

## Índices de vegetação e análise orientada em geo-objeto na identificação de áreas de soja

Carlos Antonio da Silva Junior<sup>1</sup>  
Marcos Rafael Nanni<sup>1</sup>  
Everson Cezar<sup>1</sup>  
Aline de Carvalho Gasparotto<sup>1</sup>  
Anderson Antonio da Silva<sup>1</sup>  
Guilherme Fernando Capristo Silva<sup>1</sup>  
Franciele Romagnoli<sup>1</sup>  
Rafael Moreno Campos<sup>1</sup>

<sup>1</sup> Universidade Estadual de Maringá - UEM  
Av. Colombo 5790 – 87020-900 - Maringá - PR, Brasil  
{carlos-junior89; franciele\_romagnoli; guilhermecapristo; anderson\_agrouem;  
alinegaspa}@hotmail.com, {marcos.nanni; rafaelmorenocampos}@gmail.com e  
eversoncezar@yahoo.com.br.

**Abstract.** In the southern State of Maranhão, area of interest of this study, soybean production on a large scale can be considered recent, dating back to 1978, the first year that included statistical records on this crop in the Brazilian Institute of Geography and Statistics (IBGE). Later, the producers were organizing in the 1990s and a soybean was already established in the region and that even expanded to other locations in the State. The objective of this work was to map areas planted with soybean [*Glycine max* (L.) Merr.] through vegetation indices from MODIS sensor and classification geographic-object-based image analysis. For the mapping of the soybean crop was used the Enhanced Vegetation Index (EVI) and the Crop Enhancement Index (CEI) for image classification sensor-system Terra/MODIS. For this calculation we used twelve images, including offseason and harvest the crop, as the state agricultural calendar. In addition, the segmentation was employed using scaling parameters 250, the algorithms "classification" and "marge region", and extracting attributes for classification GEOgraphic-Object-Based Image Analysis (GEOBIA). It was used to assess the accuracy of the classification parameters Kappa and Accuracy Global and its resulting t test was applied, it was soon established as null hypothesis (H0) of equal and opposite rates for their differences (H1) at a 5% level of significance. The results indicate that the proposed methodology is efficient for mapping the soybean, with 0.89 for the parameter Kappa.

**Palavras-chave:** crop area, remote sensing, classification, MODIS, GEOBIA, área de cultivo, sensoriamento remoto, classificação, MODIS, GEOBIA.

### 1. Introdução

Na região sul do estado do Maranhão, área de interesse desse estudo, a produção de soja em larga escala pode ser considerada recente, remontando ao ano de 1978, primeiro ano em que constam registros estatísticos sobre esse cultivo no Instituto Brasileiro de Geografia e Estatística (IBGE). Posteriormente, os produtores foram se organizando e na década de 1990 a soja já estava consolidada na região sendo que inclusive se expandiu para outras localidades do Estado.

O monitoramento da superfície terrestre e da dinâmica de uso (soja) por meio de técnicas de sensoriamento remoto é de grande importância para agricultura. Atualmente um dos contextos que envolvem as culturas agrícolas se relaciona a estimativa de áreas cultivadas (Adami et al., 2012; Pan et al., 2012).

A utilização do sensor MODIS (*MODerate-resolution Imaging Spectroradiometer*), a bordo do satélite Terra e Aqua, apresenta-se muito útil para mapeamento de grandes áreas agrícolas. Características marcantes para tal uso é por apresentar alta resolução temporal, quantização de 12 bits em 36 bandas espectrais, sendo a resolução espacial no nadir de 250m em duas bandas (0,620 - 0,876µm), 500 m em cinco bandas (0,459 – 2,155 µm) e 1000 m em 29 bandas (0,405 – 14,385 µm) (Huete et al., 1997). Neste estudo a escolha por se trabalhar

com produtos MODIS se deu basicamente pela existência de nuvens em imagens de sensores com resolução espacial mais refinada, como, o Thematic Mapper (TM) do satélite Landsat-5.

