

Modelagem do conhecimento aplicada à detecção de mudanças em ambiente costeiro

Mayne Assunção Moreira ^{1,2}
Paula Maria Moura de Almeida ^{1,2}
Carla Bernadete Madureira Cruz ²
Luiz Felipe de Almeida Furtado ³
Mário Luiz Gomes Soares ¹

¹ Universidade do Estado do Rio de Janeiro - UERJ
Departamento de Oceanografia
Núcleo de Estudos em Manguezais – NEMA/UERJ
Rua São Francisco Xavier, nº 524 – Maracanã
Pavilhão João Lyra Filho, 4º andar, bloco E, sala 4023
CEP 20550-900 Rio de Janeiro – RJ - BR
{mayne89, almeida.pmm, mariolgs}@gmail.com

² Universidade Federal do Rio de Janeiro - UFRJ
Departamento de Geografia, Rio de Janeiro, RJ
Laboratório Espaço de Sensoriamento Remoto e Estudos Ambientais
Av. Athos da Silveira Ramos, 274 Bloco I Sala 010
CEP 21941-611 Rio de Janeiro - RJ – BR
cmad@ufrj.br

³ Instituto Nacional de Pesquisas Espaciais – INPE
Divisão de Sensoriamento Remoto - DSR
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
furtadosere@gmail.com

Abstract. The landscape is constantly changing, be it natural or anthropogenic character. Coastal environments are naturally more dynamic than the inner portions of the continent, and lately has been suffering with landscape changes by anthropogenic action. Aiming at monitoring of these environments, the study of the landscape changes has always been the target of numerous studies of remote sensing. At the same time, the techniques used for such analyzes has been constant improvement, however, a major challenge is still analyzing large time series in such dynamic environment as coastal areas. In this context, the present work was developed in the pursuit of optimizing change detection techniques, without losing the quality of the product generated. Using a historical series of nine TM/Landsat 5 images, with 30 km resolution, covering the period 1984-2006, and object-based images analysis, a multiresolution segmentation of bands 3 and 4 each scene was done. The classification of areas of change was made in two levels of segmentation using mainly descriptors NDVI (mín/máx_NDVI and amp_NDVI). The result showed that the optimization technique and the descriptors used were very efficient for the separability of the classes “not change” and “change”, with very good global accuracy (0.81) and *Kappa* index (0.76) at 1: 150,000 scale, validated based reference points collected in the field.

Palavras-chave: OBIA, segmentação multirresolução, classificação multitemporal, *otimização*

1. Introdução

A detecção de mudança tem se tornado cada vez mais frequente no estudo e monitoramento de ambientes naturais, tanto na busca de compreender sua dinâmica e evolução natural, quanto no acompanhamento do efeito de possíveis fatores estressantes aos quais tais ambientes estejam submetidos.

Concomitantemente, os métodos utilizados para classificação de imagens tem sofrido várias alterações e aperfeiçoamento ao longo do tempo. Tem-se buscado, cada vez mais, a relação entre as feições do terreno e as características da imagem (cor, textura, padrão,

contexto etc) tornando a interpretação digital de imagens mais semelhante ao processo cognitivo humano (Cruz et al., 2007). Neste contexto, está inserida a Análise de Imagem Baseada em Objetos, do inglês, *Object-Based Image Analysis* (OBIA), que tem como fundamento, a regionalização no processo de interpretação de imagens, usando não somente características espectrais, mas também, estruturais e espaciais no processo de distinção de classes (Burnett e Blaschke, 2003; Lang e Langanke, 2005).

As vantagens trazidas pela OBIA favorecem os estudos de mudanças da paisagem por facilitar o reconhecimento de alterações nos padrões característicos de determinadas feições, uma vez que a análise tem seu foco voltado para objetos homogêneos da imagem e não mais para os pixels (Hay e Castilla, 2008).

Além disso, um dos grandes desafios relacionados à geração de produtos temáticos, é o grau de automatização, principalmente no sentido de ampliar o número de dados analisados em um menor espaço de tempo, favorecendo o monitoramento e preservação dos ambientes naturais. Sendo assim, este trabalho apresenta uma metodologia de otimização da detecção de mudanças em uma série multitemporal de imagens, de média resolução, por meio da análise baseada em objetos.

