

Aplicação do modelo linear de mistura espectral por abordagem combinada entre resoluções espaciais de imagens do sensor PROBA-V

Andeise Cerqueira Dutra ¹
Yosio Edemir Shimabukuro ¹
Egídio Arai ¹

¹Instituto Nacional de Pesquisas Espaciais - INPE
Av. dos Astronautas, 1758 - Caixa Postal 515
12201-970 - São José dos Campos - SP, Brasil
andeise.dutra@inpe.br, {yosio, egidio}@dsr.inpe.br

Resumo. A complexidade da composição de um pixel tem sido comumente referida pelo termo mistura espectral. A aquisição de pixels puros ou endmembers a partir da própria imagem em estudo é uma das abordagens mais comumente empregadas, entretanto, torna-se limitada em sensores de baixa ou moderada resolução espacial pela dificuldade ou mesmo a impossibilidade de obtenção de pixels puros, permanecendo um desafio. Este estudo propõe o uso combinado entre produtos de moderada e baixa resolução espacial para estimar as respostas espectrais na aplicação do modelo linear de mistura espectral, visando uma metodologia que possa auxiliar em estender as informações das imagens frações para áreas mais extensas. A metodologia proposta foi aplicada nos produtos fornecidos pelo satélite PROBA-V com resolução espacial de 100 m e 1 km na região do Pantanal Mato Grossense. Inicialmente, as imagens frações (proporções) foram geradas para os dados de 100 m utilizando os endmembers da própria imagem e a seguir, as refletâncias espectrais dos componentes de referência nos dados de 1 km foram estimadas por regressão linear múltipla. Para a avaliação desta metodologia foram utilizadas as imagens frações dos componentes de referência juntamente com o erro calculado. Estas análises indicaram que as respostas espectrais estimadas por regressão permitiram a melhoria dos resultados no que se refere ao erro, a variabilidade e na identificação das proporções dos componentes, visto que a escolha indevida de pixels considerados como puros em produtos de baixa resolução espacial pode superestimar ou subestimar os resultados obtidos.

Palavras-chave: Endmembers, moderada resolução espacial, regressão linear, escala regional, Pantanal.

Abstract. The complex composition of a pixel has been commonly referred by the term spectral mixing. The acquisition of pure pixels or endmembers from the study image is one of the most commonly used approaches, however, it becomes limited in low or moderate spatial resolution sensors by the difficulty or even the impossibility of obtaining pure pixels, remaining a challenge. This study proposes the use of combined products on moderate and low spatial resolution in the estimation of spectral reflectance using the linear spectral mixing model, aiming a methodology that can help in extending the information of the fraction images to more extensive areas. The proposed methodology was applied to the products supplied from the PROBA-V satellite with spatial resolution of 100 m and 1 km in the Pantanal of Mato Grosso state region. Initially, the fraction images (proportions) were generated for the 100 m data using the image endmembers and following the spectral reflectance of the reference components in the 1 km data were estimated by multiple linear regression. For the evaluation of this methodology it was used the fraction images of the reference components and the calculated error. These analyses indicated that the estimated spectral responses by regression allowed to improve the results regarding error, variability and the identification of component proportions, since the undue choice of pixels considered as pure in products of low spatial resolution may overestimate or underestimate the results obtained.

Keywords: Endmembers, moderate spatial resolution, linear regression, regional scale, Pantanal.

1. Introdução

Uma ampla gama de aplicações em estudos de observação da Terra exige uma estimativa precisa utilizando sensores de alta ou média resolução espacial. No entanto, o uso desses produtos torna-se limitado pela frequência reduzida, ou até mesmo pela incidência de nuvens (Li et al., 2017; Zhu; Woodcock, 2014; Asner, 2001). Por outro lado, sensores de baixa e moderada resolução espacial fornecem produtos de observação diária do globo terrestre, mas ressalta-se ainda a dificuldade destes estudos quando o objeto de interesse é menor que o tamanho do pixel (Baret et al., 2013).