Para um mapeamento com imagens multitemporais utilizando classificação baseada em objetos (estruturada a partir de uma árvore de decisões) foi possível chegar a uma aproximação confiável para o mapeamento de culturas agrícolas (Lucas et al., 2007). Posto isso, a partir de técnicas de sensoriamento remoto e geoprocessamento é possível analisar diferentes tipos de culturas através de sensores de baixa a média resolução espacial, inclusive a soja.

O objetivo deste trabalho foi estimar e mapear áreas plantadas com soja [*Glycine max* (L.) Merr.] por meio de imagens multitemporais EVI/MODIS e classificação de imagens baseada em geo-objeto.

## 2. Material e Métodos

A área de estudo compreende o estado do Maranhão (Figura 1), localizado na porção nordeste do Cerrado Brasileiro (6°0' S–11°0' S; 43°0' W–48°0' W), constituído por 11 municípios que abrangem uma área de 55.411 km<sup>2</sup>. A porção sul do Estado apresenta maiores índices da cultura da soja com uma área média plantada de 724.293 hectares (SIDRA/IBGE, 2012).

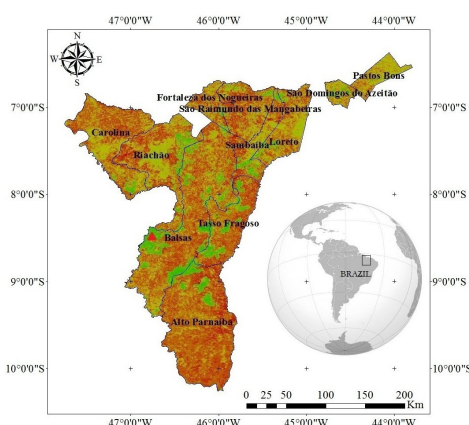


Figura 1. Mapa de localização da área estudada, concentrada no estado do Maranhão.

A verificação das áreas de soja foi dada pela interpretação visual realizada por dois intérpretes, tendo como apoio a segmentação orientada em geo-objeto (*GEographic Object-Based Image Analysis - GEOBIA*) e os pontos divergentes foi atribuído a ferramenta de visualização de séries temporais MODIS/EVI-2 (Freitas et al., 2011) para decisão final.

Para o mapeamento das lavouras de soja foram utilizados os valores de EVI (*Enhanced Vegetation Index*, Equação 1) do produto MOD13Q1, coleção 5.0, das imagens MODIS compostas de 16 dias (Huete, 1997) do satélite Terra, com resolução espacial de 250 m.

$$EVI = g \cdot \frac{\rho_{IVP} - \rho_V}{\rho_{IVP} + (c_1 \cdot \rho_V) - (c_2 \cdot \rho_A) + 1} \quad (1)$$

sendo:  $\rho_{NIR}$ ,  $\rho_R$  e  $\rho_B$  - reflectâncias na faixa espectral do infravermelho próximo, do vermelho e do azul, respectivamente;  $g$  - fator de ganho (2,5);  $c_1$  e  $c_2$  são os coeficientes de correção dos efeitos atmosféricos para o vermelho (6) e azul (7,5), respectivamente;  $l$  - fator de correção para interferência do solo.

O EVI é um índice que foi desenvolvido para atenuar os efeitos do solo (ajustado pelo SAVI) e da atmosfera (ajustado pelo ARVI) no mapeamento de vegetação.

Para o cálculo do índice CEI (*Crop Enhancement Index*), desenvolvido por Rizzi et al. (2009) são necessários obter os valores de máximo e de mínimos do EVI do plantio da cultura e desenvolvimento vegetativo, respectivamente. Para tal, foram utilizadas oito imagens EVI do ano de 2010 (da data 161, 177, 193, 209, 225, 321, 337 e 353 dia Juliano) e quatro imagens EVI do ano de 2011 (para as datas 001, 017, 033 e 049 dia Juliano).

