

Mapeamento de pastagens por meio da classificação da fusão de imagens Landsat-8/OLI e MODIS no município de São Gabriel do Oeste - MS

Ivã Luis Caon ¹
Erivelto Mercante ¹
João Francisco Gonçalves Antunes²
Carlos Eduardo Vizzotto Cattani ¹
Isaque Souza Mendes ¹
Lucas Volochen Oldoni ³

1Universidade Estadual do Oeste do Paraná
R. Universitaria, 2069 - Universitario
Cascavel - PR, 85819-110
{iva.caon, erivelto.mercante, carlos.cattani, isaque.mendes}@unioeste.br

2Embrapa Informática Agropecuária
Av. André Tosello, 209 - Caixa Postal 6041
13083-886 - Campinas - SP, Brasil
joao.antunes@embrapa.br

3Instituto Nacional de Pesquisas Espaciais - INPE
Av. dos Astronautas, 1758 - Caixa Postal 515
12201-970 - São José dos Campos - SP, Brasil
lucasoldoni@outlook.com

Resumo. O sensoriamento remoto mostra-se eficiente no mapeamento de grandes áreas geográficas, executado a partir de imagens orbitais. A alta resolução espacial presente em sensores tem permitido o mapeamento detalhado da superfície terrestre, porém a resolução temporal também se mostra importante, devido a constante mudança que ocorre nos ecossistemas. Desse modo os algoritmos de predição se mostram de grande valia, uma vez que são capazes de unir a alta resolução espacial de um sensor a alta resolução temporal de outro. O objetivo deste trabalho foi realizar o mapeamento das áreas de pastagem presentes na extensão do município de São Gabriel do Oeste - MS, bem como avaliar o desempenho de diferentes algoritmos de classificação em diferentes séries temporais, sendo uma composta apenas de imagens Landsat e outra composta de imagens geradas pelo algoritmo de predição STARFM (Spatial and Temporal Adaptive Reflectance Fusion Model). Sendo que o algoritmo Random Forest, na série temporal composta pelas imagens geradas pelo algoritmo STARFM e com a adição de métricas fenológicas apresentou as melhores acurácias, obtendo índice Kappa superior a 0,85 e exatidão global superior a 92,5%.

Palavras-chave: sensoriamento remoto, sensor orbital, processamento de imagens, mineração de dados, fusão de imagens, classificação de imagens.

Abstract. Remote sensing is efficient in the mapping of large geographic areas, executed from orbital images. The high spatial resolution present in sensors has allowed the detailed mapping of the terrestrial surface, but the temporal resolution is also important due to the constant change that occurs in the ecosystems. In this way the prediction algorithms prove to be of great value, since they are capable of joining the high spatial resolution of one sensor with high temporal resolution of another. The objective of this work was to map the pasture areas present in the extension of São Gabriel do Oeste - MS, as well as to evaluate the performance of different classification algorithms in different time series, one composed only of Landsat images and another composed of images generated by the STARFM (Spatial and Temporal Adaptive Reflectance Fusion Model) prediction algorithm. The Random Forest algorithm, in the time series composed of the images generated by the STARFM algorithm and the addition of phenological metrics, showed the best accuracy, obtaining a Kappa index higher than 0.85 and a global accuracy greater than 92.5%.

Keywords: remote sensing, orbital sensor, image processing, data mining, image fusion, image classification

1. Introdução

O conhecimento da dinâmica da paisagem numa determinada região é um fator importante no planejamento do uso racional e sustentável do meio ambiente (Barbosa, 2009). O levantamento de informações por meio de mapas temáticos de uso e cobertura da terra é uma importante ferramenta de análise para o planejamento ambiental, devido à possibilidade de quantificar os distintos tipos de usos da terra.

