

Classificação de imagem baseada em objeto (OBIA) utilizando índices de vegetação

Renata Sayuri Kawashima¹
Aline Salim²
Wilian França Costa¹
José Roberto da Silva¹
Osvaldo Souza Coutinho Filho¹
José Alberto Quintanilha¹

¹ Universidade de São Paulo - Escola Politécnica - EPUSP
Caixa Postal 61548 CEP 05508-900 - São Paulo - SP, Brasil
{renata.kawashima, wilianfc, ocoutinho, jaquinta}@usp.br
jrs.guarata@uol.com.br

² Universidade de São Paulo – Departamento de Geografia – FFLCH
Caixa Postal 72042 CEP 05508-900 - São Paulo - SP, Brasil
alinesalim@usp.br

Abstract. The aim of this study was to test the application of vegetation indices as attributes to the generation of decision rules in an Object-Based Image Analysis (OBIA) on mapping of vegetation types. The attributes assessed in the study were four vegetation indices: Simple Ratio (*SR*), Normalized Difference Vegetation Index (*NDVI*), Soil Adjusted Vegetation Index (*SAVI*) and Triangular Vegetation Index (*TVI*). It was used the concept of Data Mining (applying Weka software) for induction of decision trees. The attributes selected by the J48 algorithm were *TVI* and *SAVI* vegetation indices. The values for *NDVI* and *SR* were not considered by the Data Mining to distinguish the classes. The Mangrove class had the lowest error of omission, unlike other classes of vegetation, such as Forest and Restinga vegetation. For the identification of mangrove areas, it can be said that the classification process was good to hit the likely areas of mangrove occupation in the study area, however, note that the other forest types were misidentified, also with a high omission error for class Restinga vegetation, which was misclassified in major of the study area. The concept of Data Mining allows to definition values and thresholds to be used in the decision rules of an object-Based Image Analysis on mapping of Mangrove vegetation.

Palavras-chave: vegetation mapping, data mining, Quickbird image, mapeamento da vegetação, mineração de dados, imagens Quickbird.

1. Introdução

Estudos recentes com classificação de imagem baseada em objeto (OBIA) têm sido propostos para detecção de áreas florestadas (Wang et al., 2004; Desclee et al., 2006; Conchedda et al., 2008; Myint et al. 2008).

A classificação de imagem baseada em objeto possui a vantagem de incorporar as propriedades espaciais entre os objetos e seus vizinhos no processo de classificação (Desclee et al., 2006).

Para cada objeto criado a partir do processo de segmentação, são gerados atributos espectrais, texturais, morfológicos e contextuais, dentre outros que podem ser empregados em análise de imagem (Blaschke, 2010).

Neste trabalho analisamos o impacto dos índices de vegetação como atributos para a geração das regras de decisão em uma classificação de imagem baseada em objeto (OBIA) para o mapeamento dos tipos vegetacionais (Restinga, Mangue e Floresta) de uma área do município de Bertioga-SP.

2. Metodologia de Trabalho

2.1 Área de estudo

A área de estudo está localizada na porção sudoeste do município de Bertiooga entre as coordenadas 23,79° a 23,80° latitude sul e entre 46,14° a 46,13° de longitude oeste, sendo atravessada pelo Rio Itapanhaú (Figura 1).

