



Discriminação de áreas de soja por meio de imagens EVI/MODIS e análise baseada em geo-objeto

Carlos A. da Silva Junior¹, Thiago Frank² & Taíssa C. S. Rodrigues³

¹ DAG/UEM, Maringá, PR. E-mail: carlos-junior89@hotmail.com (Autor correspondente)

² INPE/PPGSR, São José dos Campos, SP. E-mail: frank@dsr.inpe.br

³ INPE/PPGSR, São José dos Campos, SP. E-mail: taissageo@dsr.inpe.br

Palavras-chave:

classificação digital de imagens
estimativa de área agrícola
segmentação de imagens
sensoriamento remoto

RESUMO

Neste trabalho objetivou-se 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. A área de estudo compreendeu o Sul do estado do Maranhão. Para o mapeamento das lavouras de soja foram utilizados o índice de vegetação realçado (EVI) e o índice de valorização das culturas (CEI) para a classificação das imagens do sistema-sensor Terra/MODIS. Para tal cálculo foram utilizadas doze imagens compreendendo entressafra e safra da cultura, conforme calendário agrícola do Estado. Além disto, foi empregada a segmentação utilizando-se parâmetros de escala 250, os algoritmos “classification” e “merge region” e extração de atributos para classificação baseada em geo-objeto. Foram empregados, para avaliar a precisão da classificação, os parâmetros Kappa e Exatidão Global e nas suas resultantes foi aplicado o teste Z; logo, foram estabelecidos, como hipótese nula (H0) a igualdade dos índices e o inverso para suas diferenças (H1), a um nível de 0,05 de significância. Os resultados obtidos indicam que a metodologia proposta se mostrou eficiente para mapeamento da soja, com 0,89 para o parâmetro Kappa.

Key words:

digital image classification
crop area estimates
image segmentation
remote sensing

Discrimination of soybean areas through images EVI/MODIS and analysis based on geo-object

ABSTRACT

This study aimed to estimate and map areas planted with soybean [*Glycine max* (L.) Merr.] through multitemporal images EVI/MODIS and classification of images based on geo-object. The study area comprised the southern part of the State of Maranhão. For the mapping of the soybean crop the Enhanced Vegetation Index (EVI) and the Crop Enhancement Index (CEI) for image classification sensor-system Terra/MODIS was used. For this calculation twelve images were used, including offseason and harvest of the crop, as per the state agricultural calendar. In addition, the segmentation was employed using scaling parameters 250, the algorithms “classification” and “merge region”, and extracting attributes for classification GEOgraphic-Object-Based Image Analysis (GEOBIA). To assess the accuracy of the classification, parameters Kappa and Accuracy Global and its resulting Z test were applied. A null hypothesis (H0) of equal and opposite rates for their differences (H1) at 0.05 level of significance was established. The results indicate that the proposed methodology is efficient for mapping the soybean crop, with 0.89 for the parameter Kappa.

INTRODUÇÃO

A soja é a principal oleaginosa produzida e consumida no mundo; seu primeiro derivado é destinado ao consumo animal por meio de rações, em virtude de ser rico em proteínas enquanto o segundo subproduto se destina ao consumo humano de diversas formas. No Brasil, sua produção teve início na década de 1970 e, no decorrer do tempo, se consolidou como o segundo maior produtor mundial. A produção brasileira que bateu recordes no final do século XX é um dos principais destaques econômicos do Centro-Sul do Brasil, além de estar presente nas regiões Norte e Nordeste do país (Brum et al., 2005).

Na região sul do estado do Maranhão, área de interesse deste 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 este cultivo no Instituto Brasileiro de Geografia e Estatística (IBGE); posteriormente, os produtores se foram organizando e na década de 1990 a soja já estava consolidada na região inclusive se expandindo 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 a agricultura. Atualmente, um dos contextos que envolvem as culturas agrícolas se relaciona à estimativa de áreas cultivadas (Adami et al., 2012; Pan et al., 2012).

