

Classificação de florestas naturais e plantadas no bioma Pampa com imagens de satélite multi-sensor e análise orientada a objeto

Priscila Brochado Gomes¹
Édson Luis Bolfe¹
Luciana Spinelli-Araujo¹
Daniel de Castro Victoria¹
Marilice Cordeiro Garrastazu²

¹ Embrapa Monitoramento por Satélite - CNPM
Av. Soldado Passarinho, 303
13070-115 - Campinas - SP, Brasil
{priscila.brochado, edson.bolfe, luciana.spinelli, daniel.victoria}@embrapa.br

² Embrapa Florestas - CNPF
Estrada da Ribeira, Km 111, Caixa Postal: 319
83411-000 - Colombo - PR, Brasil
marilice.garrastazu@embrapa.br

Abstract. Forest cover changes influence weather condition, affect biological diversity, lead to soil erosion, alter ecosystems services, disrupt socio-cultural practices, and increase natural disasters. Monitoring forest cover is a big challenge for public managers in a huge and diverse country such as Brazil. High resolution satellite images could be an important tool to help solve this challenge. The objective of this study was to analyze the performance of object-based image classification to discriminate natural and planted forests using RapidEye images (2012) and the improvement obtained by using additional images from Landsat 5 (2004 and 2014). The study area was Cerrito, Rio Grande do Sul state, a city located in the Pampa biome. We tested classifications using three different datasets: (1) RapidEye image from 2012; (2) Rapid Eye image from 2012 plus Landsat 5 image from 2004; (3) Rapid Eye from 2012 plus Landsat 5 images from 2004 and 2014. The Kappa index obtained in the three classification tests was all above 0.9, indicating an excellent accuracy. The best result was achieved using a combination of RapidEye (2012) and Landsat 5 (2004), with a Kappa of 0.93. This combination reduced the confusion between planted and natural forests. The results demonstrate the potential of RapidEye images and object-based image analysis for the municipal-scale monitoring of forest cover in Pampa biome.

Palavras-chave: remote sensing, forest, RapidEye, Landsat, sensoriamento remoto, floresta.

1. Introdução

A retirada da cobertura florestal de uma região influencia as condições climáticas, afeta a biodiversidade, causa erosão no solo, altera os serviços ecossistêmicos, interrompe práticas socioculturais, e aumenta a chance de ocorrência de desastres naturais, como inundações ou escassez de água (Kindu et al, 2013). Visando minimizar o desflorestamento, o Brasil vem realizando diversas ações e estabelecendo políticas públicas e legislação específica no tema. Destaca-se o programa para redução da emissão de gases de efeito estufa na agricultura (Programa ABC), estabelecido pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA, 2012). Dentre seus objetivos, destaca-se: reduzir o desmatamento, adequar as propriedades rurais à legislação ambiental, e ampliar a área de florestas cultivadas, prevendo o aumento de seis milhões de ha para nove milhões de ha de florestas plantadas até 2020. O plano nacional sobre mudança do clima (MMA, 2014a) também é outro esforço governamental, que visa a incentivar o desenvolvimento e aprimoramento de ações de mitigação no Brasil, colaborando com o esforço mundial de redução das emissões de gases de efeito estufa. Como legislação, salienta-se o estabelecimento do atual Código Florestal, em assinado em 2012 pela Presidente da República (Lei 12.651/2012), que trouxe como principais novidades o Cadastro Ambiental Rural (CAR) e o Programa de Regularização Ambiental (PRA).

Estas políticas e instrumentos jurídicos são um marco para a gestão ambiental no âmbito rural. Com eles espera-se que as ações dos órgãos ambientais sejam facilitadas no que se refere ao monitoramento da cobertura florestal e combate ao desmatamento, passando a ser um importante instrumento para planejamento de políticas públicas ambientais (MMA, 2014b). Porém, a extensão do país e a diversidade de seus biomas tornam a atividade de monitoramento da cobertura vegetal florestal algo bastante complexo. Assim, a informatização do CAR, bem como a utilização de Sistemas de Informação Geográfica (SIG) e Sensoriamento Remoto (SR) terão papel preponderante neste processo. Para isso é necessário o desenvolvimento de uma metodologia que permita aos órgãos ambientais acessar de forma rápida e eficiente as mudanças na cobertura vegetal das terras. Esta metodologia deverá ser suficientemente: (1) precisa, para analisar fenômenos envolvendo escala municipal/local; (2) completa, para detectar com precisão mudanças na cobertura da terra; (3) confiável e reproduzível em termos espaço-temporal, para que possa ser periodicamente usada para avaliação da mudança na cobertura de todo o país (Dupuy et al, 2012).

