

USO DE IMAGENS DO SATÉLITE SENTINEL-2A PARA IDENTIFICAÇÃO DE CULTURAS IRRIGADAS POR PIVÔ CENTRAL EM UNAÍ - MG**V. N. R. MELLO¹, L. B. G. MARCOS², G. S. SANTOS JUNIOR³, E. FERREIRA⁴**

¹ Engenheiro Agrônomo, Representante Técnico Comercial, RS Agropecuária de Barbacena LTDA, Rua Governador Bias Fortes, 1077, Pontilhão, Barbacena - MG, Fone: (0XX32) 991090322, vitornogg@gmail.com

² Graduanda em Engenharia Ambiental e Sanitária, Universidade Federal de Lavras - UFLA

³ Graduando em Engenharia Agrícola, Universidade Federal de Lavras - UFLA

⁴ Eng. Agrícola, Prof. Titular, Depto. Engenharia Agrícola, DEA/UFLA, Lavras, MG

Apresentado no
XLIX Congresso Brasileiro de Engenharia Agrícola - CONBEA 2020
23 a 25 de novembro de 2020 - Congresso On-line

RESUMO: O sensor MSI (*Multispectral Instrument*), a bordo do satélite Sentinel-2A, vem se destacando por fornecer dados com altas resoluções para identificar e mapear cultivos agrícolas. No presente trabalho foram utilizadas imagens do MSI/Sentinel-2A, de 04/06/2017, para identificar culturas (milho, feijão e café) irrigadas por pivôs centrais, no município de Unaí, MG. Buscando o êxito desse propósito, foram utilizadas as seguintes técnicas para análise das imagens: interpretação visual das imagens com ênfase na análise do comportamento espectral das culturas e classificação supervisionada por máxima verossimilhança. Os resultados obtidos pela interpretação visual mostraram as culturas de milho, feijão e café em diferentes cores e tonalidades, já a análise do comportamento espectral revelou as bandas B03, B06, B07, B08, B08A, B11 e B12 como sendo as mais importantes para a discriminação dessas culturas. Por último, a classificação supervisionada foi eficiente para identificar os diferentes cultivos dentro da área de estudo.

PALAVRAS-CHAVE: agricultura irrigada, resposta espectral, classificação supervisionada.

USE OF SENTINEL-2A SATELLITE IMAGES FOR IDENTIFICATION OF CROPS UNDER CENTER PIVOT IRRIGATION IN UNAÍ - MG

ABSTRACT: The Sentinel-2A Multispectral Instrument (MSI) has been highlighted, as it provides data with high spatial resolutions for identify and mapping crops. The present study used images provided by the MSI / Sentinel-2A, on June 4, 2017, to separate crops (corn, beans and coffee) irrigated by center pivots, in the municipality of Unaí, Minas Gerais State, Brazil. The following approaches were used to analyze the images: visual interpretation of the images with analysis of crop spectral response and supervised maximum likelihood classification. The results obtained by the visual interpretation showed corn, beans and coffee crops in different shades, while the analysis of the spectral response revealed that the bands B03, B06, B08, B08, B08A, B11 and B12 were the most important for the discrimination of the crops. Finally, the supervised classification was efficient to identify the different crops within the study area.

KEYWORDS: irrigated agriculture, spectral response, supervised classification.

