

Desempenho de algoritmos classificadores em imagens Landsat - 8 para mapeamento de soja e milho

Carlos Eduardo Vizzotto Cattani¹, Lucas Volochen Oldoni², Erivelto Mercante¹, Ivã Luis Caon¹, Isaque de Souza Mendes¹, Bruno Bonemberger da Silva¹

¹Universidade Estadual do Oeste do Paraná – UNIOESTE, Cascavel - PR, 85819-110

²Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos - SP, 12227-010

E-mail autor correspondente: iva.caon@unioeste.br

Artigo enviado em 23/10/2018, aceito em 05/07/2019.

Resumo: A soja e o milho estão entre as principais culturas de interesse econômico do agronegócio brasileiro. Estudos e pesquisas referentes ao acompanhamento da produção agropecuária tem um peso determinante e estratégico na economia do país. Os métodos tradicionais de previsão de safras nem sempre resultam em estimativas precisas, e dificultam a espacialização da produção. Neste contexto a associação das técnicas de sensoriamento remoto e métodos estatísticos podem tornar as estimativas menos subjetivas. O objetivo deste trabalho foi realizar a identificação da área semeada com soja e milho, para a safra 2013/2014, na região oeste do Paraná, comparando métodos de classificação supervisionada (“pixel a pixel”) com o método de Segmentação (regiões e formas), em imagens Landsat-8, bem como avaliar o desempenho dos classificadores na identificação destas culturas. Dos classificadores utilizados o algoritmo SAM (*Spectral Angle Mapper*) e Segmentação, obtiveram os melhores resultados, com Índice Kappa (K) de 0,77 e Exatidão Global (EG) de 85,0%, e maiores valores de acurácia de produtor e usuário (AP e AU), para ambas as classes milho e soja.

Palavras-chave: Sensoriamento remoto, processamento de imagens, previsão de safras.

Performance of Landsat - 8 image sorting algorithms for mapping soybean and maize

Abstract: Soy and corn are among the main crops of economic interest in Brazilian agribusiness. Studies and researches related to the monitoring of agricultural production have a decisive and strategic weight in the country's economy. Traditional crop forecasting methods do not always result in accurate estimates, and hinder spatialization of production. In this context, the association of remote sensing techniques and statistical methods may make estimates less subjective. The objective of this work was to identify the area sown with soybean and corn for the 2013/2014 harvest in western Paraná, comparing methods of supervised classification (pixel to pixel) with the Segmentation method (regions and forms), in Landsat-8 images, as well as to evaluate the performance of the classifiers in the identification of these cultures. From the classifiers used, the Spectral Angle Mapper (SAM) and Segmentation algorithm they obtained the best results, with Kappa Index (K) of 0.77 and Global Accuracy (EG) of

85.0%, and higher values of producer and user accuracy (AP and AU), for both corn and soybean classes.

Key-words: Remote sensing, Image processing, Crop Forecast.

Introdução

Os produtos oriundos da agricultura estão entre os principais *commodities* do mercado global. No ano de 2014 o Brasil foi o segundo maior produtor mundial de soja, com 86,8 milhões de toneladas (equivalente a 28,3% da produção mundial), e terceiro maior produtor de milho, com 79,9 milhões de toneladas (equivalente a 7,7% da produção mundial) (FAOSTAT, 2014).

Portanto, monitorar a dinâmica das culturas é muito importante para a cadeia agrícola, pois estimativas precisas e confiáveis da produção podem oferecer uma série de benefícios, permitindo aos diversos setores da agricultura um planejamento mais eficiente de suas atividades (ARAUJO et al., 2015).

O Sensoriamento Remoto (SR) tem assumido papel categórico no desenvolvimento de ferramentas para a obtenção de estatísticas agrícolas confiáveis (CATTANI et al., 2017), pois o caráter sinóptico, repetitivo e agilidade na aquisição de dados, são as características do SR que permitem o acompanhamento de culturas agrícolas ao longo do seu ciclo de desenvolvimento, viabilizando a estimativa de safra (CONRAD et al., 2014; ZHAO et al., 2015).

A extração de informações sobre o uso e cobertura da terra pode ser obtida por meio de classificação de imagens, e estes classificadores podem ser enquadrados em dois grupos, sendo eles supervisionados e não supervisionados.

Na classificação supervisionada, é necessário o conhecimento prévio dos alvos presentes na área de estudo, para que se possa estabelecer as classes de pixels, bem definidas espectralmente, podendo assim ser utilizadas como amostras de treinamento pelos classificadores (MENESES e ALMEIDA, 2012).

Muitos trabalhos vêm apresentando bons resultados ao aplicar técnicas de geoprocessamento em dados de sensores remotos orbitais, visando o monitoramento de safras agrícolas (GRZEGOZEWSKI et al., 2016; JOHANN et al. 2016; GILBERTSON et al., 2017).

Os métodos de classificação comumente utilizados para estes monitoramentos, tem como base algoritmos que se baseiam na análise "pixel a pixel" (PRUDENTE et al., 2017), no entanto, estes classificadores ainda encontram dificuldades para diferenciar alvos espectralmente semelhantes (ADAMI et al., 2012).