Essa problemática ocorre porque a radiância registrada pelo sensor é uma soma integrada das radiâncias de todos os objetos ou materiais contidos dentro do campo de visada instantâneo (*instantaneous field of view* – IFOV), como por exemplo sombra, solo e a copa das árvores. Desse modo, cada pixel fornece o resultado das interações da radiação eletromagnética com múltiplos constituintes, não representando a composição físico-química de um único objeto exclusivamente (Shimabukuro; Smith, 1995). A complexidade da composição de um pixel tem sido comumente referida pelo termo mistura espectral.

Diversos modelos matemáticos já foram propostos para a identificação da proporção de mistura no pixel, sendo o Modelo Linear de Mistura Espectral (MLME) proposto por Shimabukuro e Smith (1991) uma das técnicas mais comumente utilizadas, seja no estudo das mudanças sazonais da cobertura da terra e distúrbios da vegetação (Adami et al., 2018), como também no bioma Pantanal a técnica tem sido utilizada na avaliação de pastagens em degradação (Ravaglia et al., 2010), no estudo das inundações a partir de imagens MODIS (Padovani et al., 2009), na caracterização dos tipos de cobertura com dados hiperespectrais (Galvão et al., 2003) e no monitoramento da dinâmica da cobertura da terra (Shimabukuro et al., 1998).

A aplicação do MLME é possível com o conhecimento *a priori* da resposta espectral dos componentes 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 componentes disponíveis na própria imagem em estudo (Shimabukuro; Ponzoni, 2017). Entretanto, em sensores de baixa ou moderada resolução espacial, a natureza mista dos pixels torna-se uma limitação por esta abordagem devido à dificuldade ou mesmo a impossibilidade de obtenção de pixels puros, ou seja, pixels que incluem um único componente de referência (De Freitas et al., 2008). Principalmente em estudos de escala nacional ou regional, a determinação desses *endmembers* permanece um desafio (Meyer; Okin, 2015).

Nos últimos anos, produtos de novos sistemas sensores com diferentes resoluções espacial, espectral e radiométrica têm sido desenvolvidos e disponibilizados. Alternativamente, a combinação destes dados em estudos anteriores demonstra a capacidade de fundir observações de diferentes resoluções, como uma maneira promissora de aumentar a potencialidade nos estudos de observação da Terra (Li et al., 2017; De Freitas et al., 2008).

2. Objetivo

Estimar a resposta espectral de *endmembers* utilizando dados de moderada resolução espacial para aplicação do modelo linear de mistura espectral em imagens de baixa resolução espacial.

3. Material e Métodos

Uma relação linear é utilizada para representar a mistura espectral dos materiais contidos dentro do pixel, ou seja, o MLME assume que a resposta espectral de um pixel pode ser obtida como uma combinação linear das respostas de cada componente assumido como referência. Dessa forma, cada pixel contém informações sobre a proporção e a resposta espectral de cada componente (Shimabukuro; Smith, 1995). Utilizando o método dos mínimos quadrados com restrição, os valores de proporção devem ser não negativos e somatório igual a um.

Admitindo esta abordagem, entende-se então que conhecendo as proporções dos componentes de referência, as respostas espectrais dessas referências podem ser obtidas. Similarmente, se as respostas espectrais de cada componente são conhecidas, então as proporções de cada componente na mistura podem ser estimadas (Shimabukuro; Smith, 1995). Assim, o modelo linear de mistura espectral pelo método dos mínimos quadrados (Shimabukuro; Smith, 1991) pode ser representado como:

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

Onde:

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;

Admitindo que as proporções dos componentes extraídos da imagem orbital de maior resolução espacial são conhecidas, neste trabalho adotou-se o modelo matemático proposto por Richardson et al. (1975) para estimar a resposta espectral dos *endmembers* que serão posteriormente utilizados na imagem orbital de baixa resolução espacial, aplicando a regressão linear múltipla com a seguinte equação geral:

$$r_i = \beta_0 + \beta_1X_1 + \beta_2X_2 \quad (2)$$

Representada neste trabalho como:

β_0, β_1 e β_2 = respostas espectrais estimadas para cada componente de referência do MLME;

X_1 e X_2 = proporções dos componentes de referência conhecidos;

Uma vez que os valores das proporções são conhecidos, eles se tornam as variáveis de entrada na equação (2) juntamente com a refletância espectral de cada banda espectral da imagem de baixa resolução espacial. Assim, a combinação entre os produtos com diferentes resoluções espaciais permite a determinação dos fatores de refletância da sombra (β_0), solo ($\beta_0 + \beta_1$) e vegetação ($\beta_0 + \beta_2$). Assumindo que somatório do MLME deve ser igual a um,

neste caso não se torna necessário a adição da proporção da fração sombra como parâmetro de entrada do modelo.

Para a aplicação desta metodologia foram utilizados os produtos fornecidos pelo satélite PROBA-V com resolução espacial de 100 m e 1 km disponibilizados, respectivamente, em resolução temporal de 5 e 10 dias no topo do dossel (*top of canopy - TOC*). Os produtos são disponibilizados em quatro bandas espectrais: Azul (centralizado em 0,463 μm), vermelho (0,655 μm), infravermelho próximo (0,837 μm), e infravermelho médio (1,603 μm) (Wolters et al., 2018).

Como área de estudo adotou-se o bioma Pantanal que abrange uma área de aproximadamente 138.183 km² entre os estados do Mato Grosso e Mato Grosso do Sul (Silva; Abdon, 1998). A vegetação é influenciada pela predominância do Cerrado e remanescentes de Chaco, como também pela floresta Amazônica e Mata Atlântica (Adámoli, 1981), além da pecuária como principal atividade antrópica. Juntamente com a associação aos diferentes tipos de solo e a dinâmica de inundações, o Pantanal apresenta-se como um ambiente complexo e heterogêneo (Harris et al., 2005), motivo pelo qual foi adotado neste estudo.

A dinâmica de inundações é fortemente influenciada pelos padrões de precipitação, alternada principalmente por duas estações bem definidas entre outubro a abril como a estação chuvosa e entre maio a setembro como a estação seca (Silio-calzada et al., 2017). Neste estudo, o bioma Pantanal foi limitado para o estado do Mato Grosso, utilizando os dados do PROBA-V referente ao ano de 2015. E visando a aplicabilidade do modelo estimado em diferentes épocas, foram determinados os meses que apresentaram a máxima e mínima precipitação mensal observada (mm) para o mesmo ano de estudo (**Figura 1**).




Figura 1 - Localização do Pantanal Mato Grossense como área de estudo, apontando diferentes formações vegetacionais, agricultura e corpos hídricos (Fonte: *Google Earth*). Precipitação mensal observada no ano referente a 2015 à direita (adaptado de CPTEC, 2014).

Para a etapa inicial da metodologia proposta primeiramente foi necessário o ajustamento da composição temporal dos dados do PROBA-V, visto que os dados utilizados não são compatíveis. Para isto, nos dados de 100 m (5 dias) foram selecionadas as observações de cada pixel que apresentaram o máximo NDVI comparando as duas observações entre dez dias. Assim, os dados de 100 m passaram a ter uma composição temporal de dez dias, similar aos dados de 1 km.

Neste estudo foram considerados três componentes dentro do pixel: vegetação, solo e sombra. Empregando a abordagem de pixels puros selecionados em função da curva teórica dos componentes (**Figura 2**), após a aplicação do MLME nas imagens de 100 m do PROBA-V, foram adquiridas as proporções de cada componente de referência em 25 amostras na área de estudo.




Figura 2 - Curva teórica da resposta espectral dos componentes de referência na imagem.