INTRODUÇÃO: O levantamento de informações sobre áreas e culturas é de grande importância, uma vez que, ao saber onde e o que se planta, se torna possível calcular a área ocupada por cada cultura, estimar a produtividade, o consumo de água e melhorar as estatísticas agrícolas. Neste contexto, o sensoriamento remoto, aliado à constante evolução tecnológica, vem se destacando como uma importante ferramenta para identificação e monitoramento dessas áreas, podendo fornecer dados mais confiáveis sobre a agricultura. Dentre os satélites utilizados para monitoramento da agricultura, destaca-se atualmente o Sentinel-2, missão que faz parte do programa Copernicus da *European Space Agency* (ESA). Essa missão é composta por 2 satélites gêmeos (Sentinel-2A e Sentinel-2B), presentes na mesma órbita e em posições opostas. Cada Sentinel-2 leva a bordo o sensor MSI (*Multispectral Instrument*) capaz de gerar imagens em 13 faixas espectrais, com combinações de resoluções espaciais que variam de 10 a 60 metros. Possui amplo campo de visada (290 km) e opera com frequência de revisita de 5 dias (DRUSCH et al.; BERTINI, et al., 2012). As técnicas de interpretação das imagens do MSI/Sentinel-2, para obtenção de mapas de uso da terra e aplicações na agricultura, variam desde a interpretação visual até técnicas de classificação de imagens mais complexas (não supervisionada, supervisionada e orientada à objetos) (IMMITZER; VUOLO; ATZBERGER, 2016; KAPLAN; ADVAN, 2017; ZHANG et al., 2017; BELGIU; CSILLIK, 2018). Assim, o presente trabalho foi desenvolvido com o objetivo de identificar algumas culturas agrícolas, em áreas irrigadas por pivô central, utilizando técnicas de interpretação visual e classificação supervisionada em imagens do MSI/Sentinel-2A.

MATERIAL E MÉTODOS: O estudo foi realizado em uma propriedade rural localizada no município de Unaí, MG. No trabalho foram analisados 17 pivôs centrais, conforme ilustra a Figura 1.




FIGURA 1. Localização da área: (a) município de Unaí, Minas Gerais, Brasil; (b) área de estudo no município de Unaí e (c) imagem do sensor MSI/Sentinel-2A em composição colorida 432/RGB dos pivôs centrais estudados.

Para execução do trabalho foram utilizadas imagens do satélite Sentinel-2A, nível 1C, sensor MSI, cena 23KKB de 04 de junho de 2017. A imagem foi escolhida por apresentar porcentagem mínima de nuvens e, nessa data, as culturas de milho, feijão e café estarem instaladas no campo. As imagens foram obtidas gratuitamente no website do programa Copernicus da Agência Espacial Europeia (ESA, 2017). As cenas, disponibilizadas nas regiões do espectro visível, infravermelho próximo e infravermelho médio ou de ondas curtas, abrangem uma área de 10.000 km² (100 x 100 km). Na Tabela 1 é apresentada uma síntese das características das imagens geradas pelo sensor MSI/Sentinel-2 (BERTINI, et al., 2012). Na tabela, o número das bandas foi distribuído em função das resoluções espaciais: 10, 20 e 60 metros. Para facilitar e aperfeiçoar o trabalho com imagens dos satélites Sentinel, a ESA desenvolveu o software SNAP (*Sentinels Application Platform*). O SNAP consiste em uma plataforma que reúne um conjunto de ferramentas para exploração de produtos dos satélites Sentinel-1, Sentinel-2, Sentinel-3, SPOT e LANDSAT (ZUHLKE et al., 2015). Assim como as imagens, o programa é disponibilizado gratuitamente e pôde ser obtido no link: (<https://step.esa.int/main/download/>). Existem muitas possibilidades de utilização e combinação das 13 imagens do Sentinel-2. As imagens podem ser analisadas separadamente, considerando suas resoluções espaciais originais, ou podem ser reamostradas. A reamostragem espacial serve para deixar todas as bandas com a mesma resolução e número de pixels. No presente estudo, seguindo metodologia utilizada por Zhang et al. (2017), realizou-se o recorte e a reamostragem das 13 bandas para resolução espacial de 10 metros.

TABELA 1. Características das imagens geradas pelo sensor MSI: resolução espacial, número da banda, identificação da faixa espectral e comprimento de onda central.

