

COMPARATIVO ENTRE OS CLASSIFICADORES RF E MAXVER, PARA CLASSIFICAÇÃO DE USO E COBERTURA DA TERRA, EM DIFERENTES DENSIDADES TEMPORAIS

Ivã Luis Caon¹, Willyan Ronaldo Becker¹, Diandra Ganascini¹, Carlos Eduardo Vizzotto Cattani¹,
Isaque de Souza Mendes¹, Victor Hugo Rohden Prudente², Lucas Volochen Oldoni²,
Joao Francisco Goncalves Antunes³, Erivelto Mercante¹

¹Universidade Estadual do Oeste do Paraná - UNIOESTE, R. Universitária, 2069 - Universitário, CEP: 85819-110 - Cascavel, PR, Brasil {iva.caon, willyan.becker, diandra.ganascini, carlos.cattani, isaque.mendes, erivelto.mercante}@unioeste.br;

²Instituto Nacional de Pesquisas Espaciais - INPE, Av. dos Astronautas, 1758 - Caixa Postal: 515, CEP: 12227-010 - São José dos Campos - SP, Brasil, {victor.prudente, luca.oldoni}@inpe.br; ³Embrapa Informática Agropecuária, Av. André Tosello, 209, Caixa Postal: 6041, CEP: 13083-886 - Campinas, SP, Brasil, joao.antunes@embrapa.br

RESUMO

O uso combinado de sensores com melhor resolução temporal com sensores de melhor resolução espacial, têm permitido o mapeamento detalhado da superfície terrestre. Desse modo destacam-se os algoritmos de predição, que são capazes de unir a melhor resolução espacial de um sensor a melhor resolução temporal de outro. Além das resoluções das imagens, o uso de algoritmos de classificação eficientes é decisivo para se obter elevada acurácia nos mapeamentos. Assim, o objetivo desse trabalho foi comparar os classificadores *Random Forest* e Máxima Verossimilhança, com diferentes modos de entrada de dados, a fim de definir qual o melhor classificador. Os resultados apontaram que o algoritmo *Random Forest* apresentou as maiores métricas de acurácia.

Palavras-chave — Fusão de imagens, STARFM, classificação de imagens, uso e cobertura da terra.

ABSTRACT

The combined use of sensors with better temporal resolution with sensors of better spatial resolution, has allowed the detailed mapping of the terrestrial surface. In this way the prediction algorithms, which are able to unite better spatial resolution of one sensor and better temporal resolution of another one, stand out. In addition, using images, the use of identification algorithms is more important to obtain accuracy in mappings. Thus, it was compared with the Random Forest and Maximum Likelihood methods, with different modes of data entry, a process of adjusting to a better classifier. The results were similar to the Random Forest algorithm presented as the highest accuracy metrics.

Key words — Image fusion, STARFM, image classification, land use and land cover.

1. INTRODUÇÃO

Nos últimos anos houve uma acelerada evolução das tecnologias espaciais, em conjunto com avanços nas

características espaciais e espectrais de sensores orbitais, bem como no melhoramento de algoritmos de classificação. Estes avanços aumentaram o uso de dados de sensoriamento remoto para mapeamento do uso e cobertura da terra [1].

Análises realizadas com mapas temáticos associados ao uso da terra têm servido como base para mudanças nas formas de uso e ocupação da terra 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) [2], [3].

As imagens provenientes de sensores orbitais ópticos possuem características únicas quanto à resolução radiométrica, espectral, espacial e temporal, e têm se tornado fontes primárias para classificação da cobertura da terra e da vegetação em diversas escalas [4].

A resolução espacial das imagens orbitais é um dos principais elementos na definição das legendas dos mapas temáticos, para mapeamento de grandes áreas geográficas [5]. Porém vale ressaltar o fator temporal das imagens, pois como descrito por [6], os ecossistemas estão em constante processo de alteração dos seus componentes superficiais no tempo e no espaço.