As técnicas de sensoriamento remoto se mostram eficientes no mapeamento de grandes áreas geográficas, efetuado a partir de imagens orbitais, onde a resolução espacial é um dos principais elementos na definição das legendas dos mapas temáticos (Ponzoni e Rezende, 2002). A alta resolução espacial presente em sensores tem permitido o mapeamento detalhado da superfície terrestre (Ponzoni e Rezende, 2004).

Porém vale-se ressaltar também o fator temporal das imagens, pois como descrito por Coppin et al. (2004), os ecossistemas estão em constante mutação, a qual pode ser definida como uma alteração dos seus componentes superficiais ou ainda como uma movimentação da entidade vegetal no espaço ao longo do tempo, podendo ser abrupta (como uma queimada) ou sutil (acumulo de biomassa vegetal) de origem natural ou antrópica.

Com isso os algoritmos de predição se mostram úteis, ao realizarem a fusão de imagens de alta resolução espacial com imagens de alta resolução temporal, gerando assim uma série de alta resolução espacial e temporal, como é o caso do algoritmo STARFM (*Spatial and Temporal Adaptive Reflectance Fusion Model*), o qual realiza a fusão das imagens do sistema Landsat com as imagens do sensor MODIS, gerando assim uma série sintética (Gao et al., 2006).

Análises realizadas com mapas temáticos associados ao uso da terra têm servido como base para mudanças das formas de uso e ocupação do solo ao longo do tempo. Para a execução e levantamento desse tipo de mapa temático, incorporam-se as geotecnologias, especialmente os produtos provenientes do sensoriamento remoto e o processamento analítico presente nos Sistemas de Informação Geográfica (SIG) (Longley et al., 2002; Silva e Zaidan, 2004).

2. Objetivo

Avaliar o desempenho dos classificadores *Random Forest* (RF), *Support Vector Machine* (SVM), Árvore de Decisão (DT) e Máxima Verossimilhança (MAXVER), em diferentes séries temporais compostas por imagens Landsat-8/OLI e imagens STARFM, com a adição de métricas fenológicas, para a classificação de pastagem no município de São Gabriel do Oeste.

3. Material e Métodos

O desenvolvimento do trabalho seguiu o processo de mineração de dados (Fayyad et al., 1996) que é dividido em cinco etapas, sendo elas: 1) seleção dos dados, 2) Pré-processamento, 3) Transformação dos dados, 4) Mineração dos dados e 5) Avaliação. Sendo que na etapa 1 foi realizada a aquisição das imagens; na etapa 2 foi realizado o pré-processamento das imagens, e a formação dos bancos de dados de imagens Landsat-8/OLI e imagens sintéticas; a etapa 3 consistiu na classificação das series temporais; a etapa 4, na extração das métricas de acurácia; e a etapa 5, na comparação para a escolha do melhor método de classificação, como descrito no fluxograma da **Figura 1**.




Figura 1: Fluxograma descrevendo as etapas de desenvolvimento do trabalho.

A área em estudo é o município de São Gabriel do Oeste, localizado na região Centro-Norte do estado do Mato Grosso do Sul, apresentado na **Figura 2**, que possui cerca de 3.864,691 Km² de extensão, e se encontra totalmente inserido na Bacia Hidrográfica do Alto Paraguai - BAP (IBGE, 2017). A pedologia da região se caracteriza pela predominância de Latossolo Vermelho-Escuro de textura argilosa e caráter álico, ou seja, com elevada acidez e, na porção Leste do município, há ocorrência significativa de Neossolos, ambos com baixa fertilidade natural, porém se destaca no ramo da agropecuária, principalmente na produção de leite e gado (Prefeitura Municipal de São Gabriel do Oeste - MS, 2016).

Em 2016 o município contava com um rebanho composto por 234.000 bovinos, 3.197 equinos, 419 caprinos e 8.020 ovinos, além de 243.954 suínos e 309.043 aves, o que evidencia a importância dos produtos de origem animal no município (IBGE, 2016).