2. Área de Estudo

A área de estudo está localizada no extremo-sul da Bahia. Nesta região estão presentes ecossistemas extremamente frágeis como manguezais, brejos, restingas, dentre outros (Andrade e Dominguez, 2002). Na faixa marinha adjacente, entre 20 e 70 km da linha de costa, está localizado o complexo recifal dos Abrolhos, o maior do Oceano Atlântico Sul Ocidental, cuja manutenção da biodiversidade marinha e costeira se relaciona com a preservação dos recursos naturais costeiros (Soares, 2006).

Além do exposto, a região possui um elevado potencial turístico, e tem sido alvo de especulação imobiliária, projetos industriais (fábrica de celulose), atividades agropecuárias, exploração de combustíveis fósseis, entre outros (Andrade e Dominguez, 2002).

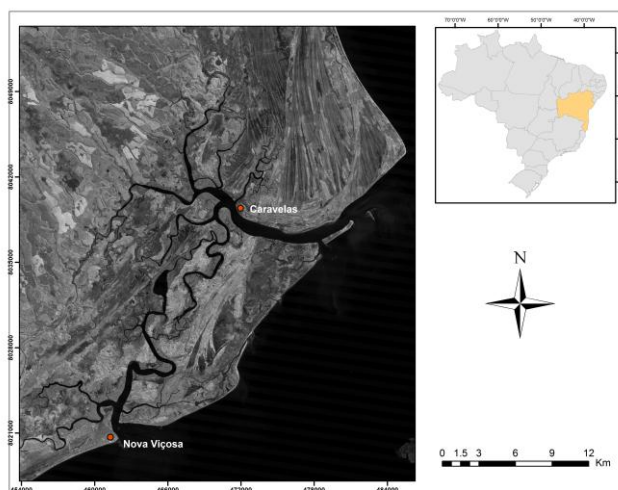


Figura1. Área de estudo

3. Metodologia de Trabalho

Foi selecionada uma série de nove imagens (Quadro 1), correspondente ao período de 1984 a 2006, obtidas pelo sensor *TM/Landsat 5* (Órbita/Ponto 215/72).

Datas das imagens	
1/6/1984	5/8/1996
9/5/1987	8/6/1998
15/4/1990	16/6/2001
7/4/1993	24/6/2004
29/5/2006	

Quadro 1. Relação das datas das imagens utilizadas na análise.

A série temporal foi georreferenciada, passou pela correção atmosférica e transformação do nível de cinza para valores de reflectância de superfície. Neste trabalho, optou-se em utilizar o modelo de correção atmosférica 6S, desenvolvido por Vermote et al. (1997).

As classes de uso e cobertura do solo, deste estudo, foram divididas duas grandes classes: “Mudança” e “Não mudança”, sendo áreas de “Mudança”, aquelas que sofreram alguma alteração ao longo da série; e, áreas de “Não mudança” aquelas que permaneceram constantes durante o período analisado. As áreas de “Não mudança” foram detalhadas nas seguintes classes: “Água” (oceano atlântico e rios), “Mangue” (vegetação do manguezal com estrutura diversificada), “Apicum” (planície hipersalina com ou sem vegetação rasteira, localizado na porção interna do manguezal e que, eventualmente, sofre lavagem pelas marés), “Outras feições” (demais feições vegetadas ou de solo exposto do terreno) e “Urbano” (perímetro urbano).

A classificação simultânea foi iniciada tomando como princípio a OBIA. Na classificação, foram utilizadas apenas as bandas do vermelho (*red*) e infra-vermelho próximo (*near infrared*). A seguir procedeu-se com a segmentação multirresolução usando toda a série temporal.

A segmentação foi realizada de forma heurística e em várias etapas até a delimitação mais fiel das feições do terreno. Por fim, foram escolhidos dois níveis de segmentação, o primeiro com parâmetro de escala 10 (L10), para separação das feições de “Água” e “Não água”, e o segundo com parâmetro de escala 5 (L5), para separação entre áreas de “Mudança” e “Não mudança”. Após a classificação realizada no *e-Cognition*[®] 8.7, deu-se início à etapa de edição manual das classes.