Uma alternativa para contornar estas limitações e melhorar a acurácia dos classificadores é o processo de segmentação (SANTOS et al., 2017), a segmentação é um método de agrupamento de regiões, baseado no conceito de região vizinha mais similar (ESPINDOLA, 2005).

O objetivo do trabalho foi comparar duas metodologias de classificação para a identificação e separação das áreas semeadas com soja e milho na safra de verão de 2013/2014, onde uma das metodologias utilizou técnicas de segmentação para obtenção dos melhores parâmetros para o classificador *K-Nearest Neighbor (KNN)*, e outra utilizou a classificação pixel a

pixel tradicional, por meio de quatro classificadores (Spectral Angle Mapper, Maxima Verossemelhança, Distância Mínima, Distância de Mahalanobis).

Material e Métodos

Seleção dos Dados

As imagens utilizadas são provenientes do satélite Landsat-8, do *tile* 223/77 (órbita/ponto), das datas de 31/10/2013 e 18/12/2013, por serem as únicas imagens livres totalmente de nuvem para a safra de verão do ano de 2013/2014. O satélite Landsat-8 possui dois sensores, o OLI (*Operational Land Imager*) e o TIRS (*Thermal Infrared Sensor*) (USGS, 2017). Para este estudo

foram utilizadas as bandas 4, 5 e 6, do sensor OLI, que cobrem respectivamente, as faixas do vermelho, infravermelho próximo e infravermelho médio. As imagens possuem resolução radiométrica de 16 bits, e possui tempo de revisita de 16 dias, são disponibilizadas ortorretificadas com resolução espacial de 30 metros, gratuitamente pelo site do USGS (*United States Geological Survey*).

A área em estudo é composta por 36 municípios (Figura 1) e está localizada na região de maior produção de soja e milho do Estado do Paraná. O tipo de solo predominante na região monitorada é o Latossolo Vermelho Distroférico, conforme a classificação de Koopen.

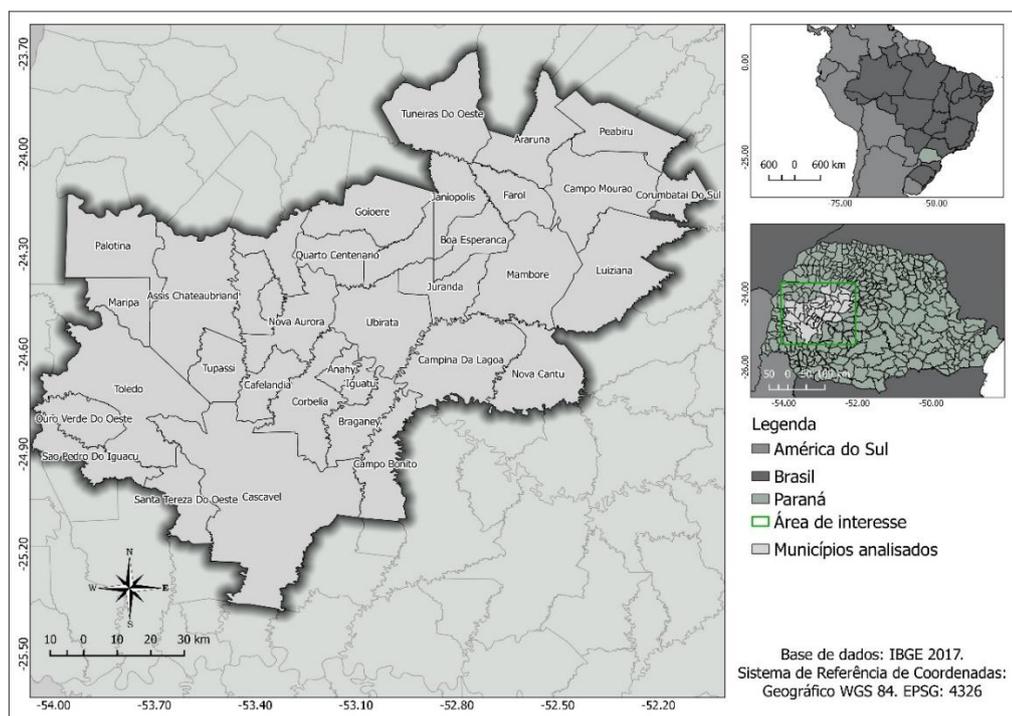


Figura 1. Localização da área de estudo

O clima da região é classificado como subtropical mesotérmico, segundo a classificação de Köppen, caracterizado como Cfa – Clima subtropical (APARECIDO et al., 2016). Nos meses de inverno, a média de temperatura é

inferior a 16°C e, nos meses de verão, as máximas superam 30°C, com temperatura média anual de 21°C e precipitação anual de 1971 mm.

Pré-Processamento

Inicialmente foi realizada a delimitação da área de estudo, correção radiométrica e aplicação de contrastes nas bandas utilizadas. Em seguida, realizou-se a conversão para refletância no topo da atmosfera (TOA) com correção para o ângulo solar (Equação 1), em que são utilizados coeficientes de redimensionamento de refletância, fornecido juntamente com as imagens (USGS, 2017).

$$\rho\lambda = \frac{M_{\rho}Q_{cal} + A_{\rho}}{\cos(\theta_{sz})} \quad (1)$$

Em que: $\rho\lambda$ = TOA reflectância planetária; M_{ρ} = Fator multiplicativo de redimensionamento de banda específica a partir dos metadados; Q_{cal} = Valores de pixel do produto padrão quantizado e calibrados (DN); A_{ρ} = Fator de redimensionamento específicos da banda a partir dos metadados; θ_{sz} = Ângulo de elevação do sol local, onde o ângulo de elevação do sol para a cena em graus é fornecido nos metadados.