Resolução espacial	Número da banda	Identificação da faixa espectral	Comprimento de onda central (nm)
10 m	B02	Azul	490
	B03	Verde	560
	B04	Vermelho	665
	B08	Infravermelho próximo	842
20 m	B05	Infravermelho próximo	705
	B06	Infravermelho próximo	740
	B07	Infravermelho próximo	783
	B08A	Infravermelho próximo	865
	B11	Infravermelho médio	1610
	B12	Infravermelho médio	2190
60 m	B01	Aerossol	443
	B09	Vapor D'água	940
	B10	Cirrus	1375

As técnicas utilizadas para análise das imagens foram: interpretação visual das imagens apoiadas na análise do comportamento espectral das culturas e classificação supervisionada por máxima verossimilhança. A interpretação visual das imagens em tons de cinza e composições coloridas foi fundamental para identificação dos elementos presentes na área. Além da tonalidade, expressa pelo comportamento espectral, as análises seguiram o roteiro

metodológico para a interpretação visual de fotografias aéreas e de imagens de satélite recomendado por Panizza e Fonseca (2011). Para destacar as culturas agrícolas em diferentes cores foram feitas as seguintes composições coloridas: 4R-3G-2B, 8R-4G-3B, 12R-11G-4B, 12R-11G-8AB, 8R-11G-2B e 11R-8G-4B. A segunda técnica de análise de imagens utilizada foi a classificação supervisionada por máxima verossimilhança (MaxVer). O classificador MaxVer considera a ponderação das distâncias entre as médias dos valores dos pixels das classes, utilizando parâmetros estatísticos. Assume que todas as bandas têm distribuição normal e calcula a probabilidade de um dado pixel pertencer a uma classe. É um classificador mais eficiente porque as classes de treinamento são utilizadas para estimar a forma da distribuição dos pixels contidos em cada classe no espaço de n bandas, como também a localização do centro de cada classe (MENESES; SANO, 2012). Foram estabelecidas oito classes para serem amostradas e classificadas: café, milho, feijão, água, palhada, mata ciliar, vegetação nativa e solo exposto. Para validação, os resultados obtidos foram confrontados com os dados coletados em campo. Desta forma, foi possível verificar qual metodologia aplicada para análise dos dados foi mais coincidente com a verdade de campo. Na Figura 2, a identificação dos dados de campo está de acordo com a seguinte numeração: pivôs 2, 4, 8 e 12, correspondem à cultura do milho, pivôs 16 e 17 à cultura do café, pivôs 1, 10, 11 e 13 estavam sem cultivo e os outros estavam plantados com feijão.

