### Classificação de formações vegetais do Pantanal por meio da análise orientada a objeto em imagens de satélite de alta resolução espacial

Priscila Brochado Gomes<sup>1</sup> Édson Luis Bolfe<sup>1</sup> Luciana Spinelli Araujo<sup>1</sup> Daniel de Castro Victoria<sup>1</sup> Marilice Cordeiro Garrastazu<sup>2</sup>

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

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

Resumo. As mudanças na cobertura vegetal das terras são componentes importantes nas discussões ambientais e de utilização das terras por atividades de produção agropecuária nos diferentes biomas brasileiros. Cada vez mais, o sensoriamento remoto tem sido utilizado para estes estudos, porém, ainda existem limitações relacionadas à resolução espacial, temporal e espectral das imagens de satélite utilizadas e à geração de metodologias para áreas mais abrangentes. O bioma Pantanal é considerado uma das maiores extensões úmidas contínuas do planeta, porém tem sido impactado fortemente pela ação antrópica. O monitoramento desse bioma é bastante difícil, principalmente pelas alterações no regime de inundações que causam mudanças no uso e cobertura vegetal. Assim, este artigo objetiva avaliar o potencial das imagens Rapideye e da análise orientada a objeto para a discriminação e classificação de formações vegetais de uma área representativa do Pantanal da Nhecolândia, município de Corumbá (MS). Realizamos alguns testes com diferentes parâmetros de escala e testamos a utilização da banda RedEdge, considerando como classes as formações florestal, savânica e campestre. A classificação identificada como mais adequada foi a que empregou escala 100 e todas as bandas do RapidEye, incluindo a RedEdge, com Kappa de 0,73. Na matriz de confusão a principal dificuldade observada foi em relação à discriminação da formação savânica, por esta se confundir muito com a formação campestre. A caracterização e espacialização dessas áreas são de suma relevância para a constituição de bases técnico-científicas de informações para amparar políticas públicas de desenvolvimento e sustentabilidade do Pantanal.

Palavras-chave: sensoriamento remoto, processamento de imagens, vegetação.

*Abstract.* Changes in land use and land cover are an important component in discussions about environment and production at the different Brazilian biomes. There is an ever growing use of Remote Sensing techniques in these studies, but restrictions still exist, for instance related to spatial, temporal and spectral resolution of the satellite images and to methods for analysis of more extensive areas. The Pantanal biome, considered one of the largest continuous wetland areas in the world, has been strongly impacted by human action. The monitoring of this biome is difficult, especially because of the changes to the flooding regime, which cause changes in land use and land cover. Thus, in this article we aim to evaluate the potential of RapidEye images and object-oriented analysis to distinguish and classify the vegetation of an area which is representative of Pantanal at Nhecolândia, Corumbá, MS. We used different scale parameters and the RedEdge band to test for the separation of forest, savanna and grasslands classes. The most adequate classification, for which we obtained a 0.73 Kappa, used a scale of 100 and all of the RapidEye's bands, including the RedEdge. In the confusion matrix, the main difficulty detected was the distinction between the savanna and the grasslands classes. The characterization and specialization of these areas are essential for the production of technical-scientific information bases to support public policies for the development and sustainability of Pantanal.

Key-words: remote sensing, image processing, vegetação.

#### 1. Introdução

O bioma Pantanal é considerado uma das maiores extensões úmidas contínuas do planeta com aproximadamente 150.355 km<sup>2</sup>, ocupando 1,76% da área total do território brasileiro. Este bioma ainda mantêm 86,77% de sua cobertura vegetal nativa, porém tem sido impactado fortemente pela ação antrópica, principalmente pela atividade agropecuária (MMA, 2014).