A dinâmica temporal das culturas, tanto a soja como outras, requerem dados atualizados além de se fazer necessário o uso de tecnologias e métodos para análise da grandeza desses dados. Conforme mencionam Adami et al. (2007), estimadores de áreas cultivadas vêm sendo utilizados através de imagens de satélites envolvendo desenho probabilístico, painel de amostragem de áreas e seleção de amostra probabilística. Em um primeiro momento referidos estimadores são métodos de pré-processamento e classificação das imagens de satélite para estratificação das áreas de interesse (Gallego, 2004) o que demanda tempo no que se refere ao trabalho. A título de exemplo são utilizados, comumente, índices de vegetação, classificações supervisionadas (pixel-a-pixel como, por exemplo, o classificador MaxVer) e não supervisionadas (crescimento de regiões, como, o IsoData).

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 (Ozdogan, 2010; Wu & Li, 2012; Peng & Gitelson, 2012). Características marcantes para tal uso por apresentar alta resolução temporal, quantização de 12 bits em 36 bandas espectrais, sendo a resolução espacial no nadir de 250 m em duas bandas (0,620-0,876 μm), 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.

A distribuição gratuita de imagens de satélite adotado por alguns países, auxilia nas aplicações de observação da Terra o que, sem dúvida, não seria possível por ser oneroso. Exemplos mencionados por Adami et al. (2012) apresentam a política de distribuição gratuita dos EUA, que desde 2000 distribui gratuitamente, através da internet, produtos MODIS (Terra/Aqua).

A cultura da soja apresenta padrões fenológicos durante algumas fases do seu desenvolvimento que permitem diferenciá-la espectralmente de outras classes vegetais em que a utilização de séries-temporais de imagens de satélite tem apresentado notoriedade na identificação de alvos agrícolas (Bernardes et al., 2011).

Para um mapeamento com imagens multitemporais utilizando classificação baseada em objetos (estruturada a partir de uma árvore de decisão) foi possível chegar a uma aproximação confiável para o mapeamento de culturas agrícolas (Lucas et al., 2007). Posto isto e 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.

Além do mais, o teste de processos computacionais relativos ao processamento digital de imagens, como a segmentação por crescimento de regiões, razão entre bandas, salienta a utilização de classificadores supervisionados e não-supervisionados que facilitam a posterior análise e interpretação dos alvos e, consequentemente, maior exatidão nos resultados.

Propôs-se, com este trabalho, estimar e mapear áreas plantadas com soja [*Glycine max* (L.) Merr.] por meio de imagens multitemporais EVI/MODIS e classificação de imagens baseadas em geo-objeto.

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 km². A porção sul do Estado apresenta maiores índices da cultura da soja com área média plantada de 724.293 ha (IBGE, 2012).

O cultivo é realizado no período entre outubro (plantio) a março (colheita). O clima é classificado do tipo Af no sistema Köppen-Geiger, com temperaturas médias entre 25 a 26 °C e precipitação média anual de 1.200 mm, com maior ocorrência entre outubro a abril porém sujeitos a ocorrências de veranico (Pinto, 1999). Os solos predominantes nos municípios referem-se sobretudo a topos de chapadas, áreas extensas e planas, compreendendo sobremaneira Latossolo e Argissolo distrófico de textura média a argilosa. São áreas de grande potencial agropecuário e se localizam principalmente no sentido leste-sul e norte-noroeste, totalizando 15,71% da mesorregião (Valladares et al., 2007).

Estágio I

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

Com vista ao mapeamento das lavouras de soja foram utilizados os valores de EVI (Enhanced Vegetation Index, Eq. 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.

$$\text{EVI} = g \cdot \frac{\rho_{\text{IVP}} - \rho_{\text{V}}}{\rho_{\text{IVP}} + (c_1 \cdot \rho_{\text{V}}) - (c_2 \cdot \rho_{\text{A}}) + 1} \quad (1)$$

sendo:

ρ_{IVP} , ρ_{V} e ρ_{A} - 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

1 - 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) é necessário se obter os




Figura 1. Área de estudo representada pelo produto MOD13Q1 e pelos cálculos do índice CEI (A), mínimos e máximos valores de EVI (B e C, respectivamente), além da série temporal (EVI-2) de um ponto amostrado (D), conforme relacionado por Freitas et al. (2011), seguido da temporalidade dos estádios fenológicos da soja

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 constam o início do preparo do solo (correção e adubação) o 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 desses valores foi então calculado o índice CEI, por meio da Eq. 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 se gerou um mapa numérico e, posteriormente, foi realizado um fatiamento no qual valores superiores ou iguais a 0,28 foram considerados pixels de soja e abaixo disto não-soja, conforme recomendam Rizzi et al. (2009).