A aplicação de qualquer metodologia utilizando SIG e SR só é possível quando se dispõe de uma base de dados confiável e com escala adequada para o estudo que se propõe. Pensando nisso, em novembro de 2012 o Ministério do Meio Ambiente (MMA) firmou contrato para aquisição de imagens RapidEye, de 5 m de resolução espacial, cobrindo todo o território brasileiro. A aquisição será periódica, sendo que até o momento duas coberturas completas, anos base 2011 e 2012, já estão disponíveis para os organismos federais e estaduais através de um sistema denominado GeoCatalogo (<http://www.geocatalogomma.com.br/>). Tais imagens, devido a sua resolução espacial, podem servir, por exemplo, como insumos para a interpretação e classificação de feições cartográficas, bem como para a produção de mapas temáticos e de referência.

A classificação digital utilizando imagens orbitais de alta resolução espacial tem sido empregada na discriminação e identificação de diferentes alvos florestais ainda de forma experimental (Gomes et al., 2008; Watzlawick et al., 2009; Cintra et al., 2011; Hessel et al., 2012). No entanto, a disponibilidade cada vez maior de bases governamentais com imagens de satélite no Brasil, a exemplo das imagens do sensor Rapideye, tem permitido gerar novos processos e metodologias mais apropriadas para estes tipos de classificações. Considerando o grande volume de dados e o custo computacional de classificações com imagens de alta-resolução, com maior variabilidade de respostas espectrais, a análise orientada a objeto vem sendo uma opção (Fernandes et al., 2012; Liu et al., 2013). Nessa abordagem, além da característica espectral de cada pixel, são incorporadas informações de contexto e a imagem é analisada a partir de pequenos segmentos, os objetos, gerados no processo de segmentação. Os objetos com características em comum são agrupados em classes, que são estruturadas formando uma rede hierárquica, onde as classes de um nível inferior (subclasses) herdam as características da classe do nível superior (superclasse). A etapa de classificação dos objetos é baseada em regras, onde o conhecimento do usuário é usado para criar um conjunto de critérios para identificação dos objetos, como características de cor, textura, forma e contexto. O emprego de regras possibilita a replicação do processo para diferentes imagens e áreas, com atualizações do código e adequações para os diferentes dados (Hofmann & Vejt 2001).

Assim, o objetivo deste trabalho foi analisar o desempenho da classificação orientada a objeto para discriminar florestas naturais e plantadas, usando imagens RapidEye e a melhoria obtida na classificação com a adição de imagens temporais do satélite Landsat 5. A área de estudo foi o município de Cerrito (RS), pertencente ao bioma Pampa. O estudo é parte do projeto intitulado “Classificação e Espacialização do Estoque de Carbono de Florestas Naturais e Plantadas por meio de Sensoriamento Remoto”, integrante da rede de Dinâmica da Emissão de Gases de Efeito Estufa e dos Estoques de Carbono em Florestas Brasileiras Naturais e Plantadas na Embrapa (GEE – Saltus). Um dos objetivos do referido projeto é

aplicar diferentes modelos de classificação digital para florestas naturais e plantadas em diferentes áreas de referência nos biomas Cerrado, Transição Cerrado/Amazônia, Pantanal, Mata Atlântica e Pampa.

2. Metodologia de Trabalho

O Município de Cerrito está localizado no Extremo Sul do Estado do Rio Grande do Sul (Figura 1), possui uma área de 451,9 km² e 6.738 habitantes. Possui a economia voltada ao setor agropecuário tendo como maior expressão a produção leiteira. Constituído, em sua maioria, por pequenas propriedades rurais e minifúndios, destaca-se a produção de milho, soja, pêssego, arroz e a avicultura. Pertence ao Bioma Pampa, apresentando manchas de Floresta Estacional Decidual e Semidecidual (IBGE 2014).

