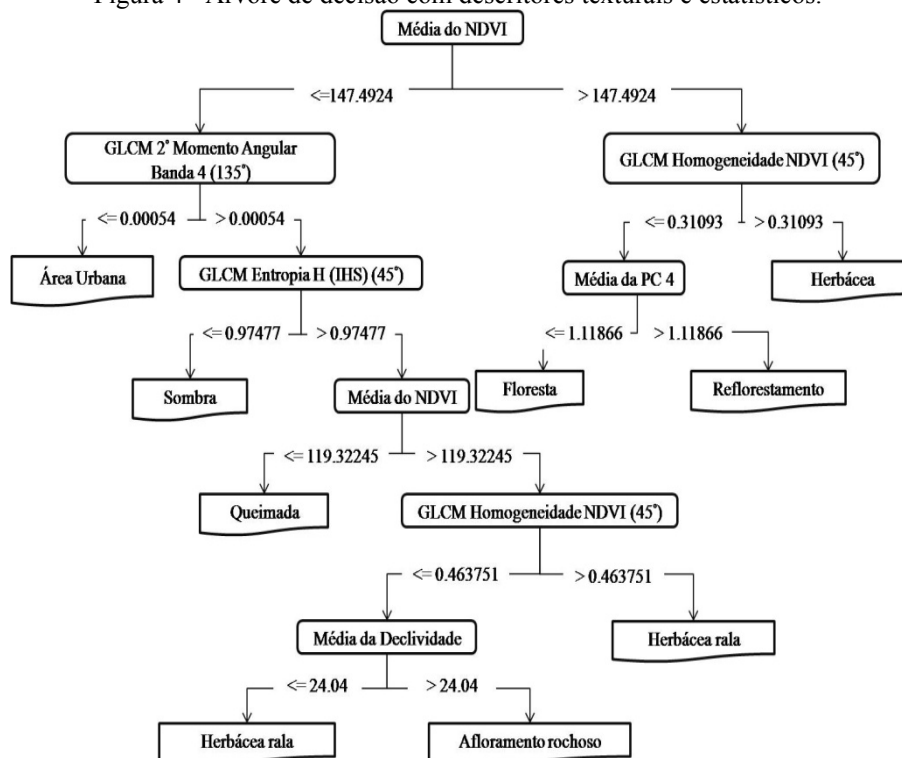



Tabela 3 – Coeficientes da Análise das Componentes Principais.

Banda	Autovetores				Autovalores
	Banda 1	Banda 2	Banda 3	Banda 4	
1	-0,327569	-0,490661	-0,562000	-0,579747	752,451172
2	-0,239809	-0,259538	-0,468761	0,809565	214,397815
3	0,840138	0,088673	-0,534118	-0,031976	11,402995
4	0,359663	-0,827061	0,423246	0,086464	2,090523

Figura 5 - Classificação de cobertura da terra por descritores texturais e estatísticos.

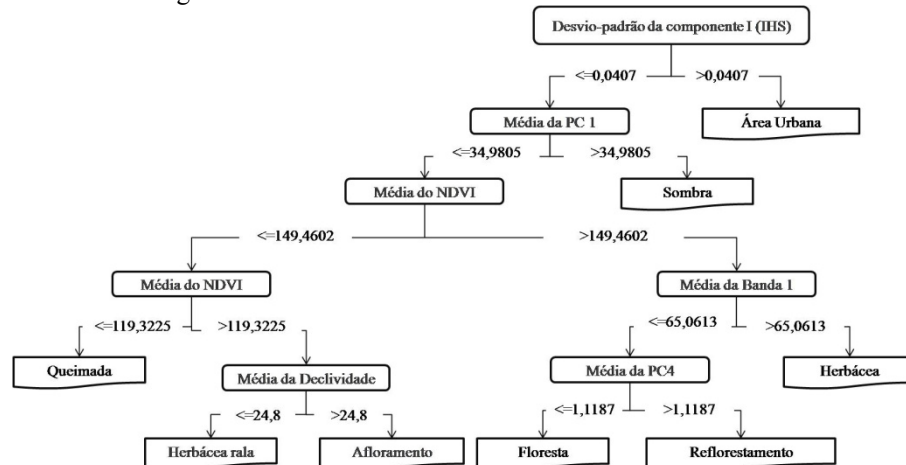


A Figura 6 apresenta a árvore treinada apenas pelos descritores estatísticos e utilizada para a classificação de cobertura da terra de Nova Friburgo (Figura 7). Dos 38 descritores, os seguintes foram utilizados pelo minerador para descrever os padrões das classes de cobertura da terra: componente I (IHS), primeira e quarta componentes principais (PC 1 e PC 4), NDVI, banda 1 e declividade.

