

MAPEAMENTO DO DESMATAMENTO E DEGRADAÇÃO FLORESTAL POR QUEIMADA NO ESTADO DO MATO GROSSO UTILIZANDO IMAGENS CBERS-4

Andeise Cerqueira Dutra¹, Yosio Edemir Shimabukuro¹, Marcell de Oliveira Terra¹, Egídio Arai¹, Valdete Duarte¹, Juliana Tramontina²

¹Instituto Nacional de Pesquisas Espaciais – INPE, Caixa Postal 515 - 12227-010, São José dos Campos - SP, Brasil
{andeise.dutra; yosio.shimabukuro; marcelli.terra; egidio.arai; valdete.duarte}@inpe.br

²Universidade Federal do Rio Grande do Sul – UFRGS, Caixa Postal 90040-060, Porto Alegre – RS, Brasil
ju_tramontina@hotmail.com

1. INTRODUÇÃO

RESUMO

As taxas de mudança da cobertura florestal ocasionadas por processos de desmatamento e degradação tem sido amplamente evidenciadas. Neste sentido, a missão CBERS (*China Brazil Earth Resources Satellite*) tem colaborado para maximizar os esforços de monitoramento da superfície terrestre. Este trabalho tem como objetivo utilizar um método de classificação automática por abordagem multi-temporal de imagens do sensor WFI a bordo do satélite CBERS-4, para mapear a extensão de áreas afetadas pelo fogo e desmatamento no estado do Mato Grosso. Do total de área desmatada mapeada no período chuvoso, 41% estavam destinadas à agropecuária. A classificação referente ao período de estiagem indicou que, do total de cicatrizes de queimada, aproximadamente 80% foram detectadas em áreas desmatadas e 20% em floresta. A acurácia global foi 0,90, apresentando os maiores erros associados à classe queimada e hidrografia, devido à maior semelhança na reflectância espectral destes alvos e a resolução espacial do sensor utilizado.

Palavras-chave — Modelo linear de mistura espectral, sensor PAN, amostras *in situ*, queimadas agrícolas, algodão.

ABSTRACT

Rates of forest cover change caused by deforestation and degradation processes have been amply demonstrated. In this sense, the CBERS (China Brazil Earth Resources Satellite) mission has collaborated to maximize the efforts to monitor Earth's surface. This work aims to use a multi-temporal approach of automatic classification of WFI sensor images on board the CBERS-4 satellite, to map the extent of affected areas by fire- and deforestation in the state of Mato Grosso, Brazil. We demonstrate that 41% of the total deforested areas were destined to agriculture in the rainy season. The classification referring to the dry season indicated that 80% of burned areas were detected in non-forested areas and 20% in forest areas. The overall accuracy was 0.90, presenting largest errors associated to burned and hydrography classes, due to the greater similarity in the spectral reflectance of these targets and the spatial resolution of the sensor used.

Key words — Linear spectral mixing model, PAN sensor, *in situ* samples, agricultural burn, cotton.

As taxas de desmatamento e seus efeitos negativos em florestas tropicais têm sido amplamente evidenciados nas últimas décadas. Os principais mecanismos deste processo estão relacionados, predominantemente, à expansão de plantações agrícolas e pastagens [1,2].

Aliados a estes mecanismos, distúrbios como corte seletivo e fogo tem avançado em frequência e extensão nas áreas florestadas [3,4]. Este fato é preocupante pois, tais distúrbios, induzem às mudanças na estrutura florestal, composição de espécies, estoques de biomassa e nos processos ecossistêmicos, além de favorecerem à conversão ao desmatamento [5].

Neste sentido, o estado do Mato Grosso tem sido alvo de diversos estudos relacionados à sua alta taxa de mudança da cobertura florestal ocasionados por processos de desmatamento e degradação [6,7]. Como exemplo, o estado apresentou um incremento acumulado do desmatamento de aproximadamente 108.350,00 km² nos biomas Amazônia e Cerrado no período de 2001 a 2017 [8,9]. Além disso, é um dos estados que apresentam a maior quantidade de focos de queimadas detectadas [1].