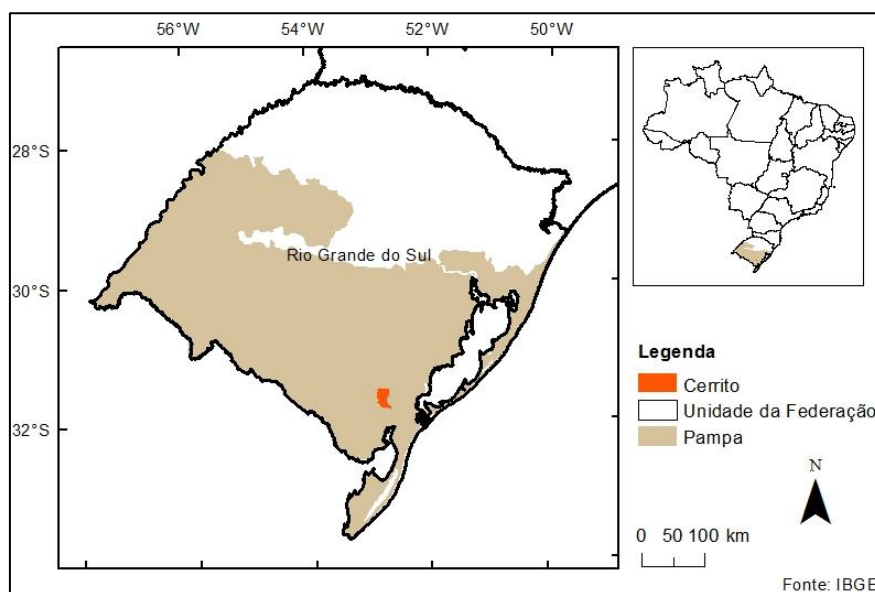


Figura 1: Localização da área de estudo.

Para classificação dos alvos utilizamos imagens do satélite RapidEye de 2012, adquiridas pelo MMA. As imagens do tipo “RapidEye Ortho – Level 3A” já vem ortoretificadas, com correção radiométrica e contemplam cinco faixas espectrais: 1) Azul (440–510nm), 2) Verde (520-590nm), 3) Vermelho (630-685nm), 4) Red-Edge (690-730nm) e 5) Infravermelho Próximo (760-850nm), com resolução espacial de 5 metros. Para cobrir toda a área do município foram necessárias seis cenas RapidEye, sendo que quatro com data de imageamento de 27/11/2012, uma de 22/09/2012 e outra de 29/08/2013. Como optamos por trabalhar com as imagens disponíveis no GeoCatálogo, não foi possível cobrir o município todo com cenas de mesma data. Como dados temporais auxiliares, utilizamos imagens do satélite Landsat 5, de 15/10/2004 e 28/01/2014. As imagens Landsat foram adquiridas gratuitamente no site da USGS (United States Geological Survey, <http://earthexplorer.usgs.gov/>). Como critério para o download das cenas foram escolhidas as imagens Landsat 5 com correção atmosférica (Land Surface Reflectance L4-5), com máximo de 20% de nuvens, corrigidas geometricamente (TM L1T).

Como o objetivo do trabalho foi testar um método simplificado, de fácil e rápida aplicação, optamos por fazer o mínimo possível de pré-processamento das imagens. Assim, para o processo de segmentação e classificação, apenas recortamos as cenas para a área do município e, no caso das imagens RapidEye, trabalhamos separadamente com as cenas de data diferente, unindo apenas as cenas de mesma data, através da função mosaico do ENVI, sem balanço de cores. Além disso, para embasar o processo de classificação na definição das classes, coleta de amostras de treinamento e validação, trabalhamos com dados espaciais já

existentes em outras bases. Os dados espaciais utilizados foram: (1) mapa de cobertura vegetal realizado pelo MMA, por meio do Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira (PROBIO, Figura 2) e disponibilizado em formato *shapefile* (<http://www.mma.gov.br/biomas/pampa/mapa-de-cobertura-vegetal>), (2) ferramentas do Google como Google Earth (incluindo série de imagens temporais), Google Maps e Google Street View (Figura 3), (3) mapa de uso e cobertura de uma fazenda de silvicultura parceira do projeto.




Figura 2: Mapa de cobertura vegetal de Cerrito, gerado através de dados do Ministério do Meio Ambiente - Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira (PROBIO).




Figura 3: Detalhe de uma mesma área em (A) imagem de satélite RapidEye (Inclui material © RapidEye AG de 2012. Todos os direitos reservados); (B) imagem do Google Maps (Imagens ©2014 CNES / Astrium, dados do mapa ©2014 Google); (C) imagem do Google Street View (Captura da imagem: jun 2012 ©2014 Google); destacando áreas de Floresta Plantada (FP) e Floresta Natural (FN).

