

## Uso da plataforma Google Earth Engine para análise multitemporal de imagens SAR para detecção de variações de áreas inundadas no Pantanal

Gabriel Henrique de Almeida Pereira <sup>1</sup>

Clóvis Cechim Júnior <sup>1</sup>

Giovani Fronza <sup>1</sup>

Flavio Deppe <sup>1</sup>

<sup>1</sup> Sistema Meteorológico do Paraná - SIMEPAR  
Centro Politécnico da UFPR, Caixa Postal 19100  
81531-980 - Curitiba - PR, Brasil  
{gabriel, cloviscechim, giovani}.simepar@gmail.com  
deppe@simepar.br

**Resumo.** O Pantanal é um dos biomas mais importantes e conservados do Brasil. Esta região é alagada anualmente em períodos de precipitação pelo rio Paraguai e seus afluentes. O entendimento da dinâmica de inundação é de extrema importância, pois esta influencia todo o ecossistema do Pantanal. Para identificar as áreas inundadas e suas alterações em diferentes períodos anualmente, devido a grande extensão territorial do bioma, surge como alternativa o uso de dados de Sensoriamento Remoto. Dentre os possíveis sensores capazes de mapeamento destas áreas inundáveis destaca-se o radar, principalmente pela baixa influência de cobertura de nuvens, permitindo imageamento em épocas de chuva ou seca. Desta forma, para este trabalho, utilizou-se imagens de radar do satélite Sentinel 1, para os anos de 2016 e 2017. Todas as imagens disponíveis destes anos para a área de estudo foram utilizadas para geração de uma imagem que representa a sazonalidade na região. Ao todo, 664 imagens de radar do Sentinel 1 para os anos de 2016 e 2017 foram processadas. O processamento de tal quantidade de dados foi possível a partir da plataforma Google Earth Engine, capaz de robusto processamento de grande quantidade de dados, em especial de Sensoriamento Remoto. Ao fim, foi possível gerar uma imagem que representa a sazonalidade de cada ano, que mostrou-se diferente em cada ano, e a comparação entre estes anos, realçando a diferença entre áreas alagadas para o ano de 2016 e 2017.

**Palavras-chave:** Sensoriamento Remoto, processamento de imagens, séries temporais de imagens, mapeamento de sazonalidade, áreas alagadas.

**Abstract.** The Pantanal is one of the most important and preserved biomes in Brazil. This region is flooded annually due to episodes of precipitation along the Paraguay River and its tributaries. Understanding the dynamics of flooding is extreme important since it influences the entire Pantanal ecosystem. Remote Sensing data is an alternative to the identification of flooded areas and their changes in different periods due to the great territorial extension of the biome. Among the possible sensors capable of mapping these flooded areas Radar sensor is one of the most attractive - mainly due to the low influence of cloud cover and atmospheric conditions, allowing imaging in drought or rainy seasons. For this work, Radar images from Sentinel 1 satellites for the years 2016 and 2017 were used. All the images available from these years for the study area were used to generate images that represent the seasonality in the region. In total, 664 Sentinel 1 radar images were processed to generate a seasonal image for each year. The processing of such amount of data was possible through Google Earth Engine platform, which is capable of robust processing of a large amount of data, especially Remote Sensing data. At the end, it was possible to generate images that represent the seasonality of each year, which was visibly different for each year. It was also possible to do the comparison between the years, highlighting the difference between flooded areas.

Key-words: Remote Sensing, image processing, time series images, seasonality mapping, wetlands.

## 1. Introdução

O Pantanal é a maior planície contínua inundável do mundo e abriga grande concentração de vida silvestre. O pulso das inundações sazonais, que representa o regime de cheias e secas, condiciona a produção de peixes e influencia a dinâmica da vegetação, afetando também a criação de gado (Padovani, 2010). O Pantanal é alagado pelo rio Paraguai e seus afluentes todos os anos na época das chuvas, devido à sua baixa altitude (variando de 80 m a 150 m) e também baixas declividades (Antunes e Esquerdo, 2014).

O entendimento da dinâmica das inundações é de fundamental importância para inferir sobre o nível das cheias, já que causam mudanças drásticas em toda a planície. Pela grande extensão do Pantanal, e devido à dificuldade de acesso, as imagens de satélite tornam-se instrumentos importantes para análise das inundações, por proverem uma visão sinóptica de toda a região.