A necessidade do monitoramento da cobertura da terra para analisar a dinâmica do ecossistema e quais sucessões de mudanças estão ocorrendo, impulsionou o avanço de produtos do sensoriamento remoto. Neste sentido, a missão CBERS (*China Brazil Earth Resources Satellite*), desenvolvida em acordo de cooperação entre Brasil e China, tem colaborado para maximizar a capacidade de observação da Terra [10].

Diante deste contexto, este trabalho tem como objetivo utilizar um método de classificação automática por abordagem multi-temporal de imagens do sensor WFI a bordo do satélite CBERS-4, para mapear a extensão de áreas afetadas pelo fogo e desmatamento no estado do Mato Grosso nos meses de maio e setembro de 2018.

2. MATERIAIS E MÉTODOS

A área de estudo está localizada no estado do Mato Grosso, abrangendo o município de Sinop e área de aproximadamente 101.078,52 km². A área contempla os dois biomas brasileiros mais extensos do país, totalizando em todo estado aproximadamente 54% da sua área referente ao bioma Amazônia, seguido do bioma Cerrado com 39% [11] (Figura

1). O regime de chuvas é marcado principalmente por duas estações bem definidas entre, novembro e maio como a estação chuvosa e junho a outubro como a estação seca [12].

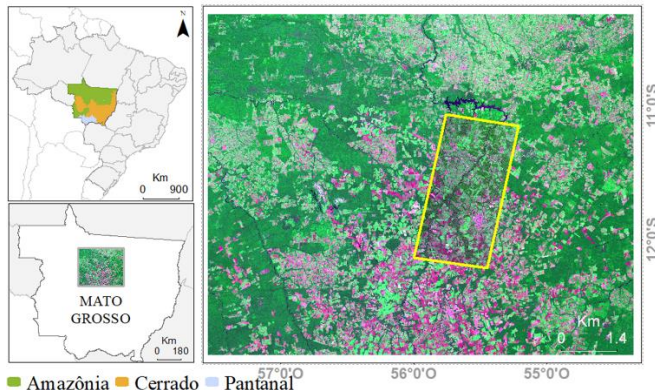


Figura 1. Localização da área de estudo compreendendo os biomas Amazônia e Cerrado à esquerda, área de estudo total utilizando o sensor WFI e, em amarelo, a área de validação com sensor PAN, à direita.

Foram obtidas imagens orbitais dos sensores PAN (*Panchromatic and Multispectral*) e WFI (*Wide-Field Imager*), a bordo do satélite CBERS-4, referentes às orbitas/pontos 167/113 e 167/111, respectivamente. O sensor WFI fornece imagens com resolução espacial de 64 m a nadir e resolução temporal de cinco dias, enquanto o sensor PAN tem resolução espacial de 10 m para as bandas espectrais do verde, vermelho e infravermelho próximo, e tempo de revisita de cinco dias [13]. Todos os dados foram adquiridos para o período referente a 30 de maio e 11 de setembro de 2018, em número digital, quantizados em 10 bits e georreferenciados. As cenas foram obtidas do catálogo de imagens do Instituto Nacional de Pesquisas Espaciais (INPE), disponibilizados na plataforma <<http://www.dgi.inpe.br/catalogo/>>.

Como etapa (1), a metodologia empregada foi baseada na utilização das imagens fração derivadas do modelo linear de mistura espectral (MLME). A aplicação do MLME é possível com o conhecimento *a priori* da resposta espectral dos alvos de referência e uma das abordagens mais comumente empregadas para a aplicação do modelo é a aquisição de pixels puros ou *endmembers* a partir das respostas espectrais dos alvos disponíveis na própria imagem em estudo. Para este trabalho, os *endmembers* foram selecionados com base na resposta espectral mais próxima da curva teórica esperada para os alvos de vegetação, solo e sombra e, então, aplicado o MLME pelo método dos mínimos quadrados [14], representado como:

$$r_i = \sum (a_{ij}x_{j1}) + \varepsilon_i \quad (1)$$

Sendo:

- r_i = refletância média espectral em todas as bandas espectrais;
- a_{ij} = resposta espectral de cada componente da mistura em um pixel;
- x_j = valor da proporção de cada componente em um pixel;
- ε_i = erro;

Na etapa (2), o processo de segmentação de imagens foi aplicado para um conjunto de dados multi-temporal composto pelas imagens fração. O algoritmo de segmentação subdivide a imagem em regiões com semelhança espectral, de forma a delinear espacialmente os limites de alvos distintos. Para a detecção de cicatrizes de queimada, por exemplo, a baixa refletância espectral das cicatrizes realça o brilho nas imagens fração sombra, separando-a dos demais alvos pela alta diferença de brilho.