Processamos as imagens RapidEye (2012) e Landsat 5 (2004 e 2014) no *software eCognition Developer* versão 8.8 (Trimble 2012), considerando 3 etapas: segmentação, construção de uma hierarquia de classes e classificação. A primeira etapa consistiu na criação de objetos na imagem através do algoritmo de segmentação multi resolução, que é baseada no conceito de evolução de rede fractal (FNEA: *Fractal Net Evolution Approach*, Trimble 2012). O procedimento é similar ao crescimento de regiões que agrupa pixels ou sub-regiões em regiões maiores minimizando a heterogeneidade média para um dado número de objetos e

maximizando sua homogeneidade baseado em parâmetros definidos (Trimble, 2012). Para a segmentação utilizamos apenas a imagem RapidEye, que é a de maior resolução espacial, com os seguintes parâmetros: 100 de escala; 0,9 de cor versus 0,1 de forma; 0,5 de compactação versus 0,5 de suavidade. Após a segmentação criamos a hierarquia de classes ilustrada pela Figura 4.



Figura 4: Hierarquia de classes usada na classificação

Para a separação da classe ‘sem vegetação’ da classe ‘vegetação’, utilizamos como atributo de separação o índice de vegetação NDVI (Equação 1) previamente criado através da ferramenta *Create New Arithmetic Feature*. Utilizamos para isso a função *Assign Class*.

$$NDVI = \frac{(NIR - R)}{(NIR + R)} \quad (1)$$

onde: NIR = número digital no infravermelho próximo; R = número digital no vermelho

Para as outras subclasses extraímos amostras através da ferramenta *Sample Selection* e realizamos a classificação através de comparação dos histogramas das amostras das classes de mesmo nível hierárquico e cálculo da função de pertinência. Ou seja, dentro da superclasse ‘vegetação’, comparamos os histogramas das subclasses ‘floresta’ e ‘sem floresta’ e calculamos a função de pertinência que melhor se ajustou aos histogramas analisados. Fizemos o mesmo para as subclasses ‘natural’ e ‘plantada’. Para todos estes casos testamos três diferentes grupos de atributos da imagem:

- Teste 1 - brilho, máxima diferença e média das faixas espectrais da imagem RapidEye e o NDVI;
- Teste 2 - brilho, máxima diferença e média das faixas espectrais da imagem RapidEye, NDVI, média das faixas espectrais da imagem Landsat de 2004;
- Teste 3 - brilho, máxima diferença e média das faixas espectrais da imagem RapidEye, NDVI, média das faixas espectrais das imagens Landsat de 2004 e de 2014.

O objetivo desta diferenciação dos atributos utilizados foi testar se existem ganhos na qualidade da classificação com o uso das imagens Landsat, através de informações temporais.

Para avaliação da qualidade da classificação, selecionamos pontos de teste para a geração da matriz de erro ou de confusão, sendo esta uma forma eficaz para representar a acurácia na precisão de cada categoria, tanto nos erros de inclusão (quando um objeto é classificado como pertencente a uma classe a qual não pertence), quanto nos erros de exclusão (quando um objeto não é corretamente classificado na classe a qual pertence) da classificação. Realizamos a seleção de pontos a partir da amostragem aleatória simples, considerando as orientações de Stehman e Foody (2009) e Congalton e Green (2009). Avaliamos os resultados aplicando o índice Kappa; Landis e Koch, 1977; Congalton e Mead, 1983) tendo como dados de referência os dados espaciais descritos anteriormente (Figuras 2 e 3). Para elaboração da matriz de confusão e cálculo do Kappa consideramos apenas as classes alvo foco do estudo, ‘Floresta Plantada’ e ‘Floresta Natural’, agrupando as outras classes em uma só, aqui denominada ‘Outros Usos e Coberturas’.

3. Resultados e Discussão

Para os três testes realizados, obtivemos altos valores de Kappa, todos superiores a 0,9, com uma pequena vantagem para o Teste 2 (0,93) em relação aos Testes 1 (0,91) e Teste 3 (0,92) (Tabela 1). Estes resultados foram semelhantes aos obtidos por Gomes et al. (2008) (0,91) e superiores aos gerados por Fernandes et al. (2012) com Kappa de 0,72, ao realizarem procedimentos de classificação orientada a objeto para a classificação de áreas florestais no Brasil utilizando imagens de satélite.