O clima da região é caracterizado como tropical de estação seca (Aw), com precipitação e temperatura médias de 1.500 mm e 18°C, respectivamente (Embrapa, 2003). O município pertence em sua maior parte as sub-bacias dos rios Aquidauana e Coxim, tributários do Rio

Taquari. Estas redes de drenagem convergem para o Pantanal que se juntam e compõe o sistema hidrográfico da BAP.




Figura 2: Localização da área de estudo pertencente a BAP.

Foram utilizadas imagens do sensor OLI, abordo do satélite Landsat-8, como imagem de alta resolução espacial (aqui descrita como “Imagem Fina”), e imagens do sensor MODIS, abordo dos satélites Terra e Aqua, como imagem de alta resolução temporal, mas baixa resolução espacial (“imagem grosseira”). O banco de dados foi composto com uma série temporal de imagens que abrangeu os períodos de 30/03/2017 a 01/03/2018, contendo ao total 93 imagens, sendo elas 12 imagens finas (OLI) e 81 imagens grosseiras (MODIS).

As imagens finas apresentam resolução espacial de 30 metros, resolução temporal de 16 dias e resolução espectral de 636 a 673 nm na banda do vermelho, e de 851 a 879 nm na banda do infravermelho próximo (USGS, 2017).

Para as imagens grosseiras foi selecionado o produto MCD43A4 da coleção 6, com resolução espacial de 500 metros, resolução temporal diária e apresenta a banda do vermelho com o intervalo de 620 a 670 nm, e a banda do infravermelho próximo com o intervalo de 841 a 876 nm (Schaaf e Wang, 2015). Porém se optou por trabalhar com uma resolução temporal de 4 dias ao invés de uma resolução diária, para assim, reduzir o fluxo de dados.

Foi realizado o cálculo de NDVI (*Normalized Difference Vegetation Index*), e as imagens resultantes foram submetidas a um pré-processamento para a remoção dos pixels com interferência de nuvens, e foram selecionadas as cenas com mais de 50% de área útil. Também foram removidos os pixels com baixa qualidade, determinados por meio de análise da banda ‘quality’, formando assim um banco de dados de imagens Landsat e outro de imagens MODIS.

Para calcular o NDVI, foi utilizada a Equação (1) (Rouse et al.,1974):

$$NDVI = \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}} \quad (1)$$

Em que: o R_{NIR} indica o valor de refletância nas regiões do infravermelho próximo e o R_{RED} o valor de refletância nas regiões próximas ao vermelho (Rouse et al., 1974).

Com o banco de dados compilado, foram elaboradas as imagens sintéticas por meio do algoritmo de predição STARFM, de modo a combinar a resolução espacial da imagem fina com a frequência temporal da imagem grosseira (Gao et al., 2006), gerando assim uma série de imagens com resolução espacial de 30 metros e resolução temporal de 4 dias.

A partir das imagens de NDVI, geradas pelo algoritmo STARFM foi montado um banco de imagens sintéticas, a esse banco também foram adicionadas algumas métricas fenológicas, sendo elas, a somatória da diferença dos NDVI's (Equação (2)), a média, a mediana, a variância, o desvio padrão, o valor máximo e o valor mínimo, as quais foram calculadas usando o próprio banco de dados.

$$NDVI_{dif} = \sum_{i=1}^{n-1} |NDVI_i - NDVI_{i+1}| \quad (2)$$

Em que: $NDVI_{dif}$ é a imagem de soma das diferenças das imagens NDVI's da série temporal, n é o número de imagens da série temporal, $NDVI_i$ é a imagem i da série temporal e $NDVI_{i+1}$ é a imagem seguinte da série temporal.

Em seguida foi realizado o mapeamento das áreas de pastagem do município, primeiro utilizando o banco de dados de imagens sintéticas com as métricas fenológicas, e utilizando-se os algoritmos de classificação RF, SVM, DT e MAXVER, e em seguida usando o banco de imagens Landsat-8/OLI e os mesmos algoritmos de classificação.

