

## Mineração de dados e análise de imagens baseada em objeto aplicadas ao mapeamento de cobertura da terra

Cristiane Nunes Francisco<sup>1</sup>  
Cláudia Maria Almeida<sup>2</sup>

<sup>1</sup>Universidade Federal Fluminense - Departamento de Análise Geoambiental,  
Campus Praia Vermelha - 24210-310 – Niterói - RJ, Brasil  
[crisnf@vm.uff.br](mailto:crisnf@vm.uff.br)

<sup>2</sup> Instituto Nacional de Pesquisas Espaciais - INPE  
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil  
[almeida@dsr.inpe.br](mailto:almeida@dsr.inpe.br)

**Abstract.** This article is committed to evaluate the performance of a semantic network generated by data mining for the classification of land cover using GEographic Object-Based Image Analysis (GEOBIA) in a tropical mountainous area. The study area corresponds to the Nova Friburgo County, with an extension of 933 km<sup>2</sup>, located in the region of the Fluminense Ridge, presenting thus a steep mountainous relief. Based on a visual interpretation of the images, eight land cover classes were defined: rockies, forest, grasslands, sparse grasslands, burn scars, reforestation, shadow, and urban areas. The dataset used for data mining was composed by 130 attributes and by 225 training samples accounting for all land cover classes. The algorithm C4.5, implemented in the software Weka 3.6.4, was employed for the data mining procedure. The following attributes were selected by C4.5: NDVI, fourth principal component, second angular moment, homogeneity, entropy, and slope. The obtained global accuracy was 88%, and the Kappa index reached 0.81. Only the class 'urban areas' presented omission errors greater than 50%, being confused in some cases with sparse grasslands, forest, and burn scars. In view of the obtained value for the Kappa index, we can state that the classification presented an excellent accuracy according to a rating scale specially elaborated for such index.

**Palavras-chave:** decision tree, texture features, ALOS images, árvore de decisão, textura, imagem ALOS

### 1. Introdução

De maneira diversa dos classificadores tradicionais, que utilizam somente a informação espectral para identificar a classe provável a ser atribuída ao elemento, a análise de imagens baseada em objetos geográficos (GEographic Object-Based Image Analysis - GEOBIA) baseia-se em informações extraídas de objetos. 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; MARPU, 2009; CAMARGO et al., 2009a).

A GEOBIA 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).

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 construção da base de conhecimento 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, 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, 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.

Este artigo tem como objetivo avaliar o desempenho de uma rede semântica gerada por mineração de dados para a classificação de cobertura da terra efetuada por GEOBIA. Para isto, utilizou-se uma rede constituída por descritores estatísticos, resultado do tratamento estatístico (média e desvio-padrão, no caso deste trabalho) dos valores dos pixels de cada objeto, e texturais, calculados através de matrizes de co-ocorrência do nível de cinza.

## 2. Metodologia de Trabalho

O município de Nova Friburgo é a área de estudo, com extensão de 933 km<sup>2</sup> e população de 182 mil habitantes (IBGE, 2011a), localizado no estado do Rio de Janeiro. Situado no Planalto Reverso da Região Serrana, apresenta relevo montanhoso a escarpado, com altitude entre 400 e 2.300 m, e 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 terrenos mais íngremes e elevados, devido à difícil acessibilidade, mantêm a Mata Atlântica em bom estado de preservação.

O mapeamento da cobertura da terra de Nova Friburgo baseou-se na aplicação de GEOBIA a partir da 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.

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 geomorfométricos TOPODATA, elaborado a partir do processamento dos dados SRTM (*Shuttle Radar Topography Mission*) disponibilizados pelo USGS (*United States Geological Survey*), resultando em Modelos Digitais de Elevação (MDE) com resolução espacial de 30 m (VALERIANO, 2005).

### 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.

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. Em trabalho realizado por Pinho et al. (2005b), objetivando a avaliação de métodos de fusão aplicadas 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 quando da utilização do método *Gram-Schmidt*.

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).

O passo seguinte foi a geração da grade de declividade, utilizando a extensão *3D Analyst* do ArcGIS 9.0, e o MDE TOPODATA. Por fim, as bases topográficas foram 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. 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, herbácea rala e 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.

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.

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, conseqüentemente, reduzido número de objetos.

O conjunto inicial de dados para mineração, composto por atributos texturais e estatísticos 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 (Tabela 1).

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

Tabela 2. Descritores utilizados na mineração de dados.

