



Integração do algoritmo *fmask* ao modelo linear de mistura espectral como subsídio à detecção de áreas queimadas na Amazônia brasileira

Integration of the *Fmask* Algorithm with a Linear Spectral Mixture Model as a Supporting Tool for Detecting Burned Areas in the Brazilian Amazon

Mikhaela Aloísia Jéssie Santos Pletsch¹, Thales Vaz Penha¹, Celso Henrique Leite Silva Junior¹, Thales Sehn Körting¹, Luiz Eduardo Oliveira e Cruz de Aragão¹ & Liana Oighenstein Anderson²

Recebido em novembro de 2017.

Aprovado em abril de 2018.

RESUMO

O fogo é um dos principais causadores de degradação nos ecossistemas Amazônicos, sendo amplamente utilizado para o manejo e transformação da cobertura da terra em diferentes usos. A sua utilização indiscriminada torna os ambientes afetados mais vulneráveis a impactos climáticos e antrópicos. Durante a queima, a combustão do material orgânico libera o gás dióxido de carbono (CO₂), principal responsável pelo efeito estufa. Embora o seu controle seja de extrema relevância, há muitas incertezas associadas às ferramentas de detecção e mapeamento de áreas queimadas por meio de sensoriamento remoto. Uma das mais difundidas abordagens utilizadas para o mapeamento de queimadas na Amazônia Brasileira é o Modelo Linear de Mistura Espectral (MLME), baseado na resposta espectral de alvos puros. Este trabalho analisou o desempenho da integração do algoritmo *Fmask* aplicado ao MLME, uma vez que o algoritmo *Fmask* pode refinar os dados gerados pelo MLME. Foram testadas imagens do sensor *Operational Land Imager* (OLI - Landsat 8) e do sensor *Multispectral Instrument* (MSI - Sentinel-2A) em coberturas de Floresta e Não Floresta para subsidiar a detecção de áreas queimadas. A área de estudo está localizada no sul do estado do Pará, no bioma Amazônia. Os resultados apresentaram uma exatidão global acima de 99% para o mapeamento gerado a partir do refinamento dos dados do MLME pelo *Fmask* em ambos os sensores. A acurácia do produtor foi acima de 97%, enquanto que a acurácia do usuário foi entre 77,54% e 95%. O resultado do índice Kappa no mapeamento via *Fmask* na imagem do

¹Instituto Nacional de Pesquisas Espaciais - INPE. Av. dos Astronautas, 1.758 - Jardim da Granja, São José dos Campos - SP, Brasil, 12227-010. E-mail: mikhaela.pletsch; thales.penha; celso.junior; thales.korting; luiz.aragao@inpe.br;

²Centro Nacional de Monitoramento e Alertas de Desastres Naturais - CEMADEN. Estrada Doutor Altino Bondensan, 500 - Parque Tecnológico de São José dos Campos, São José dos Campos - SP, Brasil, 12247-016. E-mail: liana.anderson@cemaden.gov.br

sensor OLI para áreas de cobertura de Floresta e Não Floresta foi de 0,93, e 0,97, respectivamente. Para o sensor MSI, os resultados do índice Kappa para as duas classes foram 0,87 e 0,88, respectivamente. A integração do algoritmo *Fmask* ao MLME possibilitou diminuir o tempo de processamento dos dados com alta acurácia nos resultados finais. Esta abordagem se apresenta como uma potencial ferramenta de automatização do refinamento do mapeamento de áreas queimadas na Amazônia Brasileira podendo ser aplicada inclusive em uma perspectiva de multi-sensores.

PALAVRAS-CHAVE: Sensoriamento Remoto. Floresta Tropical. Ferramenta de Suporte. Fogo. Mapeamento.

ABSTRACT

Fire is one of the most important degradation agents in Amazonian terrestrial ecosystems and is widely used to manage and transform land cover for many purposes. Uncontrolled fire use increases the vulnerability of affected environments to climate and anthropogenic impacts. During the burning process, the combustion of organic material releases carbon dioxide, the main responsible for the greenhouse effect. Although fire use control is of utmost importance, uncertainties regarding the results of burned areas detection and monitoring remote sensing tools are still lacking. One of the main used approaches for burned area mapping in the Brazilian Amazon is the Linear Spectral Mixture Model (LSMM), which considers the spectral response of pure endmembers. In this work we aimed to assess the performance of the integration of the *Fmask* algorithm with LSMM, considering that this algorithm may refine data from LSMM. We tested scenes from sensor Operational Land Imager (OLI - Landsat 8) and sensor Multispectral Instrument (MSI - Sentinel-2A) in Forest and Non Forest land covers in order to support the detection of burned areas. The study area is located in the south of Pará State, in Amazon biome. The mapping results yielded overall accuracy above 99% for the mapping from LSMM refined by *Fmask* algorithm in both sensors. The producer's accuracy was above 97%, whilst user's accuracy ranges from 77.54% and 95%. The result of the Kappa index for OLI was 0.93 for Forest and 0.97 in Non Forest, while for MSI, the results are 0.87 and 0.88, respectively. The integration of the *Fmask* algorithm with LSMM enabled accurate and less time-consuming data processing results. This approach is considered a potential automation tool to refine burned areas mapping in the Brazilian Amazon in a multi-sensors perspective.

