

Desafios e oportunidades para o monitoramento da cobertura terrestre brasileira utilizando séries temporais Landsat

Leandro Leal Parente ¹
Laerte Guimarães Ferreira ¹

¹Laboratório de Processamento de Imagens e Geoprocessamento (LAPIG/UFG)
Universidade Federal de Goiás - UFG
CEP: 74690-900 - Goiânia - GO, Brasil
leandro@lapig.iesa.ufg.br
laerte@ufg.br

Abstract. Land cover monitoring has become an important line of research, which has result in progressively more accurate information and greater spatial detail regarding the distribution of natural and anthropic landscapes. At the same time, the increase in computing power supported by cloud computing, the introduction of new classification methods based on time series, and the increasing availability of public satellite data have contributed to the emergence of a new generation of land cover monitoring products, capable of more appropriately depicting the dynamics of these landscapes and to support public policies. Specifically, this study evaluated the effective availability of Landsat 8 data (L1T) and their spatial distribution patterns across the Brazilian territory. Our results suggest that approximately 80% of Brazil have fewer than 12 annual observations free of clouds and/or cloud-shade. While the Cerrado is the Brazilian biome with the largest number of good quality observations, the Amazon biome is the most affected by low availability of observations, with large areas of Amapa state, northern Pará and regions in western Acre, Amazonas Roraima containing only one observation for the entire calendar year. The methods of analysis utilized in this study can be easily applied to the entire Landsat series, which will improve our understanding on data availability over time and enable the combined use of data from different Landsat satellites (e.g. Landsat 5 and 7).

Palavras-chave: landsat, fmask, google earth engine, mapbiomas

1. Introdução

Nas últimas décadas, o monitoramento da cobertura terrestre estabeleceu-se como uma relevante linha de pesquisa, produzindo dados progressivamente mais acurados e com maior detalhe espacial sobre a distribuição de paisagens naturais e antrópicas (Tucker et al., 1985; Hansen et al., 2000; Friedl et al., 2002; Arino et al., 2008). Fatores como a consolidação da computação em nuvens (Ma et al., 2015) e a abertura do acervo Landsat pelo United States Geological Survey - USGS (Wulder et al., 2012) impulsionam o surgimento de produtos globais com resolução mais fina (Giri et al., 2013), utilizando, principalmente, dados Landsat (Townshend et al., 2012; Feng et al., 2015).

No Brasil, a utilização de dados Landsat para esse propósito é uma prática consolidada para a geração de produtos operacionais com o objetivo de apoiar oficialmente políticas públicas (Shimabukuro et al., 1998; MMA, 2002; Coutinho et al., 2013). Para atender aos requisitos de consistência, acurácia e entrega, estes produtos são gerados por meio de métodos tradicionais de sensoriamento remoto, baseados em inspeção visual de imagens (Hansen & Loveland, 2012). Por outro lado, o recente aumento do poder computacional e abertura do acervo Landsat também subsidiaram o surgimento de métodos baseados em *machine learning* aplicados à séries temporais, com vistas à geração de produtos experimentais e de pesquisa (Kennedy et al., 2012; Hansen et al., 2013).

Assumindo que no futuro esses métodos estarão mais acessíveis e robustos, o principal desafio para geração de produtos operacionais residirá na disponibilidade de dados satelitários (Hansen & Loveland, 2012). Estudos anteriores já analisaram a disponibilidade de dados Landsat (Asner, 2001; Sano et al., 2007; Ju & Roy, 2008; Kovalskyy & Roy, 2013), entretanto, tendo por referência apenas metadados, produzindo resultados cuja a unidade de análise era o limite das cenas Landsat.

Buscando contribuir para uma melhor compreensão da disponibilidade de dados satelitários de alta resolução espacial no Brasil, este trabalho propõe um método para elaboração de um mapa anual de disponibilidade de dados Landsat (pixel à pixel), desconsiderando as observações contaminadas por nuvens e sombras. A partir da análise deste mapa, busca-se compreender a efetiva disponibilidade e distribuição de dados do satélite Landsat 8 OLI (*Operational Land Imager*), tendo por referência o surgimento de produtos operacionais e automatizados para o monitoramento da cobertura terrestre no país.

2. Dados e Método

Neste trabalho, o método proposto para o cálculo de disponibilidade de dados Landsat, ilustrado na figura 1, foi aplicado às imagens do satélite Landsat 8, produto L1T, obtidas sobre o território brasileiro no ano de 2015.