Dentre os sensores de Sensoriamento Remoto usados para o mapeamento de dinâmica de inundações e sazonalidade de determinadas áreas, os sensores do tipo *Synthetic Aperture Radar* (SAR) se destacam, pois sofrem pouca influência da cobertura de nuvens, sendo capazes de imageamento tanto em épocas de seca como de chuva. Imagens SAR tem sido muito utilizadas em estudo de áreas alagadas e em mapeamentos de uso do solo em diferentes regiões e áreas de estudos, dentre estes trabalhos estão Novo *et al.* (2002) e Zhou *et al.* (2017).

Um satélite importante que possui a bordo sensores do tipo SAR é o Sentinel 1. O Sentinel 1 trata-se de uma constelação de 2 satélites, sendo o Sentinel 1A lançado em 3 de abril de 2014 e o Sentinel 1B em 25 de abril de 2016. Tanto o Sentinel 1A como o Sentinel 1B possuem características semelhantes, como órbita Polar, síncrona ao sol, a uma altitude de 693 km. Esta família de satélites Sentinel 1 possui tempo de revisita de 6 dias, se considerado os dois satélites para o imageamento, o que permite aplicações de monitoramento ambiental contínuo.

Entretanto, normalmente, dados de Sensoriamento Remoto demandam de elevada capacidade de armazenamento e processamento, seja via *softwares* de geoprocessamento ou linguagens de programação, especialmente quando séries históricas são utilizadas. Contudo, uma nova plataforma para processamento de dados de Sensoriamento Remoto que se destaca é o Google Earth Engine. Esta plataforma combina um catálogo de petabytes de múltiplas imagens de satélite e conjuntos de dados geoespaciais com recursos para análise em escala planetária e os disponibiliza livremente a cientistas, pesquisadores e desenvolvedores para detectar mudanças, mapear tendências e quantificar diferenças na superfície da Terra.

De acordo com Gorelick *et al.* (2017), o Google Earth Engine é uma plataforma baseada na nuvem para análise geoespacial em escala planetária que traz as capacidades computacionais do Google para lidar com uma variedade de questões sociais de alto impacto, incluindo desmatamento, seca, desastres, doenças, segurança alimentar, gerenciamento de água, monitoramento climático e proteção ambiental. Ainda, a plataforma Google Earth Engine é um serviço de computação intrinsecamente paralelo de alto desempenho. Ele é acessado e controlado por meio de uma interface de programação de aplicativos (API) acessível pela Internet e por um ambiente de desenvolvimento interativo (IDE) associado à Web que permite a criação de protótipos e a visualização rápida dos resultados.