Com isso os algoritmos de predição se mostram úteis, ao realizarem a fusão de imagens de melhor resolução espacial com imagens de melhor resolução temporal, gerando assim uma série de alta resolução espacial e temporal. Neste sentido destaca-se o algoritmo STARFM (*Spatial and Temporal Adaptive Reflectance Fusion Model*), que foi desenvolvido para realizar a fusão das imagens da série Landsat com as imagens do sensor MODIS (*Moderate-Resolution Imaging Spectroradiometer*), gerando assim uma série sintética [7].

Além das imagens, a escolha da técnica de classificação também é determinante para o mapeamento confiável do uso e cobertura da terra [8]. Dentre os algoritmos de classificação, o *Random Forest* (RF) tem se destacado devido a sua superioridade na tratabilidade das imagens [1], e o classificador de máxima verossimilhança (MAXVER), por ser comumente utilizado para a realização das classificações [9].

Nesse contexto, o objetivo deste trabalho foi realizar o comparativo entre os classificadores RF e MAXVER, utilizando-se de diferentes resoluções temporais dos dados de entrada, as quais foram geradas com o uso do algoritmo de predição STARFM.

2. MATERIAIS E MÉTODOS

A área em estudo compreende o município de Cascavel, localizado na região Oeste do estado do Paraná, situado entre as coordenadas (-53,0681°; -24,7391°) e (-53,7364°; -25,3756°), WGS 84, caracterizada pela produção agrícola. A região apresenta, na maior parte de sua extensão, o solo Latossolo Vermelho Distroférico [10], com clima subtropical mesotérmico superúmido, caracterizado como Cfa – Clima subtropical, com temperatura média anual de 19°C, e altitude média de 781 metros [11].

Para as análises foram realizadas a classificação do uso e cobertura da terra, com as classes de mata, pastagem e agricultura. Da área de estudo foi retirado as áreas urbanas, devido ao mesmo apresentar uma alta mistura espectral, aumentando os erros de classificação.

Foram utilizadas imagens do sensor OLI (*Operational Land Imager*), 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 moderada resolução espacial (“Imagem Grosseira”). O banco de dados foi composto com uma série temporal de imagens que abrangeu os períodos de 28/06/2016 a 25/03/2017, contendo ao total 251 imagens, sendo elas 9 imagens finas (OLI) e 242 imagens grosseiras (MODIS). Este período foi escolhido por compreender a safra de verão da região.

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 [12].

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 [13].

Foi realizado o cálculo de NDVI (*Normalized Difference Vegetation Index*) [14], e as imagens resultantes foram submetidas a um pré-processamento para a remoção dos pixels com interferência de nuvens, de modo a selecionar 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.

Com o banco de dados compilado, foram geradas 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 [5], gerando assim uma série de imagens com resolução espacial de 30 metros e resolução temporal diária.

Em seguida foi realizada a classificação da área, abordando diferentes densidades temporais e dois classificadores. Foram utilizadas densidades temporais de 1, 2, 4, 8 e 16 dias, utilizando apenas as imagens Landsat originais e por último a imagem resumo da série, feita com o desvio padrão do banco de dados de imagens STARFM, pois em testes anteriores foi a métrica que apresentou os melhores desempenhos. O número de imagens para cada densidade temporal foi de respectivamente 242, 121, 61, 31, 15, 9 e 1.

Para os processos de classificação, foram utilizados os algoritmos *Random Forest* (RF) e Máxima Verossimilhança (MAXVER).

Para o classificador MAXVER não foi possível realizar as classificações usando a imagem resumo, a com densidade de 1 dia e a com densidade de 2 dias, devido a limitações do software *Environment for Visualizing Images* (ENVI 5.0).

Para todas as combinações de classificadores e densidade temporal foi utilizado o mesmo conjunto amostral, 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, em que foram selecionados 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. [15]. Foram distribuídos aleatoriamente 150 pontos nas máscaras, sendo 50 pontos para cada classe. A validação desses pontos foi realizada por meio da interpretação visual de imagens de maior resolução espacial, no caso imagens do Google e séries temporais por meio de um interpretador externo.

A escolha do número de pontos baseou-se no trabalho de [16], 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.