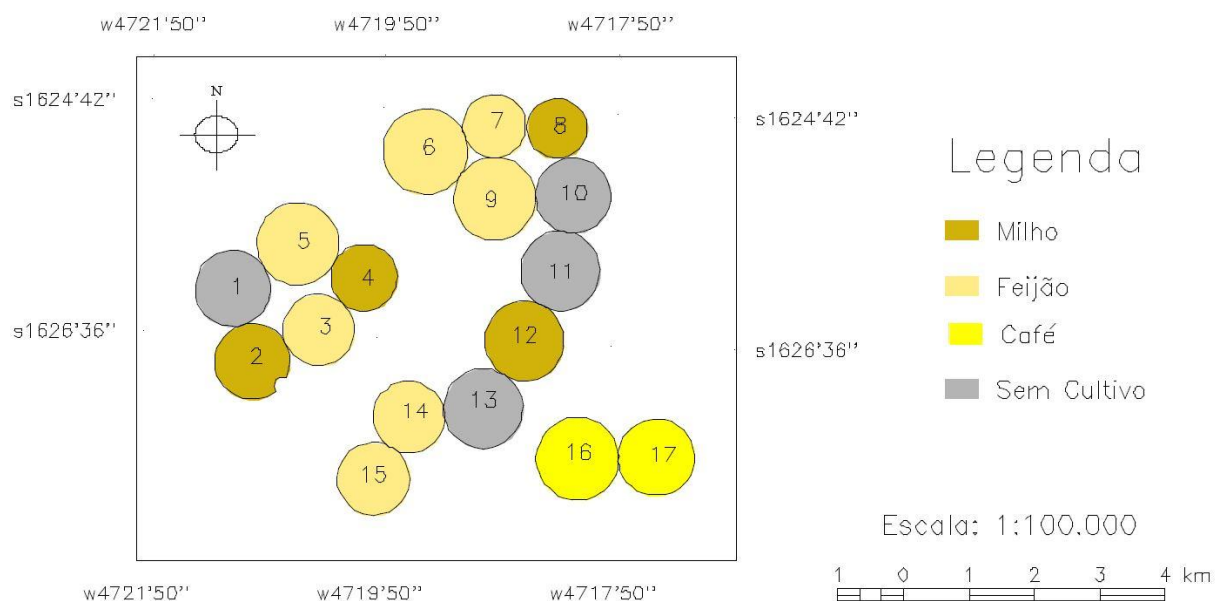


FIGURA 2. Identificação dos dados de campo, com a numeração dos pivôs da área de estudo, em 04/06/2017.

RESULTADOS E DISCUSSÃO:

1. Interpretação visual e análise da resposta espectral das culturas

A análise da resposta espectral das culturas nas 13 bandas do MSI/Sentinel-2A, reamostradas para 10 metros, foi essencial para avaliar quais delas apresentavam os maiores potenciais para a separação das culturas agrícolas. Na Figura 2 pode ser observado o comportamento ou resposta espectral das culturas do café, milho e feijão.




FIGURA 3. Resposta espectral das culturas do café, milho e feijão, em função das 13 bandas espectrais do sensor MSI/Sentinel-2A, em áreas irrigadas por pivô central em Unaí, MG. Data: 04/06/2017.

A partir Figura 3, pode-se verificar que as bandas que apresentaram as maiores diferenças entre as refletâncias das culturas foram: uma na região do visível (B03), quatro na região do infravermelho próximo (B06, B07, B08 e B08A) e duas na região do infravermelho médio (B11 e B12). Immitzer, Vuolo e Atzberger (2016) observaram o mesmo comportamento em relação à importância das bandas do infravermelho próximo e infravermelho médio para a classificação de culturas agrícolas. Esses autores destacaram ainda a importância da banda azul (B02). Na Figura 2 pode ser observado que na faixa do infravermelho médio (B11 e B12), as culturas do café e feijão não apresentaram diferenças entre suas refletâncias. Em relação às bandas com resolução espacial de 60 metros (B1, B9 e B10) pode-se observar que apenas na B09 houve diferença de refletância entre as culturas (Figura 3). Alguns autores aplicaram a reamostragem espacial para 10 metros às bandas do MSI/Sentinel-2 excluindo as bandas B1, B9 e B10 (IMMITZER; VUOLO; ATZBERGER, 2016; KAPLAN; ADVAN, 2017). A combinação de informação espacial e espectral do presente trabalho seguiu metodologia utilizada por Zhang et al. (2017), mas já se verifica nesta etapa que as bandas B01 e B10 poderão ser excluídas na fase de classificação das culturas. Mandanici e Bitelli (2016) verificaram que o fornecimento de mais detalhes nas bandas do infravermelho próximo e do infravermelho médio torna o MSI/Sentinel-2 mais adequado para aplicações na agricultura, quando comparado ao sensor *Operational Land Imager* (OLI) do satélite Landsat-8. A resposta espectral do alvo é apresentada visualmente nas imagens em tonalidades de cinza. Quanto mais claro o tom de cinza maior é a refletância naquela faixa espectral. Assim, com base na resposta espectral das culturas, foi possível interpretar as imagens das áreas de pivôs centrais de café, milho e feijão, em tons de cinza, para analisar visualmente a diferença de tonalidade entre as culturas. Rudorff, Moreira e Alves (2002), observaram que a soja apresentava tonalidade bem mais clara que a do milho devido suas folhas planiformes refletirem mais a radiação solar em relação às folhas eretas do milho. No presente estudo, a diferença entre milho e feijão pode ser atribuída ao mesmo motivo, devido à semelhança morfológica entre as folhas das duas leguminosas (soja e feijão). No café, a variação de tonalidades pode estar relacionada ao índice de área foliar, idade, manejo de poda, sistema de plantio e derriça de folhas durante a colheita (CAMPOS et al., 2009). A imagem utilizada neste trabalho coincide com a época da colheita de café, desta forma, a derriça das folhas ocasionada por esta atividade possivelmente influenciou em uma menor refletância pela cultura na região do infravermelho próximo. As diferentes interações entre os cultivos e a