Inicialmente, a árvore de decisão discrimina a classe urbana a partir do desvio-padrão da componente intensidade. No segundo nível da árvore de decisão, a

sombra é discriminada pela primeira componente principal. Como esta componente possui a maior parte da variância total dos dados, ou seja, a informação que é comum a todas as bandas originais, contém a informação de brilho associada às sombras de topografia (MATHER; KOCH, 2011), apresentando a vantagem de ser uma imagem descorrelacionada das demais componentes, o que facilita a discriminação de alvos. A partir do terceiro nível, a árvore assemelha-se à estrutura da árvore anterior. O NDVI é utilizado para dividi-la em dois grandes ramos. O ramo esquerdo discrimina as classes sem vegetação e com vegetação rasteira rala. A queimada é discriminada pelo menor valor de NDVI, e a declividade separa a herbácea rala do afloramento. No ramo da direita, a banda 1 (azul) discrimina a vegetação herbácea, dada a elevada presença de solo nesta classe, o qual possui resposta comparativamente superior à vegetação nesta faixa do espectro. Por sua vez, a discriminação entre o reflorestamento e a floresta segue o padrão da árvore anterior, ou seja, a quarta componente separa as duas classes.

Figura 6 - Árvore de decisão com descritores estatísticos.



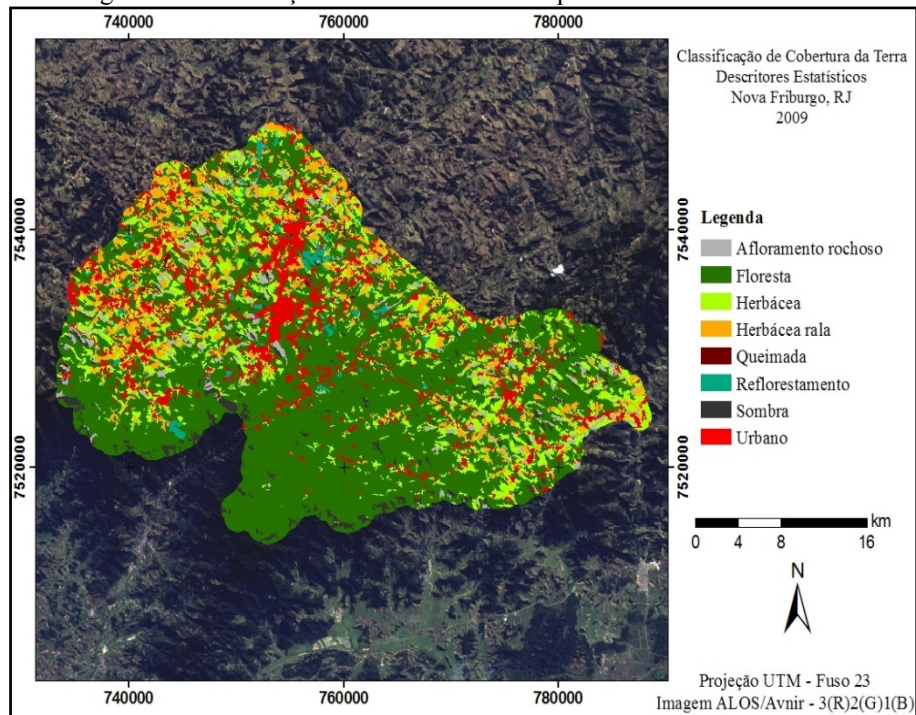
3.2 Acurácia das classificações de cobertura da terra

A Tabela 4 refere-se à matriz de erros da classificação de cobertura da terra gerada por árvore de decisão com os descritores texturais e estatísticos. O índice de exatidão global alcançado foi de 88%, e o índice *Kappa*, 0,81, considerado de excelente qualidade de acordo com Landis e Koch (1977). Apenas a classe urbana apresentou erros de omissão maiores que 50%, ou seja, exatidão do produtor de 47%, confundindo-se com herbácea rala, floresta e queimada. Por outro lado, esta mesma classe não apresentou erros de comissão, ou seja, a exatidão do usuário foi

de 100%. As classes herbácea rala e queimada, por sua vez, apresentaram baixos índices de exatidão do usuário, devido aos erros de classificação da área urbana.

A Tabela 5 refere-se à matriz de erros da classificação de cobertura da terra gerada por árvore de decisão composta apenas por descritores estatísticos. O índice de exatidão global alcançado foi de 90%, e o índice *Kappa*, 0,84, igualmente considerado de excelente qualidade de acordo com Landis e Koch (1977). Todas as classes ficaram com índice de exatidão do produtor e usuário acima de 50%, demonstrando que os erros de omissão e comissão não superaram este valor.