Para todas as combinações de classificadores e banco de imagens foi utilizado o mesmo conjunto de amostras, o qual foi composto por 100 amostras de pastagem, 100 amostras de mata e 100 amostras de agricultura. Como base para coleta das amostras de treinamento, foram utilizadas imagens Landsat-8/OLI, onde foram amostrados os pixels puros de cada classe de interesse.

As métricas de acurácia utilizadas foram obtidas por meio das matrizes de erros, que se utilizam de um painel amostral. Esta metodologia é caracterizada pela distribuição aleatória de pontos amostrais dentro do limite do município, com o objetivo de se realizar um levantamento das classes de uso e ocupação do solo de cada ponto, como sugerido por Luiz et al. (2002). Para a montagem do painel amostral foram distribuídos aleatoriamente nas máscaras 380 pontos, sendo 190 para a classe pastagem e 190 para a classe demais alvos. A validação desses pontos foi realizada por meio da interpretação visual de imagens do Google.

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 380 pontos teve a função de aumentar precisão dos índices de acurácia e diminuir o erro amostral.

A partir 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 Índice 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) (Equação (5)), o qual refere-se à probabilidade de um pixel de referência ter sido corretamente classificado, e a acurácia de usuário (AU) (Equação (6)), que indica a probabilidade que um pixel classificado na imagem de fato representa aquela categoria no campo (Congalton, 1991). Posteriormente as métricas de acurácia foram comparadas entre si, com base no tipo de dado utilizado, convencional ou sintético, bem como nos classificadores,

de modo a realizar uma análise imparcial quanto a eficiência da utilização de imagens sintéticas.

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

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

$$AP = \frac{x_{jj}}{x_j} * 100 \quad (5)$$

$$AU = \frac{x_{ii}}{x_i} * 100 \quad (6)$$

Em que: EG = exatidão global; A = pontos amostrais com acerto; n = número de pontos amostrais; K = Índice 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; AP = acurácia de produtor; AU = acurácia de usuário.

4. Resultados e Discussão

Os mapas da **Figura 3** apresentam os resultados dos algoritmos (colunas) de classificação utilizados em cada série temporal, e as séries temporais (linhas).