A preferência desses intervalos temporais foi feita com base no calendário agrícola da cultura da soja no estado do Maranhão, em que consta o início do preparo do solo (correção e adubação) e final de março (dessecação e colheita) e o início do período de semeadura, entre outubro e novembro.

De posse das imagens EVI foram então identificados os valores máximos e mínimos. Com o resultado destes valores foi então calculado o índice CEI por meio da Equação 2.

$$CEI = g * \frac{(MaxEVI + S) - (MinEVI + S)}{(MaxEVI + S) + (MinEVI + S)} \quad (2)$$

em que, MaxEVI: valor máximo de EVI observado no período de máximo desenvolvimento da cultura; MinEVI: valor mínimo de EVI observado no período de pré-plantio e/ou emergência; S: coeficiente de realce ( $10^2$ ); G = fator de ganho ( $10^2$ ).

Os valores do índice CEI podem variar entre -1 e 1, o que possibilita verificar grandes diferenças positivas entre o máximo e o mínimo EVI observados ao longo da safra da soja. Altos valores de CEI indicam grande probabilidade da reflectância do pixel ser da cultura da soja. Os valores CEI obtidos na Eq. 2 foram espacializados e gerou-se uma mapa numérico e posteriormente realizado um fatiamento, em que valores superiores ou iguais a 0,28 foram considerados pixels de soja e abaixo disso não-soja, conforme recomenda Rizzi et al. (2009).

Posteriormente aos classificadores citados foi realizado o processo de seleção dos atributos no programa computacional e Cognition 8.0 (Trimble GeoSpatial, 2009), em que foi gerado o processo de segmentação (Baatz & Schäpe, 2000) utilizando fator de escala (250), shape 0.1 e compactness 0.5. Nessa etapa foi realizado o processo de coleta de amostras por segmentos, de onde foram extraídos os atributos, média, desvio padrão, comprimentos, formas e textura de cada segmento das imagens dos índices CEI e EVI (Dia 33).

Posteriormente ao processo de mineração de dados, a árvore de decisão foi implementada no programa computacional eCognition 8.0, onde foram atribuídas as regras e selecionados os atributos a cada classe (Tabela 1). Na classificação foram inseridos todos os processos filhos utilizado o algoritmo “classification”, em que as regras são inseridas nas próprias classes (soja e não-soja). Após a etapa de classificação foi inserido um processo com o algoritmo “merge region” em que os objetos de cada classe são agrupados em objetos maiores.

Tabela 1. Lista de atributos extraídos para definição das classes

Espectral	Mean Standard deviation	Espacial (cont.)	Shape index Rectangular fit
Espacial	Area Lenght Density Asymetry	Textural	GLCM Homogeneity GLCM Contrast

A exatidão dos mapas temáticos com a espacialização das áreas ocupadas pela soja foi avaliada pelas métricas do índice Kappa e Exatidão Global (EG), assim como os erros e a

precisão sob os pontos de vista do produtor e do usuário por município. Essas métricas permitem avaliar melhor a classificação final das áreas de soja.

Para determinar os valores do Kappa e da Exatidão Global foram utilizados 5000 pontos amostrais distribuídos aleatoriamente, gerados no TerraView 4.2.0 que foram analisados como soja ou não-soja (áreas ocupadas pela vegetação natural ou por outros usos antrópicos) com base no conhecimento dos intérpretes e com apoio da segmentação orientada em geo-objeto e series-temporais (Freitas et al., 2011). Além disso, foi medida a precisão de cada categoria (soja e não-soja), utilizando-se o erro do ponto de vista do produtor e do consumidor, por meio da análise dos erros de inclusão e dos erros de omissão presentes nas classificações (Antunes et al., 2012).

De posse dos valores e sob a hipótese de igualdade entre dois coeficientes de exatidão advindos de classificações diferentes ( $\kappa_1 = \kappa_2$ ). Foi estabelecido como hipótese nula ( $H_0$ ) a igualdade dos índices e o inverso para a suas diferenças ( $H_1$ ), a um nível de 0,05 de significância.