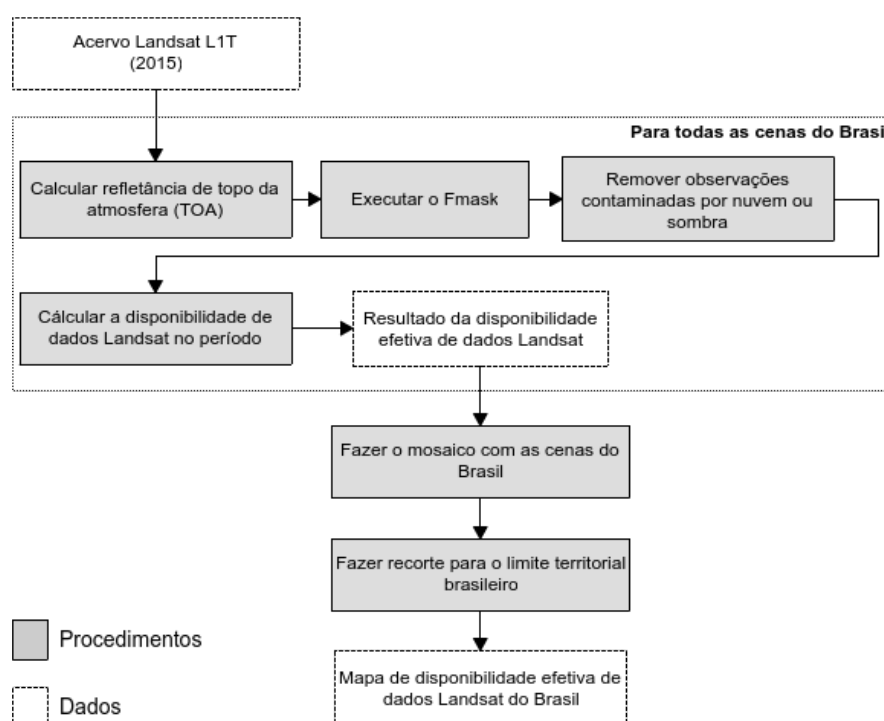


Figura 1. Dados e métodos utilizados na produção do mapa de disponibilidade efetiva de dados Landsat para o Brasil (i.e. considerando apenas as observações filtradas quanto à ocorrência de nuvens e sombras de nuvens)

O cálculo de disponibilidade de dados Landsat foi realizado para as 380 cenas do Brasil, considerando todas as passagens obtidas no ano de 2015, totalizando 6.700 imagens do produto L1T. Para cada imagem foi calculada a refletância do topo da atmosfera (TOA) e em seguida executado o algoritmo F-Mask. Esse algoritmo produziu uma banda de qualidade com informações, pixel à pixel, referentes a contaminação por sombra e nuvem (Zhu & Woodcock, 2015), a qual foi utilizada para identificar e remover as observações ruins. Em seguida, aplicou-se uma operação de contagem, de forma a se determinar as observações restantes (de boa qualidade) para cada pixel, em cada cena considerada. Todos esses procedimentos foram realizados no Google Earth Engine, uma plataforma em escala planetária para análises espaciais de dados ambientais. Desenvolvida por meio de computação em nuvem, essa plataforma dispõe de um catálogo público de dados geográficos que pode ser acessado e manipulado por meio de rotinas de processamento, desenvolvidas em Javascript e Python. (Google Earth Engine, 2016).

Para cada cena foi gerada uma imagem com valores de pixel correspondentes a quantidade de observações disponíveis em 2015, variando de 0 a 23. Essas imagens foram exportadas para o Google Drive e posteriormente recuperadas para uma estação de trabalho local. Todas as cenas foram organizadas em único mosaico, recortado segundo o limite territorial brasileiro por meio da biblioteca GDAL (Qin et al., 2014), o que resultou no mapa de disponibilidade de dados Landsat 8 L1T para o Brasil em 2015.

3. Resultados e discussão

Segundo o mapa de disponibilidade de dados Landsat 8 L1T para o Brasil (figura 2), em 2015, 80 % do território teve 12 ou menos observações livres de nuvens e sombra. Ainda segundo este mapa, e conforme mostrado na figura 3, o Cerrado é o bioma brasileiro com o maior número de observações de boa qualidade em 2015 (em média, 12 observações por pixel). Por outro lado, o bioma Amazônia (com uma média de 8 observações por pixel) é o mais afetado pela baixa disponibilidade de observações, com a maior parte do estado do Amapá, o norte do Pará e regiões no oeste do Acre, Amazonas e Roraima contendo apenas 1 observação para todo o ano. Para os demais biomas, em média, o número de observações variou entre 8 e 12 (ver figura 3), sendo que as áreas próximas ao litoral são as que apresentaram a menor disponibilidade de dados.