Para o cálculo dos descritores texturais, feito pelo Definiens Developer 7.04, foram utilizadas as matrizes de co-ocorrência do nível de cinza (*Gray Level Cooccurrence Matrix - GLCM*) com base em método proposto 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): (a) segundo momento angular ou energia – mede a uniformidade da textura. Valores elevados significam que a distribuição do nível de cinza é constante; (b) entropia – mede a desordem da imagem. Valores elevados indicam que a imagem não possui textura uniforme; (c) contraste – mede a diferença entre os valores mais altos e mais baixos de um conjunto de pixels contíguos. Elevados valores correspondem a imagens com textura rugosa; e (d) homogeneidade – mede a homogeneidade da imagem. Valores elevados correspondem a pequenas diferenças tonais entre os pixels vizinhos.

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, e 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).

## 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. 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 1,4 mil amostras de segmentos 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. No entanto, devido à reduzida área de algumas classes, não foi possível a observância deste número para todas elas.

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.

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).

## 3. Resultados

### 3.1 Cobertura da Terra de Nova Friburgo

A Figura 1 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 2). Dos 130 descritores, foram utilizados pelo algoritmo de mineração de dados para descrever os padrões das classes de cobertura da terra os seguintes: 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. 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.

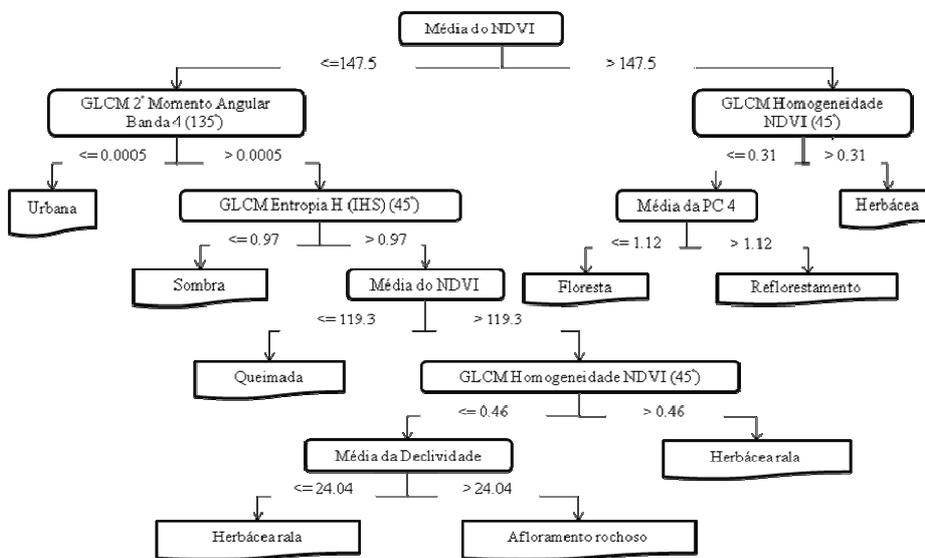


Figura 1. Árvore de decisão gerada pelo algoritmo C4.5.

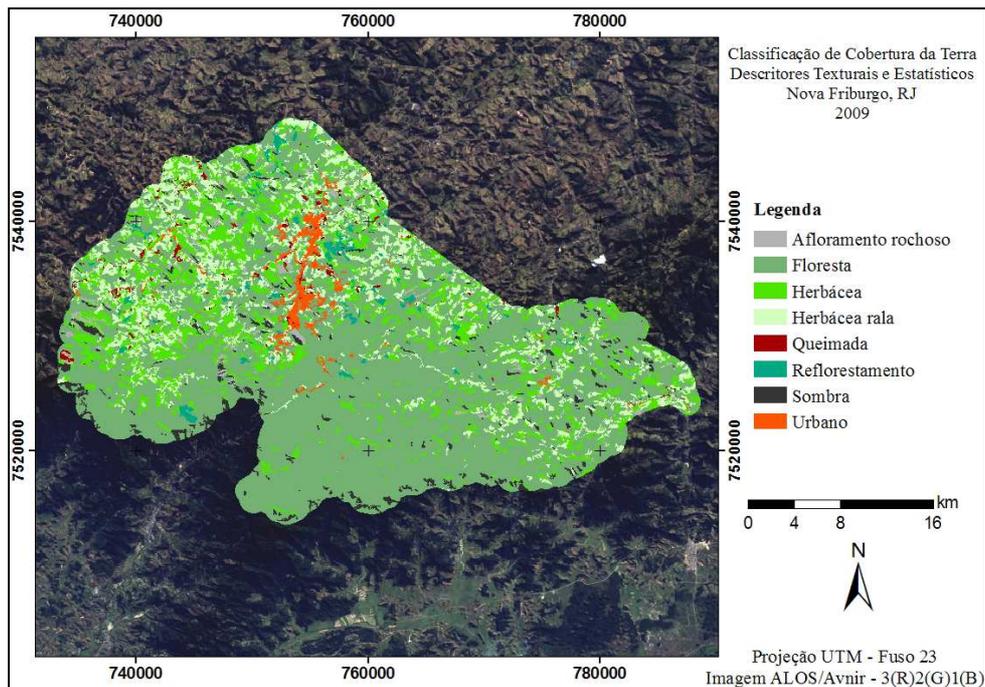


Figura 2. Classificação de cobertura da terra de Nova Friburgo.