Com a finalidade de melhorar a acurácia das classificações, foi retirado da imagem utilizada como base para classificação áreas ocupadas com matas, que poderiam dificultar a correta classificação das culturas. Para isto utilizou-se uma máscara, obtida por meio da classificação da classe mata em na imagem de 31/10/2013, pois nesta data havia ausência das culturas de soja e milho na região estudada. Para classificação do alvo mata utilizou-se os métodos de Segmentação e o Máxima Verossimilhança (MaxVer), em seguida o resultado de ambos os classificador foi sobreposto por meio do operador lógico booleano *OR*, gerando o mapa aqui chamado de “Máscara de mata”.

Classificação de Imagens

Para classificação de imagens foram utilizados cinco diferentes

métodos de classificação, dentre eles o processo de segmentação, método que consiste em classificações por regiões e outros quatro classificadores que utilizam o método “pixel a pixel”, sendo eles, Mínima Distância, Distância de Mahalanobis, Máxima Verossimilhança e SAM (*Spectral Angle Mapper*). Para o processo de classificação foram utilizadas as composições coloridas falsa cor das bandas do infravermelho próximo, do infravermelho médio e do vermelho (RGB-564).

Para o processo de segmentação foi utilizado o *software* ENVI 4.5, inicialmente foi utilizada a ferramenta *Feature Extraction*, que de acordo com Soares e Bepler (2013), necessita da definição dos parâmetros de segmentação e *merge* (união) além dos parâmetros dos classificadores.

O algoritmo segmentador é denominado *edge-based*, este algoritmo utiliza um filtro na imagem, que classifica os *pixels* como sendo de borda ou não, os *pixels* que não são separados são agregados em uma mesma categoria e em seguida define-se o método de classificação, coletando-se amostras, ou utilizando regras de decisão.

O classificador utilizado no módulo *Feature Extraction*, foi o *K-Nearest Neighbor (KNN)*, que calcula a distância euclidiana entre cada objeto da imagem segmentada e todos os objetos de treinamento que foram definidos. A distância é medida em n-dimensões tanto quanto forem os atributos dos objetos de treinamento, tais como espectrais, de textura, espaciais e de cor (CAMPOS et al., 2013).

Após segmentação, foram definidos os atributos utilizados na classificação pelo algoritmo *K-Nearest Neighbor*, onde, para as classes soja e milho foram utilizados os atributos espectrais de média das bandas 5 e 6 e também o máximo da banda 5.

Por meio de composições coloridas das bandas do infravermelho próximo, do infravermelho médio e do vermelho (RGB-564), foram coletadas amostras de *pixels* que correspondem a cultura da soja e a cultura do milho (Figura 2), a partir destas amostras realizou-se a classificação

supervisionada para os quatro classificadores. Foram utilizados os algoritmos classificadores supervisionados baseados na distância (Mínima Distância e Distância de Mahalanobis) e classificadores que utilizam como base a probabilidade e o ângulo espectral (MaxVer e SAM).

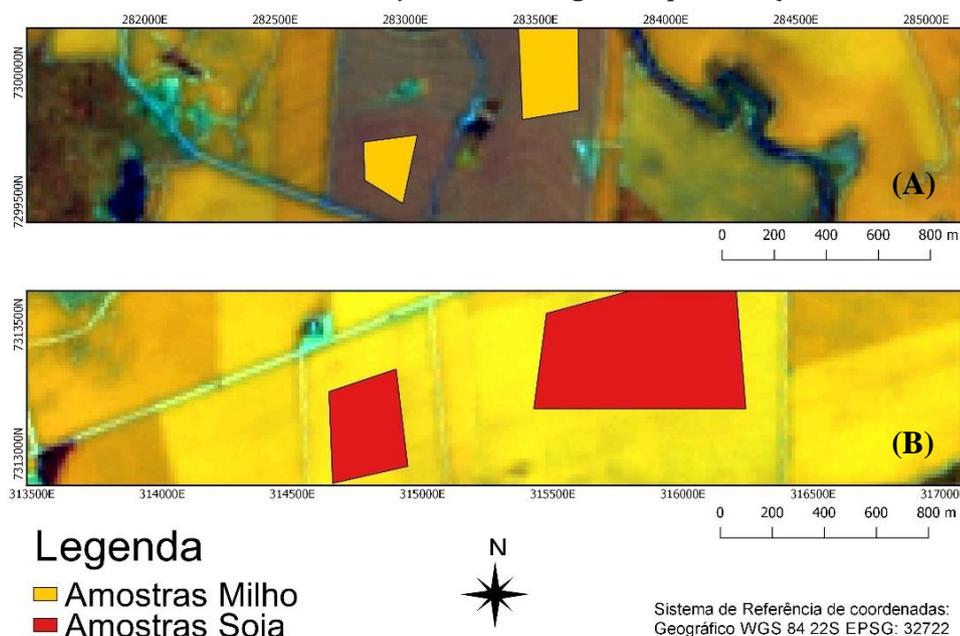


Figura 2. Exemplo de amostras de treinamento (AT) para classe soja (A) e classe milho (B)