KEYWORDS: Remote Sensing. Tropical Rainforest. Supporting Tool. Fire. Mapping.

* * *

Introdução

Os eventos de queimadas e incêndios florestais tornam os ambientes impactados mais expostos a subsequentes impactos climáticos e antropogênicos, reduzindo a quantidade de biomassa da floresta e consequentemente os estoques de carbono (SATO, 2016). Durante a combustão da matéria orgânica, libera-se o dióxido de carbono, principal gás de efeito estufa, representando cerca de 90% dos gases liberados (LASHOF, 1991). Desse modo, a queima de biomassa afeta não apenas a floresta a nível local, mas também o ciclo do carbono, influenciando as trocas radiativas terrestres e as mudanças no clima (ANDERSON et al., 2015; SHIMABUKURO et al., 2015; PADILLA et al., 2017).

Historicamente, a ocorrência de fogo na Amazônia é considerada rara (BUSH et al., 2007). Entretanto, juntamente com o aumento das taxas de desmatamento na região, esse fenômeno começou a se tornar mais frequente, já que possui estreita relação com o processo de desmatamento e manejo de áreas agrícolas e pecuárias (SHIMABUKURO et al., 2015; ARAGÃO et al., 2016). Aragão et al. (2014) e Gatti et al. (2014) destacaram que com a crescente demanda internacional por reduções nas emissões de carbono, controlar o uso indiscriminado de fogo na região da Amazônia pode ser uma eficiente estratégia para reduzir essas emissões. Apesar disso, ainda há muitas incertezas associadas às detecções e mapeamentos de áreas queimadas por meio de sensoriamento remoto, como a problemática da superestimativa de áreas queimadas (ANDERSON et al., 2005), a variabilidade e desenvolvimento temporal das características espectrais das áreas queimadas (SHIMABUKURO et al., 2015), além da própria resolução espacial das imagens e produtos (ANDERSON et al., 2015; ANDERSON et al., 2017). Algoritmos que geram estimativas de áreas queimadas operacionalmente para toda a superfície terrestre podem apresentar incertezas (HAWBACKER et al., 2017). Conforme identificado por PADILLA

et al. (2015), erros de comissão para áreas queimadas variam de 42% a 94%, enquanto os de omissão variam de 68% a 93%, dependendo do sensor usado.

O sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*), a bordo dos satélites Terra e Aqua, possui atributos específicos voltados para o monitoramento de eventos de fogo, gerando produtos ao longo da superfície terrestre (ROY et al., 2008). Embora apresente alta resolução temporal (1 a 2 dias), a resolução espacial é de 250m a 1km, não sendo indicada para estudos que exijam detalhamento. Para esses casos, Key e Benson (2006) indicaram imagens de média resolução espacial, as quais variam de 10 à 50m de acordo com Ehlers et al. (2002), como o sensor OLI (Landsat 8) com 30m (WULDER et al., 2012). Apesar disso, este sensor apresenta resolução temporal baixa (16 dias) e possível contaminação dos pixels devido à cobertura de nuvens presente nas regiões tropicais durante os períodos de queimadas (SHIMABUKURO et al., 2015). Este tipo de dado, portanto, limita os estudos contínuos. No entanto, com a disponibilidade das imagens do sensor MSI (Sentinel-2), também com cobertura global, resolução espacial de 10 à 60m e 5 dias de resolução temporal (DRUSCH et al., 2012), melhores condições de monitoramento das mudanças de uso e cobertura da terra em intervalos temporais mais curtos são gerados, diminuindo assim incertezas.