A vegetação florestal e não florestal, como as fisionomias de cerrado e os campos inundáveis, conjuntamente com os usos agropecuários e urbanos, são importantes componentes do mosaico de uso e cobertura da terra do Pantanal, que possibilitam a manutenção da biodiversidade, serviços ambientais, geração de produtos madeireiros e não madeireiros. Adamoli (1995) já destacava que o regime de inundações do Pantanal é o fator ecológico fundamental que determina os pulsos dos principais processos bióticos e abióticos, bem como as composições específicas das unidades de paisagem. As alterações no regime de inundações causam mudanças no uso e cobertura vegetal, o que influencia todo o bioma. O monitoramento dessas áreas é uma tarefa difícil, em razão das grandes extensões de terra, os diferentes usos e a dificuldade de acesso (Pott & Pott, 2004).

As geotecnologias, por meio do sensoriamento remoto orbital, têm sido aplicadas cada vez com maior intensidade para estudos neste bioma (Rodela, 2006; Adami et al, 2008; Arieira et al., 2011; Evans et al., 2013). Por outro lado, ainda existem limitações envolvendo aspectos técnico-científicos inerentes à resolução espacial, temporal e espectral das imagens de satélite. Estas limitações, em muitos casos, ainda impedem a geração de metodologias para classificações digitais localizadas e sua extrapolação para áreas geograficamente mais abrangentes.

A classificação digital utilizando imagens orbitais de alta resolução espacial tem sido empregada na discriminação e identificação de diferentes alvos agrícolas e de vegetação natural 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 (MMA, 2014), tem permitido gerar novos processos e metodologias mais apropriadas para estes tipos de classificações. As imagens advindas do sensor Rapideye são oriundas de uma constelação de cinco microssatélites multispectrais, lançados em 29 de Agosto de 2008, com resolução espacial de 5 metros (Rapideye, 2014).

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 incorporados 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.

# 2. Objetivo

O objetivo deste trabalho é avaliar o potencial das imagens Rapideye e da análise orientada a objeto para discriminação e classificação de formações vegetais de uma área representativa do Pantanal da Nhecolândia, no município de Corumbá (MS).

## 3. Material e Métodos

A região de estudo corresponde a uma cena, de 25 por 25 km, de imagem RapidEye, onde está incluída a Fazenda Nhumirim, da Embrapa Pantanal, localizada na sub-região da Nhecolândia, município de Corumbá (MS), conforme apresentado na **Figura 1**. Corumbá é um dos 19 municípios de estudo 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. O Foco primordial do projeto, portanto, são as florestas.

O Pantanal da Nhecolândia apresenta uma paisagem única com mosaico de lagoas salinas e de água doce, entremeando cordilheiras com vegetação florestal e, entre estas, corixos e vazantes (por onde escoaria a água nas cheias). Nesta sub-região predomina a vegetação natural de Cerrado, correspondendo a 80% da Nhecolândia. A área antropizada é pequena, em torno de 12%, e refere-se a porções de pastagem cultivada (Abdon & Silva, 2006). É uma das mais expressivas regiões de criação de gado do Brasil, com grande variedade de pastagens nativas, compondo unidades campestres e savânicas (Rodela, 2006). Nas cotas mais baixas do terreno, as pastagens são cobertas pela água na estação das chuvas e rebrotam após o abaixamento das águas, principalmente entre maio e julho (Rodela 2006). As fitofisionomias de maior ocorrência são, em ordem decrescente, as Savanas Gramíneo-lenhosa (Campo), a Savana Arborizada (Cerrado) e a Savana Florestada (Cerradão), com ocorrência de ecótonos de Floresta Estacional Semidecídua (Abdon & Silva, 2006).

Como o objetivo deste estudo é testar o potencial da imagem RapidEye e o método de Classificação Orientada a Objeto de formações vegetais do Pantanal, sem o apoio de trabalho de campo, optamos por generalizar as classes de vegetação em suas formações mais amplas que são: (1) Formação Campestre – aqui incluídas as áreas de campo úmido, campo sazonal, campo limpo, campo sujo e campo cerrado, além de existir a possibilidade de serem incluídas nesta classe as pastagens cultivadas; (2) Formação Savânica – nesta classe consideramos apenas o Cerrado *stricto sensu*, e (3) Formação Florestal – correspondendo ao Cerradão e à Floresta Estacional Semidecídua.