Após a segmentação, a etapa seguinte (3) foi de aplicação do classificador não supervisionado ISOSEG para classificação dos segmentos obtidos da etapa anterior (2). Finalmente, as áreas de degradação florestal por queimada são obtidas combinando os mapas resultantes das áreas de floresta e não floresta com o mapeamento das áreas queimadas adquiridas durante a estação seca (setembro) [7]. A legenda adotada neste trabalho para o mês de maio corresponde às áreas de floresta, agropecuária e áreas desmatadas, enquanto para o mês de setembro foram acrescentadas as cicatrizes de queimada. A mesma metodologia foi empregada para as imagens do sensor PAN, acrescentando o processo de edição manual realizada para minimizar os possíveis erros de omissão e inclusão que podem ocorrer na etapa de classificação automática.

A etapa (4) caracterizou-se pela validação dos resultados. Neste processo, as imagens orbitais de ambas as datas obtidas para o sensor PAN, abrangendo uma área menor que a área total do estudo (Figura 1), foram utilizadas juntamente com um conjunto de amostras coletadas *in situ*, durante campanha realizada entre 17 e 28 de setembro de 2018. Embora o conjunto de amostras tenha datação posterior as imagens orbitais, a identificação das áreas agrícolas foi possível com os resíduos encontrados das safras.

A abordagem para a obtenção das acurácias foi baseada no delineamento amostral estratificado, que considera a proporção de cada classe com base na frequência de *pixels* [15]. Assim, uma matriz de confusão é gerada com base nas proporções estimadas, apresentando as acurácias global, do produtor e usuário, ao intervalo de 95% de confiança.

Todos os pontos de amostragem e análise foram obtidos em ambiente de programação R e algoritmos disponibilizados em: <<https://github.com/openforis/accuracy-assessment>>.

3. RESULTADOS E DISCUSSÃO

Os resultados do mapeamento para os meses de maio (Figura 2) e setembro (Figura 3) apresentam distinção em termos de cobertura da terra. Comparativamente, a identificação de áreas destinadas à agropecuária foi possível para o mês referente a maio, enquanto em setembro apenas as áreas desmatadas foram identificadas.




Figura 2. Resultado da classificação automática referente ao mês de maio (a), sendo: floresta (verde), desmatamento (amarelo), e agropecuária (laranja). Amostras de campo caracterizando: colheita de algodão (b); gramínea (c); e floresta (d).

O Mato Grosso é considerado como um dos principais estados produtores de algodão, soja e milho no Brasil. O calendário agrícola do estado apresenta o término da colheita de algodão em meados de setembro, mesmo período em que há o preparo do solo para o cultivo de milho e soja [16], justificando a identificação das áreas agrícolas apenas no mês de maio.