Estágio II

Os procedimentos metodológicos se constituíram na aplicação de diferentes rotinas de tratamento digital de imagem que podem ser sintetizadas em três principais etapas: a) Pré-processamento, b) Realce e c) Classificação. O aplicativo de geoprocessamento utilizado neste trabalho foi o Sistema de Processamento de Informações Georreferenciadas (SPRING 5.2.2), desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE), WEKA 3.6.8 pela Universidade de Waikato, Nova Zelândia, eCognition 8.0 pela empresa Trimble GeoSpatial e TerraView 4.2.0 pelo INPE.

Após os devidos processamentos citados acima, as classificações consistiram na supervisão pixel a pixel, apoiada no algoritmo da MaxVer-ICM (Iterated Conditional Modes) e não supervisionada (IsoSeg e IsoData) sendo atribuída ao crescimento de regiões cujos limiares de similaridade e área (pixels) definidos pelo método exploratório foram 10 e 80, respectivamente.

Estágio III

Posterior aos classificadores citados foi realizado o processo de seleção dos atributos no programa computacional e Cognition 8.0 (Trimble GeoSpatial, 2009) e gerado o processo de segmentação (Baatiz & Schäpe, 2000) utilizando-se fator de escala (250), shape 0.1 e compactness 0.5. Nesta etapa realizou-se 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).

A partir da coleta das amostras e da escolha dos atributos a serem exportados, foi realizada a mineração de dados no WEKA 3.6.8. Neste ambiente computacional foram escolhidos os empregos das técnicas de mineração visto que indicam automaticamente entre os atributos disponíveis, aqueles mais pertinentes para descrição das classes de interesse e sem nenhuma subjetividade por parte do usuário na sua escolha e na definição dos limiares (Novack & Kux, 2010).

Posterior ao processo de mineração de dados, a árvore de decisão foi implementada no programa computacional e Cognition 8.0, ao qual foram atribuídas as regras e selecionados os atributos a cada classe (Tabela 1). Na classificação foram inseridos todos os processos filhos utilizando o algoritmo “classification”, cujas 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 Length Density Asymetry	Textural	GLCM Homogeneity GLCM Contrast

Protocolo experimental e análise estatística

De posse das imagens processadas e aplicados os devidos classificadores, foram gerados mapas temáticos das áreas de soja. O processo completo dos estágios e seus respectivos processos são apresentados na Figura 2.

A exatidão dos mapas temáticos com a espacialização das áreas ocupadas pela soja foi avaliada pelas métricas do índice Kappa (Eq. 3) e exatidão global (EG) (Eq. 4) assim como os erros e a precisão do ponto de vista do produtor e do usuário por município. Essas métricas permitem avaliar melhor a classificação final das áreas de soja.

$$\kappa = \frac{N \sum_{i=1}^k x_{ii} - \sum_{i=1}^k (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^k (x_{i+} \cdot x_{+i})} \quad (3)$$




Figura 2. Fluxograma da metodologia utilizada para geração dos mapas temáticos

$$EG = \left(\frac{\sum_{i=1}^k x_{ii}}{N} \right) \quad (4)$$

$$Z = \frac{\hat{\kappa} - \kappa}{\sqrt{\sigma^2(\hat{\kappa})}} \sim N(0,1) \quad (6)$$

$$\sigma^2(\hat{\kappa}) = \frac{1}{n} \left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_2-\theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4-4\theta_2)}{(1-\theta_2)^4} \right] \quad (7)$$

em que:

- κ - valor estimado Kappa
- k - número de linhas
- x_{ii} - número de observações na linha i e na coluna i
- $\sum_{i=1}^k x_{ii}$ - soma dos elementos da matriz em sua diagonal principal
- x_{i+} - soma total das observações para as linhas
- x_{+i} - soma total das observações para as colunas
- N - número total de observações

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 séries-temporais (Freitas et al., 2011). Além disto, 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 ($\kappa_1 = \kappa_2$), a estatística do teste foi realizada pelas Eqs. 5, 6 e 7.