**Figura 1.** Imagem RapidEye de 03/05/2012, na composição RGB - 321e localização da área de estudo

Para classificação dos alvos utilizamos uma imagem do satélite Rapideye, que é parte da aquisição feita pelo Ministério do Meio Ambiente do Governo Federal brasileiro para apoiar a obtenção das informações geospaciais temáticas relacionadas ao Programa de Regularização Ambiental (instituído pelo Decreto Presidencial 7830/2012). As imagens do tipo "RapidEye Ortho – Level 3A" já vem ortorretificadas, 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 este estudo utilizamos uma cena de 25 por 25 km, datada de três de maio de 2012, na qual está incluída a Fazenda Nhumirim.

Processamos a imagem 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). Testamos a classificação com dois parâmetros de escala (100 e 250), e para todos os testes o parâmetro de forma utilizado foi 0,1 e de compactação foi 0,5. Após a segmentação testamos as hierarquias de classe, a que apresentou melhor resultado e, portanto, foi utilizada em todos os testes é representada na **Figura 2**.



Figura 2. Hierarquia de classe usada na classificação

Todo o procedimento de classificação foi realizado para as imagens segmentadas com parâmetro escalar 100 e 250. 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*.

**Equação 1**:  $NDVI = \frac{(\rho NIR - \rho R)}{(\rho NIR + \rho R)}$ 

onde:  $\rho$ NIR = valor de refletância no infravermelho próximo;  $\rho$ R = valor de refletância 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 'arborizada' e 'campestre' e calculamos a função de pertinência que melhor se ajustou aos histogramas analisados. Fizemos o mesmo para as subclasses 'água' e 'solo', 'campestre' e 'florestal'. Para todos estes casos testamos dois diferentes grupos de atributos da imagem: (1) brilho, média das faixas espectrais do visível (azul - B, verde - G e vermelho - R) e infravermelho próximo (NIR) da imagem RapidEye e o NDVI calculado com as bandas R e NIR, conforme Equação 1. (2) brilho, média das faixas espectrais B, G, R, NIR e aqui incluída a faixa do RedEdge (RE) da imagem RapidEye e o NDVI. O objetivo desta diferenciação dos atributos utilizados foi testar o incremento da banda RE que é uma inovação trazida pelas imagens RapidEye específica para monitoramento da atividade fotossintética da vegetação. Assim, considerando os dois parâmetros de escala testados mais os dois grupos de atributos utilizados, testamos quatro diferentes métodos de classificação, conforme resumido na **Tabela 1**.

Tabela 1. Parâmetros e atributos utilizados para a classificação nos quatro testes realizados.

Atributos	Escala 100	Escala 250	
Sem RedEdge (Brilho, B, G, R, NIR, NDVI) Com RedEdge (Brilho, B, G, R, RE, NIR, NDVI)	Teste 1 Teste 2	Teste 3 Teste 4	

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 (**Equação 2**; Landis e Koch, 1977; Congalton et al., 1983) tendo como dados de referência o mapeamento realizado por Rodela (2006), uma imagem GeoEye de 15/01/2013 contemplando parte da área, e imagens do Google Earth (https://www.google.com/earth/). Para elaboração da matriz de confusão e cálculo do Kappa consideramos apenas as classes alvo foco do estudo (Floresta, Cerrado e Campo), não avaliando as outras classes também mapeadas, como água e solo exposto. A comparação entre os valores de Kappa dos testes foi realizada pelo teste Z, utilizando a equação proposta por Congalton e Mead (1983, **Equação 3**).