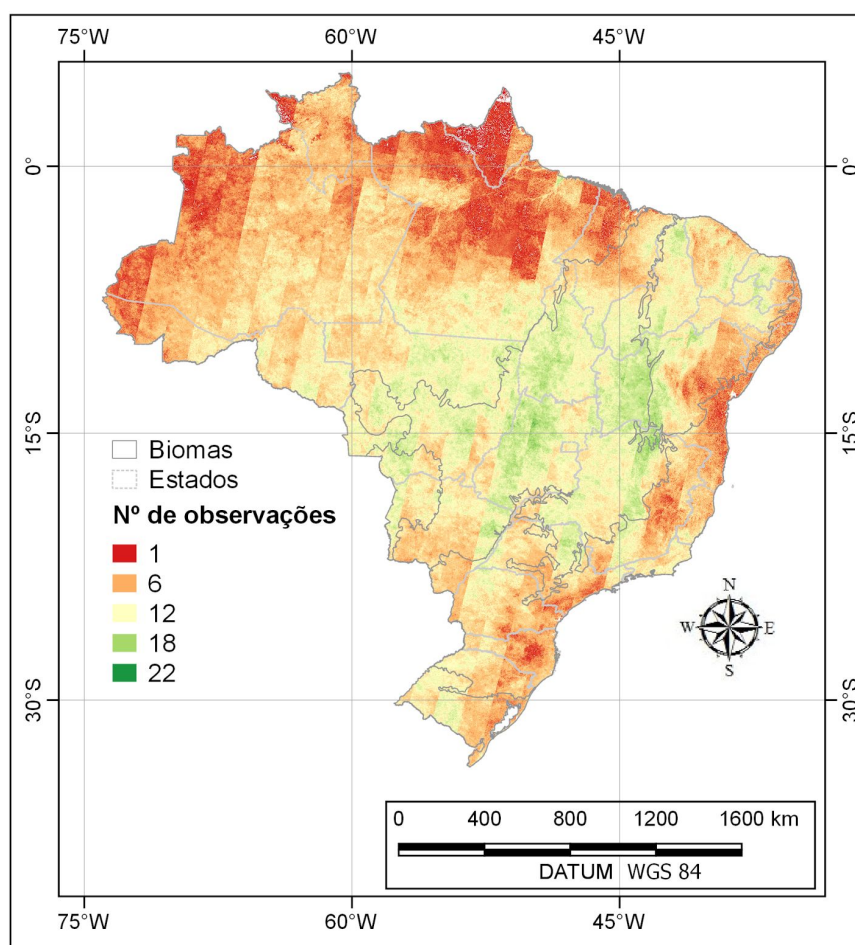


Figura 2. Mapa de disponibilidade de dados Landsat 8 OLI (L1T) em 2015 para o Brasil (considerando apenas as observações de boa qualidade, não contaminadas por nuvens ou sombras de nuvens)