Figura 3: Classificação de cobertura da terra por descritores estatísticos.



O teste de hipótese feito entre os índices *Kappa* mostrou, com nível de 5%, que não há diferença significativa de acurácia entre as duas classificações, ou seja, a inclusão de descritores texturais não aumentou a acurácia da classificação dentro de um intervalo de confiança de 95%.

No entanto, na análise do *Kappa* condicional, verifica-se que há diferenças expressivas entre as duas classificações (Tabela 6). Para a classificação com descritores texturais e estatísticos, os valores do *Kappa* condicional (usuário) ficaram entre 0,38 e 1,00, enquanto que para a classificação utilizando apenas

descritores estatísticos, os valores situaram-se entre 0,50 e 1,00. A primeira apresentou um índice maior do que a segunda nas classes afloramento rochoso e área urbana em relação aos erros de comissão, sendo que a rugosidade é uma propriedade importante para a identificação de ambas. O teste de hipótese demonstrou, com nível de significância de 5%, que apenas o *Kappa* condicional (usuário) das classes herbácea e reflorestamento não são significativamente diferentes nas duas classificações. No caso da classe reflorestamento, foi utilizado o mesmo descritor (PC4) para a sua discriminação no ramo final das duas árvores.

Tabela 4: Matriz de erros da classificação com descritores texturais e estatísticos.

Classes		Amostras de referência								Total classificadas
		Afloramento	Floresta	Herbácea	Herbácea rala	Queimada	Reflorestamento	Sombra	Urbana	
Classificadas	Afloramento	20			1	1		3		25
	Floresta		418	12			2		7	439
	Herbácea	4	4	78	3		4			93
	Herbácea rala	4		7	30				16	57
	Queimada	1				7		1	9	18
	Reflorestamento		1				15			16
	Sombra	1	2					41		44
	Urbana								28	28
Total coletadas		30	425	97	34	8	21	45	60	720
Exatidão do produtor		67%	98%	80%	88%	88%	71%	91%	47%	88%
Exatidão do usuário		80%	95%	84%	53%	39%	94%	93%	100%	

Tabela 5: Matriz de erros da classificação com descritores estatísticos.

Classes		Amostras de referência								Total classificadas
		Afloramento	Floresta	Herbácea	Herbácea rala	Queimada	Reflorestamento	Sombra	Urbana	
Classificadas	Afloramento	22	3	3	7		3	4		42
	Floresta		417	1				1		419
	Herbácea	5	1	63			1			70
	Herbácea rala	1	2	5	22			1		31
	Queimada				1	8				9
	Reflorestamento		1				17			18
	Sombra							39		39
	Urbana	3	2	21	4				61	91
Total coletadas		31	426	93	34	8	21	45	61	719
Exatidão do produtor		71%	98%	68%	65%	100%	81%	87%	100%	90%
Exatidão do usuário		52%	100%	90%	71%	89%	94%	100%	67%	

Em relação ao *Kappa* condicional (produtor), para a classificação textural e estatística, os valores ficaram entre 0,45 e 0,96, ao passo que para a classificação baseada somente em descritores estatísticos, esses valores situaram-se entre 0,64 e 1,00. A primeira apresentou um índice maior, ou seja, menores erros de omissão, para as classes herbácea, herbácea rala e sombra, ou seja, precisamente nas classes com textura mais lisa, enquanto maior erro de omissão foi observado na classe urbana, onde a rugosidade é um fator proeminente para a sua discriminação. O teste de hipótese demonstrou, com nível de significância de 5%, que o *Kappa* condicional (produtor) das classes afloramento rochoso, floresta, queimada e reflorestamento não são significativamente diferentes.

Por fim, a análise das diferenças entre a área das classes de cobertura da terra nas classificações testadas ficou abaixo de 8% (Tabela 7), com exceção das classes afloramento rochoso, herbácea rala, queimada e urbana. O reflorestamento apresentou a menor diferença, pois, como já foi descrito, nas duas árvores testadas a quarta componente principal foi utilizada para a sua diferenciação de floresta no último ramo. A classe urbana apresentou a maior diferença, próximo a 600%. No caso da árvore de decisão gerada com descritores estatísticos, isto ocorre possivelmente devido ao fato de a mesma ter selecionado apenas o desvio-padrão da componente I (IHS) para a separação da área urbana das demais classes imediatamente no primeiro ramo. A árvore com atributos texturais utilizou o NDVI para essa diferenciação, o que possivelmente explica a razão pela qual a primeira árvore apresentou mais erros de comissão, como já exposto anteriormente. O afloramento rochoso foi discriminado utilizando a primeira componente, o NDVI e a declividade na árvore com atributos apenas estatísticos. Na outra árvore, além dos dois últimos, foram incluídos descritores de textura.