Avaliação de Acurácias

A avaliação da exatidão das máscaras foi realizada por meio das matrizes de erros, utilizando a metodologia chamada de painel amostral, caracterizada pela distribuição aleatória de pontos amostrais dentro do limite da área de estudo, com o objetivo de se realizar um levantamento das classes de uso do solo de cada ponto (LUIZ et al., 2002). Foram utilizados 150 pontos amostrais espalhados de forma aleatória nas máscaras (Figura 3), sendo

60, 60 e 30 pontos, das classes Soja, Milho e Outros, respectivamente.

A escolha do número de pontos baseou-se no trabalho de Johann et al. (2012), que utilizaram 400 amostras distribuídas de forma estratificada e aleatória com o objetivo de obter erro amostral em torno de 5%. Neste sentido a utilização de 150 pontos teve a função de aumentar a acurácia da classificação e diminuir o erro amostral, sendo que se trata de uma área menor que a do trabalho citado.

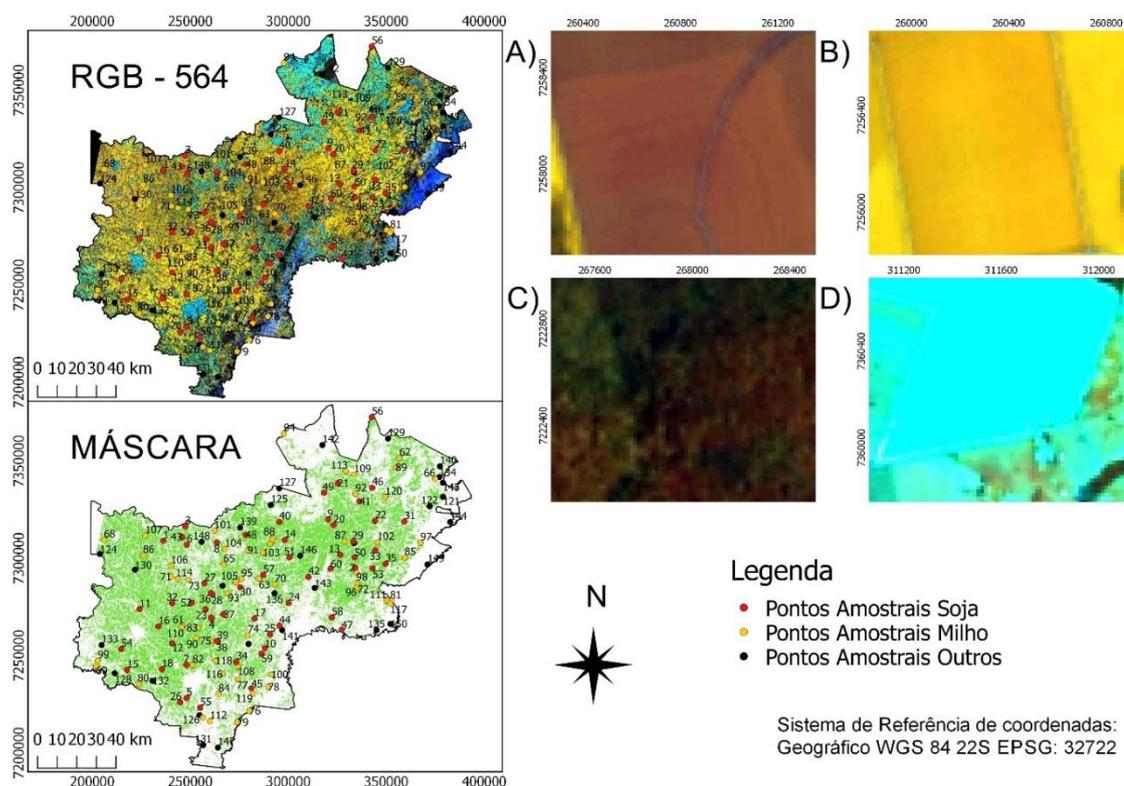


Figura 3. Pontos amostrais aleatórios, (RGB-564) e mascaras de soja e milho, alvos (A) soja, (B) milho, (C) Mata, (D) Solo.

A avaliação dos pontos para se determinar a qual classe eles eram pertencentes, foi realizada por meio de inspeção visual utilizando como base a imagem RGB-564. A classe à qual os pontos pertenciam foram identificadas levando em considerando as características espectrais dos alvos (Figura 3), a partir dos pontos construiu-se a matriz de erros

Por meio da matriz de erros, foram calculados os índices de Exatidão Global (EG) (Equação 3), que expressa o total de acertos em relação ao total de

amostras da imagem classificada e coeficiente Kappa (K) (Equação 4), utilizado para expressar a precisão da classificação. Foram utilizados ainda, como forma de avaliação das classificações, os valores da acurácia de produtor (AP), o qual refere-se à probabilidade de um *pixel* de referência ter sido corretamente classificado e a acurácia de usuário (AU) que indica a probabilidade que um *pixel* classificado na imagem de fato representa aquela categoria no campo (CONGALTON, 1991).

$$EG = \frac{A}{n} * 100 \quad (3)$$

$$K = \frac{[n * \sum_{i=1}^r x_{ij} - \sum_{i=1}^r (x_i * x_j)]}{[n^2 - \sum_{i=1}^r (x_i * x_j)]} \quad (4)$$

Em que: EG = exatidão global; A = pontos amostrais com acerto; n = número de pontos amostrais; K = coeficiente Kappa de concordância; r = número de linhas da matriz de erro; x_{ij} = observação na linha i e coluna j; x_i = total marginal da linha i; x_j = total marginal da coluna j.

