

Comparação de métodos detecção de mudança no uso e cobertura da terra

Aline Delfino Germano¹, Roberta Aversa Valente², Fabiana da Silva Soares³ e Ivan Vanderley-Silva⁴

^{1,2,3,4}Universidade Federal de São Carlos, Brasil, ^{1,2,3,4}Rodovia João Leme dos Santos (SP-264), km 110 – Sorocaba – SP, ¹germanoad@outlook.com.br; ²roavalen@ufscar.br; ³fabianasoes@estudante.ufscar.br; ⁴ivanvanderley@yahoo.com.br.

RESUMO

A utilização de geotecnologias é fundamental para gestão do território, porém sua aplicabilidade demanda conhecimento da ferramenta, das informações iniciais e do processamento dos dados. Nesse sentido, o objetivo foi analisar dois métodos de detecção de mudanças do uso e cobertura da terra (DM) visando otimizar a obtenção dos resultados. Para isso, utilizou-se cenas da série do Landsat para gerar a diferença do Índice de vegetação de diferença normalizada (NDVI) e a *Change Vector Estration* (CVA). Os métodos foram avaliados estatisticamente com relação aos números de acertos e erros. Os resultados mostram que o DM_{NDVI} apresentou melhor desempenho que o DM_{CVA} com média geral entre os anos de 94% e 61% respectivamente. Quando comparado os erros de forma geral, percebe-se que o DM_{NDVI} , também, apresentou os menores erros. Portanto, o recomenda-se a utilização do método de detecção de mudança o uso e cobertura da terra utilizando o NDVI. Entretanto, aconselha-se novos estudos para que o procedimento seja mais eficaz e rápido.

Palavras-chave — *Análise temporal, sensoriamento remoto e monitoramento ambiental.*

ABSTRACT

The use of geotechnologies is fundamental for territory management, but its applicability demands knowledge of the tool, initial information, and data processing. In this sense, the objective was to analyze two methods for detecting changes in land use and land cover (DM) to optimize the results obtained. For this, scenes from the Landsat series were used to generate the difference in the Normalized Difference Vegetation Index (NDVI) and the Change Vector Extraction (CVA). The methods were statistically evaluated regarding the number of correct answers and errors. The results show that the DM_{NDVI} performed better than the DM_{CVA} , with an overall average between 94% and 61%, respectively. When comparing the errors in general, it is clear that the DM_{NDVI} also presented minor errors. Therefore, it is recommended to use the NDVI method for land use and land cover change detection. However, further studies are advised to make the procedure more effective and faster.

Key words — *Temporal analysis, remote sensing and environmental monitoring.*

1. INTRODUÇÃO

A utilização de geotecnologias, sejam elas em ambientes de sensoriamento remoto (SR) ou em sistema de informação geográficas (SIG), é comumente utilizada na gestão do território, pois oferecem suporte adequado para tomada de decisão ao avaliar diferentes variáveis ambientais em um único plano de informação [1].

A despeito disso, a sua aplicação demanda conhecimento prévio dos dados de entrada, do processamento e das ferramentas aplicadas, pois podem intervir de maneira direta ou indireta nos resultados.

A aplicabilidade das geotecnologias depende, ainda, do objetivo a ser empregado, principalmente quando há demanda por respostas rápidas e essenciais, como ocorrem nos desastres naturais ocasionados por fatores antrópicos. Entretanto, há uma carência por processos científicos que desenvolvam procedimentos automatizados no ambiente SIG para identificar alterações no uso e cobertura da terra [2].

A detecção de mudança (DM) tem sido uma ferramenta importante para analisar a dinâmica do uso e cobertura da terra e, desde a década de 80, estudos buscam aprimorar as técnicas [3], especialmente, utilizando metodologias de processamento digital.