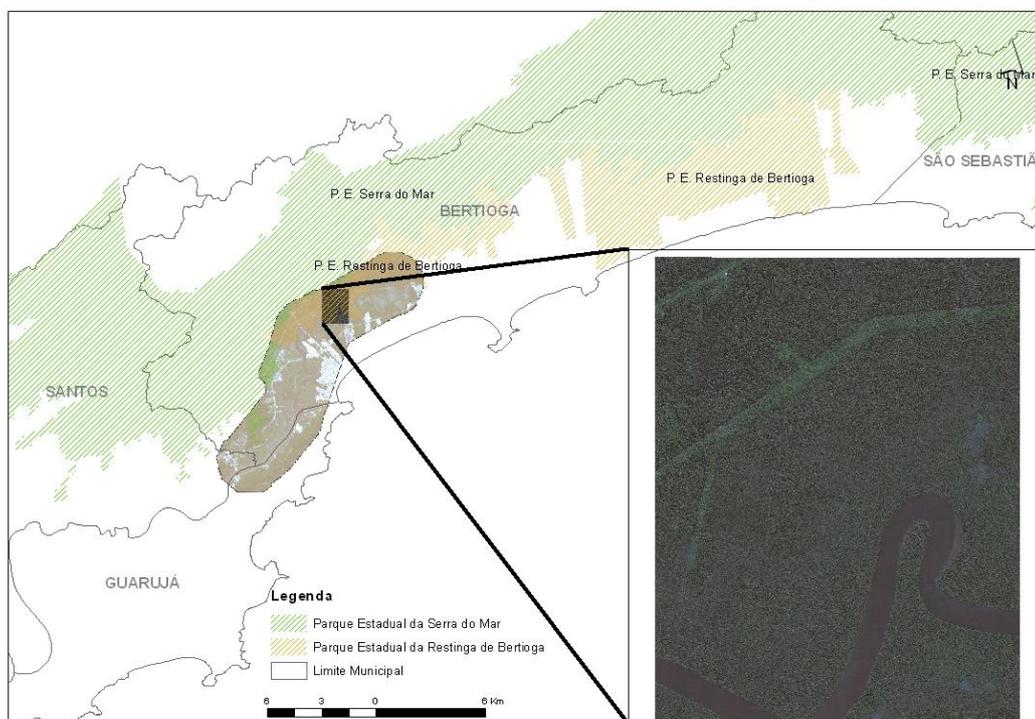


Figura 1. Localização da área de estudo no município de Bertiooga – SP.

A área de estudo também está inserida nos limites do Parque Estadual da Restinga de Bertiooga, este com seu decreto de criação nº 56.500, de 09 de dezembro de 2010. Bertiooga também possui leis de restrição ambiental e de ocupação dentro dos limites do Parque Estadual da Serra do Mar (decreto estadual nº 10.251 de 1977 e alteração no decreto estadual nº 13.313 de 1979). De acordo com Souza (2008), o processo de urbanização de Bertiooga ocorreu simultaneamente com as ações de especulação imobiliária e de restrições da legislação incidente no território, as quais contribuíram para a formação da paisagem constituída de matriz vegetal entremeada por manchas de urbanização.

A imagem de satélite utilizada nesse estudo é do Laboratório de Geoprocessamento do Departamento de Engenharia de Transportes da USP e se refere a uma imagem de alta resolução Quickbird, possuindo quatro bandas multiespectrais definidas pelas seguintes faixas de comprimento de onda eletromagnética: azul (de 430 a 545 nm), verde (de 466 a 620 nm), vermelho (de 590 a 710 nm) e infravermelho próximo (de 715 a 918 nm) (DIGITALGLOBE, 2011, 2012), ortoretificada e datada de 09 de julho de 2009.

2.2 Classificação OBIA

Nas próximas seções são apresentados os conceitos aplicados no processo de classificação OBIA aplicados neste estudo.

2.2.1 Segmentação da imagem

A atividade básica para a análise de imagem orientada a objetos é o sucesso na obtenção da segmentação da imagem. A segmentação é o processo no qual são produzidos segmentos não sobrepostos (polígonos) representados por grupos de pixels homogêneos e semanticamente representativos (Blaschke, 2010).

Utilizou-se o algoritmo multiresolução, presente no software Definiens Developer.

O parâmetro de escala define a heterogeneidade dos pixels determinando o tamanho dos objetos; o parâmetro de forma promove o equilíbrio da suavidade da borda de um segmento e a compacidade estabiliza os critérios de homogeneidade dos objetos (Whiteside e Ahmad, 2005).

Os parâmetros de segmentação adotados no estudo foram: escala de segmentação 50, forma 0.1 e compacidade 0.5. Dessa forma, foi possível a diferenciação dos segmentos, tomados como objetos, entre si, resultando em polígonos distinguíveis para cada classe, inclusive a separação dos polígonos de Sombra.