### 3.2 Acurácia das Classificações de Cobertura da Terra

O índice de exatidão global alcançado foi de 88%, e o índice *Kappa*, 0,81 (Tabela 2), considerado de excelente qualidade de acordo com Landis e Koch (1977). Apenas a classe urbana apresentou erros de omissão maiores que 50%, 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.

Os valores do *Kappa* condicional do usuário ficaram entre 0,38 e 1,00, enquanto os do produtor, entre 0,45 e 0,96 (Tabela 3). Os piores desempenhos foram das classes queimada e herbácea rala, que alcançaram, respectivamente, *Kappa* do usuário igual a 0,38 e 0,50. Já no índice do produtor, o pior desempenho foi da classe urbana, com valor 0,45.

### 4. Conclusões

Considerando-se o índice *Kappa* global, pode-se afirmar que a classificação apresentou excelente qualidade quanto à sua acurácia. As classes de cobertura da terra, avaliadas pelo índice *Kappa* condicional, apresentaram qualidade de acurácia de muito boa a excelente, pois a grande maioria dos índices ficou acima de 0,6.

Este trabalho demonstrou a importância da inclusão de outras informações que não somente espectrais para a discriminação das classes de cobertura. Neste caso particular, a declividade foi capaz de discriminar duas classes que apresentavam respostas espectrais e texturais semelhantes. O afloramento rochoso e a herbácea rala foram discriminados no último ramo com o auxílio deste descritor.

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 conseqüentemente, 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 (CAMARGO et al., 2009b).

Classes	Amostras de referência								
	Afloramento	Floresta	Herbácea	Herbácea rala	Queimada	Reflorestamento	Sombra	Urbana	Total classificadas
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	18
	Reflorestamento		1				15		16
	Sombra	1	2					41	44
	Urbana								28

Tabela 2. Matriz de erros da classificação de cobertura da terra.

Classe	Kappa - Usuário	Kappa - Produtor
Afloramento rochoso	0,79	0,66
Floresta	0,88	0,96
Herbácea	0,81	0,78
Herbácea rala	0,50	0,88
Queimada	0,38	0,87
Reflorestamento	0,94	0,71
Sombra	0,93	0,91
Urbana	1,00	0,45

Tabela 3. Índice *Kappa* condicional da classificação de cobertura da terra.

## Referências Bibliográficas

- 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.
- CONGALTON, R.; GREEN, K. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. Boca Raton: CRC/Taylor & Francis, 2009. 183p.
- 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.
- 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; DINSTEIN, I. Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics*, v. 3, p. 610-620, 1973.
- IBGE. *Cidades @*. <http://www.ibge.gov.br/cidadesat>. (accessed 09 Ago. 2011a)
- IBGE. *Ortofotos 1:25.000 - Rio de Janeiro*. [ftp://geoftp.ibge.gov.br/mapas/ortofoto/Projeto\\_RJ25/TIF/](ftp://geoftp.ibge.gov.br/mapas/ortofoto/Projeto_RJ25/TIF/). (accessed Feb. 2011b)
- ITO, R. H.; KIM, H. Y.; SALCEDO, W. J. *Classificação de Texturas Invariante a Rotação Usando Matriz de Co-ocorrência*. <http://www.lps.usp.br/~hae/Ito-Kim-Salcedo-Textura.pdf>. (accessed 20 Jul. 2011)
- JACOBSEN, K. DEMs based on space images versus SRTM height models. In: ASPRS 2005 Annual Conference. *Proceedings...* Baltimore, Maryland, March 7-11, 2005.
- 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. p. 3-28. 2008.
- 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., RENNÓ, C. D., KUX, H. J. H. Avaliação de técnicas de fusão aplicadas à imagem Quickbird. In: XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, p. 4225-4232, 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: 7<sup>th</sup> RS and GIS for Cultural Heritage Management and Documentation, 2008. *Proceedings...* Rome, Italy, Sept. 30-Oct. 4, 2008.
- 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.
- VALERIANO, M. M. Modelo digital de variáveis morfológicas 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.