Nesse sentido, as principais técnicas de DM utilizam o método de diferença de imagens e razões, pois são meios fáceis de implementação e a baixo custo operacional. Diante dos métodos disponíveis, ressaltam-se utilização da série Landsat dos anos 1990 a 2015 para detecção de uso antrópico [4], as técnicas de detecção de mudanças não supervisionadas com imagens multiespectral e bi-temporal [5], a aplicação de sensores ópticos e radar de média resolução para detecção de desmatamento ilegal [6] e a eficiência dos índices de vegetação em baixa resolução para detecção de mudanças de padrões espaciais no sertão nordestino [7].

Desta forma, buscou-se avaliar dois métodos de detecção de mudança no uso e cobertura da terra visando tornar a aplicação mais prática e rápida para efeito e gestão do território e tomada de decisão.

2. MATERIAL E MÉTODOS

Área de estudo é a bacia do rio Sarapuí (Figura 1), pertencente à URGHI 10 e localizada entre as sub-bacias do médio e alto Sorocaba. O rio Sarapuí é uma afluente do Rio Tietê e abastece quatro cidades do estado, fornecendo água para uso doméstico, fins agrícolas e outros.




Fig. 1. Área de estudo da detecção de mudança da bacia do rio Sarapuí-SP.

Originalmente, coberta pelo bioma da Mata Atlântica, a bacia do rio Sarapuí apresenta remanescentes florestais nativos de Floresta Ombrófila Densa, clima temperado úmido com invernos secos (Cwa), segundo classificação Köppen, e precipitação anual entre 1354,7 e 1807,7 mm [8].

Assim, para determinar um método e DM foram utilizadas imagens da série dos satélites Landsat 5 e 8 (Tabela 1).

Tabela 1. Datas das cenas da series do satélite Landsat para a bacia do rio Sarapuí (SP, Brasil).

Sensor	Data
Landsat 5	27/03/1988
Landsat 5	02/07/1994
Landsat 5	20/09/2000
Landsat 5	22/02/2005
Landsat 5	04/02/2010
Landsat 8	10/06/2015
Landsat 8	28/01/2019

Ressalta-se que os sensores da série dos satélites Landsat apresentam características diferenciadas ao longo de sua trajetória, em virtude das suas diferentes missões, mas que não inviabilizaram a utilização no método.

Assim, as cenas foram avaliadas em dois métodos de entradas de dados. No primeiro, empregou-se o Índice de vegetação de diferença normalizada (NDVI) [9], neste estudo denominado com DM_{NDVI} . No segundo, utilizou-se a *Change Vector Estration* (CVA) [10], denominado como DM_{CVA} .

No método DM_{NDVI} , aplicou-se o índice para cada cena e, após, calculou-se a diferença de um ano para o outro. Enquanto que no método DM_{CVA} foram realizadas análises da magnitude e direção. Para ambos os métodos, foi necessário determinar um limiar de DM de uma cena para outra.

Assim, para o método DM_{NDVI} , determinou-se o limiar por meio da diferença entre o índice de cada data, seguido de avaliação estatística para definir um valor ótimo. Posteriormente, aplicou-se a metodologia de classificação

supervisionada pelo método de *Object-Based Image Analysis*, ou seja, classificação orientada ao objeto e a classificação da imagem segmentada foi realizada com um algoritmo não-paramétricos o *Support Vector Machine* (SVM).

Para o limiar do DM_{CVA} , estudou-se os ângulos e definido visualmente as amplitudes de mudança. Após, o ângulo limiar foi aplicado como condicional, ou seja, o pixel que engloba os valores dentro do limiar, foram classificados como mudança.

Após a limiarização dos métodos, por meio de visualização, verificou além das mudanças, quais valores seriam de mudanças de perda ou ganho de vegetação. Em que Perda significa que do ano referência (i.e., mais antigo) para o ano atual (i.e., mais novo) houve supressão de vegetação. Enquanto ganho (rebrote) significa que do ano de referência para o atual houve incremento de vegetação.