radiação eletromagnética também foi observada ao adicionar cores nas imagens utilizando os filtros RGB. As composições coloridas são apresentadas na Figura 4.




Figura 4. Composições coloridas de imagens do MSI/Sentinel-2A mostrando diferentes tonalidades das culturas nas áreas de pivôs centrais em 04/06/2017, município de Unaí, MG: (a) 4R-3G-2B; (b) 8R-4G-3B; (c) 12R-11G-4B; (d) 12R-11G-8AB; (e) 8R-11G-2B; (f) 11R-8G-4B

A interpretação visual das imagens leva em conta não só as cores, que estão relacionadas ao comportamento espectral dos alvos, mas também outros elementos da paisagem (PANIZZA; FONSECA, 2011). Essa estratégia pode ser utilizada para auxiliar na identificação dos pivôs com a cultura de café, pois apareceram divididos em quadrantes (pivôs 16 e 17). Na Figura 4, é possível perceber que estes pivôs são fracionados em quatro partes iguais, enquanto aqueles pivôs ocupados com as culturas anuais (milho e feijão) não apresentam essa divisão. Os pivôs sem cultivo apresentaram coloração bem discrepante em relação àqueles ocupados com culturas agrícolas. Nota-se ainda que o pivô 1 e faixa do pivô 13 diferem dos demais pivôs sem cultivo por apresentar palhada na superfície do solo, dando assim um outro padrão de cor. Estas observações foram baseadas nas anotações obtidas “in situ”, sendo estas informações relevantes e que comprovam e explicam detalhes e particularidades encontrados nas imagens.

2. Classificação supervisionada por máxima verossimilhança

O resultado da classificação supervisionada utilizando o classificador por Máxima Verossimilhança (MaxVer) é apresentado na Figura 5. Como o classificador tende a confundir alvos com resposta espectral semelhante (FONSECA; OLIVEIRA; RIZZI, 2001), foram utilizadas somente as bandas que apresentaram maior discriminação entre eles (bandas 3, 6, 7, 8, 8A, 11 e 12).