Analisando a matriz de confusão apresentada na Tabela 1, observamos que o resultado ligeiramente melhor apresentado pelo Teste 2 foi devido, principalmente, à menor confusão entre as classes 'Floresta Natural' e 'Floresta Plantada'. O erro de exclusão da classe 'Floresta Plantada' caiu de 17,39% no Teste 1 para 13,04% nos Testes 2 e 3; já o erro de inclusão passou de 11,63% no Teste 1 para apenas 4,76% no Teste 2 e 6,98% no Teste 3. Para a classe 'Floresta Natural', o erro de exclusão passou de 7,14% no Teste 1 para 5,56% no Teste 2, tendo ficado em 6,35% no Teste 3. Para esta classe, o erro de inclusão foi de 7,87% no Teste 1, 4,8% no Teste 2 e 5,6% no Teste 3. Para a classe 'Outros Usos e Coberturas', o erro de exclusão não variou entre os três testes, ficando em 1,44%, e o erro de inclusão variou muito pouco, ficando entre 2 e 3%.

Tabela 1: Matriz de confusão e resultado do Índice Kappa para os três testes realizados.

Dados de referência					
Dados Classificados	Floresta Natural	Floresta Plantada	Outros usos e coberturas	Total	Erro de inclusão (%)
Teste 1 – Apenas imagem RapidEye					
Floresta Natural	117	5	5	126	7,87
Floresta Plantada	5	38	0	46	11,63
Outras coberturas	4	3	343	348	2,00
Total	127	43	350	520	
Erro de exclusão (%)	7,14	17,39	1,44		
Kappa					0,91
Teste 2 – Imagem RapidEye + Landsat 2004					
Floresta Natural	119	1	5	125	4,80
Floresta Plantada	2	40	0	42	4,76
Outras coberturas	5	5	343	353	2,83
Total	126	46	348	520	
Erro de exclusão (%)	5,56	13,04	1,44		
Kappa					0,93
Teste 3 - Imagem RapidEye + Landsat 2004 + Landsat 2014					
Floresta Natural	118	2	5	125	5,60
Floresta Plantada	3	40	0	43	6,98
Outras coberturas	5	4	343	352	2,56
Total	126	46	348	520	
Erro de exclusão (%)	6,35	13,04	1,44		
Kappa					0,92

A pequena melhoria na separação entre as florestas 'plantada' e 'natural' ocorreu devido a algumas florestas terem sido plantadas após 2004 e, assim, na imagem daquele ano, as áreas posteriormente ocupadas por floresta plantada estavam com outro tipo de cobertura. Isso permitiu que alguma confusão que ocorreu na separação de florestas naturais e plantadas nas imagens RapidEye fosse resolvida com o uso do dado temporal do Landsat. Contudo, a

diferença no resultado final foi tão pequena entre os três tratamentos que podemos afirmar que apenas as imagens RapidEye foram suficientes para gerar uma classificação das florestas de Cerrito com alta acurácia, conforme padrões descritos por (Congalton e Green (2009). Esses resultados, corroboram outros estudos realizados em biomas de outros países, que obtiveram ótimos resultados na classificação de alvos florestais com uso de imagens RapidEye e Classificação Orientada a Objetos, como o estudo feito por Kindu et al. (2013) na Etiópia.

Os resultados obtidos neste estudo contemplam um município do bioma Pampa. Importante bioma do estado do Rio Grande do Sul, onde ocupa uma área de 176.496 km², correspondendo a 63% do território estadual, as paisagens naturais do Pampa são variadas, de serras a planícies, de morros rupestres a coxilhas, com predomínio dos campos nativos, mas também presença de matas e outras formações (MMA, 2014c). Um dos fatores que potencialmente contribuíram para a qualidade dos resultados obtidos é inerente às características das formações florestais deste bioma, que ocorrem principalmente em uma paisagem cuja matriz predominante é campestre. Podemos verificar, portanto, que as imagens Rapideye têm alto potencial para detecção automática de alvos florestais no Bioma Pampa, que o método de classificação orientada ao objeto é um método adequado para classificação com imagens RapidEye e que as imagens Landsat podem fornecer dados temporais auxiliares para apurar a classificação. Mapas e dados como os apresentados na Figura 5 serão de grande valia para acompanhamento da cobertura florestal de municípios, se realizados de forma periódica, apoiando o monitoramento da execução de políticas públicas e da legislação florestal.