2.2.2 Definição das classes

As classes foram estabelecidas com base na análise visual da imagem. Houve a necessidade de definir a classe Sombra após o resultado da segmentação, pois os segmentos de Sombra poderiam interferir na definição dos objetos relacionados aos tipos vegetacionais da imagem. Para a área de estudo foram definidas cinco classes: Mangue, Restinga, Floresta, Água e Sombra.

2.2.3 Geração dos atributos

As extrações dos atributos referem-se ao uso de quatro índices de vegetação com ampla aplicabilidade, tais como o Razão Simples (*SR*), do Índice de Vegetação por Diferença Normalizada (*NDVI*), Índice de Vegetação Ajustado ao Solo (*SAVI*) e Índice de Vegetação Triangular (*TVI*).

Os índices de vegetação foram customizados e calculados no software Definiens Developer®.

Historicamente, o *SR* foi o primeiro índice a ser usado (Jordan, 1969), obtido pela divisão de valores da quantidade relativa de radiação eletromagnética refletida por uma dada superfície referente à região do infravermelho próximo por valores da quantidade relativa de radiação eletromagnética refletida correspondentes à região do vermelho.

Para a geração da *SR* foi utilizada a seguinte expressão (Equação 1):

$$SR = \rho_{nir} / \rho_{red} \quad (1)$$

em que: ρ_{nir} = valores dos níveis de cinza correspondente à banda do infravermelho próximo e ρ_{red} = valores dos níveis de cinza correspondente à banda do infravermelho

O *SR* fornece valiosas informações sobre a biomassa da vegetação para vegetação de grande biomassa, tais como florestas (Jensen, 2009).

Rouse et al. (1973) normalizaram a razão simples para o intervalo de -1 a +1, propondo o *NDVI*. O *NDVI* permite estimar mudanças sazonais da vegetação.

A razão reduz os ruídos de diferenças solar, sombras de nuvens, algumas atenuações atmosféricas e algumas variações topográficas; entretanto, é um índice sensível a variações do substrato sob o dossel, com valores altos para substratos mais escuros (Jensen, 2009).

Para a geração do *NDVI* foi utilizada a seguinte expressão (Equação 2):

$$NDVI = \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}} \quad (2)$$

em que: ρ_{nir} = valores dos níveis de cinza correspondente à banda do infravermelho próximo e ρ_{red} = valores dos níveis de cinza correspondente à banda do infravermelho.

As características do solo têm uma considerável influência no espectro de radiação proveniente de dosses vegetais esparsos, e conseqüentemente, no cálculo dos índices de vegetação (Huete, 1988). Assim, em numerosos estudos, o brilho do solo (principalmente em substratos de solos escuros) tem mostrado um aumento no valor de índices de vegetação como o *SR* e o *NDVI* (Ponzoni e Shimabukuro, 2009).

O *SAVI* é um índice de vegetação que inclui um termo de correlação dos efeitos da contaminação do sinal pelo fundo do dossel, principalmente o ruído originado pelo solo (Huete, 1988). No *SAVI* introduziu-se uma constante *L* que tem a função de minimizar o efeito do solo no resultado final do índice, segundo o qual os valores ótimos são: $L=1$ (para densidades baixas de vegetação); $L=0,5$ (densidades médias) e $L=0,25$ (densidades altas).

Nesse estudo optamos por adotar o valor de *L* como 0,5 pela densidade de vegetação intermediária, consistindo em vegetação nem tão exuberante e nem esparsa.

Para a geração do *SAVI* foi utilizada a seguinte expressão (Equação 3):

$$SAVI = \frac{(1 + L)(\rho_{nir} - \rho_{red})}{\rho_{nir} + \rho_{red} + L} \quad (3)$$

em que: ρ_{nir} = valores dos níveis de cinza correspondente à banda do infravermelho próximo e ρ_{red} = valores dos níveis de cinza correspondente à banda do infravermelho.