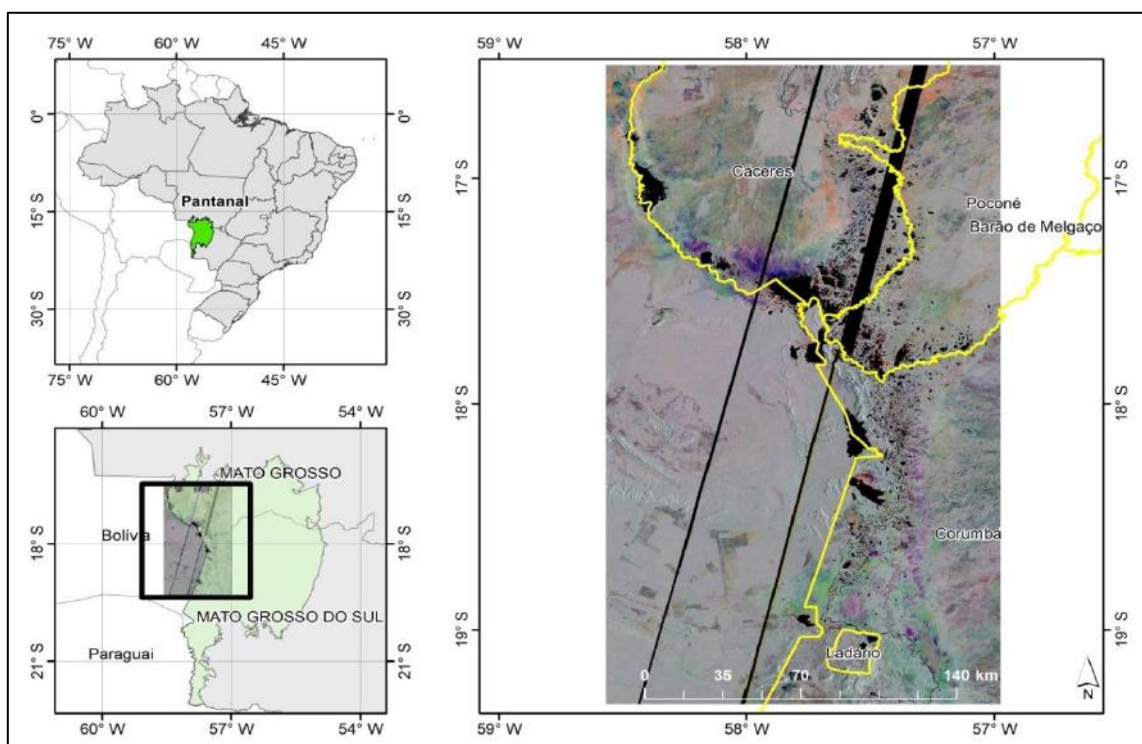
O Google Earth Engine está em uso em uma ampla variedade de disciplinas, abrangendo tópicos como mudança global de florestas (Hansen *et al.*, 2013), mudança global de superfície alagadas (Pekel *et al.*, 2016), estimativa de rendimento de culturas (Lobell *et al.*, 2015), mapeamento de arroz (Dong *et al.*, 2016), mapeamento urbano (Zhang *et al.*, 2015, Patel *et al.*, 2015), mapeamento de inundação (Coltin *et al.*, 2016), recuperação de fogo (Soulard *et al.*, 2016) e mapeamento de risco de malária (Sturrock *et al.*, 2014). Também, o Google Earth Engine foi integrado em várias aplicações de terceiros, por exemplo, analisando as faixas de habitat das espécies (Map of Life, 2016), monitorando o clima (Climate Engine, 2016) e avaliando a mudança no uso da terra (Collect Earth, 2016).

## **2. Objetivo**

O objetivo deste trabalho foi mapear a sazonalidade referente às áreas de inundação em uma área na região do Pantanal por meio do processamento de imagens SAR do satélite Sentinel 1 nos anos de 2016 e 2017, através da plataforma Google Earth Engine.

## **3. Materiais e Métodos**

A área de estudo compreende os estados de Mato Grosso e Mato Grosso do Sul, no Centro Oeste do Brasil, e avançando sobre a Bolívia, abrangendo parte da área do bioma Pantanal. A área de estudo e extensão das imagens de radar Sentinel 1 utilizadas neste trabalho são apresentadas na Figura 1.



**Figura 1** – Mapa de Localização da área de estudo.

As séries temporais de imagens SAR (*Synthetic Aperture Radar* - SAR), compreendendo os satélites Sentinel 1A e 1B, contêm resolução espacial de 10m e temporal que pode chegar a 6 dias, com comprimento de onda de banda C (5.4 GHz), e polarizações horizontais e verticais (H e V). Com isso, a partir da alternância das polarizações H e V, é possível gerar 4 combinações:

- VV: transmissão e recebimento do dado na vertical;
- HH: transmissão e recebimento do dado na horizontal;
- VH: transmissão na vertical e recebimento do dado na horizontal;
- HV: transmissão na horizontal e recebimento do dado na vertical.

A partir da combinação destas polarizações nos canais RGB é possível gerar diferentes tipos de composições que facilitam a identificação e também possibilitando o mapeamento e a quantificação das áreas de inundação em diferentes períodos de análise. Para este estudo, priorizou-se o uso da composição VV. Ou seja, utilizou-se da informação emitida e recebida com polarização vertical (V).

Devido a grande capacidade de processamento da plataforma Google Earth Engine, fez-se uso de uma abordagem que demanda grande processamento para geração de uma composição RGB. Inicialmente, foram adquiridos todos os dados SAR Sentinel 1 disponíveis na polarização VV para os anos de 2016 e 2017. Isto representa um total de 215 e 449 imagens SAR Sentinel 1 na área de estudo para 2016 e 2017, respectivamente. Para cada pixel da área de estudo, gerou-se o valor médio desta polarização VV por período. Este valor médio por período foi então associado a cada canal RGB. Os períodos selecionados e dispostos em cada canal seguem na **Tabela 1**.