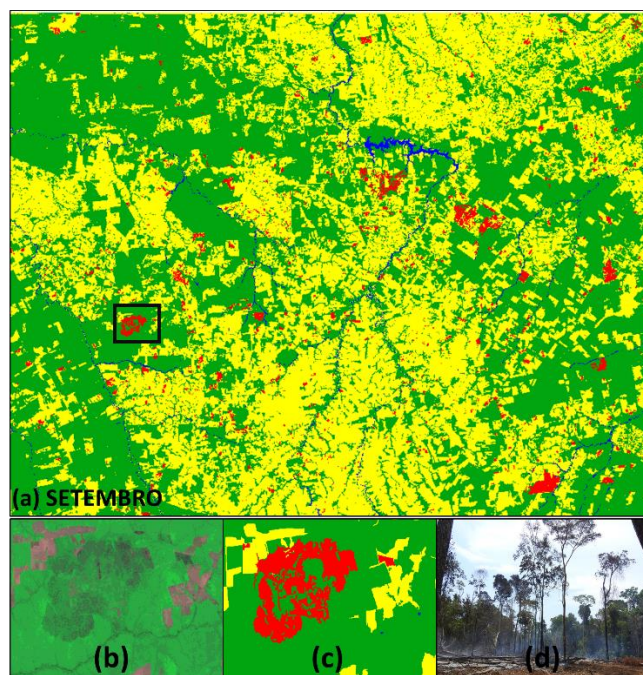


Figura 3. Resultado da classificação automática referente ao mês de setembro, sendo: floresta (verde), desmatamento (amarelo), e cicatrizes de

queimada (vermelho) (a). Detalhe da cicatriz de queimada na imagem orbital do sensor WFI (b); classificação (c); e validação em campo (d).

Este resultado evidencia o uso de séries temporais para a identificação dos diferentes usos e coberturas da terra, a partir do conhecimento a priori dos padrões fenológicos, durante as fases de desenvolvimento de determinadas culturas e sua diferenciação espectro-temporal [17]. Referente às taxas de desmatamento e distúrbios florestais, o uso de um conjunto de dados multi-temporal é fundamental para melhor compreender os padrões, causas e consequências relacionadas a estes processos [7]. Quantitativamente, este fato é evidenciado no total de 46.989,34 km² de área desmatada mapeada em setembro, da qual 41% estavam destinadas à agropecuária no mês de maio (Tabela 1).

As estimativas de áreas queimadas evidenciaram que do total de 1.979,17 km² mapeados, aproximadamente 80% (1,584.00 km²) das cicatrizes de queimada foram detectadas em áreas desmatadas e 20% (395,00 km²) em áreas florestadas.

Tabela 1 - Estimativas de área das classes mapeadas nos diferentes períodos.

Período de Análise	Classes (Km ²)				
		Floresta	Desmatamento	Agropecuária	Queimada
	Maio			19.253,00	
Setembro			46.989,34		1.979,17
Total		51.743,98			

As áreas queimadas em florestas apresentam rebrota nos anos posteriores. Por outro lado, nas áreas desmatadas ocorre primeiramente a retirada da cobertura florestal e, em seguida, a vegetação remanescente é queimada para permitir o uso da terra para fins agrícolas e renovação da pastagem [7]. Embora a adoção de uma agricultura mais intensiva tenha favorecido o declínio global de áreas queimadas nos últimos anos [18], aliado a um cenário de redução da precipitação [19], a tendência é de que as queimadas agrícolas, cada vez mais, permeiem as áreas florestadas, evoluindo para incêndios descontrolados [18].

Além disso, os instrumentos políticos mais efetivos na redução de incêndios florestais não são os mais efetivos em reduzir o desmatamento e vice-versa, sugerindo que ambos os objetivos não possam ser alcançados com uma única medida de intervenção política [20].

Na matriz de confusão, os valores diagonais apresentam o número de pixels classificados corretamente em termos de proporção de área [15], resultando na acurácia global de 0,90 nas classificações referentes aos meses de maio (Tabela 2) e setembro (Tabela 3). Os valores fora da diagonal representam os erros de omissão (produtor) e inclusão (usuário) de cada classe, que apresentaram os resultados mais inferiores na classe Agropecuária, Hidrografia e Área Queimada.

Observa-se que a classe Agropecuária apresentou os maiores erros associados à classe Floresta, enquanto a classe Hidrografia obteve o maior erro associado à sua inclusão na classe Área Queimada e conseqüentemente, maior erro de omissão desta última classe. Este resultado pode estar relacionado à maior semelhança na reflectância espectral destes alvos e à média resolução espacial do sensor utilizado.

Tabela 2 – Acurácias globais, do produtor e usuário ponderadas pela área, por classe de uso e cobertura da terra.