Broge e Leblanc (2000) desenvolveram o *TVI*, o qual descreve a energia radiativa absorvida pelos pigmentos como uma função da diferença relativa entre as refletâncias no vermelho e no infravermelho próximo conjuntamente com a magnitude da refletância na região do verde, onde a absorção de luz pelas clorofilas a e b é relativamente insignificante (Jensen, 2009). Para a geração do *TVI* foi utilizada a seguinte expressão (Equação 4):

$$TVI = 0,5 (120 (\rho_{red} - \rho_{green})) - 200 (\rho_{red} - \rho_{green}) \quad (4)$$

em que: ρ_{red} = valores dos níveis de cinza correspondente à banda do infravermelho e ρ_{green} = valores dos níveis de cinza correspondente à banda do verde.

2.2.4 Coleta e análise das amostras

Posteriormente à definição dos atributos, foram realizadas coletas de amostras de objetos (segmentos) das classes por meio da avaliação cognitiva dos analistas, de forma que os objetos fossem representativos para cada classe.

Em sequência, estes segmentos e seus respectivos atributos (valores dos índices de vegetação calculados pelas Equações 1, 2, 3 e 4) foram exportados em formato vetorial (*shapefile*) e tabela (*csv*).

As amostras exportadas em tabela foram utilizadas como entrada no software WEKA (*Waikato Environment for Knowledge Analysis*) (Witten e Frank, 2005) onde se optou pela utilização do algoritmo J48, uma implementação do C4.5 (Quinlan, 1993), que utiliza o conceito de mineração de dados para a indução de 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 exibe a classe esperada, sendo que, para cada nó, o algoritmo escolhe o melhor atributo que separe os dados em classes individuais (Francisco e Almeida, 2012).

2.2.5 Classificação da imagem

Os valores e limiares gerados pela árvore de decisão obtida do J48 foram convertidos em regras para a criação da rede semântica, utilizando o algoritmo *classification* para a classificação dos objetos no software Definiens Developer®.

2.2.6 Avaliação dos resultados

O resultado da classificação baseada em objeto foi exportado para polígonos em formato ESRI® *shapefile*. Este mapa foi utilizado no ArcGIS® para geração de duzentos pontos aleatórios gerados na região delimitada pelo retângulo envolvente mínimo que define a área de estudo. Estes pontos foram utilizados para gerar as amostras de controle e as amostras com o resultado da classificação.

Para as amostras de controle (considerada como verdade), foi realizada a intersecção do ESRI® *shapefile* do Inventário Florestal (INSTITUTO FLORESTAL, 2005) com os pontos aleatórios previamente gerados para obter a informação de cada classe do Inventário Florestal no ponto coincidente. Em para ambas as amostras (classificação e controle) foi utilizada a ferramenta *Identity* para identificar cada ponto com a classe do objeto coincidente.

De posse destas informações, o próximo passo foi a geração da matriz de confusão para calcular o coeficiente Kappa de Cohen (COHEN, 1960) de concordância entre as amostras. Este coeficiente fornece uma medida de concordância entre a classificação (*shapefile* resultante da classificação) e o que foi considerado verdade (*shapefile* do Inventário Florestal). Este coeficiente foi utilizado por ser considerada uma medida de maior robustez em relação ao cálculo percentual de concordância simples entre amostras, pois, o cálculo de k leva também em conta as chances da concordância ocorrer ocasionalmente. Neste trabalho foi utilizado o Kappa não ponderado no qual a implementação foi adaptada de Cardillo (2007).

3. Resultados e Discussão

3.1 Mineração de Dados

A Figura 2 ilustra a árvore de decisão gerada pelo classificador J48 com base no conjunto de amostras coletadas para cada classe.