$$Z = \frac{(\hat{\kappa}_1 - \hat{\kappa}_2) - (\kappa_1 - \kappa_2)}{\sqrt{\sigma^2(\hat{\kappa}_1) + \sigma^2(\hat{\kappa}_2)}} \sim N(0,1) \quad (5)$$

em que:

$$\theta_1 = \frac{\sum_{k=1}^c x_{kk}}{n}$$

$$\theta_2 = \frac{\sum_{k=1}^c x_{k+} x_{+k}}{n^2}$$

$$\theta_3 = \frac{\sum_{k=1}^c x_{kk} (x_{k+} + x_{+k})}{n^2}$$

$$\theta_4 = \frac{\sum_{i=1}^c \sum_{j=1}^c x_{ij} (x_{i+} + x_{+j})}{n^3}$$

Foram estabelecidos, como hipótese nula (H_0) a igualdade dos índices e o inverso para 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 parâmetro para verificação da avaliação do mapeamento.

RESULTADOS E DISCUSSÃO

Ao se analisar os dados obtidos pelos métodos utilizados nas estimativas de áreas de soja, constatou-se que a classificação

orientada em geo-objeto (GEOBIA) ficou em destaque com maior parâmetro Kappa (κ) e Exatidão Global (EG), ao contrário do classificador IsoSeg utilizado na imagem do dia 33 do sensor MODIS (Tabela 2). O mesmo fator de piora na classificação ocorreu no algoritmo IsoData que apresenta o mesmo princípio em que há ausência de treinamento para qualquer tipo de objeto que se queira identificar.

A classificação GEOBIA obteve parâmetros de EG e κ de 0,97 e 0,89, respectivamente. O valor κ mostra a conformidade da classificação obtida. O índice Kappa apresenta vantagens sobre a Exatidão Global visto que incorpora todos os elementos da matriz de erro, objetos classificados corretamente ou não; além disto, o κ 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 referência ao índice de Exatidão Global, os acertos foram de 97% o que, de acordo com Foody (2002), é desejável que uma classificação alcance índices de acerto superiores a 85%. Ressalta-se que todos os classificadores, com exceção feita ao IsoSeg/MODIS Dia 33, superaram o valor tido como desejável de EG.

O índice CEI e o método GEOBIA se mantiveram superiores na estimativa de áreas de soja, fato passível de ser confirmado pela Tabela 2, que apresentaram valores Kappa superiores às demais, além do CEI estar presente na mineração de dados e ser utilizado como principal atributo na árvore de decisão gerada pelo programa computacional WEKA 3.6.8.

Em geral, a mineração de dados (também chamada descoberta de conhecimento) é o processo de análise de dados

Tabela 2. Matriz de confusão das classificações em função dos diferentes métodos de estimativa de área de soja e seus respectivos valores dos índices κ e EG

		Referência			
		GEOBIA			
		Soja	Não-Soja	Σ	
Classificação	Soja	255	39	294	κ = 0,89 EG = 0,97
	Não-Soja	13	1321	1334	
	Σ	268	1360	1628	
MaxVer-ICM/MODIS Dia 33					
Classificação	Soja	211	145	356	κ = 0,64 EG = 0,96
	Não-Soja	68	4519	4587	
	Σ	279	4664	4958	
IsoSeg/MODIS Dia 33					
Classificação	Soja	242	1083	1325	κ = 0,23 EG = 0,77
	Não-Soja	41	3598	3639	
	Σ	283	4681	4964	
CEI					
Classificação	Soja	192	57	249	κ = 0,71 EG = 0,97
	Não-Soja	91	4626	4717	
	Σ	283	4683	4966	
MaxVer-ICM/CEI					
Classificação	Soja	174	38	212	κ = 0,69 EG = 0,97
	Não-Soja	105	4641	4746	
	Σ	279	4679	4958	
IsoData/CEI					
Classificação	Soja	215	494	709	κ = 0,40 EG = 0,89
	Não-Soja	32	4105	4137	
	Σ	247	4599	4846	

a partir de diferentes perspectivas com o objetivo de resumilas em informações úteis, ou seja, é o processo de se encontrar correlação ou padrões entre dezenas de campos relacionais em um grande banco de dados (Yang et al., 2008).