No Brasil, existem diferentes projetos que monitoram os fenômenos de queimadas e incêndios florestais nos diferentes biomas, uma vez que cada ambiente exige uma abordagem própria. Um exemplo é o Programa de Monitoramento de Queimadas - INPE, o qual detecta áreas queimadas em dados de média resolução espacial na região do Cerrado (INPE, 2017). Na Amazônia, uma das mais difundidas abordagens utilizadas para a detecção e monitoramento de áreas queimadas consiste na aplicação do Modelo Linear de Mistura Espectral (MLME) (ANDERSON et al., 2005; LIMA et al., 2012; CARDOZO et al., 2013; ANDERE et al., 2015; SILVA JUNIOR et al., 2017). Esse modelo considera que o valor do pixel de uma imagem é uma combinação linear da resposta de cada elemento dentro da área do pixel imageado. Assim, a base para a geração do modelo é proveniente da resposta

espectral de alvos puros, também chamados de *endmembers* (SHIMABUKURO e SMITH, 1991; INPE, 2006). A aplicação do MLME apresenta resultados adequados nos estudos de detecção e mapeamento de cicatrizes de áreas de queimadas (ANDERSON et al., 2005; LIMA et al., 2012; CARDOZO et al., 2013; ANDERE et al., 2015; SILVA JUNIOR et al., 2017). Nestas abordagens, apenas a fração sombra derivada do MLME é utilizada, uma vez que apresenta resposta espectral semelhante ao das queimadas. Apesar disso, outros atributos como água e sombra de nuvem também são inclusos nesta fração, devido à resposta espectral semelhante entre esses alvos, conforme já reportado por Bastarrika et al. (2011). Dessa forma, o mapeamento baseado na fração sombra exige etapas posteriores de filtragem. Para isso, máscaras de superfícies de corpos de água podem contribuir no refinamento dos dados, bem como técnicas de edição manual, visando eliminar os erros de comissão. Dados auxiliares e produtos baseados na temperatura dos alvos podem também contribuir para uma maior acurácia (ANDERE et al., 2015). Nesse contexto, embora existam esforços, ainda há uma lacuna de estudos voltados para a automatização dos processos de filtragem dos mapeamentos de áreas queimadas baseados no MLME na região da Amazônia.

Desenvolvido em 2012 (ZHU e WOODCOCK, 2012) e atualizado em 2015 (ZHU et al., 2015), o algoritmo *Fmask* (*Function of Mask*) detecta alvos básicos em imagens da Série Landsat (4-8) e Sentinel-2, como água e sombra de nuvem. Levando em consideração os processos de filtragem requeridos na detecção e mapeamento de eventos de queimadas pela aplicação do MLME, e os produtos gerados pelo algoritmo *Fmask*, a utilização deste algoritmo se mostrou uma viável ferramenta de subsídio a estudos de áreas queimadas ao longo da Amazônia, embora ainda seja necessário avaliar o quanto esse algoritmo pode refinar o mapeamento realizado pelo MLME. Nesse contexto, para esta pesquisa foram elaboradas as seguintes perguntas:

- a) A aplicação do algoritmo *Fmask* refina o mapeamento de áreas queimadas gerado pelo MLME?
- b) Qual a exatidão de um modelo de classificação semi-automático de áreas queimadas baseado na integração do algoritmo *Fmask* ao MLME?
- c) O mapeamento refinado via *Fmask* é afetado pelo tipo de cobertura Floresta ou Não Floresta?

A primeira pergunta teve como objetivo analisar o desempenho do mapeamento final de áreas queimadas gerado pela integração do algoritmo *Fmask* ao MLME (Mapeamento via *Fmask*) em imagens dos sensores *Operational Land Imager* (OLI - Landsat 8) e *Multispectral Instrument* (MSI - Sentinel-2A). Para isso, foram analisadas as acurácias do Mapeamento via *Fmask* frente a um mapeamento de referência. A segunda, teve como objetivo analisar a viabilidade de gerar um modelo semi-automático de classificação de áreas queimadas. Os resultados encontrados na primeira pergunta foram também aqui avaliados. Finalmente, a terceira questão teve como objetivo analisar se o Mapeamento via *Fmask* sofre distorções em coberturas de Floresta e Não Floresta. Para isso, foram comparados os resultados do Mapeamento via *Fmask* em ambas as classes.

2 Algoritmo *Fmask*

Criado por Zhu e Woodcock (2012) e aperfeiçoado por Zhu et al. (2015), o algoritmo *Fmask* requer como dados de entrada todas as bandas disponíveis em cada sensor estudado. Como dado de saída, são gerados cinco atributos: nuvem, sombra de nuvem, neve, água e terreno. Este último elemento refere-se à área correspondente ao que não se encaixa nos demais atributos e não possui dado nulo. Baseado nesses autores, Flood e Gillingham (2017) estruturaram o conteúdo na linguagem de programação

de alto nível e *open source Python*, sendo que a resolução espacial dos dados de saída pode ser definida pelo usuário.