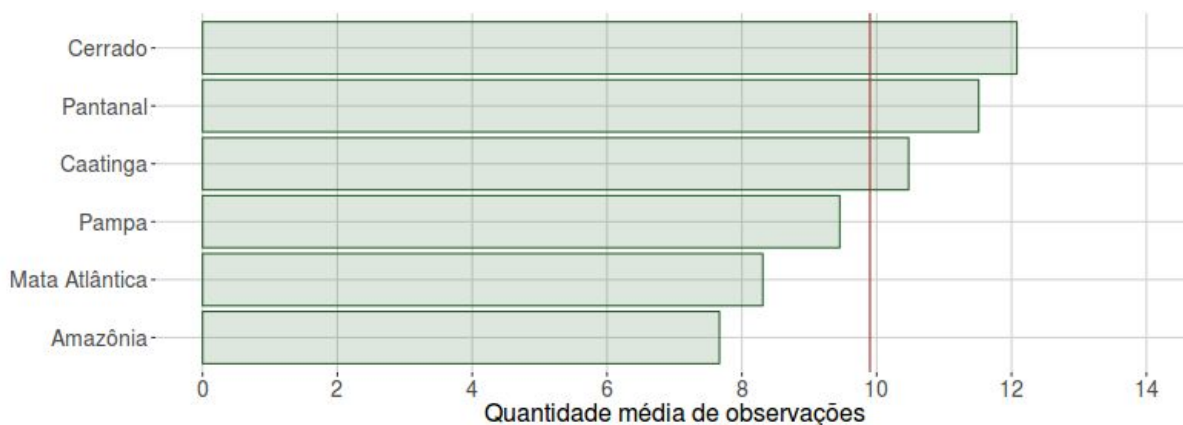


Figura 3. Quantidade média de observações Landsat 8 OLI (L1T) para os biomas brasileiros (considerando apenas as observações de boa qualidade, não contaminadas por nuvens ou sombras de nuvens). A barra vermelha indica o valor médio de observações em todo Brasil

Em relação às unidades federativas do Brasil, Goiás e Tocantins foram os estados que apresentaram a maior quantidade de dados em 2015, com um valor médio de 13 observações de boa qualidade, resultado que contribuiu significativamente para a média de observações no bioma Cerrado (ver figura 3). O destaque negativo da análise é o estado do Amapá, que apresentou a pior disponibilidade de dados Landsat no período, com um valor médio de 3 observações, número muito abaixo da média dos demais estados.




Figura 4. Quantidade média de observações Landsat 8 OLI (L1T) em 2015 para os estados brasileiros (considerando apenas as observações de boa qualidade, não contaminadas por nuvens ou sombras de nuvens). A barra vermelha indica o valor médio de observações em todo Brasil

Assumindo que o satélite Landsat 8, em função da sua resolução temporal, têm capacidade de gerar até 23 observações por pixel em um ano calendário, os resultados mostram que para o ano de 2015, a disponibilidade de dados de boa qualidade, para 80 % do território brasileiro, foi de menos da metade da capacidade de imageamento do sensor OLI.

Esse resultado pode orientar a utilização de métodos de monitoramento baseados no uso de séries temporais satelitárias, aplicados, por exemplo, às seguintes categorias de mudanças: sazonais, afetadas por ciclos fenológicos (ex: áreas de pastagens); efêmeras, decorrente de alterações temporárias na paisagem (ex: áreas alagadas); e graduais, consequência de um processo progressivo de alteração na resposta comum a uma cobertura específica (ex: degradação de áreas vegetadas) (Verbesselt et al., 2010). Atualmente, os produtos operacionais brasileiros monitoram apenas mudanças abruptas, decorrentes de processos de conversão da paisagem, à exemplo de desmatamentos em áreas de vegetações primárias, os quais podem ser identificados por métodos de sensoriamento remoto tradicionais, que comparam duas imagens obtidas em anos diferentes (dispensando portanto o uso de abordagens baseadas em séries temporais). Entretanto, há uma demanda crescente pelo monitoramento continuado de áreas naturais (ex. em processo de degradação) (Bustamante et al, 2016) e convertidas (ex. com ocorrência de florestas secundárias) (Müller et al., 2016), a qual, espera-se, venha a ser incorporada na concepção e geração de produtos operacionais brasileiros.

Em fato, os métodos ainda utilizados na geração destes produtos são um legado do alto custo de aquisição de dados satelitários, da ausência de poder computacional, e de métodos mais eficazes e objetivos de automatização. A adoção de métodos computacionalmente mais intensos, baseados em série temporais, ainda enfrentam certos desafios, como a implementação de estratégias robustas de validação (Hansen & Loveland, 2012). Entre as iniciativas nesta direção, destaca-se o Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil (MapBiomas) que têm como propósito contribuir para o entendimento da dinâmica do uso do solo no Brasil, a partir de abordagens ágeis, confiáveis e de baixo custo para gerar mapas anuais de cobertura e uso do solo do Brasil desde 1985 (Mapbiomas, 2016).

4. Considerações finais

O aumento do poder computacional apoiado por computação em nuvens, o surgimento de métodos baseados em séries temporais e a crescente disponibilidade de dados satelitários públicos contribuíram para o surgimento de uma nova geração de produtos de monitoramento da cobertura terrestre. Esse produtos, ainda em estágio experimental, tem o potencial de detectarem categorias de mudanças mais sensíveis e podem auxiliar, entre outros, o monitoramento de áreas convertidas, tais como pastagens e florestas secundárias. Apesar de atualmente não possuírem maturidade suficiente para substituírem produtos operacionais e apoiarem oficialmente políticas públicas, seus avanços científicos possibilitarão que essa substituição ocorra em um futuro próximo. Nesse sentido, espera-se que esse trabalho contribua para uma melhor compreensão da disponibilidade efetiva de dados satelitários, bem como seus padrões de distribuição espacial sobre o território brasileiro.