O κ , que avalia a concordância ou discordância entre as classificações realizadas, variou entre 0,23 (IsoSeg/MODIS Dia 33) e 0,89 (GEOBIA) (Tabela 2) o que, segundo classificação proposta por Landis & Koch (1977), é de razoável a excelente qualidade ($\kappa > 0,21$ e 0,81) respectivamente, aos valores; assim, pode-se dizer que os mapas temáticos gerados para a cultura da soja, principalmente quando utilizado o GEOBIA, se aproximaram da realidade de campo. Os valores foram, ainda, mais significativos quando comparados com trabalhos nos quais se utilizou o mesmo sensor porém com outra metodologia, como Lamparelli et al. (2008) que obtiveram, ao estimar a cultura da soja com dados MODIS, parâmetro Kappa entre 0,60 a 0,80. O menor valor do parâmetro Kappa e Exatidão Global de outros classificadores principalmente os não-supervisionados (IsoSeg e IsoData), pode estar associado a maior confusão na vegetação natural e consequente superestimativa das áreas de soja.

Portanto, a avaliação dos classificadores mostra que aqueles baseados na estrutura pixel a pixel como, por exemplo, o MaxVer que conta com a aquisição de amostras por parte do usuário, possuem resultados mais refinados e de melhor exatidão. Por outro lado, a combinação com o ICM aprimorou os resultados visto que considera a dependência espacial na classificação, ou seja, a classe atribuída depende tanto do valor observado neste pixel quanto das classes atribuídas aos seus vizinhos (Moreira, 2011).

Ao se analisar os dados das Tabelas 3 e 4 nas quais estão contidos os erros do produtor e do 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 para esta mesma classe o erro de omissão ocorrida nesta classificação foi de 0,13 significando que entre os 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 e 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 à qual ele não pertence e o erro do consumidor

Tabela 3. Erro e precisão do ponto de vista do produtor e do usuário para as Matrizes de Erros para a classe soja construídas a partir das imagens

Método de análise	Produtor		Consumidor	
	Erro	Precisão	Erro	Precisão
GEOBIA	0,05	0,95	0,13	0,87
MaxVer-ICM/MODIS Dia 33	0,24	0,76	0,41	0,59
IsoSeg/MODIS Dia 33	0,14	0,86	0,82	0,18
CEI	0,32	0,68	0,23	0,77
MaxVer-ICM/CEI	0,38	0,62	0,18	0,82
IsoData/CEI	0,13	0,87	0,30	0,70

Tabela 4. Erro e precisão do ponto de vista do produtor e do usuário para as Matrizes de Erros para a classe não-soja construídas a partir das imagens

Método de análise	Produtor		Consumidor	
	Erro	Precisão	Erro	Precisão
GEOBIA	0,03	0,97	0,01	0,99
MaxVer-ICM/MODIS Dia 33	0,03	0,97	0,01	0,99
IsoSeg/MODIS Dia 33	0,23	0,77	0,01	0,99
CEI	0,01	0,99	0,02	0,98
MaxVer-ICM/CEI	0,01	0,99	0,02	0,98
IsoData/CEI	0,10	0,90	0,01	0,99

quando um objeto é excluído da classe a que pertence (Johann et al., 2012).

Um dos métodos de análise com o erro do produtor que merecem destaque para a classe soja, foi o MaxVer-ICM/MODIS Dia 33 (Tabela 3), apresentando valor de 0,24; no entanto, do ponto de vista do consumidor a precisão foi de 59% sendo, assim mesmo com uma avaliação de 76% das áreas sendo identificadas como cultura de soja, apenas 59% tinham realmente este uso, ou seja, a área de tal classe foi superestimada.

Por outro lado e no que se refere à classe não-soja (Tabela 4) pode-se destacar o valor obtido no erro do produtor presente no método IsoSeg/MODIS Dia 33, que foi de 0,24. Em relação ao consumidor não se pode observar o mesmo de vez que o erro obtido foi de 0,01 tendo, como consequência, subestimativa da classe soja e aumento da classe não-soja.