Por fim, procedeu-se à validação do produto gerado com base em dados de referência. Os pontos para validação foram coletados em Maio/2014. Pelo fato do mapeamento final ser o resultado de uma análise multitemporal de 22 anos, foi necessário realizar um ajuste nestes pontos de forma que eles representassem áreas de “Mudança” e “Não mudança”. Para isso foram utilizados um total de 301 pontos de validação que serviram como referência nos cálculos de acurácia global e índice *Kappa* (Congalton e Green, 1999).

4. Resultados e Discussão

Parte dos resultados obtidos é resultante das abordagens empíricas e de modelagem do conhecimento utilizadas para a proposta de detecção de mudança multitemporal. Sendo assim, os resultados aqui apresentados representam o detalhamento da metodologia descrita anteriormente, a modelagem do conhecimento, o mapeamento, propriamente dito, e sua avaliação.

4.1. Análise da Trajetória do Alvo

Para identificar de forma simultânea as mudanças na área analisada, foram estabelecidas relações entre as imagens utilizando os valores de NDVI de cada objeto gerado pela segmentação.

Vicens et al (2009) conduziram um estudo no Rio de Janeiro com o propósito de diferenciar fisionomias de remanescentes florestais do Rio de Janeiro. Eles analisaram a variação mensal do Índice de Vegetação de Diferença Normalizada, do inglês, *Normalized*

Differencing Vegetation Index (NDVI) a partir de amostras florestais com o propósito de identificar os valores máximos e mínimos e gerar uma imagem de amplitude do NDVI. Essa imagem serviu como descritor de sazonalidade para distinção entre floresta ombrófila e estacional. O cálculo do NDVI é bastante utilizado em estudos que buscam comparações sazonais, interanuais e de longo prazo da vegetação, além da distinção entre fitofisionomias (Lisenberg et al., 2007). Além disso, a utilização de índices de vegetação associados a metodologias de OBIA tem fornecido informações acessórias, como topologia, forma, textura e até mesmo dados temáticos, que aprimoram o resultado da classificação.

Foi então estabelecida uma trajetória temporal dos valores de NDVI de cada objeto a fim de identificar o valor mínimo e o valor máximo de NDVI e, então, calcular a amplitude de NDVI ao longo da série de imagens. Devido ao fato da proposta de trabalho ser uma análise simultânea de nove imagens e também, em virtude da mudança da paisagem ser em sua maioria relacionada à alteração da cobertura “vegetada” para a “não vegetada”, optou pelo estudo da variação do NDVI ao longo de toda série histórica (Figura 1a). Sendo assim, para detecção simultânea de mudanças, foram estabelecidas relações entre as imagens utilizando os valores de NDVI de cada objeto gerado pela segmentação.

Foram então criados descritores anuais de NDVI, baseando-se no método de análise de variação mensal de NDVI, proposto por Vicens et al (2009). Cada objeto da imagem foi analisado individualmente a fim de identificar, ao longo da série de imagens, os momentos nos quais são registrados o maior e o menor valor de NDVI (mín/máx_NDVI). A partir da identificação desses valores, foi obtida a imagem amp_NDVI para a série temporal, resultado da subtração do máx_NDVI pelo mín_NDVI. Cada objeto da imagem foi caracterizado com um valor de amp_NDVI, aqueles que apresentaram um valor próximo a ‘zero’ possuem menor chance de terem sofrido mudança ao longo do tempo, já os que apresentaram valores próximos a ‘um’ possuem mais chance de pertencerem à áreas estáveis (Figura 1b). De posse de todos os descritores, seguiu-se à modelagem e distinção das classes.




Figura 1. a) Variação anual do NDVI em amostras (objetos) das classes de “Mudança” e “Não mudança”; b) Distribuição do valores de amp_NDVI em amostras (objetos) das classes “Mudança” e “Não mudança”.

4.2. Modelagem do Conhecimento

Em primeira estância, as classes do mapeamento foram estruturadas de maneira que os objetos, gerados na etapa de segmentação, herdassem características para os níveis seguintes de classificação.

A classe hierárquica para a obtenção da legenda final teve a seguinte ordem:

- Água (nível L10)
- Não água (nível L10)
 - Mudança (nível L5)
 - Não mudança (nível L5)
 - Apicum (nível L5)
 - Verde (nível L5)
 - Mangue (nível L5)
 - Outras feições (nível L5)

No nível L10 foram separadas as feições “Água” e “Não água”, utilizando os descritores “brilho” e “mín_NDVI” para modelagem da água. A justificativa para a escolha desses descritores se dá pelo fato dos objetos de água possuírem tonalidade escura, com baixos valores de brilho e também, pelo fato da água ser, dentre todas as feições, aquela que apresenta os menores valores de NDVI.