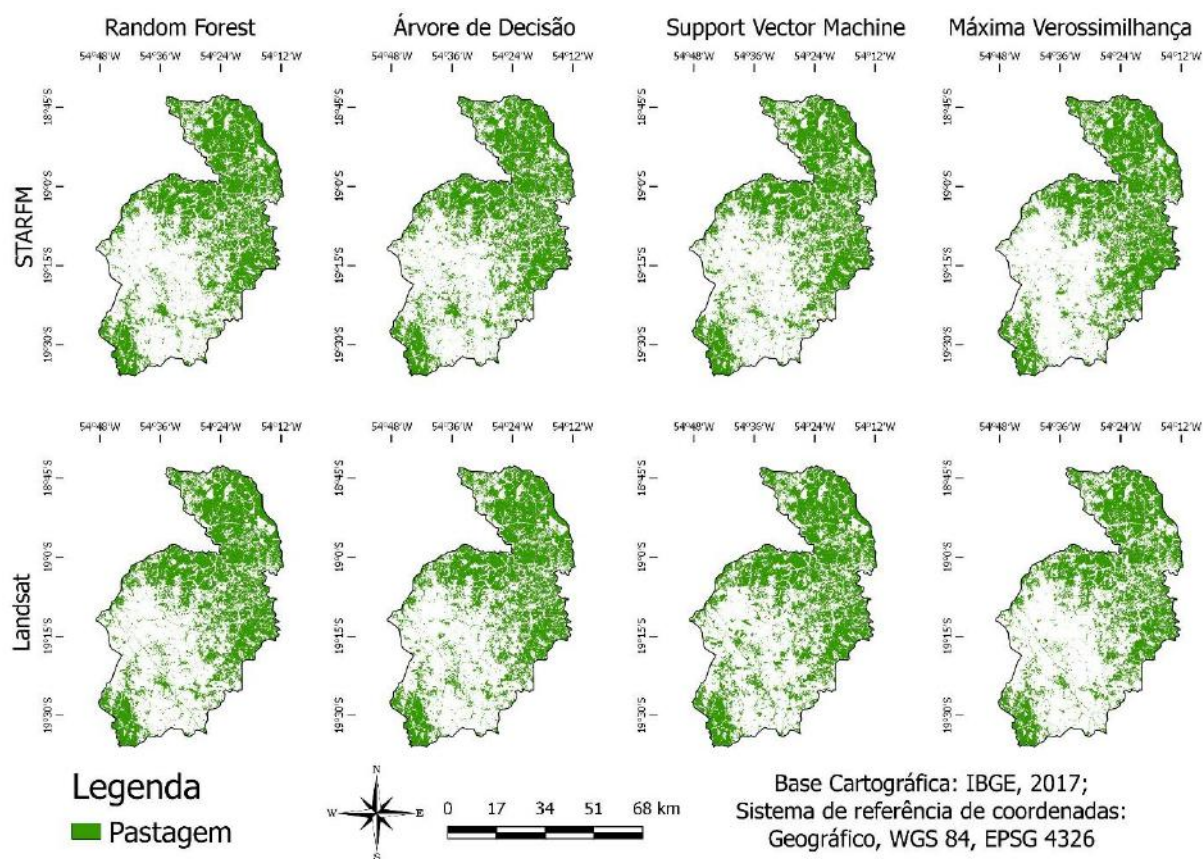


Figura 3: Classificações feitas usando as series temporais com diferentes classificadores.

Na **Tabela 1** são apresentados os valores de Índice Kappa e Exatidão Global obtidos para cada algoritmo em ambas as séries temporais.

Tabela 1: Valores de índice Kappa e exatidão global.

Classificador	Índice Kappa		Exatidão Global (%)	
	STARFM	Landsat	STARFM	Landsat
RF	0,8526	0,7895	92,63	89,47
DT	0,8474	0,7947	92,37	89,74
SVM	0,8421	0,8263	92,11	91,32
MAXVER	0,7368	0,7789	86,84	88,95

A classificação realizada com o algoritmo RF apresentou os melhores resultados, obtendo um índice Kappa superior a 0,85 e Exatidão Global superior a 92,5% para a série temporal composta pelas imagens do STARFM. Já para a série temporal composta pelas imagens Landsat-8/OLI, a melhor classificação foi a do algoritmo SVM, com índice Kappa superior a 0,83 e exatidão global superior a 91,5%.

O melhor desempenho do algoritmo RF é explicado por Walton (2008), que destaca a capacidade do mesmo em lidar com variáveis explicativas fracas, o que explica o aumento da acurácia com o acréscimo de variáveis.

O algoritmo MAXVER apresentou os piores resultados quando aplicado nas imagens sintéticas STARFM, e o algoritmo SVM apresentou resultados semelhantes em ambas as classificações. Esses resultados ocorrem devido ao superajustamento dos dados às amostras de treinamento que esses algoritmos sofrem, como explicado por (Novack et al. 2011).

Na **Tabela 2** pode-se observar os valores de acurácia de produtor e usuário obtido para a classificação de pastagem e de demais alvos, de acordo com o classificador e a série temporal utilizada.

Tabela 2: Valores de acurácia de usuário e produtor.