Para as mesmas amostras foram adquiridas as refletâncias espectrais das imagens de 1 km do PROBA-V, considerando que um pixel de 1 km corresponde a oitenta e um pixels em resolução de 100 m, pois os produtos foram disponibilizados em 0.008929° e 0.000992° , respectivamente (**Figura 3**).




Figura 3 - Representação da composição de um pixel em diferentes resoluções do PROBA-V em falsa composição colorida em R ($1,603 \mu\text{m}$) G ($0,837 \mu\text{m}$) B ($0,655 \mu\text{m}$).

Em seguida foram estimadas as respostas espectrais dos componentes de referência utilizando a equação (2) e finalmente com estas estimativas, o MLME foi aplicado às imagens de 1 km. Para fins comparativos, o MLME também foi aplicado às imagens de 1 km utilizando os componentes de referência da própria imagem. O mesmo procedimento foi aplicado no período de estiagem utilizando as mesmas amostras, exceto àquelas que apresentaram incidência de nuvens.

4. Resultados e Discussão

Os valores estimados das respostas espectrais para determinação dos *endmembers* no produto de 1 km do PROBA-V para os períodos chuvoso e de estiagem estão relacionados na **Tabela 1**

e 2. Assim como a equação obtida com a regressão linear múltipla (2) para cada banda espectral adotada.

Tabela 1 – Fator de refletância dos componentes estimados no período de máxima precipitação.

Fevereiro de 2015				
<i>Endmembers</i>	Azul	Vermelho	IVP ¹	IVM ²
Sombra	0,02	0,02	0,06	0,03
Solo	0,09	0,18	0,22	0,41
Vegetação	0,01	0,03	0,54	0,24
<i>R múltiplo</i> (N =25)	0,74	0,84	0,72	0,79
<i>Equação R =</i>	$0,0204 + 0,0712 - 0,0316$	$0,0194 + 0,1639 + 0,0096$	$0,0558 + 0,1625 + 0,4818$	$0,0317 + 0,3796 + 0,2058$

Tabela 2 – Fator de refletância dos componentes estimados no período de mínima precipitação.

Agosto de 2015				
<i>Endmembers</i>	Azul	Vermelho	IVP ¹	IVM ²
Sombra	0,02	0,02	0,04	0,01
Solo	0,06	0,14	0,37	0,40
Vegetação	0,02	0,04	0,49	0,25
<i>R múltiplo</i> (N =25)	0,77	0,82	0,79	0,87
<i>Equação R =</i>	$0,0159 + 0,0413 + 0,0033$	$0,0193 + 0,1250 + 0,0175$	$0,0446 + 0,3229 + 0,4409$	$0,0122 + 0,3890 + 0,2374$

IVP¹ - *Infravermelho Próximo*; IVM² - *Infravermelho Médio*.

Comparando a resposta espectro-temporal dos alvos analisados neste estudo, como esperado, observa-se que o pico da componente vegetação no infravermelho próximo atingiu os valores mais elevados no mês de fevereiro, coincidindo com o período de máximo vigor vegetativo em função da precipitação. Inversamente os valores inferiores são observados no mês de agosto, caracterizado pelo período de estiagem.

Um dos métodos para avaliação do desempenho do MLME utilizando os *endmembers* estimados com a combinação dos produtos de baixa e moderada resolução espacial foi realizado pela comparação da média obtida entre as amostras das frações erro geradas por esta abordagem e entre a abordagem convencional (*endmembers* obtidos na própria imagem) (**Tabela 3**).

Tabela 3 – Média das amostras geradas da fração erro do MLME onde estimado e imagem correspondem a resolução espacial de 1km.

	Fevereiro de 2015			Agosto de 2015		
	Estimado	Imagem	100 m	Estimado	Imagem	100 m
Erro Médio	0,48	0,60	0,51	0,49	0,59	0,72

As frações erro normalmente apresentam valores baixos de acordo com a acurácia dos modelos empregados. Neste sentido, o erro médio obtido pela abordagem proposta neste trabalho foi inferior àquela obtida pela abordagem convencional em ambas as resoluções. Entretanto, ressalta-se que o erro médio mais elevado no período de estiagem para o produto de resolução moderada pode estar associado ao fato de que outros componentes podem estar contidos no pixel devido a melhor resolução e assim o número de componentes definidos neste trabalho não ser o suficiente para o modelo utilizado.