Os melhores resultados foram obtidos para a classe soja com a técnica GEOBIA devido, possivelmente, ao fato de que, diferente dos demais classificadores, esta técnica leva em consideração outros atributos além da resposta espectral de cada pixel. Para tanto são levados em consideração vários atributos no contexto do espaço em que se inseriram os alvos a partir do processo de segmentação. Entretanto ocorreu, para a classe não-soja, uma pequena diferença entre os erros do GEOBIA, MaxVer-ICM/CEI e o fatiamento feito no índice CEI pois o contingente da mistura espectral é maior e generalizado para os classificadores.

Os testes de hipóteses em função dos resultados dos índices estão apresentados na Tabela 5. Para o parâmetro κ , a maioria dos testes resultou em diferença significativa, exceto os comparativos MaxVer-ICM/MODIS Dia 33 x MaxVer-ICM/CEI e CEI x MaxVer-ICM/CEI. Ressalta-se que, quanto mais

Tabela 5. Teste de hipótese para comparar os resultados de exatidão entre os índices

Kappa ₁ versus Kappa ₂	Z	valor-p
GEOBIA x MaxVer-ICM/MODIS Dia 33	9,02	0,0000*
GEOBIA x IsoSeg/MODIS Dia 33	32,47	0,0000*
GEOBIA x CEI	6,62	0,0000*
GEOBIA x MaxVer-ICM/CEI	6,81	0,0000*
GEOBIA x IsoData/CEI	19,22	0,0000*
MaxVer-ICM/MODIS Dia 33 x IsoSeg/MODIS Dia 33	15,66	0,0000*
MaxVer-ICM/MODIS Dia 33 x CEI	-1,99	0,0233*
MaxVer-ICM/MODIS Dia 33 x MaxVer-ICM/CEI	-1,57	0,0585 ^{ns}
MaxVer-ICM/MODIS Dia 33 x IsoData/CEI	7,83	0,0000*
IsoSeg/MODIS Dia 33 x CEI	-17,96	0,0000*
IsoSeg/MODIS Dia 33 x MaxVer-ICM/CEI	-16,81	0,0000*
IsoSeg/MODIS Dia 33 x IsoData/CEI	-7,30	0,0000*
CEI x MaxVer-ICM/CEI	0,37	0,3566 ^{ns}
CEI x IsoData/CEI	9,90	0,0000*
MaxVer-ICM/CEI x IsoData/CEI	9,21	0,0000*

^{ns}Não significativo; *Significativo a 0,05 de probabilidade, ou seja, se H0: Kappa₁ - Kappa₂ = 0; H1: Kappa₁ - Kappa₂ < 0

próximo de zero o valor-p maior é a evidência contra a hipótese de igualdade, fato apenas não observado na comparação entre os parâmetros das classificações MaxVer-ICM/MODIS Dia 33 x CEI, além dos outros comparativos supracitados que obtiveram zero absoluto.

Para os municípios estudados foram gerados resultados quantificados em hectares do cultivo da soja individualmente, os quais estão apresentados na Tabela 6. Ao ser comparada com dados oficiais do IBGE (2012) a técnica GEOBIA conseguiu aproximar-se dos dados reais. Na análise realizada pelo teste Z observou-se, pela técnica em questão, que todos os valores apresentaram significância de 95% de probabilidade e superioridade quando comparados com os demais parâmetros κ gerados pelas demais classificações; este resultado sugere que as estimativas apresentadas nas Tabelas 5 e 6, demonstram proximidade da verdade terrestre.

As áreas de soja estimadas pela Tabela 6 apresentaram semelhança entre as classificações realizadas pelo GEOBIA e MaxVer-ICM/MODIS Dia 33, variando em torno daqueles estimados por dados oficiais (IBGE, 2012). Em função do índice CEI apresentar melhor parâmetro κ , na Tabela 2 e confirmado pela Tabela 5, acabou subestimando a estimativa quando também foi utilizado o classificador MaxVer-ICM aplicado ao CEI. As superestimativas foram encontradas nas classificações

Tabela 6. Áreas estimadas de soja em hectares por município do estado do Maranhão