Após a separação das classes “Água” e “Não água”, seguiu-se para um nível mais detalhado de segmentação (L5), de modo a identificar as áreas de mudança e não mudança, além de detalhar as classes finais da legenda existentes dentro da área de não mudança.

Para a modelagem da “Não Mudança”, foram escolhidos os descritores de “amp_NDVI” e “mín_NDVI”. O critério para a detecção de áreas sem mudanças de feições foi, principalmente o descritor “amp_NDVI”. Aqueles objetos que apresentaram valores de “amp_NDVI” próximos de zero tinham maior probabilidade de pertencerem à classe “Não Mudança”, e quanto maior o valor de “amp_NDVI” mais chance do objeto pertencer à classe MUDANÇA.

O detalhamento das classes-filhas de “Não Mudança” foi realizado em duas etapas: na primeira, distinguiu-se entre áreas com/sem vegetação. Nesse nível foram criadas as classes “Apicum” e “Verde”. A classe “Apicum” foi modelada utilizando os descritores “max_NDVI” e “min_NDVI”; e, na segunda etapa, as classes-filhas pertencentes à classe “Verde” foram separadas em “Mangue” e “Outras feições”. Devido à especificidade da classe, a melhor estratégia para esta etapa da classificação foi a modelagem da classe MANGUE e, os atributos selecionados foram “brilho” e “média_b4_1996”.

4.3. Mapeamento

O mapeamento final da detecção de mudanças na área de estudo está representado na Figura 2. Os valores correspondentes à área total mapeada e o detalhamento das áreas de “Mudança” e das classes pertencentes à “Não mudança” estão descritos na Tabela 1.