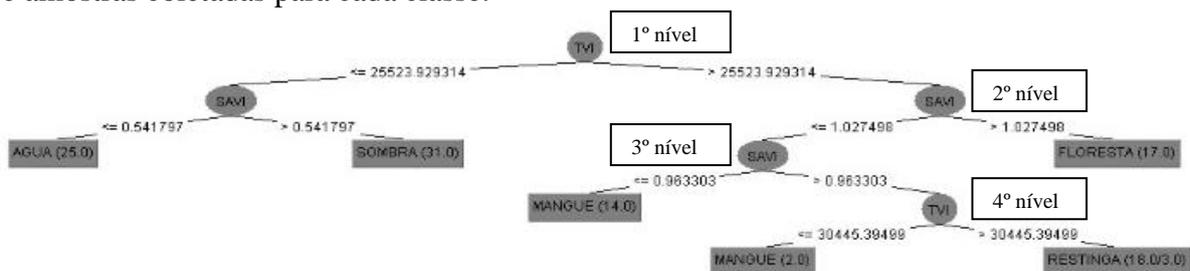


Figura 2. Árvore de decisão.

Os atributos considerados no WEKA-J48 foram os índices de vegetação *TVI* e *SAVI*. Os valores para *NDVI* e *SR* foram cortados da árvore de classificação. Os valores para *NDVI* e *SR* não foram considerados pelo minerador de dados para a separação das classes. Considerando a Figura 2, observa-se que inicialmente a árvore divide-se em dois grandes ramos, tendo como raiz o nó *TVI*, no qual para o ramo esquerdo foram atribuídos os objetos não-vegetacionais e no ramo direito as classes dos tipos vegetacionais.

Para o ramo esquerdo, pode-se observar que o índice *SAVI* foi escolhido para separação entre as classes Água e Sombra.

Para separação dos tipos vegetacionais, no ramo da direita, com valores maiores de *TVI*

foram classificadas a Floresta, Restinga e Mangue.

No ramo da direita (2º nível) o descritor *SAVI* foi usado para definir a Floresta. Em seu nó filho esquerdo (3º nível), valores menores de *SAVI* foram utilizados para distinguir o Mangue da Restinga. Nesta partição o índice *SAVI* separou uma primeira classe Mangue e o *TVI* (4º nível) foi utilizado para a separação final entre Mangue e Restinga.

3.2 Classificação da imagem

O resultado pela utilização dos índices *SAVI* e *TVI* pela árvore de decisão permitiu a identificação das áreas de manguezal, apesar de uma confusão ocorrida em uma região perto da Floresta, na parte superior da imagem (Figura 3).