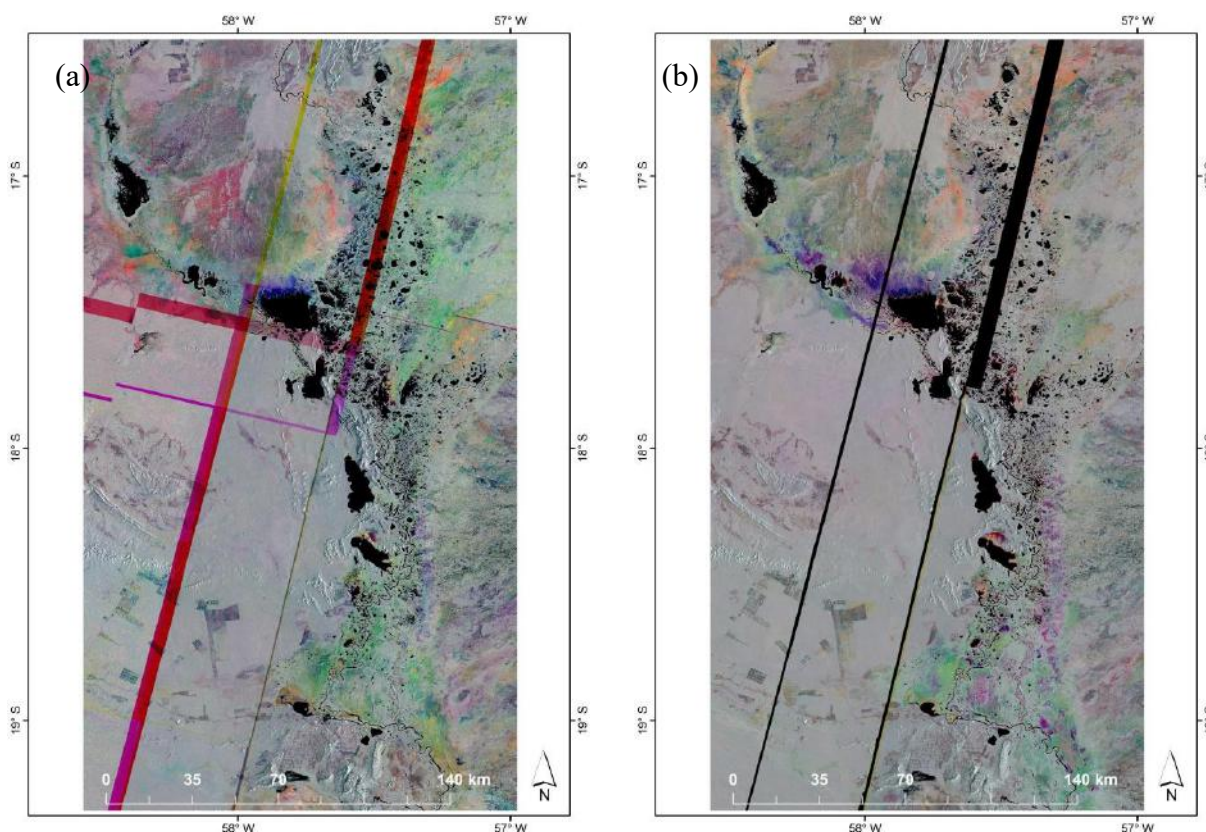
**Tabela 1** – Período e época das imagens selecionadas associadas a cada banda.

Canal	Período	Época
R	Janeiro a Março	Seca
G	Abril a Setembro	Cheia
B	Outubro a Dezembro	Seca

Ou seja, para cada pixel da imagem na área de estudo calculou-se o valor médio das imagens SAR Sentinel 1, polarização VV, de Janeiro a Março, e atribui-se ao canal R; de Abril a Setembro para o canal G; e de Outubro a Dezembro ao canal B. Com isso, 664 (449+215) imagens SAR Sentinel 1 foram processadas para geração de valores médios por período para associação a cada canal da composições RGB para os anos de 2016 e 2017.

#### 4. Resultados e Discussão

As imagens resultantes do valor médio por período associado a cada canal das composições RGB, para os anos de 2016 e 2017, são apresentadas na **Figura 2**.



**Figura 2** – Imagem da composição SAR-Sentinel 1. (a) Ano 2016, (b) Ano 2017.

Inicialmente, percebe-se que a distribuição de cores e tonalidades ao longo de cada imagem da **Figura 2** são diferentes, demonstrando, assim, variabilidade de informação (e resposta média de cada pixel por época do ano) para os anos de 2016 e 2017.