Foram analisadas também algumas métricas derivadas da matriz de confusão total, matriz proveniente da matriz de erros, estas métricas são o índice de sensibilidade (S), índice de especificidade (E) e o coeficiente de correlação de Matthews (CCM) (

Tabela 1), utilizadas na comparação dos mapas temáticos (SOUZA et al., 2013).

Tabela 1. Métricas derivadas da matriz de confusão total

Métrica	Equação
S	$a/(a+c)$
E	$d/(b+d)$
CCM	$((a \cdot d) - (b \cdot c)) / ((a+b) \cdot (a+c) \cdot (d+b) \cdot (d+c))^{(1/2)}$

Em que: a = quantidade de *pixels* que foram corretamente classificados; b = quantidade de *pixels* que não pertencem às classes do mapa real e foram classificados como pertencentes às classes no mapa modelo; c = quantidade de *pixels* que pertencem às classes do mapa real e que pertencem às classes diferente no mapa modelo; d = quantidade de *pixels* que não pertencem às classes no mapa real e foram classificados como não pertencente as classes no mapa modelo.

O índice de sensibilidade (S) é uma medida que indica a probabilidade de um *pixel* no mapa modelo ser classificado como pertencente à classe k

se realmente ele pertence à classe k no mapa real, sendo assim uma medida equivalente à acurácia de produtor (FIELDING e BELL, 1997). O índice de especificidade (E) indica a probabilidade de um *pixel* não pertencente à classe k do mapa real ser classificado como não pertencente à classe k no mapa modelo (LURZ et al., 2001). O coeficiente de correlação de Matthews (CCM) é uma versão discreta do coeficiente de correlação de Pearson, e seus valores se encontram no intervalo [-1;1], sendo que o valor 1 equivale a uma predição perfeita, 0 equivale a uma predição aleatória e -1 significa uma predição inversa (DALPOSSO et al., 2012).

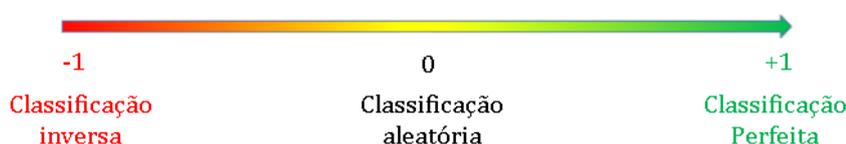


Figura 4. Escala do coeficiente de correlação de Matthews
Adaptado: Santos et al. (2017).

Resultados e Discussão

Os mapas temáticos (Figura 5) apresentam os resultados dos métodos de classificação por região e “pixel a

pixel”: Segmentação (A), Mapeador de ângulo espectral - SAM (B), MaxVer (C), Distância Mínima (D), distância de Mahalanobis (E).