Os resultados aqui apresentados utilizaram apenas dados do satélite Landsat 8, produto L1T, obtidos em 2015 sobre o Brasil. Entretanto, os métodos de análise empregados podem ser facilmente aplicados à todo o acervo de imagens Landsat 5, 7 e 8, com vistas à se mapear a disponibilidade de dados das séries Landsat ao longo do tempo. Outra possibilidade promissora é a combinação da disponibilidade de dados obtidos por dois satélites Landsat em um mesmo ano. Por exemplo, se em 2015 fosse considerado dados do satélite Landsat 7, o número de observações disponíveis seria substancialmente maior. A utilização de dados

Landsat 7 é viável, pois o método apresentado é capaz de identificar os pixels afetados pela falha no mecanismo de *Scan Line Corrector* (SLC). Uma outra frente a ser investigada é a possibilidade de determinarmos, para um ano qualquer (ex. 2015), a distribuição intra-anual das observações de boa qualidade. A maneira como estas observações se concentram (ex. predominantemente durante o período seco) pode afetar a disponibilidade efetiva de dados e o potencial de discriminação destes, o qual, assume-se, irá variar em função de padrões sazonais regionais e da resposta fenológica individual das várias classes de cobertura e uso que constituem uma paisagem de interesse.

Agradecimentos

Os autores agradecem o apoio da Gordon and Betty Moore Foundation, da iniciativa MapBiomas e da Fundação de Amparo à Pesquisa do Estado de Goiás (FAPEG).

Referências Bibliográficas

Arino, O.; Bicheron, P.; Achard, F.; Latham, J.; Witt, R.; Weber, J. L. The most detailed portrait of Earth. **Eur. Space Agency**, v. 136, p. 25-31, 2008.

Asner, G.P. Cloud cover in Landsat observations of the Brazilian Amazon. **International Journal of Remote Sensing**, 2001, vol. 22, no. 18, 3855–3862

Bustamante, M. M.; Roitman, I.; Aide, T. M.; Alencar, A.; Anderson, L.; Aragão, L.; Asner, G. P.; Barlow, J.; Berenguer, E.; Chambers, J.; Costa, M. H.; Fanin, T.; Ferreira, L. G.; Ferreira, J. N.; Keller, M.; Magnusson, W. E.; Morales, L.; Morton, D.; Ometto, J.; Palace, M.; Peres, C.; Silvério, D.; Trumbore, S.; Vieira, I. C. Towards an integrated monitoring framework to assess the effects of tropical forest degradation and recovery on carbon stocks and biodiversity. **Global Change Biology**, v. 1, p. n/a-n/a, 2016.

Coutinho, A. C.; Almeida, C.; Venturieri, A.; Esquerdo, J. C. D. M.; Silva, M. **Uso e cobertura da terra nas áreas desflorestadas da Amazônia Legal: TerraClass 2008**. Brasília, DF: Embrapa; São José dos Campos, SP: INPE, 2013.

Feng, M.; Sexton, J. O.; Channan, S.; Townshend, J. R. A global, high-resolution (30-m) inland water body dataset for 2000: first results of a topographic–spectral classification algorithm. **International Journal of Digital Earth**, p. 1-21, 2015.

Friedl, M. A.; Mciver, D. K.; Hodges, J. C.; Zhang, X. Y.; Muchoney, D.; Strahler, A. H.; Woodcock C. E.; Gopal S.; Schneider A.; Cooper A.; Baccini A.; Gao F.; Schaaf C. Global land cover mapping from MODIS: algorithms and early results. **Remote Sensing of Environment**, v. 83, n. 1, p. 287-302, 2002.

Giri, C.; Pengra, B.; Long, J.; Loveland, T. R. Next generation of global land cover characterization, mapping, and monitoring. **International Journal of Applied Earth Observation and Geoinformation**, v. 25, p. 30-37, 2013.