Por fim, a estimativa de área cultivada com soja foi comparada com aquela fornecida pelo Sistema IBGE de Recuperação Automática – SIDRA do Instituto Brasileiro de Geografia e Estatística - IBGE como um parâmetro para verificação da avaliação do mapeamento.

### 3. Resultados e Discussão

A classificação GEOBIA obteve parâmetros de EG e  $\kappa$  de 0,97 e 0,89, respectivamente (Tabela 2). O valor  $\kappa$  mostra a conformidade da classificação obtida. O índice Kappa apresenta vantagens sobre a Exatidão Global, pois incorpora todos os elementos da matriz de erro, objetos classificados corretamente ou não, além disso, o  $\kappa$  avalia a exatidão temática porque é mais sensível às variações dos erros do consumidor e produtor e avalia a coincidência espacial entre duas situações (Moreira, 2011). Ainda em relação ao índice de Exatidão Global, os acertos foram de 97%, que de acordo com Foody (2002), é desejável que uma classificação alcance índices de acerto superiores a 85%. Vale ressaltar que os dois classificadores superaram o valor tido como desejável de EG.

O método GEOBIA apresentou alcance superior para o índice Kappa, pois o índice CEI esta presente na mineração de dados e foi utilizado como principal atributo na árvore de decisão gerada pelo programa computacional WEKA 3.6.8.

Geralmente a mineração de dados (também chamada de descoberta de conhecimento) é o processo de análise de dados a partir de diferentes perspectivas com o objetivo de resumi-las em informações úteis, ou seja, é o processo de encontrar correlação ou padrões entre dezenas de campos relacionais em um grande banco de dados (Yang et al., 2008).

Tabela 2. Matrix de confusão para as diferentes classificações de estimativas de áreas de soja.

		Referência			
		GEOBIA			
		Soja	Não-Soja	$\Sigma$	
Classif.	Soja	255	39	294	$\kappa = 0,89$ EG = 0,97
	Não-Soja	13	1321	1334	
	$\Sigma$	268	1360	1628	
		CEI			
Classif.	Soja	192	57	249	$\kappa = 0,71$ EG = 0,97
	Não-Soja	91	4626	4717	
	$\Sigma$	283	4683	4966	

O  $\kappa$ , que avalia a concordância ou discordância entre as classificações realizadas variou entre 0,71 (CEI) e 0,89 (GEOBIA) (Tabela 2), o que segundo classificação proposta por

Landis & Koch (1977), são de excelente qualidade. Assim, pode-se dizer que os mapas temáticos gerados para a cultura da soja principalmente quando utilizado o GEOBIA, aproximaram-se da realidade de campo. Os valores foram ainda mais significativos quando comparados com trabalhos que utilizaram o mesmo sensor, porém com outra metodologia, como Lamparelli et al. (2008) que ao estimar cultura da soja com dados MODIS obtiveram parâmetro Kappa entre 0,60 a 0,80.

Ao se analisar os dados das Tabelas 3 e 4, em que estão contidos os erros do produtor e consumidor (inclusão e omissão, respectivamente), ressalta-se que o menor valor para o erro de inclusão para a classe soja foi obtido com a classificação orientada a geo-objeto (GEOBIA), com um erro de 0,05, enquanto que para essa mesma classe o erro de omissão ocorrida nesta classificação foi de 0,13. Isso significa que 95% das áreas classificadas como soja 87% corresponderam realmente a essa classe (Tabela 3). Esses resultados são semelhantes aos obtidos por Rudorff et al. (2007), no estado do Rio Grande do Sul ao estimar a cultura da soja com sensor MODIS, onde obtiveram parâmetros de Exatidão Global de 76,17% e Kappa de 0,503, considerado por Pax-Lenney & Woodcock (1997) como bom desempenho.

Deste modo, o erro do produtor ocorre quando um objeto é incluído na classe a qual ele não pertence e o erro do consumidor quando um objeto é excluído da classe a qual pertence (Johann et al., 2012).