Série temporal	Classificador	Acurácia	Pastagem	Demais alvos	
STARFM	RF	AP	87,85	98,80	
		AU	98,95	86,32	
	DT	AP	88,15	97,63	
		AU	97,89	86,84	
	SVM	AP	87,04	98,78	
		AU	98,95	85,26	
	MAXVER	AP	82,11	93,21	
		AU	94,21	79,47	
	Landsat	RF	AP	83,48	98,08
			AU	98,42	80,53
DT		AP	83,86	98,09	
		AU	98,42	81,05	
SVM		AP	86,51	97,58	
		AU	97,89	84,74	
MAXVER		AP	88,54	89,36	
		AU	89,47	88,42	

Analisando os valores de acurácia de produtor e usuário, é possível observar uma tendência de que a acurácia de usuário seja alta para a pastagem e a de produtor para os demais alvos. Isso indica que poucos pontos de pastagem foram classificados de forma incorreta. Porém o baixo

valor de acurácia de usuário para os demais alvos e a de produtor para a pastagem indicam que houve um número alto de pontos com demais alvos classificados como pastagem.

Isso mostra que mesmo utilizando uma série temporal mais densa e as métricas fenológicas, ainda houve confusão das áreas de pastagem com outros alvos, porém em níveis menores.

Pode-se ainda observar que os valores de acurácia, em média, se mantiveram maiores utilizando o classificador RF na série temporal STARFM, tendo o maior valor de acurácia de usuário, quando aplicado na classe pastagem (98,95%) (igual ao valor obtido pelo classificador SVM) e o maior valor de acurácia de produtor quando aplicado nos demais alvos (98,80%), e se mantiveram menores, em média, utilizando o classificador MAXVER na mesma série, o qual obteve a menor valor de acurácia de produtor para a classe mata (82,11%) e o menor valor de acurácia de usuário para os demais alvos (79,47%).

O desempenho do algoritmo RF, corroboram com os resultados apresentados por Monteiro (2015), pois o presente algoritmo possui uma grande capacidade de pesquisar relações entre os dados e a geração de resultados em árvores de decisão simples e com legibilidade, permitindo ao autor obter uma exatidão global de 98% e um índice Kappa de 0.975.

5. Conclusões

Utilizando a série temporal composta por 88 imagens (STARFM e métricas fenológicas) conjuntamente com o algoritmo *Random Forest*, foram obtidos os maiores valores de acurácia para o mapeamento das áreas de pastagem no município de São Gabriel do Oeste - MS.

Com a utilização do algoritmo de predição STARFM para geração das imagens sintéticas, conjuntamente, com as métricas fenológicas oriundas do NDVI, foi possível melhorar de maneira geral os valores de acurácia dos classificadores, com a exceção para o MAXVER.

6. Agradecimentos

Os autores agradecem ao Programa de Pós-Graduação em Engenharia Agrícola (PGEAGRI) da UNIOESTE, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), à Fundação Araucária (FA) e ao Parque Tecnológico Itaipu (PTI) pelo apoio financeiro.

7. Referências

- Barbosa, A. P. **Comparação de métodos de classificação de imagens, visando o gerenciamento de áreas citrícolas**. 2009. 65p. Dissertação (Mestrado em Agronomia/Energia na Agricultura) - Universidade Estadual Paulista, Botucatu, 2009.
- Congalton, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v.37, p. 35-46, 1991.
- Coppin, P.; Jonckheere, I.; Nackaerts, K.; Muys, B. Digital change detection methods in ecosystem monitoring: a review. **International Journal of Remote Sensing**, 25, n. 9, p. 1565-1596, 2004.
- Embrapa. Centro Nacional de Pesquisa de Solos. **Zoneamento agroecológico do Município de São Gabriel do Oeste, MS: Referencial para o Planejamento, Gestão e Monitoramento Territorial** / Déa Sousa Assis [et al.].- 1 ed. rev. ampl. 60 p. - Rio de Janeiro, RJ: Embrapa, 2003.
- Fayyad, U.; Piatetsky-Shapiro, G.; Smyth, P. From Data Mining to Knowledge Discovery in Databases. **AI Magazine**, v.17, n.3, p.37-54, 1996.
- Gao, F.; Masek, J.; Shwaller, M. & Hall, F. On the Blending of the Landsat and MODIS Surface Reflectance: Predicting Daily Landsat Surface Reflectance. **Ieee Transactions on Geoscience and Remote Sensing**, v.44, n.8, p.2207-2218, 2006.