		Mapa de Referência 10 m – Mês de Maio			
Classe		Agropecuária	Desmatamento	Floresta	Total
Classificação WFI 64 m	Agropecuária	0.161	0.009	0.017	
	Desmatamento	0.017	0.341	0.019	
	Floresta	0.020	0.013	0.403	
	Wi	0.187	0.377	0.436	1
	Área [km ²]	1,460.01	2,688.71	3,239.04	7,387.76
	95% IC* [km ²]	±158.38	±155.36	±169.08	
	Usuário	0.86	0.90	0.92	
Produtor	0.81	0.94	0.92		
Acurácia Global		0.90			

Tabela 3 – Acurácias globais, do produtor e usuário ponderadas pela área, por classe de uso e cobertura da terra.

		Mapa de Referência 10 m - Mês de Setembro				
Classe		Floresta	Desmatamento	Hidrografia	Queimada	Total
Classificação WFI 64 m	Floresta	0.301	0.008	0.010	0.010	
	Desmatamento	0.012	0.283	0.010	0.005	
	Hidrografia	0.017	0.003	0.246	0.014	
	Queimada	0.002	0.002	0.002	0.074	
	Wi	0.33	0.31	0.28	0.08	1
	Área [km ²]	3,519.75	3,145.70	2,856.50	1,100.38	10,622.33
	95% IC* [km ²]	±236.45	±192.26	±236.66	±179.35	
Usuário	0.91	0.91	0.88	0.93		
Produtor	0.91	0.96	0.92	0.72		
Acurácia Global		0.90				

* Sendo: IC representa o intervalo de confiança das classes e Wi a proporção de cada classe.

4. CONCLUSÕES

O uso de um conjunto de dados multi-temporal é fundamental para melhor compreender os padrões, causas e consequências relacionadas aos processos de desmatamento e degradação florestal.

As classificações derivadas do sensor WFI apresentaram bons resultados. Entretanto, para a detecção da degradação florestal por queimada, sugere-se também a utilização de uma máscara de hidrografia ou sensores de melhor resolução espacial, como o sensor PAN, também a bordo do satélite CBERS.

5. AGRADECIMENTOS

O presente trabalho foi realizado como parte do projeto financiado pela (FAPESP, Processo 2016/19806-3). Os autores agradecem o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ), pela concessão de bolsa.

6. REFERÊNCIAS

- [1] Instituto Nacional de Pesquisas Espaciais - INPE, "Monitoramento da cobertura florestal da Amazônia por satélites: sistemas PRODES, DETER, DEGRAD e Queimadas 2007-2008," *Ministério da Ciência e Tecnol.*, p.47, 2008.
- [2] Tyukavina, A., Hansen, M.C., Potapov, P.V., Stehman, S.V., Smith-Rodriguez, K., Okpa, C. E. Aguilar, R. "Types and rates of forest disturbance in Brazilian Legal Amazon, 2000–2013". *Science*, v.3, n.4, 2017.

[3] Asner, G. P.; Knapp, D. E.; Broadbent, E. N.; Oliveira, P. J. C.; KELLER, M.; and Silva, J. N., "Selective logging in the Brazilian Amazon," *Science*, v. 310, n. 5747, pp. 480–482, 2005.

[4] Aragão, L. E. O. C.; Malhi, Y.; Barbier, N.; Lima, A., Shimabukuro, Y., Anderson, L. e Saatchi, S., "Interactions between rainfall, deforestation and fires during recent years in the Brazilian Amazonia", *Philosophical Transactions of the Royal Society of London*, v. 363, pp 1779–85, 2008.

[5] Watson, J.E., Evans, T., Venter, O., Williams, B., Tulloch, A., Stewart, C., Thompson, I., Ray, J.C., Murray, K., Salazar, A. e Mcalpine, C., "The exceptional value of intact forest ecosystems", *Nature ecology & evolution*, v.2, pp. 599-610, 2018.

[6] Miettinen, J. *et al.*, "On the extent of fire-induced forest degradation in Mato Grosso, Brazilian Amazon, in 2000, 2005 and 2010," *Int. J. Wildl. Fire*, v. 25, n. 2, pp. 129–136, 2016.