O desempenho da metodologia proposta também foi avaliado comparando quantitativamente as imagens fração da vegetação, solo e sombra obtidos pelo MLME nas três aplicações (**Tabela 4**). Observa-se que as imagens fração derivadas do MLME utilizando os

endmembers estimados por regressão apresentou maior semelhança com as imagens fração derivadas da imagem de melhor resolução espacial. Em geral, observa-se que as imagens fração geradas diretamente na imagem de 1 km foram subestimadas ou superestimadas em ambos os períodos e também apresentaram maior desvio padrão.

Tabela 4 – Média e desvio padrão das proporções dos componentes estimados por regressão e na própria imagem de 1km e 100m.

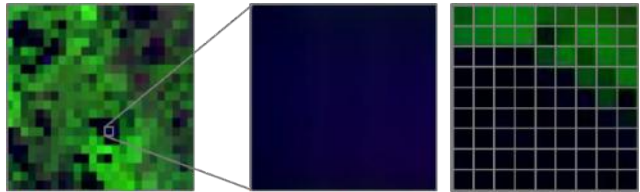
	Fevereiro de 2015		Agosto de 2015		
	Imagem	Desvio Padrão	Imagem	Desvio Padrão	
Sombra	0,46	0,46	Sombra	0,23	0,11
Solo	0,29	0,31	Solo	0,40	0,38
Vegetação	0,51	0,27	Vegetação	0,36	0,35
	Estimado		Estimado		
Sombra	0,40	0,35	Sombra	0,49	0,30
Solo	0,25	0,23	Solo	0,38	0,33
Vegetação	0,51	0,25	Vegetação	0,40	0,32
	100 m		100 m		
Sombra	0,24	0,17	Sombra	0,57	0,27
Solo	0,27	0,25	Solo	0,35	0,29
Vegetação	0,50	0,24	Vegetação	0,41	0,23

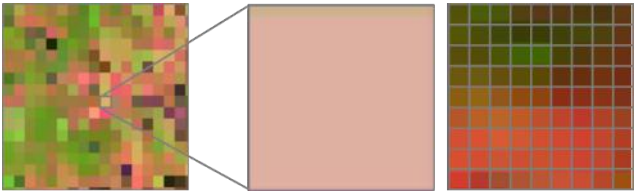
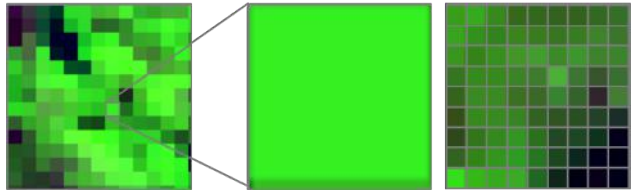
De modo geral, as maiores diferenças observadas estiveram relacionadas a fração sombra, assumindo que a maior mistura de pixels devido ao aumento de áreas susceptíveis ao alagamento durante o período chuvoso pode ter superestimado ambos os resultados utilizando o produto de 1 km. De acordo com Goltz et al. (2006), existem diversas formas de alagamento que podem ocorrer no Pantanal, tanto em lagoas temporárias como em áreas anteriormente estabelecidas como vegetadas, por exemplo.

No que se refere a variação da proporção das frações em relação a variação sazonal no bioma Pantanal, o que era de se esperar para a região em estudo é o aumento da proporção da fração vegetação e sombra durante o período chuvoso e em contrapartida, a maior influência do solo em agosto em função do período de estiagem.