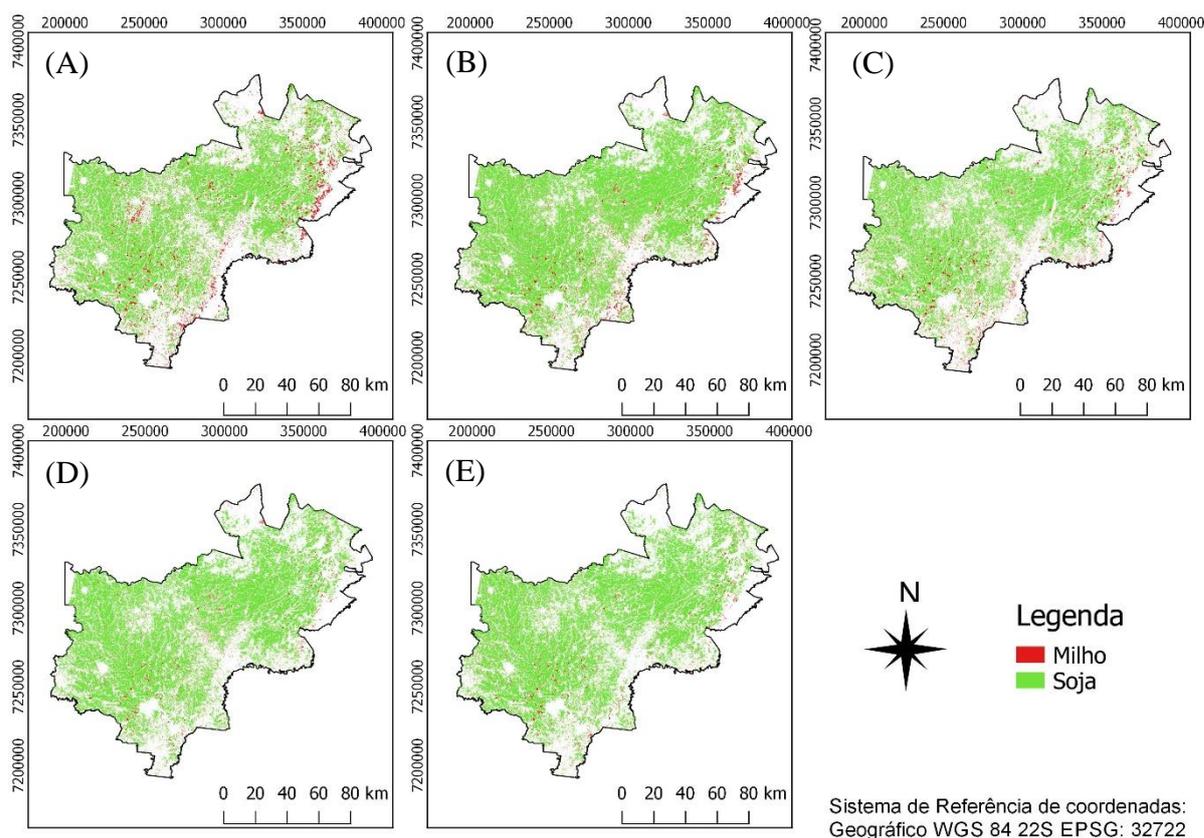


Figura 5. Métodos de classificação: (A) Segmentação; (B) Mapeador de ângulo espectral - SAM, (C) MaxVer, (D) Distância Mínima, (E) distância de Mahalanobis

Assim como descrito por Souza et al. (2015) e Zhong et al. (2016), a soja e milho, em sua grande maioria estão dispostas entre as regiões norte e oeste do Paraná.

Ambas classificações visualmente apresentam distribuição espacial semelhante para a cultura da soja, entretanto existe uma diferença de Tabela 2. Área (em ha) de soja e milho.

Tabela 2. Área (em ha) de soja e milho

	Segmentação	SAM	MaxVer	Min. Distância	Mahalanobis
Soja	717490,53	862164,00	700242,48	804058,29	853526,16
Milho	96937,74	107538,75	87413,49	58043,70	65383,92

Os resultados da exatidão global e coeficiente Kappa, obtidos para todos os métodos de classificação realizados (Tabela 3), mostram que dos cinco métodos de classificação examinadas, apenas três obtiveram exatidão global

aproximadamente 18,0% entre a quantidade de área classificada pelos algoritmos Mahalanobis (E) e MaxVer (D).

Fato semelhante ocorre para a classe milho, que apresentou variação de 53,97% quando comparadas áreas classificadas pelos algoritmos SAM e Mahalanobis (

superior a 80,0%, os maiores valores de EG foram de 85,0% para os classificadores Segmentação e SAM, o classificador MaxVer mostrou acurácia na ordem de 82,0%. Os algoritmos Mínima Distância e Distância de

Mahalanobis apresentaram valores de EG inferiores a 80,0%, sendo eles 76,0%

Landis e Koch (1977) sugerem que valores do coeficiente Kappa entre 0,61 e 0,8, indica fortemente que a qualidade de uma dada classificação é muito boa, ou seja, se aproxima da verdade terrestre. Apenas três classificadores que obtiveram valores de Kappa superiores a 0,7, sendo os classificadores Segmentação e SAM com os maiores valores de acurácia (0,77),

e 72,0% respectivamente.

seguidos do classificador MaxVer, que obteve valor de acurácia de 0,72.

Os classificadores Mínima Distância e Distância de Mahalanobis obtiveram resultados de acurácia inferiores em relação aos demais, com Kappa de 0,64 para o algoritmo Mínima Distância e 0,58 para o classificador Distância de Mahalanobis.

Tabela 3. Valores da exatidão global, índice Kappa

Classificadores / Índices	Exatidão Global (%)	Índice Kappa
Segmentação	85	0,77
SAM	85	0,77
MaxVer	82	0,72
Mínima Distância	76	0,64
Distância de Mahalanobis	72	0,58

A acurácia de produtor (AP) refere-se à probabilidade de um *pixel* de referência ter sido corretamente classificado. E a acurácia de usuário (AU) indica a probabilidade que um *pixel* classificado na imagem de fato representa aquela categoria no campo (SOUZA et al., 2013). Para a classe soja a classificação pelo método Segmentação obteve o maior valor de acurácia do produtor de 80,00% e a acurácia de usuário de 100,00% (Tabela 4). Estes valores, indicam que 80,00% dos *pixels* de soja foram realmente classificados como soja.

O método de Segmentação perdeu 20,00% (erro de omissão) dos *pixels* de soja na imagem e 0,00 % (erro de comissão) dos *pixels* classificados como soja que pertenciam a outras

classes. Para a classe da soja apenas Mahalanobis não obteve acurácia do usuário de 100,0%, com 98,33%.

Para a classe milho os métodos de classificação Segmentação e MaxVer apresentaram AP de 100%, indicando que todos os *pixels* de referência foram corretamente classificados, com baixo erro de omissão (0,00%).