**Equação 2**: 
$$K = \frac{(P_o - P_c)}{1 - P_c}$$

Onde:  $P_o =$  proporção de unidades que concordam plenamente;  $P_c =$  proporção de unidades que concordam por casualidade;

$$Z = \frac{K_2 - K_1}{\sqrt{\alpha_{k_2}^2 + \alpha_{k_1}^2}}$$
Equação 3:

onde: Z = valor Z calculado; K<sub>1</sub> = coeficiente Kappa do classificador 1; K<sub>2</sub> = coeficiente Kappa do classificador 2;  $\alpha_{k_1}^2$  = variância de Kappa do classificador 1;  $\alpha_{k_2}^2$  = variância de Kappa do classificador 2. As variâncias foram calculadas baseadas na aproximação proposta por Ma e Readmond (1995, **Equação 4**):

Equação 4: 
$$\alpha^2 \approx \frac{P_o(1-P_o)}{N(1-P_c)^2}$$

Se o valor Z calculado para o teste for maior que o valor Z tabelado, diz-se que o resultado foi significativo, concluindo-se que os dois classificadores são estatisticamente diferentes. O valor 'Z tabelado' ao nível de 5% de probabilidade é igual a 1,96.

#### 4. Resultados e Discussão

Ao processarmos a classificação seguindo a hierarquia de classe definida na **Figura 2**, observamos que a classe 'sem vegetação' foi superestimada nas áreas de cota mais baixa do terreno. Isso ocorreu pelo fato da imagem RapidEye utilizada para este estudo ser referente ao mês de maio, período que coincide com o início da vazante no Pantanal da Nhecolândia, quando os campos que ficam inundados durante a cheia secam e começam a rebrotar (Rodela, 2006). Como a imagem corresponde ao início do mês de maio, o processo de rebrota poderia estar apenas no início e, portanto, a área de campo sazonal com baixa cobertura vegetal. Quando comparamos uma mesma área com esta característica na imagem RapidEye de maio de 2012 com a imagem de julho de 2011 podemos observar uma notável diferença na cobertura vegetal (**Figura 3**). Para minimizar este efeito no resultado da classificação, discriminamos a classe

'campestre', através de análise de histograma de amostras, tanto da superclasse 'vegetação' quanto da 'sem vegetação'.



**Figura 3.** Comparação de duas diferentes datas (03/05/2012 - A; 16/07/2011 - B) de uma área de campo sazonal em imagens RapidEye evidenciando a diferença de cobertura vegetal.

Os resultados de Kappa para avaliação da qualidade da classificação variaram de 0,65 a 0,73 entre os quatro métodos testados (**Tabela 2**), foram analisados 647 pontos. O parâmetro de escala 100 utilizado para a segmentação gerou um resultado melhor que o parâmetro de escala 250 segundo o índice Kappa, porém, essa diferença não foi significativa, pelo teste Z, ao nível de significância de 5%. A utilização da banda RE não alterou significativamente o resultado da classificação, tanto quando analisada a escala 100 quanto a 250 (**Tabela 2**). Os únicos tratamentos que diferiram significativamente entre si foram o Teste 2 (escala 100 e uso do RE) e o Teste 3 (escala 250 sem o RE), em que o incremento na detecção da vegetação gerado pela banda RE se somou a melhoria do resultado com o uso da escala 100. Schuster et al. (2012) também testaram a banda RE para a classificação do uso da terra de uma área na Alemanha com imagens RapidEye, obtendo um pequeno incremento na acurácia do resultado quando comparado o uso da RE com o não uso.

Tabela 2. Comparação do resul	tado de Kappa entre os	quatro testes realizados.
-------------------------------	------------------------	---------------------------

Atributos	Escala	Escala	
	100	250	
Sem RedEdge (Brilho, B, G, R, NIR, NDVI)	0,72ab	0,65b	
Com RedEdge (Brilho, B, G, R, RE, NIR, NDVI)	0,73a	0,67ab	

As letras ao lado dos valores de Kappa indicam se os tratamentos são significativamente diferentes (letras diferentes) ou não (letras iguais) entre si ao nível de significância de 5% segundo o teste Z.