Comparando os resultados das proporções por pixels que poderiam ser selecionados como pixels puros nos produtos de baixa resolução espacial, na **Tabela 5** observa-se que foram obtidas proporções mais condizentes quando utilizado os dados de melhor resolução ou a combinação entre os produtos de diferentes resoluções espaciais.

Tabela 5 - Proporção dos componentes nas resoluções espaciais de 1km e 100m por pixel.

Representação do pixel em 1km (esquerda zoom) e 100m (direita)	Proporção dos componentes			
	Imagem	Estimado	100m	
	Sombra	1,00	0,88	0,70
	Solo	0,02	0,05	0,01
	Vegetação	0,00	0,08	0,32

	Imagem	Estimado	100m	
	Sombra	0,00	0,00	0,00
	Solo	0,80	0,54	0,57
Vegetação	0,47	0,49	0,31	
	Imagem	Estimado	100m	
	Sombra	0,00	0,31	0,32
	Solo	0,00	0,00	0,00
Vegetação	1,00	0,88	0,70	

Dessa forma, é possível observar que o uso combinado de um dado com melhor resolução espacial permitiu ao operador o aperfeiçoamento do MLME no que se refere a determinação de pixels que incluam um único membro de referência, visto que o resultado do modelo depende diretamente da escolha dos parâmetros de entrada, o que se torna uma limitação em produtos de baixa resolução espacial.

5. Conclusões

Este trabalho sugere que a combinação de sensores com diferentes resoluções espaciais para estimar as respostas espectrais dos *endmembers* em aplicações do modelo linear de mistura espectral é uma alternativa vantajosa. As análises realizadas neste trabalho permitiram observar que as respostas espectrais estimadas permitiram a melhoria dos resultados no que se refere ao erro, a variabilidade e na identificação das proporções dos componentes, visto que a escolha indevida de pixels considerados como puros em produtos de baixa resolução espacial pode superestimar ou subestimar os resultados obtidos.

Assim, umas das principais aplicações para o uso desta metodologia está na possibilidade de estender as informações das imagens-fração contidas em escala local para estudos em escala regional utilizando a combinação de sensores de baixa e moderada resolução espacial.

6. Agradecimentos

Os autores desejam expressar seu agradecimento ao Instituto Nacional de Pesquisas Espaciais – INPE, a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq, e a Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP.

7. Referências

- Adami, M.; Bernardes, S.; Arai, E.; Freitas, R. M.; Shimabukuro, Y. E.; Espírito-Santo, F. D. B.; Rudorff, B. F. T.; Anderson, L. O. Seasonality of vegetation types of south america depicted by moderate resolution imaging spectroradiometer (MODIS) time series. **International Journal of Applied Earth Observation and Geoinformation**, v. 69, n. February, p. 148–163, 2018.
- Adámoli, J. O Pantanal e suas relações fito geográficas com os Cerrados. Discussão sobre o conceito de "Complexo do Pantanal". In: Congresso Nacional de Botânica, 32., 1981, Teresina. **Anais...** Teresina: Sociedade de Botânica do Brasil, p.109-119, 1982.
- Asner, G. P. Cloud cover in landsat observations of the brazilian amazon. **International Journal of Remote Sensing**, v. 22, n. 18, p. 3855–3862, 2001.
- Baret, F.; Weiss, M.; Lacaze, R.; Camacho, F.; Makhmara, H.; Pacholczyk, P.; Smets, B. Geov1: *LAI* and *FAPAR* essential climate variables and *FCOVER* global time series capitalizing over existing products. part1: principles of development and production. **Remote Sensing of Environment**, v. 137, p. 299–309, 2013.

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>.

De Freitas, R. M.; Haertel, V.; Shimabukuro, Y. E. Modelo linear de mistura espectral em imagem de moderada resolução espacial. **Boletim de Ciências Geodesicas**, v. 14, n. 1, p. 55–71, 2008b.