O classificador SAM e Segmentação apresentaram maiores valores de AU, sendo 68,33 e 66,67% respectivamente, indicando que dos *pixels* classificados como milho mais de 30,0 % pertenciam a outras classes.

Esta margem de erro pode ser atribuída a semelhança espectral encontrada entre áreas de mata nativa e reflorestamento e pastagens com as áreas de milho (YAO et al., 2015).

Tabela 4. Valores de acurácia do produtor e acurácia do usuário

	Segmentação		SAM		MaxVer		Min. Distância		Mahalanobis	
	AP (%)	AU (%)	AP (%)	AU (%)	AP (%)	AU (%)	AP (%)	AU (%)	AP (%)	AU (%)
Soja	80,0	100,0	78,95	100,0	78,95	100,0	68,97	100,0	69,41	98,33
Milho	100,0	66,67	97,62	68,33	100,0	65,0	93,55	48,33	96,30	43,33

Utilizando os valores da matriz de confusão total geradas para cada um dos métodos de classificação, obtiveram-

se as métricas de índice de sensibilidade (S), especificidade total (E) e coeficiente de correlação de Matthews (Tabela 5).

Tabela 5. Métricas obtidas das matrizes de confusão total.

Métrica	Segmentação	SAM	MaxVer	Min. Distância	Mahalanobis
S	0,85	0,85	0,82	0,77	0,73
E	0,93	0,93	0,91	0,88	0,86
CCM	0,78	0,78	0,73	0,65	0,59

O índice de especificidade total (E) indica a capacidade do método de classificação em evitar classificações incorretas, os resultados foram de 0,93 para os classificadores Segmentação e SAM. Para o índice de sensibilidade (S) mostra a como métodos de Segmentação e SAM obtiveram os melhores resultados com 0,85.

Pelo Coeficiente de Correlação de Matthews (CCM), verifica-se que os mapas gerados pelos métodos de Segmentação e SAM se aproximaram mais da verdade de campo com 0,78, em ambas as classificações, indicando correlação forte positiva (próxima do valor +1).

Jia et al. (2014) sugerem que estudos utilizando métricas temporais de índices de vegetação (IV's), podem auxiliar os classificadores a obter melhores acurácias. Outra abordagem para elevar os valores das acurácias é o estudo da cultura em múltiplas datas, Senf et al. (2015) afirmam que acrescentar mais imagens durante o ciclo da cultura diminuiu a confusão entre os classificadores, fator que resultou em melhores acurácias.

Conclusões

Os métodos de classificação de imagens utilizados permitiram a realização da estimativa de área semeada com a cultura da soja e do milho (máscara de soja e milho), sendo importante a utilização da máscara de

mata para reduzir a confusão dos classificadores.

Os valores das análises de acurácia indicaram que os níveis foram muito bons, de acordo com a literatura, destacando que o método de classificação por Segmentação, e o classificador SAM apresentaram os melhores resultados.

Agradecimentos

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e à Fundação Araucária/Parque Tecnológico Itaipu (FA/PTI) pelo apoio financeiro.

Referências

- ADAMI, M.; MELLO, M. P.; AGUIAR, D. A.; RUDORFF, B. F. T.; DE SOUZA, A. F. A web platform development to perform thematic accuracy assessment of sugarcane mapping in South-Central Brazil. **Remote Sensing**, v. 4, n. 10, p. 3201–3214, 2012
- ARAUJO, G. L.; MANTOVANI, E. C.; HADDAD, G.; VIEIRA, S.; COSTA, M. S. Modelos para a estimativa da produção de biomassa aplicados à cultura do milho. **Revista da Faculdade de Ciências Gerenciais de Maringá**, v. 12, n. 1, p. 43–56, 2015.