- IBGE - Instituto Brasileiro de Geografia e Estatística. **Mato Grosso do Sul, São Gabriel do Oeste**. 2017. Disponível em:<<https://cidades.ibge.gov.br/brasil/ms/sao-gabriel-do-oeste/panorama>>. Acesso em: 28 de junho de 2018.
- IBGE - Instituto Brasileiro de Geografia e Estatística. **Pesquisa Pecuária Municipal**.2016. Disponível em:<<https://sidra.ibge.gov.br/pesquisa/ppm/quadros/brasil/2016>>. Acesso em: 10 de julho de 2018.
- 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**, Brasília, DF, v. 47, n. 9, p. 1295-1306, set. 2012.
- Longley, P. A.; Goodchild, M. F.; Maguire, D. J.; Rhind, D. W. **Geographic information systems and science**. New York: John Wiley & Sons, 2005, 519p.
- Luiz, A. J. B.; Oliveira, J. C.; Epiphanyo, 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.
- Monteiro, F. P. **CLASIS: uma metodologia para classificação supervisionada de imagens de satélite em áreas de assentamento localizados na Amazônia**. 2015. 82p. Dissertação (Mestrado em engenharia elétrica) - Universidade Federal do Pará, Belém, PA, 2015.
- Novack, T.; Esch, T.; Kux, H.; Stilla, U. Machine Learning Comparison between WorldView-2 and QuickBird-2- Simulated Imagery Regarding Object-Based Urban Land Cover Classification. **Remote Sensing**, v.3, p. 2263-2282, 2011.
- Ponzoni, F. J.; Rezende, A. C. P. Influência da resolução espacial de imagens orbitais na identificação de elementos da paisagem em Altamira-PA. **Revista Árvore**, v.26, n.4, p. 403-410, 2002.
- Ponzoni, F. J.; Rezende, A. C. P. Caracterização espectral de estágios sucessionais de vegetação arbórea secundária arbórea em Altamira (PA), através de dados orbitais. **Revista Árvore**, v.28, n.4, p. 535-545, 2004.
- Prefeitura Municipal de São Gabriel do Oeste - MS. **Conheça o Município**. 2016. Disponível em:<<http://www.saogabriel.ms.gov.br/nossa-cidade/conheca-o-municipio>>. Acesso em: 28 de junho de 2018.
- Rouse Junior, J. W.; Haas, R. H.; Schell, J. A.; Deering, D. W.; Harlan, J. C. Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation. **Remote Sensing Center Texas A&M University College Station, Texas**, 1974.
- Schaaf, C., Wang, Z.; **MCD43A4 MODIS/Terra+Aqua BRDF/Albedo Nadir BRDF Adjusted Ref Daily L3 Global - 500m V006**. NASA EOSDIS Land Processes DAAC, USGS Earth Resources Observation and Science (EROS) Center, Sioux Falls, South Dakota (<https://lpdaac.usgs.gov>). 2015. Disponível em:<<http://dx.doi.org/10.5067/MODIS/MCD43A4.006>>. Acesso em 28 de junho de 2018.
- Silva, J. X. Da; Zaidan, R. T. **Geoprocessamento e análise ambiental: aplicações**. Rio de Janeiro: Bertrand Brasil, 2004, 368p.
- USGS - U.S. Geological Survey. **What are the band designations for the Landsat satellites**. 2017. Disponível em:<<https://landsat.usgs.gov/what-are-band-designations-landsat-satellites>>. Acesso em: 28 de junho de 2018
- Walton, J. T. Subpixel Urban Land Cover Estimation: Comparing Cubist, Random Forests, and Support Vector Regression. **Photogrammetric Engineering And Remote Sensing**, v.74, p. 1213-1222, 2008.