Município	GEOBIA	MaxVer-ICM/ MODIS Dia 33	IsoSeg/MODIS Dia 33	CEI	MaxVer- ICM/CEI	IsoData/CEI
Alto Parnaíba	63.925,00	63.880,14	173.927,85	64.542,17	61.144,56	62.793,75
Balsas	215.968,75	191.371,85	414.471,43	191.734,10	173.509,40	234.237,50
Carolina	21.350,00	40.252,98	173.921,61	15.645,26	12.847,23	57.725,00
Fortaleza dos Nogueiras	10.962,50	8.475,30	38.891,44	8.787,58	6.951,37	23.612,50
Loreto	26.368,75	30.803,37	115.181,61	23.183,72	16.600,84	81.918,75
Pastos Bons	525,00	10.823,65	50.483,30	1.748,77	986,81	52.131,25
Riachão	81.387,50	70.494,24	218.165,54	45.336,91	36.336,98	76.150,00
Sambaíba	40.162,50	32.214,88	68.820,42	30.185,05	25.044,91	64.881,25
São Domingos do Azeitão	11.281,25	15.214,31	50.564,49	13.134,52	9.899,30	30.412,50
São Raimundo das Mangabeiras	15.737,50	11.223,37	37.692,28	11.298,31	7.101,26	47.731,25
Tasso Fragoso	80.150,00	86.239,44	210.452,20	76.084,07	69.332,56	98.837,50
Total	567.818,75	560.993,53	1.552.572,17	481.680,46	419.755,22	830.431,25

não-supervisionadas (IsoSeg e IsoData), evento já esperado pela ausência de treinamento para geração da classificação. 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 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.

Métodos objetivos trazem, contudo, incertezas, confirmadas apenas com dados confiáveis que são representados na sua realidade. Com isto, 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 (Xiao et al., 2002; Ippoliti-Ramilo et al., 2003; Lamparelli et al., 2008; Ozdogan, 2010; Pan et al., 2012; Peng & Gitelson, 2012; Wu & Li, 2012). Assim, a confiabilidade de determinado mapeamento obtida por imagens de satélite, é maior quando se trata de maior resolução espacial aumentando, então, o detalhamento. Mesmo assim, os resultados aqui demonstrados apresentam grande potencial para estimativas de áreas agrícolas cultivadas com a cultura da soja, sobretudo

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 o mapeamento de culturas de verão.

Ao observar a Figura 3 pode-se perceber semelhança entre a distribuição espacial da estimativa das áreas de soja na classificação GEOBIA, MaxVer-ICM/MODIS Dia 33 e no mapa gerado pelo índice CEI e MaxVer-ICM/CEI. Por apresentar superestimativa (Tabela 6), os classificadores IsoSeg/MODIS Dia 33 e IsoData/CEI se mostraram com mais intensidade nas áreas coloridas que demonstram as prováveis áreas de soja.

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




Figura 3. Distribuição espacial de áreas cultivadas com soja conforme suas respectivas técnicas de classificação

CONCLUSÕES

1. As classificações geradas por imagens do sensor MODIS apresentaram-se viáveis para estimativa de áreas de soja no Sul do Maranhão.
2. A estimativa de áreas ocupadas pela soja por meio dos classificadores não-supervisionados apresentou não apenas desempenho inferior para sua quantificação e espacialização mas também generalização.
3. O método de classificação orientada em geo-objeto (GEOBIA) aplicado para estimativas de áreas plantadas com soja apresentou potencial para ser reaplicado em áreas semelhantes às do Sul do Maranhão.
4. As estimativas das áreas ocupadas pela soja por meio do índice CEI e classificadores supervisionados, aproximam-se mais das estimativas obtidas pelo GEOBIA indicando melhor precisão.