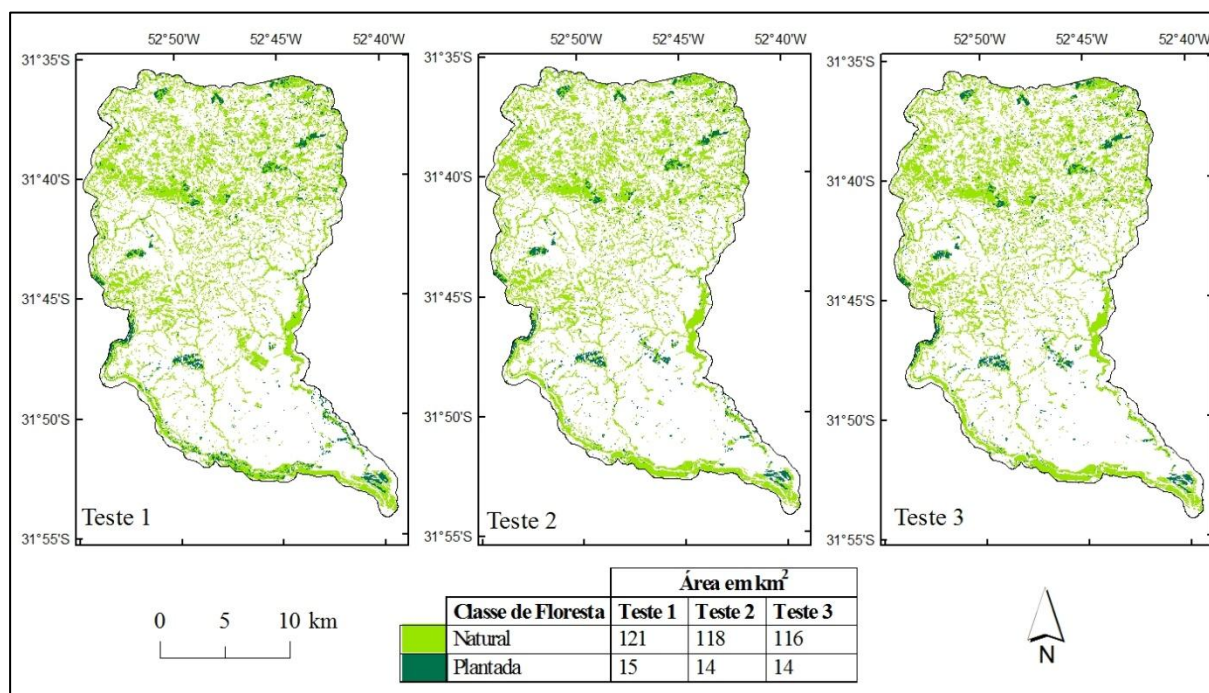


Figura 5: Mapas de cobertura florestal no município de Cerrito (RS), gerados pelas classificações realizadas nos Testes 1, 2 e 3, e área ocupada pelas duas classes de floresta em cada um dos testes.

4. Conclusão

A acurácia dos resultados obtidos na área de estudo no bioma pampa, por meio da classificação orientada a objeto utilizando imagens RapidEye, foi adequada para a detecção e diferenciação entre florestas naturais e plantadas. A adição das imagens Landsat no processo de classificação utilizando não gerou melhorias significativas na acurácia final do mapeamento.

A aquisição de imagens RapidEye pelo Ministério do Meio Ambiente constitui-se em uma importante base de dados para estudos de uso e cobertura florestal no Brasil, como no projeto: “Classificação e Espacialização do Estoque de Carbono de Florestas Naturais e Plantadas por meio de Sensoriamento Remoto”.

Visando avaliar a presente metodologia e sua indicação para apoiar a legislação florestal vigente, sugere-se testar estes procedimentos e imagens utilizadas para biomas e regiões com maior complexidades da estrutura e cobertura vegetal, a exemplo do Bioma Cerrado.

5. Agradecimentos

Os autores agradecem ao projeto: “Classificação e Espacialização do Estoque de Carbono de Florestas Naturais e Plantadas por meio de Sensoriamento Remoto” (GeoSaltus) (Embrapa – SEG n. 01.11.01.001.03.00).