- CAMPOS, A. R.; FONSECA, D. F.; SAMPAIO, D. M.; FARIA, S. D.; ELMIRO, M. A. T. **Classificação orientada a objeto para mapeamento do uso e cobertura do solo do município de Rio Acima - MG: por crescimento de regiões e por extração de objetos.** Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil, 13 a 18 de abril de 2013, INPE.
- CATTANI, C. E. V.; GARCIA, M. R.; MERCANTE, E.; JOHANN, A. J.; CORREA, M. M.; OLDONI, L. V. Spectral-temporal characterization of wheat cultivars through NDVI obtained by terrestrial sensors. **Revista brasileira de engenharia agrícola e ambiental.** v. 21, n. 11 p. 769-773, 2017.
- CONGALTON, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v.37, p. 35-46.
- CONRAD, C.; DECH, S.; DUBOVKY, O.; FRITSCH, S.; KLEIN, D.; LOW, F.; SCHORCHT, G.; ZEIDLER, J. Derivation of temporal windows for accurate crop discrimination in heterogeneous croplands of Uzbekistan using multitemporal RapidEye images. **Computers and Electronics in Agriculture**, v. 103, p.63-74, 2014.
- DALPOSSO, G. H.; Uribe-OPAZO, M. A.; MERCANTE, E.; JOHANN, J. A.;BORSSOI, J. A. Comparison measures of maps generated by geostatistical methods. **Engenharia Agrícola**, v. 32, n. 1, p. 174-1831 2012.
- EMBRAPA. Sistema brasileiro de classificação de solos. 2ª ed. Rio de Janeiro: Embrapa-CNPS. 2006. 306p.
- FAOSTAT. **Production quantities by country - Average 1993-2014.**
- FIELDING, A.H.; BELL, J.F. A review of methods for the assessment of prediction errors in conservation presence/absence models. **Environmental Conservation**, n. 24. p. 38-49, 1997.
- GILBERTSON, J. K.; KEMP, J.; VAN NIEKERK, A. Effect of pan-sharpening multi-temporal Landsat 8 imagery for crop type differentiation using different classification techniques. **Computers and Electronics in Agriculture**, v. 134, p. 151-159, 2017.
- GRZEGOZEWSKI, D. M.; JOHANN, J. A.; URIBE-OPAZO, M. A.; MERCANTE, E.; COUTINHO, A. C. Mapping soya bean and corn crops in the State of Paraná, Brazil, using EVI images from the MODIS sensor. **international Journal of Remote Sensing.** v. 37, n. 6, p. 1257-1275, 2016.
- JIA, K.; LIANG, S.; WEI, X.; YAO, Y.; SU, Y.; JIANG, B.; WANG, X. Land cover classification of landsat data with phenological features extracted from time series MODIS NDVI data. **Remote Sensing**, v. 6, n. 11, p. 11518-11532, 2014.
- JOHANN, J. A.; BECKER, W. R.; URIBE-OPAZO, M. A.; MERCANTE, E. Uso de imagens do sensor orbital modis na estimação de datas do ciclo de desenvolvimento da cultura da soja para o estado do Paraná. **Engenharia Agrícola**, v. 36, n. 1, p. 126-142, 2016.
- 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, n. 9, p. 1295-1306, 2012
- LANDIS, J.R.; KOCH, G.G; The measurement of observer agreement for

- categorical data. **Biometrics**, v. 33, n. 1, p. 159-174, 1977
- LUIZ, A.J.B.; OLIVEIRA, J.C.; EPIPHANIO, J.C.N.; FORMAGGIO, A.R. Auxílio das imagens de satélite aos levantamentos por amostragem em agricultura. **Agricultura em São Paulo**, v.49, p.41-54. 2002.
- LURZ, P.W.W.; RUSHTON, S.P.; WAUTERS, L.A.; BERTOLINO, S.; CURRADO, I.; MAZZOGLIO, P.; SHIRLEY, M.D.F. Predicting grey squirrel expansion in North Italy: a spatially explicit modeling approach. **Landscape Ecology**, n.16, p.407-420, 2001.
- MENESES, P.R.; ALMEIDA, T. de. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. 1 ed. Brasília: UnB/CNPq, v.1, 2012.
- PRUDENTE, V. H. R.; DA SILVA, B. B.; JOHANN, J. A.; MERCANTE, E.; OLDONI, L. O. Mapeamento do uso e ocupação do solo utilizando árvores de decisão comparando abordagem pixel a pixel e análise orientada a geo-objeto. **Engenharia Agrícola**. v. 37, n. 5, p. 1015-1027, 2017.
- SANTOS, C. J.; SOUZA, V. G. B.; MAYRINK, V. T. M.; HIPPERT, H. S.; VIEIRA, M. T. Classificadores binários, políticas públicas sociais e dados desbalanceados. **Revista de Informática Aplicada**. v. 13, n. 1, p. 35-50, 2017.
- SENF, C.; LEITÃO, P. J.; PFLUGMACHER, D.; VAN DER LINDEN, S.; HOSTERT, P. Mapping land cover in complex Mediterranean landscapes using Landsat: Improved classification accuracies from integrating multi-seasonal and synthetic imagery. **Remote Sensing of Environment**, v. 156, p. 527-536, 2015.
- SOARES, A. R.; BEPPLER, M. **Estudo Comparativo entre Softwares na Classificação de Imagens de Alta Resolução Espacial**. Anais do Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil, 13 a 18 de abril de 2013, INPE.
- SOUZA, C. H. W.; MERCANTE, E.; PRUDENTE, V. H. R.; JUSTINA, D. D. D. Methods of performance evaluation for the supervised classification of satellite imagery in determining land cover classes. **Ciencia e Investigación Agraria**. 40(2):419-428. 2013.
- SOUZA, C. H. W.; MERCANTE, E.; JOHANN, J. A.; LAMPARELLI, R. A. C.; URIBE-OPAZO, M. A. Mapping and discrimination of soya bean and corn crops using spectro-temporal profiles of vegetation indices. **International Journal of Remote Sensing**, v. 36, n. 7, p. 1809-1824, 2015.
- USGS. United States Geological Survey. Landsat Missions - Landast 8.
- YAO, F.; TANG, Y.; WANG, P.; ZHANG, J. Estimation of maize yield by using a process-based model and remote sensing data in the Northeast China Plain. **Physics and Chemistry of the Earth**, v.87, p.142-152. 2015.
- ZHAO, Y.; CHEN, X.; CUI, Z.; LOBELL, D.B. Using satellite remote sensing to understand maize yield gaps in the North China Plain. **Field Crops Research**, v.183, p.31-42, 2015.
- ZHONG, L.; HU, L.; YU, L.; GONG, P.; BIGING, G. S. Automated mapping of soybean and corn using phenology. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 119, p. 151-164, 2016