Tabela 3. Erro e precisão do ponto de vista do produtor e consumidor para a classe soja.

Método de Análise	Produtor		Consumidor	
	Erro	Precisão	Erro	Precisão
GEOBIA	0,05	0,95	0,13	0,87
CEI	0,32	0,68	0,23	0,77

Tabela 4. Erro e precisão do ponto de vista do produtor e consumidor para a classe não-soja.

Método de Análise	Produtor		Consumidor	
	Erro	Precisão	Erro	Precisão
GEOBIA	0,03	0,97	0,01	0,99
CEI	0,01	0,99	0,02	0,98

Os melhores resultados foram obtidos para a classe soja com a técnica GEOBIA, possivelmente devido ao fato de que diferentemente dos demais classificadores essa técnica leva em consideração outros atributos além da resposta espectral de cada *pixel*. Para tanto são levados em consideração diferentes atributos no contexto do espaço em que se inseriram os alvos a partir do processo de segmentação. Entretanto, para a classe não-soja, houve uma pequena diferença entre os erros do GEOBIA e o fatiamento feito no índice CEI.

O teste de hipóteses com base nos resultados dos índices foram significativos ( $\alpha = 0,05$ ). Em função dos parâmetros entre os Kappa's GEOBIA *versus* CEI para as duas classificações realizadas, verificou-se  $Z=6,62$  e  $p$ -valor 0,000. Vale ressaltar que quanto mais próximo de zero o  $p$ -valor, maior a evidência contra a hipótese de igualdade. Com isso, há superioridade no parâmetro Kappa calculado para o mapa de soja classificado pela análise orientada em geo-objeto.

Para os municípios estudados foram gerados resultados quantificados em hectares do cultivo da soja individualmente, onde estão apresentados na Tabela 5. Ao ser comparado com dados oficiais do SIDRA/IBGE (2012), a técnica GEOBIA conseguiu se aproximar dos dados reais.

As áreas de soja estimadas pela Tabela 5 apresentaram semelhança entre as classificações realizadas pelo GEOBIA e índice CEI, variando em torno daqueles estimados por dados oficiais (SIDRA/IBGE, 2012).

Vale ressaltar que essas estimativas são baseadas em métodos objetivos (estatístico) com a utilização de imagens de satélite, com resolução espacial de 250 m, adverso das estimativas do SIDRA/IBGE (2012), que são obtidas de maneira subjetiva por meio de entrevistas com produtores, reuniões com técnicos para verificação de intenção de plantio realizadas por amostragem e quantidade de insumos vendidos para safra.

Contudo, métodos objetivos também trazem incertezas, sendo confirmados apenas com dados confiáveis que são representados na realidade. Com isso, representam quase sempre super ou subestimativas quando relacionados a dados oficiais, sendo comprovados em diversas pesquisas científicas com a utilização de técnicas de sensoriamento remoto nas estimativas de áreas agrícolas (Ippoliti-Ramilo et al., 2003).

Tabela 5. Áreas estimadas de soja em hectares por município no estado do Maranhão.

Município	GEOBIA	CEI
Alto Parnaíba	63.925,00	64.542,17
Balsas	215.968,75	191.734,10
Carolina	21.350,00	15.645,26
Fortaleza dos Nogueiras	10.962,50	8.787,58
Loreto	26.368,75	23.183,72
Pastos Bons	525,00	1.748,77
Riachão	81.387,50	45.336,91
Sambaíba	40.162,50	30.185,05
São Domingos do Azeitão	11.281,25	13.134,52
São Raimundo das Mangabeiras	15.737,50	11.298,31
Tasso Fragoso	80.150,00	76.084,07
Total	567.818,75	481.680,46

Com isso, é percebido que a confiabilidade de determinado mapeamento obtidos por imagens de satélite é maior quando se trata de maior resolução espacial, aumentando assim o detalhamento. Entretanto, os resultados aqui demonstrados apresentam grande potencial para estimativas de áreas agrícolas cultivadas com a cultura da soja, principalmente em grandes extensões. Tal fato é ponto positivo, pois dados do sistema-sensor Terra/MODIS além de apresentar gratuidade (NASA, 2012), uma largura de área observada de 2.330 km e órbita circular, quase polar, hélio-sincrônica, sua resolução temporal é de 1-2 dias, fazendo com que a probabilidade de aquisição de imagens livre de nuvens seja maior, favorecendo assim mapeamento de culturas de verão.