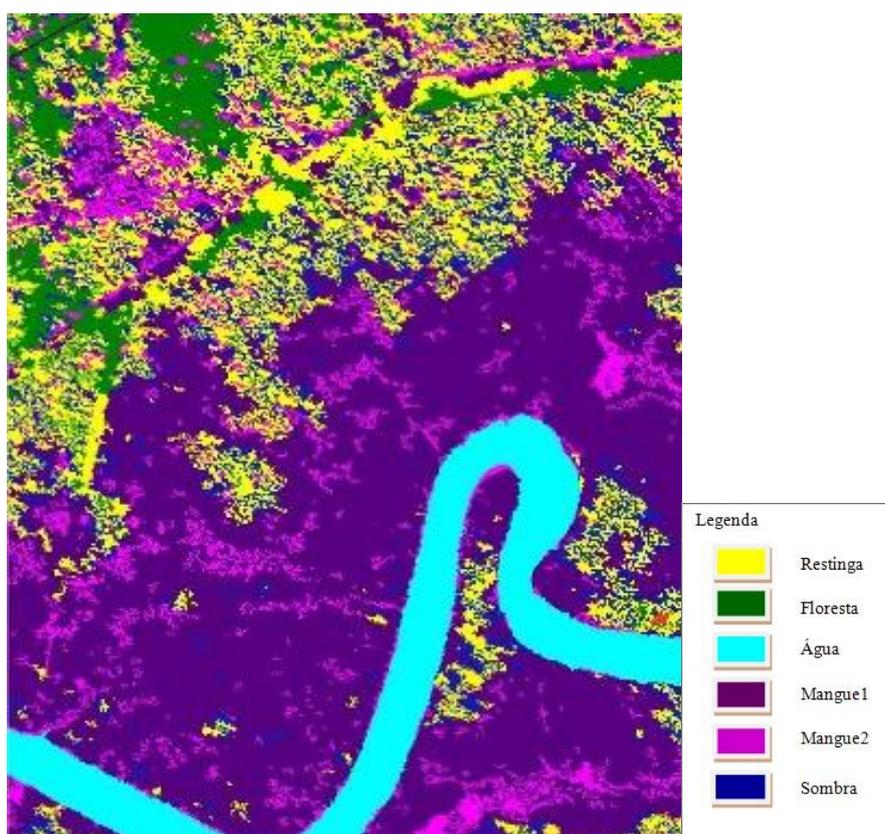


Figura 3. Resultado da classificação OBIA.

Diante da árvore de decisão foi possível também identificar tipos de mangue, classificado como Mangue 1 e 2. Apenas pela análise da imagem não foi possível identificar e extrair informações da veracidade dos dois tipos. A classe Restinga foi bem identificada, principalmente por ser uma vegetação com menor densidade que a Floresta, apesar de a classificação ter mapeado uma região de Restinga onde possivelmente é uma área de Mangue, verificada na porção interior da curva do rio.

A Água foi bem identificada na imagem e não houve confusão com outras classes, ao contrário do resultado para a Floresta e Restinga. Apesar da área de Floresta ter sido identificada na porção norte da imagem, ela apresentou confusão com a classe Restinga em uma extensão da linha de transmissão de energia elétrica.

3.3 Avaliação da classificação

A Tabela 1 demonstra a matriz de confusão gerada para avaliar a classificação.

Tabela 1. Matriz de confusão.

	Referência Instituto Florestal			Total classificadas
	Mangue	Restinga	Floresta	
Mangue	60	44	2	106
Restinga	1	32	6	39
Floresta		12	5	17
Total coletadas	61	88	13	162
Exatidão do produtor	98%	36%	38%	
Classificação Exatidão do usuário	57%	82%	29%	60%

A classificação obteve uma Exatidão Global de 60% e Coeficiente Kappa de 0,68.

A classe Mangue obteve o menor erro de omissão na classificação, ao contrário das outras classes de tipologia de vegetação, como a Restinga e a Floresta. Para a identificação das áreas de mangue, pode-se afirmar que o processo de classificação foi bom para acertar as áreas prováveis de ocupação de mangue na área de estudo; contudo, nota-se que os outros tipos florestais obtiveram um desempenho fraco de classificação apresentando um considerável erro de omissão para a classe Restinga, a qual foi erroneamente classificada na maior parte da área de estudo. Dessa forma, ressalta-se a necessidade de melhor delineamento experimental para a definição da Restinga na área de estudo.

4. Conclusões

O tratamento dos segmentos como objetos permitiu a aplicação dos índices de vegetação considerando os parâmetros aplicados para a definição das classes. Esse tratamento permitiu o uso do conceito de mineração de dados para a definição de valores e limiares a serem utilizados nas regras de decisão de uma classificação baseada em objeto.

A exatidão global da classificação (60%) mostra um resultado razoável para a proposta de utilizar os índices de vegetação para diferenciar a tipologia Mangue. Contudo, não foi adequada para as outras tipologias de vegetação, como Restinga e Floresta, as quais apresentaram grande confusão na classificação. Apesar de ter sido possível identificar a tipologia de vegetação com erro menor para a classe Mangue, ainda é necessário um delineamento experimental com uma melhor conceituação para a classe Restinga.

Agradecimentos

À Escola Politécnica da Universidade de São Paulo (EPUSP) pela possibilidade de aperfeiçoamento acadêmico; ao Laboratório de Geoprocessamento por oferecer condições para a realização do presente estudo. Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo suporte aos pesquisadores bolsistas.

Referências Bibliográficas

Blaschke, T. 'Object based image analysis for remote sensing'. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n1, p. 2-16, 2010.

Broge, N. H. ; Leblanc, E. Comparing prediction power and stability of Broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. **Remote Sensing of Environment**, v. 76, p. 156-172. 2000.