Para a validação dos resultados foram realizados 385 pontos de controles, obtidos aleatoriamente e divididos da seguinte forma, 80% dedicados as áreas de mudanças pelos métodos (i.e., mudança correta e falso positivo) e 20% para regiões externas as áreas de mudanças (i.e., verificação de falsos negativos). Portanto, os pontos foram explorados para determinação de falsos positivos (fp) e negativos (fn), ou seja, computados os erros onde não houve mudança real.

Além disso, empregou-se o índice Kappa (K) para a comparação entre os dois procedimentos. O K é um método amplamente utilizado nas avaliações de resultados de classificações de mapas temáticos [11], [12] e [13] e varia de 0 (concordância nula) a 1 (concordância perfeita) [14].

Para avaliação do K, utilizou-se os dados de falso positivo e negativo da DM de todos os anos, com os anos testados representando as classes. Assim, os pontos classificados perfeitamente foram computados como corretos dentro da classe e os falsos negativos foram os pontos classificados erroneamente em uma classe diferente de origem.

Por fim, realizou-se para ambos os métodos o teste de significância estatística e comparando os dois métodos testados por meio do Teste Z [15].

3. RESULTADOS

Os resultados demonstram a robustez dos procedimentos adotados, no qual os valores ótimos da classificação OBIA para o método DM_{NDVI} foram 40 para os fatores de segmentação (Edge) e 60 para o nível de mesclagem, obtidos por tentativas e acertos (i.e., análise visual). Esses limiares geraram valores igualitários para grupos do mesmo sensor (Tabela 2), ou seja, do ano de 1988 a 2010 (i.e., sensor TM) foi usado um, de 2010 e 2015 (i.e., TM e OLI) outro e por fim 2015 e 2019 (i.e., OLI).

Tabela 2. Limiares de diferentes mudanças para o método o DM_{NDVI} para bacia do rio Sarapuí (SP, Brasil).

Sensor	Limiar	Tipo de Mudança
TM (i.e., Landsat 5)	-1 a -0,2	Perda
	0,25 a 1	Ganho
TM e OLI (i.e., Landsat 5 e 8)	-1 a -0,4	Perda
	0,05 a +1	Ganho
OLI (i.e., Landsat 8)	-1 a 0,01	Perda
	0,25 a 1	Ganho

Já para o método DM_{CVA} os ângulos de perdas e ganhos estão apresentados na Tabela 3 e foram utilizados para DM.

Tabela 3. Limiares de mudanças (i.e., magnitude) do método DM_{CVA} para a bacia do rio Sarapuí (SP, Brasil).

Ano	Perda	Ganho
1988-1994	270° - 360°	0° - 90°
1994-2000	270° - 360°	0° - 90°
2000-2005	340° - 20°	110° - 130°
2005-2010	335° - 360°	140° - 180°
2010-2015	54° - 57°	65° - 68°
2015-2019	270° - 360°	0° - 90°

A análise de número de acertos e erros totais resultou em média de 94% acertos para o método DM_{NDVI} entre os anos, resultado superior ao método DM_{CVA} que atingiu média de 61% de acerto.

Em relação aos falsos positivos e negativos, o DM_{NDVI} resultou em melhor desempenho com 5,5% de falso positivo, enquanto que o DM_{CVA} houve 35% de falso positivo. Ambos apresentaram valores baixos para falsos negativos.

Na figura 2 está especializado os erros e acertos de ambos os métodos. Logo, o teste Z resultou em valor 30,57, demonstrando diferença significativa entre os métodos para 99% de confiança ($Z < 2,57$) e 95% de confiança ($Z < 1,96$).

4. DISCUSSÃO

Os procedimentos adotados mostram que os valores obtidos confirmam a viabilidade de utilização de índices de vegetação para detecção de mudanças no uso e cobertura da terra, especialmente, para identificar perda ou ganho de florestas.