Ao observar a Figura 2, pode-se perceber semelhança entre a distribuição espacial da estimativa das áreas de soja na classificação GEOBIA e pelo índice CEI.

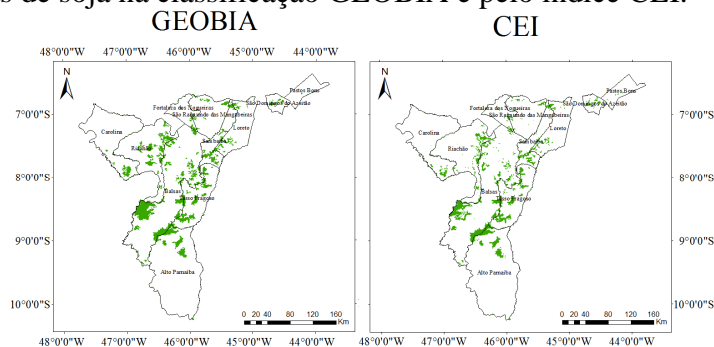


Figura 2. Distribuição espacial de áreas de soja estimado pelo GEOBIA e índice CEI.

As técnicas metodológicas demonstradas e avaliadas neste estudo apresentam relevante potencial de utilização para mapeamento da cultura da soja, principalmente a orientada a geo-objeto (GEOBIA). Assim, podendo ser utilizada como complemento para órgãos oficiais das esferas municipal, estadual e federal no levantamento da cultura, especializando-a num detalhamento até por município e obtendo com maior rapidez estatísticas agrícolas objetivas.

As regressões lineares com base na estimativa de áreas de soja realizados pelo IBGE (Instituto Brasileiro de Geografia e Estatística) são apresentadas na Figura 3. Pode-se observar que os métodos realizados aqui (GEOBIA e CEI) estão próximos do estimado pelo órgão oficial, em que apresentou alta correlação ( $R^2 > 0,75$ ).




Figura 3. Regressões em função das áreas estimadas pelo IBGE (hectares) e métodos do GEOBIA e CEI (hectares).

#### 4. Conclusões

O método de classificação orientada em geo-objeto (GEOBIA) tem grande potencial para ser reaplicado em áreas afins ao sul do Maranhão para estimar áreas de soja.

A estimativa das áreas de soja por meio do índice CEI aproximou-se das estimativas obtidas por GEOBIA, o que indica uma adequada precisão.

#### Agradecimentos

Ao Conselho de Desenvolvimento Científico e Tecnológico (CNPq) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão das bolsas de estudos.

#### Referências Bibliográficas

Adami, M.; Moreira, M. M.; Rudorff, B. F. T.; Freitas, C. C.; Faria, R. T.; Deppe, F. Painel amostral para estimativa de áreas agrícolas. **Pesquisa Agropecuária Brasileira**, v.42, n.1, p.81-88, 2007.

Antunes, J. F. G.; Mercante, E.; Esquerdo, J. C. D. M.; Lamparelli, R. A.; Rocha, J. V. Estimativa de área de soja por classificação de imagens normalizada pela matriz de erros. **Pesquisa Agropecuária Brasileira**, v.47, n.9, p.1288-1294, 2012.

Foody, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, v.80, n.1, p.185-201, 2002.