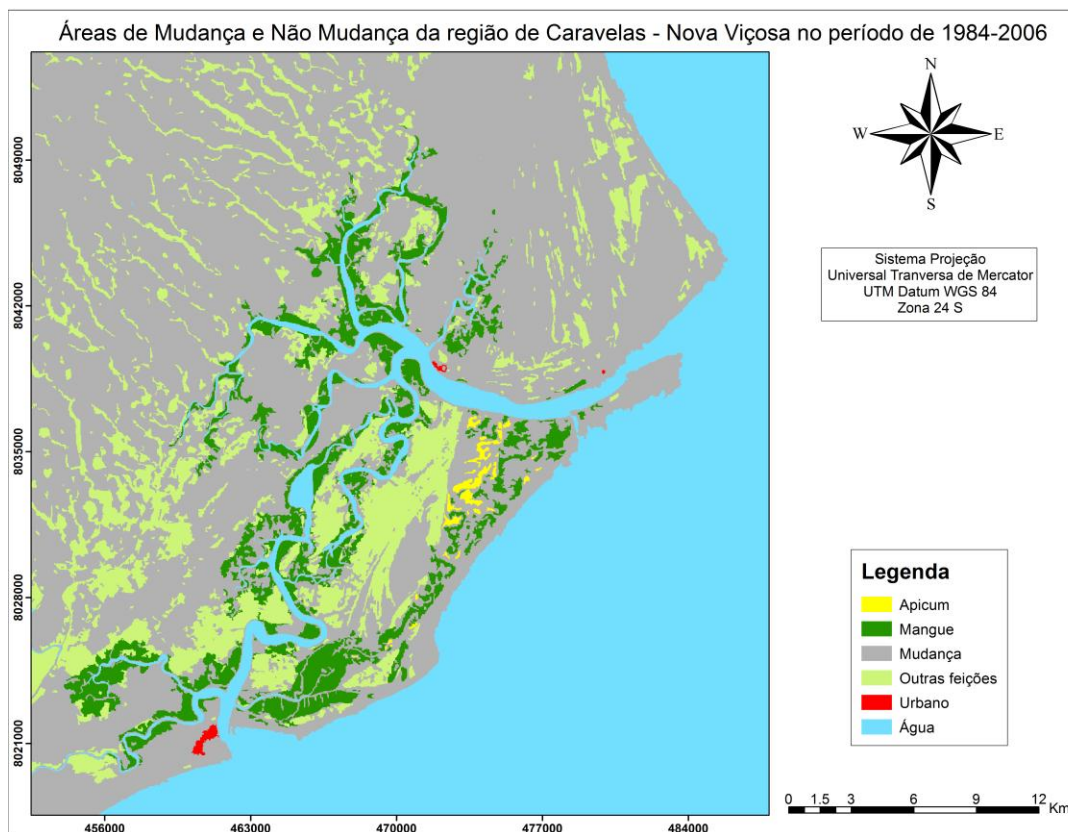


Figura 2. Classificação temática das áreas de “Não mudança” e “Mudança” da área de estudo no período entre 1984 a 2006.

Tabela 1. Total e percentual das áreas correspondentes ao mapeamento das classes de “Não mudança” e “Mudança”.

CLASSES	Área	
	Km ²	%
Mudança	646,4	48,6
Água	468,2	35,2
Apicum	3,1	0,2
Mangue	72,4	5,4
Outras feições	139,0	10,4
Urbano	0,9	0,1
TOTAL	1330,0	100

Com relação ao detalhamento das classes pertencentes à “Não mudança” temos, a classe “Água” contribuindo com 468,2 km² (35,2 %) da área total da “Não mudança” (Tabela 1).

A classe “Outras feições” é a segunda mais representativa com 139 km² (10,4%) de área. Essa classe compreende todas as feições naturais que não correspondem às áreas de floresta de mangue ou apicum.

A classe “Mangue” contribui com 5,4% (72,4 km²) da área de “Não mudança”. Observa-se na Figura 2 que as áreas de mangue conservadas desde o início da análise, são aquelas mais internas. Áreas de mangue localizadas nos limites com outras feições, como água e apicum, são áreas mais dinâmicas e favoráveis à mudança ao longo do tempo.

A classe “Apicum” apresenta 3,1 km² de área (0,2%) e a classe “Urbano” tem uma área pouco representativa para “Não mudança” (0,1%).

Com relação à avaliação geral do mapeamento, a acurácia global e o índice *Kappa* foram de 0,81 e 0,76, respectivamente. Estas análises levam em consideração os acertos de cada

classe em função do total de pontos de referência. Segundo **Fonseca (2000)**, baseando-se no índice *Kappa*, este mapeamento é classificado como MUITO BOM.

São inúmeras as técnicas utilizando a detecção de mudanças (Coppin et al., 2004), bem como são diversas as fontes de imageamento terrestre, sendo assim, as comparações entre as porcentagens de acertos obtidos por esse tipo de análise torna-se um tanto complicada. Diversos trabalhos apresentam valores de acurácia global e índice *Kappa* excelentes para a detecção de mudança (Coppin et al., 2004; Conchedda et al., 2008). Vale ressaltar que a grande maioria, senão todos, estudam áreas reduzidas, utilizam em suas análises imagens de alta resolução, e manipulam um pequeno número de imagens. Este trabalho, por sua vez, aborda uma área de 1330 km², utiliza dados de média resolução e manipula, simultaneamente, uma série de 22 anos composta por nove imagens, características estas que podem agregar uma série de erros ao longo das suas etapas de pré-processamento e classificação. Entretanto, ainda assim, resultaram em um produto de elevado grau de acurácia e concordância com a realidade, podendo ser replicado, com os devidos ajustes, à outros ambientes costeiros com a presença de classes semelhantes.

4.4. Otimização da técnica de detecção de mudança

Considerando as nove imagens, tínhamos uma área total de 11970 km² a ser modelada e mapeada. Com a utilização deste método de detecção simultânea da mudança, foi alcançada uma redução de 51,4% da área a ser mapeada. Em outras palavras, toda a área que permaneceu sem alteração ao longo da série temporal foi mapeada de uma só vez, nas nove imagens, restando somente a modelagem mudanças interanuais, que corresponde à 48,6% da área total.

5. Conclusões

A análise de uma longa série temporal, de média resolução, assegurada pelos valores bastante satisfatórios de acurácia e concordância do resultado final, favorece a análise em grande extensão espaço-temporal da dinâmica natural entre as feições do ambiente costeiro, bem como das mudanças geradas pela intervenção humana na paisagem provocando a sua modificação. Além disso, a nova abordagem proposta para detecção de mudança de forma simultânea mostrou-se bastante satisfatória com redução de mais da metade do esforço empregado na modelagem e edição das classes de mapeamento.