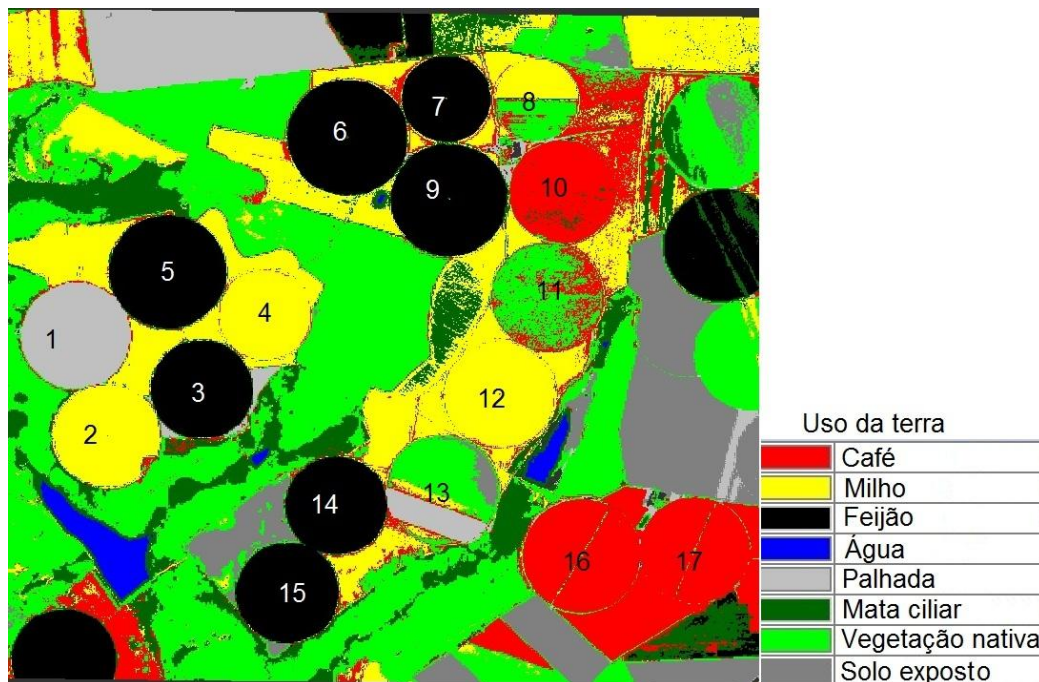


Figura 5. Resultado da classificação supervisionada utilizando o classificador por Máxima Verossimilhança (MaxVer) em imagens do MSI/Sentinel-2A, de 04/06/2017, município de Unai, MG.

Analisando apenas os pivôs cultivados com milho, café e feijão, pode-se observar que não houve muita mistura entre as classes. Notou-se também que mesmo com a presença de milho em estádios fenológicos distintos, não houve problema em agrupá-los na mesma classe, diferentemente do que ocorreu com Fonseca, Oliveira & Rizzi (2001). Esses autores obtiveram baixa precisão na classificação do milho devido à presença de áreas com folhas verdes e áreas com folhas amarronzadas. O pivô número 6 (feijão), que nas análises anteriores estava sendo confundido com milho e café, também foi separado com sucesso. Ainda pela Figura 5 percebe-se que as classes água, solo exposto e palhada foram bem separadas. Foi identificado milho em áreas de sequeiro e áreas de café, próximas aos pivôs 16 e 17, estando de acordo com a verdade de campo. Em contrapartida, algumas áreas foram classificadas como café erroneamente, como é o caso do pivô número 10. De certa forma, o estudo confirmou as observações feitas por Inglada et al., (2015) que reviram o estado-da-arte de mapeamentos de culturas usando dados dos satélites Landsat-8, SPOT e Sentinel-2 simulados. O estudo indicou que os mapas de tipo de cultura, com detalhamentos suficientes para monitorar parcelas individuais, não disponíveis globalmente, poderiam ser potencialmente gerados a partir de dados do Sentinel-2. Assim, a lacuna que existe entre a disponibilidade de mapeamentos para a agricultura e a acurácia necessária dessas informações seria finalmente preenchida.

CONCLUSÕES: No estudo, por meio do estudo da resposta espectral dos alvos e interpretação visual das imagens em tons de cinza e em composições coloridas, foi possível identificar os três cultivos por se apresentarem em tonalidades distintas. Concluiu-se também que, das 13 bandas do sensor MSI/Sentinel-2A, apenas sete (B03, B06, B07, B08, B08A, B11 e B12) foram importantes para discriminação das culturas por apresentarem refletâncias

diferentes entre as culturas estudadas. A classificação supervisionada utilizando o classificador de máxima verossimilhança, por basear-se em amostras para identificar áreas semelhantes, conseguiu fazer a discriminação total das culturas de milho, feijão e café, mesmo havendo plantas de milho em estádios fenológicos distintos. A utilização de dados de campo foi fundamental para explicar as particularidades e detalhes, estágios das culturas e condições dos pivôs centrais no período considerado. Por fim, a metodologia aplicada mostrou-se útil, podendo auxiliar trabalhos futuros que buscam identificar e mapear cultivos agrícolas.