6. Referências Bibliográficas

- Cintra, D.; Rego, L.; Oliveira, R. Classifying successional forest stages using ikonos in atlantic forest of Rio de Janeiro. **Revista Geográfica Acadêmica**, América do Norte, v. 521, n. 07, 2011.
- Congalton, R.G., Green, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. Taylor & Francis Group, New York. 2009.
- Congalton, R.G.; Mead, R.A. A quantitative method to test for consistency and correctness in photointerpretation. **Photogrammetric Engineering & Remote Sensing**, v. 49, n.1, p. 69-74, 1983.
- Dupuy, S.; Barbe, E.; Balestrat, M. An object-based image analysis method for monitoring land conversion by artificial sprawl use of RapidEye and IRS data. **Remote Sensing**, v. 4, p. 404-423, 2012.
- Fernandes, R.R.; Nunes, G. M.; Silva, T.S.F. Classificação orientada a objetos aplicada na caracterização da cobertura da terra no Araguaia. **Pesquisa Agropecuária Brasileira**, v.47, n.9, p.1251-1260, 2012.
- Gomes, P.B.; Ferreira, M.C.; Lingnau, C.; Bolfe, E.; Siqueira, M.F. Segmentação e classificação de dossel florestal em imagens Quickbird. **Ambiência**, v. 4, p. 35-46, 2008.
- Hessel, F.O.; Carvalho Junior, O.A.; Gomes, R.A.T; Martins, E.S.; Guimarães, R.F. Dinâmica e sucessão dos padrões da paisagem agrícola no município de cocos (Bahia). **Raega - O Espaço Geográfico em Análise**. v. 26, p. 128-256, 2012.
- Hoffmann, A; Vejt, J.W.V. New sensor systems and new classification methods: laser-and digital camera-data meet object-oriented strategies. **Journal for Spatial Information and Decision Making**. v. 6, n.1, p. 18-23, 2001.
- IBGE. Disponível em: <http://www.cidades.ibge.gov.br/xtras/perfil.php?lang=&codmun=430512>. Acessado em 22 set. 2014.
- Landis, J.R.; Koch, G.G.. The measurement of observer agreement for categorical data. **Biometrics**, v. 3, n. 1, p. 159-174, 1977.
- Kindu, M; Schneider, T; Teketay, D; Knoke, T. Land use/land cover change analysis using Object-Based Classification Approach in Munessa_Shashemene Landscape of Ethiopian Highlands. **Remote Sensing**, v. 5, p. 2411-2435, 2013.
- Liu, E.; Zhou, W.; Zhou, J.; Shao, H.; Yang, X. Combining spectral with texture features into object-oriented classification in mountainous terrain using advanced land observing satellite image. **Journal of Mountain Science**, v. 10, n. 5, p. 768-776, 2013.
- MMA (Ministério do Meio Ambiente)a. **Plano nacional sobre mudanças no clima**. Disponível em: <<http://www.mma.gov.br/clima/politica-nacional-sobre-mudanca-do-clima/plano-nacional-sobre-mudanca-do-clima>>. Acesso em 03 nov. 2014.
- MMA (Ministério do Meio Ambiente)b. **Cadastro Ambiental Rural**. Disponível em: <<http://www.car.gov.br/#/>>. Acesso em 23 out. 2014.
- MMA (Ministério do Meio Ambiente)c. **Biomas – Pampa**. Disponível em: <<http://www.mma.gov.br/biomas/pampa>>. Acesso em 23 out. 2014.
- MAPA (Ministério da Agricultura, Pecuária e Abastecimento). **Plano ABC**. Disponível em: <<http://www.agricultura.gov.br/desenvolvimento-sustentavel/plano-abc>>. Acesso em 03 nov. 2014.
- Stehman, S.V.; Foody, G.M.. Accuracy assessment. In: Warner, T.A., Nellis, M.D., Foody, G.M. (Eds.), **The Sage Handbook of Remote Sensing**. SAGE, London, p. 297–309, 2009
- Trimble, eCognition Developer 8.8 User Guide. Trimble Germany GmbH, Munich, Germany. 2012
- Watzlawick, L. F.; Kirchner, F. F.; Sanguetta, C.R. Estimativa de biomassa e carbono em floresta com araucária utilizando imagens do satélite IKONOS II. **Ciência Florestal**, v. 19, n. 2, p. 169-181, 2009.