[7] Shimabukuro, Y. E.; Arai, E.; Anderson, L. O.; Aragão, L. E. O. C. ; e Duarte, V., "Mapping Degraded Forest Areas Caused By Fires During the Year 2010 in Mato Grosso State, Brazilian Legal Amazon Using Landsat-5 Tm Fraction Images," *Rev. Bras. Cartogr.*, vol. 69, no. 1, pp. 23–32, 2017.

[8] Instituto Nacional de Pesquisas Espaciais - INPE, Taxas de desmatamento: PRODES. Disponível em: < <http://www.obtinpe.br/prodes/dashboard/prodes-rates.html> >

[9] TeraBrasilis/INPE. Incrementos de desmatamento anuais no Cerrado Brasileiro. Disponível em < <http://terabrasilis.dpi.inpe.br/dashboard/deforestation/biomes/cerrado/increments/> >, 2018.

[10] Fonseca, L. M. G.; Epiphany, J. C. N.; Valeriano, D. M.; Soares, J. V.; Dalge, J. C. L.; e Alvarenga, M. A., "Earth Observation Applications in Brazil with Focus on the CBERS Program," *IEEE Geosci. Remote Sens. Mag.*, v. 2, n. 2, pp. 53–55, 2014.

[11] Instituto Brasileiro de Geografia e Estatística/Ministério do Meio Ambiente - IBGE/MMA. Mapa de Biomas do Brasil - Primeira Aproximação. Disponível em < <https://brasilemsintese.ibge.gov.br/territorio.html> >, 2004.

[12] CPTEC – Centro de Previsão de Tempo e Estudos Climáticos. "Monitoramento Climático Mensal e Sazonal das Chuvas no Brasil na Página CPTEC/INPE", 2014. Disponível em: <http://clima1.cptec.inpe.br/evolucao/pt>.

[13] Instituto Nacional de Pesquisas Espaciais - INPE. CBERS: Câmeras Imageadoras CBERS-3 e 4. Disponível em < <http://www.cbets.inpe.br/sobre/meras/cbers3-4.php> >, 2018.

[14] Shimabukuro, Y. E. e Smith, J. A., "The Least-Squares Mixing Models to Generate Fraction Images Derived From Remote Sensing Multispectral Data," *IEEE Trans. Geosci. Remote Sens.*, v. 29, no 1, pp. 16–20, 1991.

[15] Olofsson, P.; Foody, G. M.; Herold, M.; Stehman, S. V.; Woodcock, C. E.; and Wulder, M. A., "Good practices for estimating area and assessing accuracy of land change," *Remote Sens. Environ.*, v. 148, pp. 42–57, 2014.

[16] Empresa Mato-Grossense de pesquisa, assistência e extensão rural – EMPAER. "Calendário Agrícola", 2018. Disponível em: <http://www.empaer.mt.gov.br/-/806684-3-calendario-agricola?ciclo=>.

[17] Silva Junior, C.A.; Frank, T. e Rodrigues, T. "Discriminação de áreas de soja por meio de imagens EVI/MODIS e análise baseada em geo-objeto". *Revista Brasileira de Engenharia Agrícola e Ambiental-Agrambi*, v.18, pp.44-53, 2014.

[18] Andela, N.; Morton, D. C.; Giglio, L.; Chen, Y.; Van Der Werf, G. R.; Kasibhatla, P. S.; Defries, R. S.; Collatz, G. J.; Hantson, S.; Kloster, S.; Bachelet, D.; Forrest, M.; Lasslop, G.; Li, F.; Manganon, S.; Melton, J. R.; Yue, C. e Randerson, J. T. "A human-driven decline in global burned area", *Science*, v. 356, n. 6345, p. 1356–1362, 2017.

[19] Marengo, J. A.; Jones, R.; Alves, L. M. e Valverde, M. C. "Future change of temperature and rainfall extremes in South America as derived from the PRECIS regional climate modeling system", *Int. J. Climatol.*, v. 29, n.15, pp. 2241–2255, 2009.

[20] Morello, T. F.; Parry, L.; Markusson, N. e Barlow, J., "Policy instruments to control Amazon fires: A simulation approach," *Ecol. Econ.*, v. 138, pp. 199–222, 2017.