Tabela 6 – Índice *Kappa* condicional da classificação.

Classe	Kappa - Usuário		Kappa - Produtor	
	Texturais e Estatísticos	Estatísticos	Texturais e Estatísticos	Estatísticos
Afloramento rochoso	0,79	0,50	0,66	0,70
Floresta	0,88	0,99	0,96	0,95
Herbácea	0,81	0,89	0,78	0,65
Herbácea rala	0,50	0,70	0,88	0,64
Queimada	0,38	0,89	0,87	1,00
Reflorestamento	0,94	0,94	0,71	0,80
Sombra	0,93	1,00	0,91	0,86
Urbana	1,00	0,64	0,45	1,00

Tabela 7 – Área das classes de cobertura da terra.

Classe	Classificação (texturais e estatísticos)		Classificação (estatísticos)		Variação (%)
	Área (km²)	Área (%)	Área (km²)	Área (%)	
Afloramento rochoso	14,9	1,3	37,6	3,4	153,1
Floresta	679,7	61,2	628,8	56,7	-7,5
Herbácea	183,5	16,5	170,7	15,4	-7,0
Herbácea rala	157,6	14,2	88,6	8	-43,8
Queimada	8,8	0,8	2,9	0,3	-67,5
Reflorestamento	15,7	1,4	15,7	1,4	-0,3
Sombra	29,7	2,7	28,7	2,6	-3,4
Urbana	19,8	1,8	136,7	12,3	592,2

4. CONCLUSÕES

Considerando-se o índice *Kappa* global, pode-se afirmar que as duas classificações avaliadas, por descritores estatísticos e por descritores estatísticos e texturais, apresentaram elevada qualidade quanto à acurácia da classificação. O teste de hipótese entre os dois índices mostra que não há diferenças significantes entre

eles, ou seja, a inclusão dos descritores texturais não aumenta a acurácia global da classificação com um intervalo de confiança de 95%. Isto implica dizer que outras informações, além das texturais, conseguem discriminar os alvos de interesse de maneira eficiente, podendo-se, portanto, prescindir dos atributos de textura neste estudo em particular.

Em relação às classes de cobertura da terra avaliadas pelo índice *Kappa* condicional, pode-se afirmar que a qualidade da classificação é reconhecidamente satisfatória, pois a grande maioria dos índices ficou acima de 0,60. O melhor desempenho coube à classe floresta, que obteve *Kappa* igual ou acima de 0,88 em todos os índices avaliados, sendo a classificação considerada de excelente qualidade nas duas abordagens (com e sem descritores texturais).

Este trabalho demonstrou a importância da inclusão de informações não somente espectrais, como também geomorfométricas, a exemplo da declividade, no caso particular deste trabalho, para a discriminação das classes de cobertura da terra. A declividade foi capaz de discriminar duas classes que apresentavam respostas espectrais e texturais semelhantes, afloramento rochoso e herbácea rala, as quais foram separadas no último ramo de ambas as árvores com o auxílio deste descritor.

Em relação às vantagens do método apresentado, é válido mencionar que, em termos operacionais, a elaboração de rede semântica por meio de mineração de dados mostra-se vantajosa, por permitir a automatização dos procedimentos de seleção de atributos e definição das regras de decisão, e consequentemente, mostrar-se menos sujeita à subjetividade do intérprete. Ademais, este método de classificação permite a reaplicação da rede semântica hierárquica em outras áreas com características semelhantes em termos de distribuição espacial e classes de cobertura da terra, uma vez que o método de GEOBIA permite o ajuste fino dos limiares das regras de decisão, de forma a ajustar o modelo às peculiaridades de áreas com paisagens diferenciadas (CAMARGO et al., 2009b).

5. 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.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- 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.
- BARALDI, A.; PARMIGGIANI, F. An Investigation of the Textural Characteristics Associated with Gray Level Co-occurrence Matrix Statistical Parameters.