Google Earth Engine. Intro. Disponível em: < <https://earthengine.google.org/#intro>>. Acesso em: 10.Out.2016

Hansen, M. C.; Defries, R. S.; Townshend, J. R.; Sohlberg, R. Global land cover classification at 1 km spatial resolution using a classification tree approach. **International Journal of Remote Sensing**, v. 21, n. 6-7, p. 1331-1364, 2000.

Hansen, M. C.; Loveland, T. R. A review of large area monitoring of land cover change using Landsat data. **Remote sensing of Environment**, v. 122, p. 66-74, 2012.

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, n. 6160, p. 850-853, 2013.

Ju, J.; Roy, D. P. The availability of cloud-free Landsat ETM+ data over the conterminous United States and globally. **Remote Sensing of Environment**, v. 112, n. 3, p. 1196-1211, 2008.

Kennedy, R. E.; Yang, Z.; Cohen; W. B. Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr—Temporal segmentation algorithms. **Remote Sensing of Environment**, v. 114, n. 12, p. 2897-2910, 2010.

Kovalskyy, V.; Roy, D. P. The global availability of Landsat 5 TM and Landsat 7 ETM+ land surface observations and implications for global 30m Landsat data product generation. **Remote Sensing of Environment**, v. 130, p. 280-293, 2013.

Ma, Y.; Wu, H.; Wang, L.; Huang, B.; Ranjan, R.; Zomaya, A.; Jie, W. Remote sensing big data computing: challenges and opportunities. **Future Generation Computer Systems**, v. 51, p. 47-60, 2015.

Mapbiomas. O QUE É O MAPBIOMAS. Disponível em: <<http://mapbiomas.org/pages/about/about>>. Acesso em: 20.Out.2016

MMA. **Projeto de conservação e utilização sustentável da diversidade biológica brasileira: relatório de atividades**. Brasília: Ministério do Meio Ambiente, 2002.

Müller, H.; Rufin, P.; Griffiths, P.; Hissa, L. D. B. V.; Hostert, P. Beyond deforestation: Differences in long-term regrowth dynamics across land use regimes in southern Amazonia. **Remote Sensing of Environment**, v. 186, p. 652-662, 2016.

Qin, C. Z.; Zhan, L. J.; Zhu, A. How to apply the Geospatial Data Abstraction Library (GDAL) properly to parallel geospatial raster I/O?. **Transactions in GIS**, v. 18, n. 6, p. 950-957, 2014.

Sano, E. E.; Ferreira, L.g.; Asner, G.; Steinke, E. Spatial and temporal probabilities of obtaining cloudá free Landsat images over the Brazilian tropical savanna. **International Journal of Remote Sensing**, v. 28, p. 2739-2752, 2007.

Shimabukuro, Y. E.; Batista, G. T.; Mello, E. M. K.; Moreira, J. C.; Duarte, V. Using shade fraction image segmentation to evaluate deforestation in Landsat Thematic Mapper images of the Amazon region. **International Journal of Remote Sensing**, v. 19, n. 3, p. 535-541, 1998.

Townshend, J. R.; Masek, J. G.; Huang, C.; Vermote, E. F.; Gao, F.; Channan, S.; Sexton J. O.; Feng M.; Narasimhan R.; Kim D.; Song K.; Song D.; Song P.; Noojipady P.; Tan B.; Hansen M.; Li M.; Wolfe R. E. Global characterization and monitoring of forest cover using Landsat data: opportunities and challenges. **International Journal of Digital Earth**, v. 5, n. 5, p. 373-397, 2012.

Tucker, C. J.; Townshend, J. R.; Goff, T. E. African land-cover classification using satellite data. **Science**, v. 227, n. 4685, p. 369-375, 1985.

Verbesselt, J.; Hyndman, R.; Newnham, G.; Culvenor, D. Detecting trend and seasonal changes in satellite image time series. **Remote sensing of Environment**, v. 114, n. 1, p. 106-115, 2010.

Wulder, M. A.; Masek, J. G.; Cohen, W. B.; Loveland, T. R.; Woodcock, C. E. Opening the archive: How free data has enabled the science and monitoring promise of Landsat. **Remote Sensing of Environment**, v. 122, p. 2-10, 2012.

Zhu, Z.; Wang, S.; Woodcock, C. E. Improvement and expansion of the Fmask algorithm: Cloud, cloud shadow, and snow detection for Landsats 4–7, 8, and Sentinel 2 images. **Remote Sensing of Environment**, v. 159, p. 269-277, 2015.