A partir da matriz de erros foram calculados os índices de Exatidão Global (EG), que expressa o total de acertos em relação ao total de amostras da imagem classificada e Índice Kappa (K), utilizado para expressar a precisão da classificação [17].

Para se comparar os valores de K obtidos será utilizado o teste Z, a 5% de significância, como descrito por [17].

3. RESULTADOS E DISCUSSÃO

A Figura 1 apresenta o resultado das classificações. Colunas representam os classificadores e as linhas as diferentes densidades temporais.

Como é possível observar na Figura 1, o resultado da mudança da densidade temporal, assim como o classificador cria diferenças na distribuição espacial das classes.

A Tabela 1 apresenta os valores de K e EG, para as classificações realizadas. Para o K foi aplicado o teste Z para comparação entre os valores obtidos, a 5% de precisão.




Figura 1. Classificações realizadas com os algoritmos RF e MAXVER para a imagem resumo (R), para as imagens Landsat (L8), e para as densidades temporais de 16, 8, 4, 2 e 1 dia (16d, 8d, 4d, 2d e 1d).

Como observado pelo teste Z, na Tabela 1, a pior classificação foi a com a imagem resumo, e a melhor foi a do classificador RF, com densidade temporal de 4 dias, pois foi a única que estatisticamente se diferenciou da classificação do MAXVER com 4 dias, com resultado melhor.

Tabela 1. valores de índice Kappa e exatidão global obtidos para as classificações.

	RF		MAXVER	
	K	EG	K	EG
R	0,44 a	62,67%		
L8	0,75 bc	83,33%	0,75 bc	83,33%
16d	0,78 bc	85,33%	0,79 bc	86,00%
8d	0,72 bc	81,33%	0,73 bc	82,00%
4d	0,80 c	86,67%	0,69 b	79,33%
2d	0,76 bc	84,00%		
1d	0,75 bc	83,33%		

Nota: imagem resumida (R), imagens Landsat (L8), e densidades temporais de 16, 8, 4, 2 e 1 dia (16d, 8d, 4d, 2d e 1d).

Nota 2: letras iguais representam valores estatisticamente iguais segundo o teste Z a 5% de precisão.

A Figura 2 mostra graficamente o comportamento das acurácias com o aumento das informações de entrada. O número de informações de entrada foi calculado usando o número de pontos amostrais multiplicado pelo número de imagens utilizadas.




Figura 2. Valor de K nas linhas e valor de EG nas colunas versus o número de informações de entrada, barras de erro indicam $\pm 5\%$.

Como observado na Figura 2, o classificador MAXVER sofre um superajuste, atingindo um ponto de máxima acurácia, com algo próximo a 4500 informações de entrada, e em seguida sofrendo um declínio. O classificador RF sofre um ajuste fino, com uma tendência de aumento de acurácia com o acréscimo das informações de entrada.

Esses comportamentos dos classificadores são explicados por [18], o qual destaca a capacidade do algoritmo RF de lidar com variáveis explicativamente fracas, e por [19], o qual diz que o classificador MAXVER sofre uma maior influência devido à alta dimensionalidade e correlação do espaço de atributos.

Os resultados mostram que o aumento da densidade temporal não foi tão significativo para a classificação de uso e cobertura terra, mas o método proposto pode ser útil para a identificação e monitoramento de alvos que apresentem uma alta dinâmica, tal como culturas agrícolas.

4. CONCLUSÕES

O classificador RF apresenta melhores resultados com o aumento da entrada de informações, enquanto o classificador MAXVER, além de se mostrar limitado ainda apresenta um superajuste, levando a maiores erros de classificação.

O uso do algoritmo de predição STARFM se mostrou útil para a densificação de séries temporais, o que permite o aumento do número informações de entrada para os classificadores.

5. AGRADECIMENTOS

Os autores agradecem a Universidade Estadual do Oeste do Paraná (UNIOESTE) e o Laboratório de Topografia e Geoprocessamento (GeoLAB) pela infraestrutura ofertada e apoio técnico-científico, a Fundação Araucária (FA), a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro.