Uma característica importante dos dados SAR é que normalmente não há retorno do pulso de energia para o sensor a partir de áreas alagadas, uma vez que o pulso enviado normalmente é absorvido ou refletido em outra direção. Por vezes, este pulso de energia acaba retornando ao sensor quando refletido por ondulações, presença de sólidos suspensos ou objetos, como embarcações.

Sendo assim, é possível verificar nas imagens que áreas constantemente alagadas permanecem na cor preta ou muito escura, demonstrando ausência (ou pouca informação) de retorno ao sensor SAR.

Ainda, é possível destacar que áreas em que a informação possa ter sofrido variação sazonal apresenta-se em escala colorida, uma vez que cada canal RGB que prevalece sobre outro gera uma cor, em razão de que aquela informação ter sido alterada em maior ou menor grandeza no período de tempo associado.

Áreas em escala de cinza demonstram que os canais RGB contém o mesmo valor, ou valores muito próximos. Ou seja, cada período do ano em cada canal RGB se comportou de maneira parecida e, com isso, não apresentando variações sazonais.

De maneira a melhor discutir os resultados, a Figura 3 é apresentada trazendo um recorte da área de estudo para análise.



**Figura 3** – Detalhe das imagens da composição SAR-Sentinel 1. (a) Ano Base 2016 e (b) Ano Base 2017.

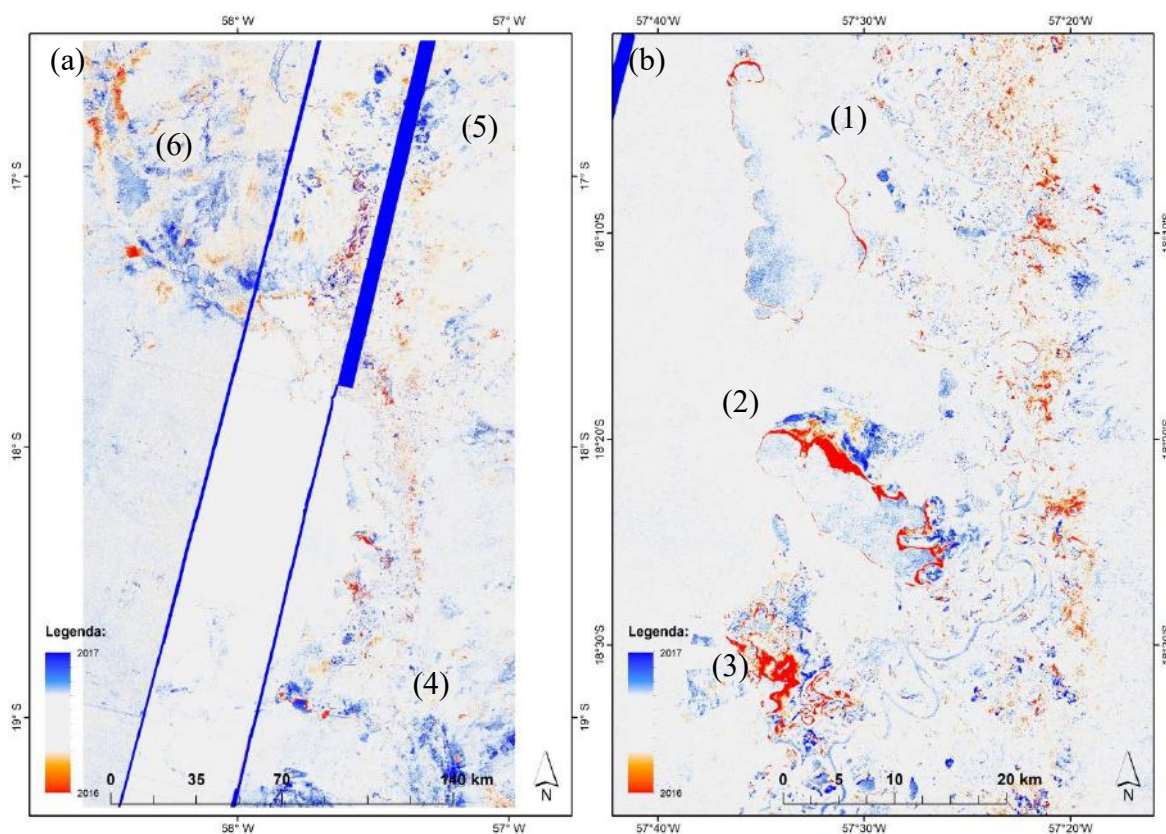
Novamente, é possível a verificação de áreas constantemente escuras, representando áreas alagadas ao longo de todo o ano. Também, é possível verificar a presença de grande quantidade de áreas em escala de cinza, o que representa pouca variabilidade de informação nos canais RGB, ou seja, baixa variabilidade sazonal.