Assim, a determinação visual dos limiares supriu a necessidade de estabelecer um valor de referência para comparação entre os anos e as imagens dos satélites Landsat. Os valores definidos para o DM_{NDVI} , por exemplo, condisseram com o encontrado na literatura científica, ou seja, Edge 50 e nível de mesclagem 70 para o sensor TM Landsat-5 [16] e Edge 10 e nível de mesclagem de 60 para o sensor OLI do Landsat-8 [17].

Quando comparado os erros de forma geral, percebe-se que o DM_{NDV} além de apresentar os maiores acertos, apresenta os menores erros. Percebe-se resultado semelhante para os

falsos positivos e negativos, no qual o DM_{NDV} ainda apresenta melhores relações que o método DM_{CVA} . Já os falsos negativos são baixas para todos os métodos e reforça a aplicação dos procedimentos adotados nesse estudo.

Nesse sentido, fazendo uma relação entre o acerto e os erros, pode-se dizer que o melhor método seria qual apresentar mais acerto sem fp e fn. Portanto, o DM_{NDVI} se apresenta superior ao DM_{CVA} . Na figura 2 nota-se a diferença entre os dois métodos, sendo que no DM_{NDVI} as áreas de mudanças foram maiores e no DM_{CVA} as mudanças foram mais pontuais, visto que o DM_{NDV} foi realizada classificação OBIA o que diminui os efeitos conhecidos como sal e pimenta.




Fig. 2. Áreas com mudanças do uso e cobertura da terra do ano de 2015 para 2019 para a bacia do rio Sarapuí-SP. A) Método CVA e B) Método NDVI.

Finalmente, a aplicação do teste Z para todos os anos corrobora para diferença estatisticamente significativa entre os métodos, apontando para maior eficiência do método DM_{NDVI} utilizando imagem do sensor multiespectral com resolução espacial de 30 metros.

5. CONCLUSÕES

A aplicação das técnicas de sensoriamento remoto na bacia do rio Sarapuí corroboram para eficiência da ferramenta no monitoramento de mudanças do uso e cobertura da terra, principalmente, para determinação de ganhos e perda de vegetação florestal, mas ainda exige muita complexidade na operação, dificultando uma automatização prática. Entretanto, a realização de procedimentos diretos como DM_{NDVI} e DM_{CVA} auxilia o analista, de maneira simples, a identificar áreas de conversão de forma automática.

Por fim, conclui-se o DM_{NDVI} é um método semiautomático, que conduzido com auxílio de um especialista, mostra-se de fácil manuseio e agilidade. Assim, os resultados da DM pode auxiliar na tomada de decisão no monitoramento ambiental, na fiscalização de mudanças no uso e cobertura da terra e para programas de pagamentos de serviços ambientais.