- IEEE Transactions on Geoscience and Remote Sensing*, v. 33, n. 2, p.293-304, 1995.
- CAMARGO, F. F.; FLORENZANO, T. G.; ALMEIDA, C. M.; OLIVEIRA, C. G.; FEITOSA, R. Q. Análise Orientada a Objeto e Dados ASTER/Terra na Classificação do Relevo. *Boletim de Ciências Geodésicas*, v. 15, p. 81-102, 2009a.
- 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 (Print)*, v. 30, p. 6613-6620, 2009b.
- 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, p. 91-110, 2008.
- 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.
- DALL'OGGIO, P. *Programando com Orientação a Objetos*. São Paulo: Novatec, 2009. 2. ed. 574 p.
- DANTAS, M. E. Geomorfologia do estado do Rio de Janeiro. In: Silva, L. C.; Cunha, H. V. S. *Geologia do Estado do Rio de Janeiro: texto explicativo do mapa geológico do Estado do Rio de Janeiro*. Brasília: CPRM, 2001.
- DANTAS, P. Total de mortos na região serrana do Rio chega a 837. *O Estado de São Paulo*, São Paulo, 27 jan. 2011.
- 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.
- 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.
- ENVI. *ENVI User's Guide - ENVI Version 4.7*. ITT Visual Information Solutions. 2009.
- HALL, M.; FRANK, E.; HOLMES, G; PFAHRINGER, B; REUTEMANN, P.; WITTEN, I. The WEKA Data Mining Software: An Update. *SIGKDD Explorations*, v. 11, 2009.
- HAN, J.; KAMBER, M. *Data Mining: Concepts and Techniques*. San Francisco: Morgan Kaufmann Publishers, 2006. 743p.
- 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.

- IBGE. *Cidades @*. Disponível em: <http://www.ibge.gov.br/cidadesat>. Acesso em 09 de agosto de 2011a.
- IBGE. *Ortofotos 1:25.000 - Rio de Janeiro*. Disponível em: ftp://geofpt.ibge.gov.br/mapas/ortofoto/Projeto_RJ25/TIF/. Acesso em fevereiro de 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 de julho de 2011.
- JACOBSEN, K. DEMs based on space images versus SRTM height models. In: ASPRS 2005 Annual Conference. *Proceedings...* Baltimore, Maryland, March 7-11, 2005.
- 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...*, 2006.
- LANDIS, J.; KOCH, G. The measurement of observer agreement for categorical data. *Biometrics*, v. 33, p. 159 - 174, 1977.
- MARPU, P. R. *Geographic Object-based Image Analysis*. Freiberg, 2009. 121f. Tese (Doutorado em Engenharia) - Faculty of Geosciences, Geo-Engineering and Mining Technische Universität Bergakademie Freiberg, 2009.
- MATHER, P.; KOCH, M. *Computer Processing of Remotely-Sensed Images: An Introduction*. New York: Wiley, 2011. 4. ed. 460 p.
- NAVULUR, K. *Multispectral image analysis using the object-oriented paradigm*. Boca Raton: Taylor & Francis Group, 2006. 165p.
- PINHO, C. M. D. *Análise orientada a objetos de imagens de satélite de alta resolução espacial aplicada à classificação de cobertura do solo no espaço intraurbano: o caso de São José dos Campos – SP*. 2005. 179 p. Dissertação. (Mestrado em Sensoriamento Remoto) – INPE. São José dos Campos, 2005.
- QUINLAN, R. *C4.5: programs for machine learning*. San Francisco: Morgan Kaufmann. 1993.
- RICHTER, C.; TEICHERT, B. Usability of IKONOS images as a basis of data capture for the NascaGIS. In: 7th RS and GIS for Cultural Heritage Management and Documentation, 2008. *Proceedings...* Rome, Italy, Sept. 30-Oct. 4, 2008.
- RIEDEL, T.; THIEL, C.; SCHMULLIUS, C. Fusion of multispectral optical and SAR images towards operational land cover mapping in Central Europe. In: Blaschke, T.; Lang, S.; Hay, G.J. *Object-Based Image Analysis Spatial Concepts for Knowledge-Driven Remote Sensing Applications*. Berlin: Springer, p. 493-511, 2008.
- ROSSITER, D. G. *Technical Note: Statistical methods for accuracy assesment of classified thematic maps*. Enschede: International Institute for Geo-information Science & Earth Observation (ITC), 2004.

- SILVA, M. P. S. *Mineração de padrões de mudança em imagens de Sensoriamento Remoto*. 128 p. Tese (Doutorado em Sensoriamento Remoto) – INPE. São José dos Campos, 2006.
- TÖNJES, R.; GROWE, S.; BÜCKNER, J.; LIEDTCKE, 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: XII Simpósio Brasileiro de Sensoriamento Remoto, 12, 2005, Goiânia, GO. *Anais ...*, p. 1-8, 2005.

(Recebido em setembro de 2011. Aceito em maio de 2012.)