Com isso, é possível verificar que o rio Paraguai permaneceu quase que constantemente dentro da calha, uma vez que este apresenta-se constantemente com característica escura e poucos tons coloridos no seu entorno.

Contudo, percebe-se que existem também áreas em tons coloridos distribuídos ao longo das imagens, tanto para o ano de 2016 quanto de 2017, representando variações sazonais intranuais. Isto porque cada canal RGB (ou combinação dos mesmos) que se destaca em relação aos demais traz tonalidades coloridas demonstrando variações nos períodos do ano associados a cada canal RGB.

Em uma comparação interanual, é possível verificar colorações distintas entre as imagens de 2016 e 2017. Ou seja, a sazonalidade de cada ano se apresentou diferente. Ainda, atenta-se a diferença de informação principalmente no contorno de grandes massa d'água, o que mostra que cada ano estas massas d'água se apresentaram com limites diferentes.

De maneira a melhor caracterizar as diferenças sazonais entre os anos de estudo, a Figura 4 é apresentada. Nesta **Figura 4** estão ressaltadas as áreas onde ocorreram as maiores diferenças entre os anos de 2016 e 2017. Ou seja, estas imagens apresentam, primordialmente, as áreas onde existiu maior tendência de alagamento em uma comparação interanual (entre 2016-2017). A Figura 4a evidencia a área de estudo total (como apresentada na **Figura 2**) e a Figura 4b apresenta a comparação interanual para o mesmo recorte apresentado na **Figura 3**.



**Figura 4** – Delimitação de áreas predominantes de cheia nos anos de 2016 e 2017. (a) Área total; (b) Detalhe da imagem.

Como é possível verificar, em especial na Figura 4b, áreas que em 2016 foram alagadas ou que permaneceram mais tempo alagadas, como nas áreas de margens das lagoas assinaladas em (1) (Lagoa Mandioré) e (2). Ainda, percebe-se uma grande extensão de área que não foi alagada (ou parcialmente alagada por curto período de tempo) em 2017, como assinalada no caso (3).

Em contrapartida, 2017 obtiveram-se mais áreas alagadas de maneira mais distribuída, como é possível verificar na Figura 4a, que representa a área de estudo como um todo. Percebe-se que em 2017 as áreas foram mais alagadas na região sudeste, nordeste e noroeste, da área de estudo, assinaladas nos casos (4, 5 e 6), respectivamente.

## 5. Conclusões

Por mais que este artigo não tenha a intenção (inicial) de quantificar as áreas alagadas no período de 2016 e 2017, o mesmo traz uma boa demonstração de metodologia para análise da sazonalidade da área de estudo, mostrando que cada ano apresentou uma dinâmica sazonal diferente (uma vez que as Figuras 2 e 3 apresentam imagens distintas entre si, com colorações diferentes); e, ainda, apresenta como a capacidade de mapear as áreas que alagaram (ou não, ou que permaneceram pouco tempo submersas) entre um ano e outro, como no caso da **Figura 4**.

A partir do processamento de imagens SAR foi possível gerar composições que evidenciam diferentes interações quanto à sazonalidade da área de estudo. A utilização de dados multitemporais SAR tornou os resultados mais robustos, uma vez que tal sensor permite coleta de dados com pouca (ou nenhuma) influência de nuvens, permitindo o imageamento tanto em épocas de seca como em épocas de chuva - diferentemente dos sensores passivos, por exemplo. Caso algum período não apresentasse as imagens necessárias (como no caso da cobertura de nuvens em imagens coletadas por sensores passivos) seria impossível a utilização da metodologia e abordagem utilizada neste artigo.

E, por fim, ressalta-se a importância da plataforma Google Earth Engine para a geração dos resultados. Por meio do Google Earth Engine foi possível o processamento das 664 imagens para comporem a imagem síntese de 2016 e 2017 de maneira muito mais efetiva. Este processamento seria também possível a partir da utilização de linguagens de programação implementadas localmente ou em *softwares* de geoprocessamento, porém, com o processamento na nuvem e em paralelo, o processamento dos dados de Sensoriamento Remoto se deu de forma muito mais rápida e otimizada.