6. REFERÊNCIAS

[1] Adam, E; Mutanga, O.; Odindi, J.; Abdel-Rahman, E.M. "Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers". *International Journal of Remote Sensing*, volume (35), número (10), páginas (3440-3458), 2014.

[2] Longley, P. A.; Goodchild, M. F.; Maguire, D. J.; Rhind, D. W. "Geographic information systems and science". John Wiley & Sons, New York, páginas (519), 2005.

[3] Silva, J. X. Da; Zaidan, R. T. "Geoprocessamento e análise ambiental: aplicações". Bertrand Brasil, Rio de Janeiro, páginas (368), 2004.

[4] Lu, D.; Li, G.; Moran, E.; Kuang, W. "A comparative analysis of approaches for successional vegetation classification in the Brazilian Amazon". *GIScience & Remote Sensing*, volume (51), número (6), páginas (695-709), 2014.

[5] 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*, volume (28), número (4), página (535-545), 2004.

[6] Coppin, P.; Jonvkeere, I.; Nackaerts, K.; Muys, B. "Digital change detection methods in ecosystem monitoring: a review". *International Journal of Remote Sensing*, volume (25), número (9), página (1565-1596), 2004.

[7] 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*, volume (44), número (8), página (2207-2218), 2006.

[8] Lu, D.; Weng, Q. "A survey of image classification methods and techniques for improving classification performance". *International journal of Remote sensing*, volume (28), número (5), página (823-870), 2007.

[9] Rêgo, J.C.L.; Soares-Gomes, A.; Silva, F.S. "Loss of vegetation cover in a tropical island of the Amazon coastal zone (Maranhão Island, Brazil)". *Land Use Policy*, volume (71), páginas (593-601), 2018.

[10] Curcio, G. B.; Oliveira Sobrinho, V.; Do Nascimento, L. A.; Garrastazu, M. C.; Rosot, M. A. D.; Lima, V. C. "Mapa simplificado de solos do estado do paran ". 2012.

[11] Aparecido, L. E. O.; Rolim, G. S.; Richetti, J.; Souza, P. S.; Johann, J. A. "K ppen, Thornthwaite and Camargo climate classifications for climatic zoning in the State of Paran , Brazil". *Ci ncia e Agrotecnologia*, volume (40), n mero (4), p ginas (405-417), 2016.

[12] USGS - U.S. Geological Survey. "What are the band designations for the Landsat satellites". 2017. Dispon vel em: <<https://landsat.usgs.gov/what-are-band-designations-landsat-satellites>>. Acesso em: 28 de junho de 2018.

[13] Schaaf, C.; Wang, Z. "MCD43A4 MODIS/Terra+Aqua BRDF/Albedo Nadir BRDF Adjusted Ref Daily L3 Global - 500m V006". NASA EOSDIS Land Processes DAAC, 2015.

[14] 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*, p gina (390), 1974.

[15] Luiz, A. J. B.; Oliveira, J. C.; Epiph nio, J. C. N.; Formaggio, A.R. "Aux lio das imagens de sat lite aos levantamentos por amostragem em agricultura". *Agricultura em S o Paulo*, volume (49), p ginas (41-54), 2002.

[16] Johann, J. A.; Rocha, J. V.; Duft, D. G.; Lamparelli, R. A. C. "Estimativa de  reas com culturas de ver o no Paran , por meio de imagens multitemporais EVI/Modis". *Pesquisa Agropecu ria Brasileira*, volume (47), n mero (9), p ginas (1295-1306), 2012.

[17] Congalton, R. G.; Green, K. "Assessing the accuracy of remotely sensed data : principles and practices -- 2nd ed.". Taylor & Francis Group, p gina (183), 2009.

[18] Walton, J. T. "Subpixel Urban Land Cover Estimation: Comparing Cubist, Random Forests, and Support Vector Regression". *Photogrammetric Engineering And Remote Sensing*, volume (74), p ginas (1213-1222), 2008.

[19] 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*, volume (3), p ginas (2263-2282), 2011.