LITERATURA CITADA

- Adami, M.; Moreira, M. M.; Rudorff, B. F. T.; Freitas, C. C.; Faria, R. T.; Deppe, F. Paineis amostrais para estimativa de áreas agrícolas. *Pesquisa Agropecuária Brasileira*, v.42, p.81-88, 2007.
- Adami, M.; Rudorff, B. F. T.; Freitas, R. M.; Aguiar, D. A.; Sugawara, L. M.; Mello, M. P. Remote sensing time series to evaluate direct land use change of recent expanded sugarcane crop in Brazil. *Sustainability*, v.4, p.574-585, 2012.
- 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, p.1288-1294, 2012.
- Baatz, M.; Schäpe, A. Multiresolution segmentation: An optimization approach for high quality multi-scale image segmentation. *Journal of Photogrammetry and Remote Sensing*, v.58, p.12-23, 2000.
- Bernardes, T.; Adami, M.; Formaggio, A. R.; Moreira, M. A.; França, D. A.; Novaes, M. R. Imagens mono e multitemporais Modis para estimativa da área com soja no Estado de Mato Grosso. *Pesquisa Agropecuária Brasileira*, v.46, p.1530-1537, 2011.
- Brum, A. L.; Heck, C. R.; Lemes, C. L.; Müller, P. K. A economia mundial da soja: impactos na cadeia produtiva da oleaginosa no Rio Grande do Sul 1970-2000. *Congresso da Sober em Ribeirão Preto*, 43, 2005, São Paulo. Anais...Brasília: SOBER, 2005. CD-Rom
- Foody, G. M. Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, v.80, 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, p.57-68, 2011.
- Gallego, F. J. Remote sensing and land cover area estimation. *International Journal of Remote Sensing*, v.25, p.3019-3047, 2004.
- 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, 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.; Epiphany, 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, p.1521-1534, 2003.
- Johann, J. A.; Rocha, J. V.; Duft, D. G.; Lamparelli, R. A. C. Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI/Modis. *Pesquisa Agropecuária Brasileira*, v.47, p.1295-1306, 2012.
- Lamparelli, R. A. C.; Waste, M. O. C.; Marcante, E. Mapeamento de semeaduras de soja (*Glycine max* (L.) Merr.) mediante dados MODIS/Terra e TM/Landsat 5: Um comparativo. *Engenharia Agrícola*, v.28, p.334-344, 2008.
- Landis, J. R.; Koch, G. G. The measurement of observer agreement for categorical data. *Biometrics*, v.33, 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, p.165-185, 2007.
- Moreira, M. A. Fundamentos do sensoriamento remoto e metodologias de aplicação. 4a.ed. Viçosa: UFV, 2011. 422p.
- NASA - National Aeronautics and Space Administration. Technical specifications: Moderate Resolution Imaging Spectroradiometer (MODIS). <<http://modis.gsfc.nasa.gov/>>. 30 Nov. 2012.
- Novack, T.; Kux, H. J. H. Urban land cover and land use classification of an informal settlement area using the open-source knowledge-based system InterIMAGE. *Journal of Spatial Science*, v.55, p.23-41, 2010.
- Ozdogan, M. The spatial distribution of crop types from MODIS data: Temporal unmixing using independent component analysis. *Remote Sensing of Environment*, v.114, p.1190-1204, 2010.
- 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, 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, 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, p.440-448, 2012.

- Pinto, A. C. de Q.; Ferreira, F. R. Recursos genéticos e melhoramento da mangueira no Brasil. In: Queiróz, M. A. de; Goedert, C. O.; Ramos, S. R. R. (ed.). Recursos genéticos e melhoramento de plantas para o Nordeste Brasileiro. Versão 1.0. Petrolina: Embrapa Semi-Árido/Brasília, Embrapa Recursos Genéticos e Biotecnologia, 1999. <<http://www.cpatsa.embrapa.br>>. 2 Dez. 2012.
- Rizzi, R.; Risso, J.; Epiphanyo, 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, p.118-125, 2007.
- Trimble Geospatial. Definiens e-Cognition developer. Version 8. Munich: Trimble GeoSpatial, 2009.
- Valladares, G. S.; Quartaroli, C. F.; Hott, M. C.; Miranda, E. E. de; Nunes, R. da S.; Klepker, D.; Lima, G. P. Mapeamento da aptidão agrícola das terras do Estado do Maranhão. Campinas: Embrapa Monitoramento por Satélite, 2007. 25p. *Boletim de Pesquisa e Desenvolvimento*, 6.
- 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, p.101-112, 2012.
- Xiao, X.; Boles, S.; Frolking, S.; Salas, W.; Moore, B.; Li, C.; He, L.; Zhao, R. Landscape-scale characterization of cropland in China using Vegetation sensor data and Landsat TM imagery. *International Journal of Remote Sensing*, v.23, p.3.579-3.594, 2002.
- Yang, T. L.; Bai, P.; Gong, Y. S. Spatial Data Mining Features between general Data Mining. *International Workshop on ETT and GRS*, v.2, p.541-544, 2008.