6. REFERÊNCIAS

- [1] J. R. Jensen and J. John R, *Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres (Tradução da Segunda Edição)*, Parêntese. São José dos Campos: Parêntese, 2009.
- [2] L. Khelifi and M. Mignotte, "Deep Learning for Change Detection in Remote Sensing Images: Comprehensive Review and Meta-Analysis," *IEEE Access*, vol. 8, no. Cd, pp. 126385–126400, 2020, doi: 10.1109/ACCESS.2020.3008036.
- [3] G. M. Wickware and P. J. Howarth, "Change detection in the Peace-Athabasca delta using digital Landsat data," *Remote Sens. Environ.*, vol. 11, no. C, pp. 9–25, 1981, doi: 10.1016/0034-4257(81)90003-1.
- [4] M. Ibrahim, "Change Detection of Vegetation Cover Using Remote Sensing Data as a Case Study : Ajloun Area Change Detection of Vegetation Cover Using Remote Sensing Data as a Case Study : Ajloun Area," *Civ. Environ. Res. ISSN 2224-5790 ISSN 2225-0514 Vol.8, No.5, 2016*, no. May, pp. 1–6, 2016.
- [5] F. Bovolo, S. Marchesi, and L. Bruzzone, "A framework for automatic and unsupervised detection of multiple changes in Multitemporal Images," *IEEE Trans. Geosci. Remote Sens.*, vol. 50, no. 6, pp. 2196–2212, 2012, doi: 10.1109/TGRS.2011.2171493.
- [6] T. Rodrigues, E. E. Sano, T. de Almeida, J. M. Chaves, and J. Doblas, "Detection of land cover change in the Brazilian Cerrado using radar data (Sentinel-1A)," *Soc. Nat.*, vol. 31, pp. 1–20, 2019, doi: <http://dx.doi.org/10.14393/SN-v31-2019-46315> Detection.
- [7] E. P. Ribeiro, R. S. Nóbrega, F. de O. M. Filho, and E. B. M. Moreira, "Estimativa dos índices de vegetação na detecção de mudanças ambientais na bacia hidrográfica do rio Pajeú," *Geosul*, vol. 31, no. 62, pp. 59–92, 2016, doi: 10.5007/2177-5230.2016v31n62p59.
- [8] C. A. Alvares, J. L. Stape, P. C. Sentelhas, J. L. De Moraes Gonçalves, and G. Sparovek, "Köppen's climate classification map for Brazil," *Meteorol. Zeitschrift*, vol. 22, no. 6, pp. 711–728, 2013, doi: 10.1127/0941-2948/2013/0507.
- [9] J. W. Rouse, R. H. Hass, J. A. Schell, and D. W. Deering, "Monitoring vegetation systems in the great plains with ERTS," in *Third Earth Resources Technology Satellite (ERTS) symposium*, 1973, vol. 1, pp. 309–317, doi: citeulike-article-id:12009708.
- [10] W. A. Malila, "Change Vector Analysis: an Approach for Detecting Forest Changes With Landsat.," *Proc. Soc. Photo-Optical Instrum. Eng.*, pp. 326–336, 1980.
- [11] J. Sen Lee, M. R. Grunes, and E. Pottier, "Quantitative comparison of classification capability: Fully polarimetric versus dual and single-polarization SAR," *IEEE Trans. Geosci. Remote Sens.*, vol. 39, no. 11, pp. 2343–2351, 2001, doi: 10.1109/36.964970.
- [12] H. S. Lim, M. Z. Matjafri, K. Abdullah, and N. M. Saleh, "High Spatial Resolution Land Cover Mapping Using ALOS Data Over Kedah, Malaysia," in *First Joint PI Symposium of ALOS DataNodes for ALOS Science Program Kyoto*, 2007, pp. 1–4.
- [13] P. R. Meneses and T. De Almeida, *Introdução ao Processamento de Imagens de Sensoriamento Remoto*, CNPq. Brasília, 2012.
- [14] J. Cohen, "A Coefficient of Agreement for Nominal Scales," *Educ. Psychol. Meas.*, vol. 20, no. 1, pp. 37–46, 1960, doi: 10.1177/001316446002000104.
- [15] R. G. Congalton and K. Green, *Assessing the accuracy of remotely sensed data: Principles and practices*, Lewis Publ. New York: Lewis Publishers, 1999.
- [16] D. D. O. Soares, A. C. Dos Santos, and E. B. Da Silva, "Análise das classificações supervisionada e não supervisionada com o uso de imagens Landsat 5 TM e RapidEye, e suas contribuições para o mapeamento do uso e cobertura do solo no Parque Nacional das Emas," *Rev. Bras. Geomática*, vol. 4, no. 2, p. 110, 2016, doi: 10.3895/rbgeo.v4n2.5492.
- [17] D. F. T. Garofalo, C. G. Messias, V. Liesenberg, É. L. Bolfe, and M. C. Ferreira, "Análise comparativa de classificadores digitais em imagens do Landsat-8 aplicados ao mapeamento temático," *Pesqui. Agropecuária Bras.*, vol. 50, no. 7, pp. 593–604, 2015, doi: 10.1590/S0100-204X2015000700009.