Como o resultado do teste de acurácia da classificação não diferiu significativamente entre os testes, apresentamos e discutimos aqui apenas a matriz de confusão gerada pelo Teste 2 (Escala 100, com RE), por ter sido o que apresentou o Kappa um pouco maior entre os quatro testes. A formação de maior erro de exclusão foi a Savânica, com uma porcentagem de 69,5%. A maior confusão foi com a Formação Campestre, que respondeu por 59,4% dos erros de classificação da Savânica, a confusão com a Formação Florestal foi de 10,1%. Esta confusão entre as classes era esperada devido à característica do Cerrado, que forma um gradiente de vegetação que vai do Campo Limpo, com predomínio de vegetação herbácea, passando pelo Campo Sujo, onde os indivíduos arbóreos aparecem de forma isolada, o Cerrado Típico, com maior predomínio de indivíduos arbóreos, até chegar a formação florestal do Cerradão (IBGE, 2012). Como a divisão entre as fitofisionomias é gradual e não abrupta, a separação das classes por método automático é muito difícil. Em seu trabalho de mapeamento da sub-região da Nhecolândia com imagens de radar, Evans et al. (2013) obtiveram confusão entre as mesmas classes aqui apresentadas. A **Figura 4** ilustra a feição das três classes na imagem RapidEye.

**Tabela 3.** Matriz de confusão para avaliação da qualidade da classificação da imagem RapidEye pelo teste 2 (parâmetro de escala 100 e utilização dos atributos: média de todas as bandas do RapidEye, Brilho e NDVI).

Dados de referência					
	Campestre	Savânica	Florestal	Total	Erro de inclusão (%)
Dados classificados					
Campestre	314	76	6	396	20,7
Savânica	0	39	2	41	4,9
Florestal	4	13	193	210	8,1
Total	318	128	201	647	
Erro de exclusão (%)	1,3	69,5	4,0		



**Figura 4.** Detalhe da imagem RapidEye da área de estudo ilustrando os três tipos de formações classificadss: (A) Formação Florestal (elipse branca); (B) Formação Savânica (círculo vermelho), e (C) Formação Campestre (destaque do Campo Sujo no círculo amarelo).

As outras duas formações analisadas (Campestre e Florestal) foram bem classificadas, apresentando baixos erros de exclusão (1,3 e 4% respectivamente, Tabela 3). Os erros de inclusão nessas classes foram quase que exclusivamente gerados pela confusão com a Formação Savânica. A confusão entre as formações Campestre e Florestal foi muito baixa, sendo que apenas 1,3% das áreas campestres foram erroneamente classificadas como florestal e 2,99% das áreas florestais foram classificadas como campestre.

Pela classificação gerada pelo teste 2, verificamos que a formação predominante na área de estudo é Campestre, com 69,36% da área total estudada, seguida pela Florestal, com 24,01% e da Savânica, com 4,15% (**Tabela 4**). O mapa de formações vegetais da área de estudo gerado pela classificação do Teste 2 é apresentado na **Figura 5**.

**Tabela 4.** Área ocupada por cada classe de cobertura do solo na área de estudo, calculada com base no Mapa da classificação da imagem RapidEye, pelo Teste 2.

	Área (ha)	%
Formação Campestre	43353	69,36
Formação Savânica	2596	4,15
Formação Florestal	15006	24,01
Solo	773	1,24
Água	681	1,09
Não Classificado	90	0,14
TOTAL	62500	100,00



**Figura 5.** Mapa de formações vegetais da área de estudo, gerado pela classificação da imagem RapidEye, de 03/05/2012, pelo Teste 2 (parâmetro de escala 100 e utilização dos atributos: média de todas as bandas do RapidEye, Brilho e NDVI).

## 5. Conclusões

A imagem RapidEye e o método de classificação orientada a objeto foram ferramentas adequadas para classificação das fitofisionomias de pantanal aqui analisadas e são instrumentais relevantes na constituição de bases de dados para o Pantanal. Recomendamos para este tipo de processamento no *eCognition* a utilização do parâmetro de escala 100 e o uso de todas as bandas do RapidEye, incluindo a banda RedEdge. A separação da fitofisionomia Floresta, foi realizada com alta qualidade, ressaltando que estamos realizando novos estudos para aprimorar a separação da classe Cerrado.