Agradecimentos

Os autores agradecem à Coordenação de Aperfeiçoamento Pessoal de Nível Superior - CAPES pela bolsa; ao Instituto Nacional de Ciência e Tecnologia (INCT-AmbTropic) pelo suporte financeiro; ao Laboratório ESPAÇO de Sensoriamento Remoto e ao Núcleo de Estudos em Manguezais pelo apoio favorável à realização deste estudo.

Referências Bibliográficas

Andrade, A.C.S.; Dominguez, J.M.L. Informações geológico-geomorfológicas como subsídios à análise ambiental: o exemplo da planície costeira de Caravelas – Bahia. **Boletim Paranaense de Geociências**, v. 51, p. 9-17, 2002.

Burnett, C.; Blaschke, T. A multi-scale segmentation/object relationship modelling methodology for landscape analysis. **Ecological modelling**, v.168, n.3, p.233-249, 2003.

Conchedda, G.; Durieux, L.; Mayaux, P. An object-based method for mapping and change analysis in mangrove ecosystems. **Journal of Photogrammetry & Remote Sensing**, v. 63, p.578-589, 2008.

Congalton, R. G.; Green, K. **Assessing the Accuracy of Remotely Sensed Data: principles and practices**. Boca Raton: CRC Press, 1999. 183 p.

Coppin, P.; Jonckheere, I.; Nackaerts, K.; Muys, B.; Lambin, E. Review article digital change detection methods in ecosystem monitoring: a review. **International Journal of Remote Sensing**, v.25, n.9, p.1565-1596, 2004.

Cruz, C.B.M.; Vicens, R.S.; Seabra, V.S.; Reis, R.B.; Faber, O.A.; Richter, M.; Arnaut, P.K.E.; Araujo, M. Classificação orientada a objetos no mapeamento dos remanescentes da cobertura vegetal do bioma Mata Atlântica, na escala 1:250.000. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 13, 2007, Florianópolis. **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**. São José dos Campos: INPE, 2007. Artigos, p.. CD-ROM, On-line. ISBN 978-85-17-00031-7. Disponível em <<http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2007/01.31.19.10/doc/capa.htm>>. Acesso em: 31 out. 2014.

Fonseca, L. M. G. **Processamento digital de imagens**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais (INPE), 105p., 2000.

Hay, G.J. e Castilla, G., 2008. Geographic Object-Based Image Analysis (GEOBIA). In: Blaschke, T.; Lang, S.; Hay, G. J. (Eds.) **Object-Based Image Analysis - Spatial concepts for knowledge-driven remote sensing applications**. New York: Editora Springer, 2008. cap. 1.4, p. 81- 92.

Huete, A.; Didan, K.; Miura, T.; Rodriguez, E. P.; Gao, X; Ferreira, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195-213, 2002.

Lang, S.; Langanke, T. Multiscale GIS tools for site management. **Journal for Nature Conservation**, v.13, p.185-196, 2005.

Soares, M.L.G. (Coord.). **Laudo Biológico do Sistema Caravelas – Nova Viçosa com Vistas à Criação da Reserva Extrativista do Cassurubá**. Brasília: MMA. 247 p. 2006.

Vermote, E. F.; Tanré, D.; Deuze, J. L.; Herman, M.; Morcrette, J. J. Second simulation of the satellite signal in the solar spectrum, 6S: an overview. **IEEE Transaction on Geoscience and Remote Sensing**, v. 35, p. 675–686, 1997.

Vicens, R. S.; Cronembergue, F. M.; Cruz, C. B. M. Análise multi-resolução e modelagem do conhecimento na diferenciação de fisionomias de florestas em remanescentes de Mata Atlântica no Estado do Rio de Janeiro. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 14, 2009, Natal. **Anais XIV Simpósio Brasileiro de Sensoriamento Remoto**, São José dos Campos: INPE, 2009. Artigos, p. 7789-7796. CD-ROM, On-line. ISBN 978-85-17-00044-7. Disponível em <<http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2009/03.02.18.19/doc/capa.htm>>. Acesso em: 31 out. 2014.