Galvão, L. S.; Pereira Filho, W.; Abdon, M. M.; Novo, E. M. M. L.; Silva, J. S. V.; Ponzoni, F. J. Spectral reflectance characterization of shallow lakes from the brazilian pantanal wetlands with field and airborne hyperspectral data. **International Journal of Remote Sensing**, v. 24, n. 21, p. 4093–4112, 2003.

Harris, M. B.; Tomas, W.; Mourão, G.; Da Silva, C. J.; Guimarães, E.; Sonoda, F.; Fachim, E. Safeguarding the pantanal wetlands: threats and conservation initiatives. **Conservation Biology**, v. 19, n. 3, p. 714–720, 2005.

Li, W.; Baret, F.; Weiss, M.; Buis, S.; Lacaze, R.; Demarez, V.; Dejoux, J. Francois; BATTUDE, M.; Camacho, F. Combining hectometric and decametric satellite observations to provide near real time decametric fapar product. **Remote Sensing of Environment**, v. 200, n. August, p. 250–262, 2017.

Meyer, T.; Okin, G. S. Evaluation of spectral unmixing techniques using modis in a structurally complex savanna environment for retrieval of green vegetation, nonphotosynthetic vegetation, and soil fractional cover. **Remote Sensing of Environment**, v. 161, p. 122–130, 2015.

Padovani, C. R.; Vettorazzi, C. A.; Shimabukuro, Y. E.; Adami, M.; Freitas, R. M. De. Estudo das inundações do pantanal a partir de imagens modis. In: Anais XIV Simpósio Brasileiro de Sensoriamento Remoto. 2009, Natal, Brasil. **Anais...** Natal, Brasil: INPE, p. 4805–4812, 2009.

Ravaglia, A. G.; Cristini, L.; Silva, F.; Santos, S. A.; Shimabukuro, Y. E.; Pellegrin, L. A.; Soriano, B. M.; Aguiar, G. Uso de um modelo linear de mistura espectral e índice de vegetação na avaliação de pastagens em degradação no pantanal. **5º Simposio sobre Recursos Naturais e Socioeconomicos do Pantanal**, p. 1–5, 2010.

Richardson, A. J.; Wiegand, C. L.; Gausman, H. W.; Cuellar, J. A.; Gerbermann, A. H. Plant, soil, and shadow reflectance components of row crops. **Photogramm. Eng. Rem. s.**, v. 41, n. 11, p. 1401–1407, 1975.

Shimabukuro, Y. E.; Novo, E. M.; Ponzoni, F. J. Índice de vegetação e modelo linear de mistura espectral no monitoramento da região do pantanal. **Pesquisa Agropecuária Brasileira**, v. 33, n. SUPPL. 2, p. 1729–1737, 1998.

Shimabukuro, Y. E.; Smith, J. A. Fraction images derived from landsat tm and mss data for monitoring reforested areas. **Canadian Journal of Remote Sensing**, v. 21, n. 1, p. 67–74, 1995.

Shimabukuro, Y. E.; Smith, J. A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, n. 1, p. 16–20, 1991.

Silio-Calzada, A.; Barquín, J.; Huszar, V. L. M.; Mazzeo, N.; Méndez, F.; Álvarez-Martínez, J. M. Long-term dynamics of a floodplain shallow lake in the pantanal wetland: is it all about climate? **Science of the Total Environment**, v. 605–606, p. 527–540, 2017.

Silva, J. D. S. V. Da; Abdon, M. D. M. Delimitação do pantanal brasileiro e suas sub-regiões. **Pesquisa Agropecuária Brasileira**, v. 33, n. Especial, p. 1703–1711, 1998.

Wolters, E.; Dierckx, W.; Iordache, M.-D.; Swinnen, E. PROBA-v products user manual v3.01. Image (rochester, n.y.), n. C, p. 1–110, 2018.

Zhu, Z.; Woodcock, C. E. Automated cloud, cloud shadow, and snow detection in multitemporal landsat data: an algorithm designed specifically for monitoring land cover change. **Remote Sensing of Environment**, v. 152, p. 217–234, 2014.