#### 6. Referências

Abdon, M.M.; Silva, J.S.V. Fisionomias da Vegetação nas Sub-regiões do Pantanal Brasileiro. São José dos Campos: INPE; Campinas: Embrapa Informática Agropecuária, 2006. 1 CD-ROM. ISBN 85-50424-00-8. Disponível em: < http://www.dsr.inpe.br/site\_fisionomias\_pantanal/>. Acesso em 12 ago. 2014.

Adamoli, J. Zoneamento ecológico do Pantanal baseado no regime de inundações. In: Encontro Sobre Sensoriamento Remoto Aplicado a Estudos no Pantanal, 1, 1995, Corumbá. **Anais**. São José dos Campos: Inpe, 2005. p.15-17.

Adami, M.; Freitas, R.M.; Padovani, C.R.; Shimabukuro, Y.E.; Moreira, M.A. Estudo da dinâmica espaço-temporal do bioma Pantanal por meio de imagens MODIS. **Pesquisa Agropecuária Brasileira**, v.43, p.1371-1378, 2008.

Arieira, J.; Karssenberg; D.; de Jong, S.M.; Addink, E.A.; Couto, E.G.; Nunes da Cunha, C.; Skøien, J.O. Integrating field sampling, geostatistics and remote sensing to map wetland vegetation in the Pantanal, Brazil, **Biogeosciences**, v. 8, p. 667-686, 2011.

Cintra, D.; Rego, L.; Oliveira, R. Classifyng 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.

Evans T.L.; Costa, M. Landcover classification of the Lower Nhecolândia subregion of the Brazilian Pantanal Wetlands using ALOS/PALSAR, RADARSAT-2 and ENVISAT/ASAR imagery. **Remote Sensing of Environment**, v. 128, n. 21, p. 118-137, 2013.

Evans T.L.; Costa, M.; Tomas, W.; Camilo, A.R. A SAR fine and medium spatial resolution approach for mapping the Brazilian Pantanal. **Geografia**, v. 38, n. especial, p. 25-43, 2003

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.

#### IBGE. Manual Técnico da Vegetação Brasileira. IBGE, 2012

Landis, J.R.; Koch, G.G.. The measurement of observer agreement for categorical data. **Biometrics**, v. 3, n. 1, p. 159-174, 1977.

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.

Ma, Z.; Redmond, R.L. Tau coefficients for accuracy assessment of classification of remote sensing data. **Photo-grammetric Engineering & Remote Sensing**, v. 61, n.4, p. 435-439, 1995.

MMA (Ministério do Meio Ambiente). **Imagens RapidEye – Geocatálogo**. Disponível em: <a href="http://geocatalogo.ibama.gov.br/">http://geocatalogo.ibama.gov.br/</a>. Acesso em 28 jul. 2014.

Pott, A.; Pott, V.J. Features and conservation of the Brazilian Pantanal wetland. Wetlands Ecology and Management, v.12, p.547-552, 2004.

Rodela, L.G. Unidades **de vegetação e pastagens nativas do Pantanal da Nhecolândia, Mato Grosso do Sul**. Tese (Doutorado). Departamento de Geografia da Faculdade de Filosofia, Letras e Ciências Humanas. Universidade de São Paulo. São Paulo – SP . 222 p. 2006.

RapidEye AG. RapidEye. Disponível em: <a href="http://www.rapideye.de/">http://www.rapideye.de/</a>. Acesso em 05 ago 2013.

Schuster, C.; Förster, M.; Kleinschmit, B. Testing the red edge channel for improving land-use classification based on high-resolution multi spectral satellite data. **International Journal of Remote Sensing**, v. 33, n. 17, p. 5583-5599, 2012

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.