Freitas, R. M.; Arai, E.; Adami, M.; Souza, A. F.; Sato, F. Y.; Shimabukuro, Y. E.; Rosa, R. R.; Anderson, L. O.; Rudorff, B. F. T. Virtual laboratory of remote sensing time series: visualization of MODIS EVI2 data set over South America. **Journal of Computational Interdisciplinary Sciences**, v.2, n.1, p.57-68, 2011.

Huete, A. R.; Liu, H. Q.; Batchily, K.; Leeuwen, W. van. A comparison of vegetation indices over a global set of TM images for EOS- MODIS. **Remote Sensing of Environment**, v.59, n.3, p.440- 451, 1997.

IBGE - Instituto Brasileiro de Geografia e Estatística. SIDRA – **Sistema IBGE de recuperação automática**. <<http://www.sidra.ibge.gov.br>>. 10 Dez. 2012.

Ippoliti- Ramilo, G.; Epiphonio, J. C. N.; Shimabukuro, Y. E. Landsat- 5 thematic mapper data for pre- planting crop area evaluation in tropical countries. **International Journal of Remote Sensing**, v.24, n.7, p.1521-1534, 2003.

Johann, J. A.; Rocha, J. V.; Lamparelli, R. A. C.; Duft, D. G. Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI/Modis. **Pesquisa Agropecuária Brasileira**, v.47, n.9, p. 1295-1306, 2012.

Lamparelli, R. A. C.; Waste, M. O. C; Marcante, E. Mapeamento de semeaduras de soja (*Glycinemax* (L.) Merr.) mediante dados MODIS/Terra e TM/Landsat 5: Um comparativo. **Engenharia Agrícola**, v.28, n.2, p.334-344, 2008.

Landis, J. R.; Koch, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v.33, n.1, p.159-174, 1977.

Lucas, R.; Rowlands, A.; Brown, A.; Keyworth, S.; Bunting, P. Rule-based classification of multi-temporal satellite imagery for habitat and agricultural land cover mapping. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.62, n.3, p.165-185, 2007.

Moreira, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. 4a.ed. Viçosa: Editora UFV, 2011. 422p.

Pan, Y.; Li, L.; Zhang, J.; Liang, S.; Zhu, X.; Sulla-Menashe, D. Winter wheat area estimation from MODIS-EVI time series data using the Crop Proportion Phenology Index. **Remote Sensing of Environment**, v.119, n.1, p.232-242, 2012.

Pax-Lenney, M.; Woodcock, C. E. The effect of spatial resolution on the ability to monitor the status of agricultural lands. **Remote Sensing of Environment**, v.61, n.2, p.210-220, 1997.

Peng, Y.; Gitelson, A. A. Remote estimation of gross primary productivity in soybean and maize based on total crop chlorophyll content. **Remote Sensing of Environment**, v.117, n.1, p.440-448, 2012.

Rizzi, R.; Risso, J.; Epiphonio, R. D. V.; Rudorff, B. F. T.; Formaggio, A. R.; Shimabukuro, Y. E.; Fernandes, S. L. Estimativa da área de soja no Mato Grosso por meio de imagens MODIS. In: Simpósio Brasileiro de Sensoriamento Remoto, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p.387-394.

Rudorff, C. M.; Rizzi, R.; Rudorff, B. F. T.; Sugawara, L. M.; Vieira, C. A. O. Superfícies de reposta espectro-temporal de imagens do sensor MODIS para classificação de áreas de soja no Estado do Rio Grande do Sul. **Ciência Rural**, v.37, n.1, p.118-25, 2007.

Trimble Geospatial. Definiens e-Cognition developer. Version 8. Munich: Trimble GeoSpatial, 2009.

Wu, B.; Li, Q. Crop planting and type proportion method for crop acreage estimation of complex agricultural landscapes. **International Journal of Applied Earth Observation and Geoinformation**, v.16, n.1, p.101-112, 2012.

Yang, T. L.; Bai, P.; Gong, Y. S. Spatial Data Mining Features between general Data Mining. **International Workshop on ETT and GRS**, v.2, n.1, p.541-544, 2008.