REFERÊNCIAS:

BELGIU, M.; CSILLIK, O. Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. **Remote Sensing of Environment**, v. 204, p. 509-523, 2018.

Bertini, F. et al. **Sentinel-2 ESA's Optical High-Resolution Mission for GMES Operational Services**. Boletim da European Space Agency (ESA). SP 1322, 2012. 78p.

CAMPOS, P. M. et al. **Uso da geotecnologia para o mapeamento da cultura do café no município de Ribeirão do Pinhal – Paraná**. In: Simpósio Brasileiro de Sensoriamento Remoto, 14., 2009, Natal. *Anais...* São José dos Campos: INPE, 2011. p. 3629-3634.

DRUSCH, M. et al. Sentinel-2: ESA's optical high-resolution mission for GMES operational services. **Remote Sensing of Environment**, v. 120, p. 25–36, 2012.

ESA - EUROPEAN SPACE AGENCY. Imagens do Satélite MSI/Sentinel-2A. ESA: Paris, 2017. Imagem. Dimensões: 100x100 km. Disponível em: <<https://scihub.copernicus.eu/dhus/#/home>>. Acesso em: 7 mar. 2018.

FONSECA, E. L.; OLIVEIRA, J. C.; RIZZI, R. **Avaliação da identificação de áreas com cultivos agrícolas para fins de previsão de safras utilizando procedimentos de classificação digital de imagens do sensor TM / Landsat 5**. In: Simpósio Brasileiro de Sensoriamento Remoto, 10., 2001, Foz do Iguaçu. *Anais...* São José dos Campos: INPE, 2001. p. 79-86.

INGLADA, J. et al. Assessment of an Operational System for Crop Type Map Production Using High Temporal and Spatial Resolution Satellite Optical Imagery. **Remote Sensing**, v.7, n.9, p. 12356-12379, 2015.

IMMITZER, M.; VUOLO, F.; ATZBERGER, C. First experience with Sentinel-2 data for crop and tree species classifications in central Europe. **Remote Sensing**, v. 8, n. 3, p. 166, 2016.

KAPLAN, G.; ADVAN, U. **Mapping and monitoring wetlands using Sentinel - 2 satellite imagery**. In: ISPRS Annals Of The Photogrammetry, Remote Sensing And Spatial Information Sciences: International Geoadvances Workshop, 4., 2017, Safranbolu, Karabuk, Turquia. *Anais...* ISPRS: Turquia, 2017. p. 271-277.

MANDANICI, E.; BITELLI, G. Preliminary comparison of Sentinel-2 and Landsat 8 imagery for a combined use. **Remote Sensing**, v. 8, n. 12, p. 1014, 2016. 10p.

MENESES, P.R.; SANO, E. Classificação pixel a pixel de imagens. In: MENESES, P.R.; ALMEIDA, T. de (Org) **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: UNB/CNPq, 2012. cap 12, p.191-208.

PANIZZA, A. de C.; FONSECA, F.P. Técnicas de interpretação visual de imagens. **Espaço e Tempo**, São Paulo, n.30, p.30-43, 2011.

RUDORFF, B. F. T.; MOREIRA, M. A.; ALVES, M. Sensoriamento remoto aplicado à agricultura. In: RUDORFF et al. **Curso de uso de sensoriamento remoto no estudo do meio ambiente**. São José dos Campos: INPE, cap 9, p. 19, 2002.

ZHANG, T., SU, J., LIU, C., CHEN, W-H, LIU, H. LIU, G. **Band selection in Sentinel-2 satellite for agriculture applications**. In: International Conference On Automation & Computing (ICAC), 23., 2017, Huddersfield, UK. *Anais...* Huddersfield: IEEE, 2017. 7p.

ZUHLKE, M. et al. **SNAP (Sentinel Application Platform) and the ESA Sentinel 3 Toolbox**. In: SENTINEL-3 For Science Workshop, ESA Special Publication, Veneza, 2015. *Anais...*ESA: Veneza, v. 734, p. 21, 2015.