Cardillo G. **Cohen's kappa: compute the Cohen's kappa ratio on a 2x2 matrix**, 2007. Disponível em <<http://www.mathworks.com/matlabcentral/fileexchange/15365>>. Acesso em:01 ago. 2012.

- Cohen, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. 20, 37-46, 1960.
- Conchedda, G.; Durieux, L.; Mayaux, P. An object-based method for mapping and change analysis in mangrove ecosystems. **ISPRS Journal of Photogrammetry & Remote Sensing**, vol.63, p. 578–589, 2008.
- Desclee, B., Bogaert, P.; Defourny, P. Forest change detection by statistical object-based method. **Remote Sensing of Environment**, vol. 102, n°1, p. 1–11. 2006.
- DigitalGlobe. DigitalGlobe Imagery Support Data (ISD) - Documentation Supplemental information for the Product Guide. jan, 2011 Disponível em: <http://www.digitalglobe.com/downloads/Imagery_Support_Data_Documentation.pdf>. Acesso em: 16 jun. 2012.
- _____. DigitalGlobe Core Imagery Products Guide. 2012. Disponível em: <http://www.digitalglobe.com/downloads/DigitalGlobe_Core_Imagery_Products_Guide.pdf>. Acesso em: 16 jun. 2012.
- Francisco, C. N; Almeida, C. M. Data Mining Techniques and GEOBIA applied to Land Cover Mapping. Proceeding of the 4th GEOBIA, May 7-9, 2012. Rio de Janeiro, Brazil, p.089. 2012.
- Huete, A. R. A soli-adjusted vegetation index. **Remote Sensing of Environment**, v. 25, p. 295-309. 1988.
- Jensen, J. R. **Sensoriamento Remoto do Ambiente: Uma perspectiva em Recursos Terrestres**. 2nd edition. Prentice Hall, Upper Sadler River, NY. 592 p. 2009.
- Jordan, C. F. Derivation of leaf area index from quality of light on the Forest floor. **Ecology**, v.50, p.663-666, 1969.
- Myint, S.W.; Giri, C.P.; Wang, L.; Zhu, Z.; Gillette, S.C. Identifying mangrove species and their surrounding land use and land cover classes using an object-oriented approach with a lacunarity spatial measure. **Remote Sensing**, v. 45, p. 188-208. 2008.
- Ponzoni, F. J.; Shimabukuro, Y. E. **Sensoriamento Remoto no estudo da vegetação**. São José dos Campos, SP. Silva Vieira Ed, 2009.
- Quinlan, R. **C4.5: programs for machine learning**. San Francisco: Morgan Kaufmann, 316p. 1993.
- Rouse, J.W.; Haas, R.H.; Schell, J.A.; Deering, D.W. **Monitoring vegetation systems in the Great Plains with ERTS**. Third Symposium of ERTS, Greenbelt, Maryland, USA. NASA SP-351, V1:309-317. 1973
- Souza, R. S. R. de. **Bertioga: paisagem, ambiente e urbanização**. 2008. 293 p. Dissertação (Mestrado em Arquitetura e Urbanismo)- Faculdade de Arquitetura e Urbanismo da Universidade de São Paulo, São Paulo. 2008.
- Instituto Florestal de São Paulo. **Inventário florestal da vegetação natural do Estado de São Paulo**. São Paulo: Secretaria do Meio Ambiente. Seção de Manejo e Inventário Florestal. 200 p. 2005.
- Wang, L., Souza, W.P., Gong, P. Integration of object-based and pixel-based classification for mapping mangroves with IKONOS imagery. **International Journal of Remote Sensing**, vol. 25, n°24, p.5655–5668. 2004.
- Whiteside, T.; Ahmad, W. A comparison of object-oriented and pixel-based classification methods for mapping land cover in Northern Australia. In: the Nation Biental Conference of the Spatial Sciences Institute, September, 2005. ISBN 0-9581366-2-9. 2005.
- Witten, I.; Frank, E. **Data Mining: Practical Machine Learning Tools and Techniques**. 2. Ed. San Francisco, CA: Morgan Kaufmann Publishers, 524 p. 2005.