## 6. Referências

- Antunes, J.F.F.; Esquerdo, J.C.D.M. **Classificação sub-pixel de séries temporais de dados MODIS para a quantificação de áreas inundadas do Pantanal**. Anais 5º Simpósio de Geotecnologias no Pantanal, Campo Grande, MS. Embrapa Informática Agropecuária. 2014.
- Climate Engine, 2016. Desert Research Institute, University of Idaho. <http://climateengine.org>
- Collect Earth, 2016. United Nations Food and Agriculture Organization. <http://www.openforis.org/tools/collect-earth.html>
- Coltin, B.; McMichael, S.; Smith, T.; Fong, T. **Automatic boosted flood mapping from satellite data**. Int. J. Remote Sens., 37 (5), p. 993-1015, 2016.
- Dong, J.; Xiao, X.; Menarguez, M.A.; Zhang, G.; Qin, Y.; Thau, D.; Biradar, C.; Moore, B. **Mapping paddy rice planting area in northeastern Asia with Landsat 8 images, phenology-based algorithm and Google Earth Engine**. Remote Sens. Environ, v.185, p. 142-154, 2016.
- Gorelick, N.; Hancher, M.; Dixon, M.; Ilyushchenko, S.; Thau, D.; Moore, R. **Google Earth Engine: Planetary-scale geospatial analysis for everyone**. Remote Sensing of Environment, v. 202, p. 18-27, 2017.
- Hansen, M.C.; Potapov, P.V.; Moore, R.; Hancher, M.; Turubanova, S.A.; Tyukavina, A.; Thau, D.; Stehman, S. V.; Goetz, S. J.; Loveland, T. R.; Kommareddy, A.; Egorov, A.; Chini, L.; Justice, C. O.; Townshend, J. R. G. **High-resolution global maps of 21st-century forest cover change**. Science, v.342, p. 850-853, 2013.
- Lobell, D.; Thau, D.; Seifert, C.; Engle, E.; Little, B. **A scalable satellite-based crop yield mapper**. Remote Sens. Environ., v.164, p. 324-333, 2015.
- Map of Life, 2016. <http://www.mol.org>
- Novo, E.L.M; Costa, M.P.F. **Fundamentos e aplicações de radar no estudo de áreas alagáveis**. In: SOUZA, R. B. Oceanografia por Satélites, 2ed. Oficina de Textos, 2009, 382 p.
- Padovani, C.R. **Dinâmica Espaço-Temporal das Inundações do Pantanal**. 174p. Tese (Doutorado em Ecologia Aplicada) - Escola Superior de Agricultura «Luiz de Queiroz», Piracicaba, SP, 2010.
- Patel, N.; Angiuli, E.; Gamba, P.; Gaughan, A.; Lisini, G.; Stevens, F.; Tatem, A.; Trianni, A. **Multitemporal settlement and population mapping from Landsat using google earth engine**. Int. J. Appl. Earth Obs. Geoinf., v.35, p. 199-208, 2015.
- Pekel, J.F.; Cottam, A.; Gorelick, N.; Belward, A.S. **High-resolution mapping of global surface water and its long-term changes**, Nature Geoscience, v. 540 (7633), p. 418-122, 2016.
- Soulard, C.E.; Albano, C.M.; Villarreal, M.L.; Walker, J.J. **Continuous 1985–2012 Landsat monitoring to assess fire effects on meadows in Yosemite National Park, California**. Remote Sens., v.8 (5), p. 371, 2016.
- Sturrock, H.J.; Cohen, J.M.; Keil, P.; Tatem, A.J.; Le Menach, A.; Ntshalintshali, N.E.; Hsiang, M.S.; Gosling, R.D. **Fine-scale malaria risk mapping from routine aggregated case data**. Malar. J., v.13 (1), p. 1-9, 2014.
- Zhang, Q.; Li, B.; Thau, D.; Moore, R. **Building a better urban picture: combining day and night remote sensing imagery**. Remote Sens., v.7 (9), p. 11887-11913, 2015
- Zhou, T.; Pan, J.; Zhang, P.; Wei, S.; Han, T. **Mapping winter wheat with multi-temporal SAR and optical images in an urban agricultural region**. Sensors, v.17, p. 1-16, 2017.