Devido ao seu desempenho, o algoritmo *Fmask* foi adotado para ser aplicado na série Landsat (FOGA et al., 2017). A identificação de alvos básicos em imagens Landsat foi de grande relevância, principalmente pela possibilidade de aplicar filtros de maneira automatizada em séries temporais e em imagens de média resolução espacial. O Programa Landsat distribui imagens multiespectrais da Terra continuamente desde o começo da década de 70, sendo o satélite Landsat 8 (L8) o mais recente da sequência (USGS, 2016).

Levando em consideração o potencial do *Fmask*, diferentes autores têm aplicado este algoritmo em diversas etapas de estudos científicos. Existem duas linhas de pesquisas relacionadas à aplicação deste algoritmo: a primeira se utiliza dos dados de saída deste algoritmo como objetos de estudos (KLEIN et al., 2017; SEONG et al., 2017, SUN et al., 2017; VUOLO et al., 2017). Assim, o algoritmo *Fmask* se tornou uma abordagem única no sentido de viabilizar a compreensão da mudança de atributos básicos em imagens de sensoriamento remoto. A segunda linha utiliza dos dados de saída para eliminar alvos indesejados ou eventuais ruídos (HERMOSILLA et al., 2015; GÓMEZ et al., 2016; MARINO et al., 2016; WALKER, 2016; SAN-MIGUEL et al., 2017; AZZARI e LOBELL, 2017; PENHA et al., 2017), permitindo por exemplo análises sobre a dinâmica de uso e cobertura da terra sem interferências de ruídos externos. Comumente, ele é utilizado para detectar nuvens e sombra de nuvens, uma vez que ambos os atributos podem omitir as informações da superfície terrestre e influenciar as análises. Conforme ressaltam Zhu e Woodcock (2012), esses alvos são fontes significativas de ruídos, podendo induzir a falsa detecção de mudança na cobertura do solo, e correções atmosféricas com baixa precisão. Dessa forma, o algoritmo *Fmask* pode ser aplicado em uma etapa de pré-processamento, para evitar a inclusão dos alvos não desejados em etapas de processamento e análises dos resultados.

3 Área de Estudo

A área de estudo está localizada no sul do estado do Pará, no domínio do bioma Amazônia, e está inserida na região denominada arco de desflorestamento (Figura 1). Esta região abrange parte de três (3) municípios: São Félix do Xingu, Cumaru do Norte e Ourilândia do Norte. O surgimento destes municípios está relacionado à abertura de estradas, principalmente após a construção da BR 163 (Cuiabá (MT) – Santarém (PA)), e aos projetos de colonização incentivados pelo governo federal nos anos 1970 (SILVA et al., 2008). Esses municípios ainda contam com territórios indígenas, sendo em sua maioria já regularizados (ITERPA, 2017).

Figura 1 – Mapa de Localização da área de estudo



Fonte: Elaborado pelos autores.

Nesta região, as principais classes de cobertura da terra são as Florestas (68,65%) e as Pastagens (2,15%), de acordo com os dados do

projeto TerraClass para o ano de 2014 (ALMEIDA et al., 2016). Além disso, segundo Silva et al. (2008) que estudaram os agentes de mudanças de uso da terra nesta região, São Félix do Xingu apresenta uma das maiores taxas anuais de desmatamento na Amazônia e possui 10% do gado do estado do Pará. A ocorrência de queimadas na região, portanto, está intimamente relacionada às atividades antrópicas como o desmatamento e o uso do fogo para manutenção das áreas de pastagem que, por vezes, atingem também áreas de florestas, conforme verificado por Alencar et al. (2006).

O recorte espacial da área de estudo foi definido com base na sobreposição das cenas 224/66 do sensor *Operational Land Imager* (OLI – Landsat 8) e cena 22LDR/22LDQ do *MultiSpectral Instrument* (MSI – Sentinel-2^a). As imagens foram adquiridas para o ano 2016, devido ao aumento de ocorrência de incêndios florestais associados com uma anomalia de seca causada por El Niño (JIMÉNEZ- MUÑOZ et al., 2016) e confirmado com dados de referência do Programa de Monitoramento de Queimadas (INPE, 2017).

4 Materiais e Métodos

A metodologia desenvolvida foi pautada em três principais etapas: aquisição e pré-processamento dos dados (item 4.1), processamento (item 4.2) e validação (item 4.3) (Figura 2), detalhada a seguir.

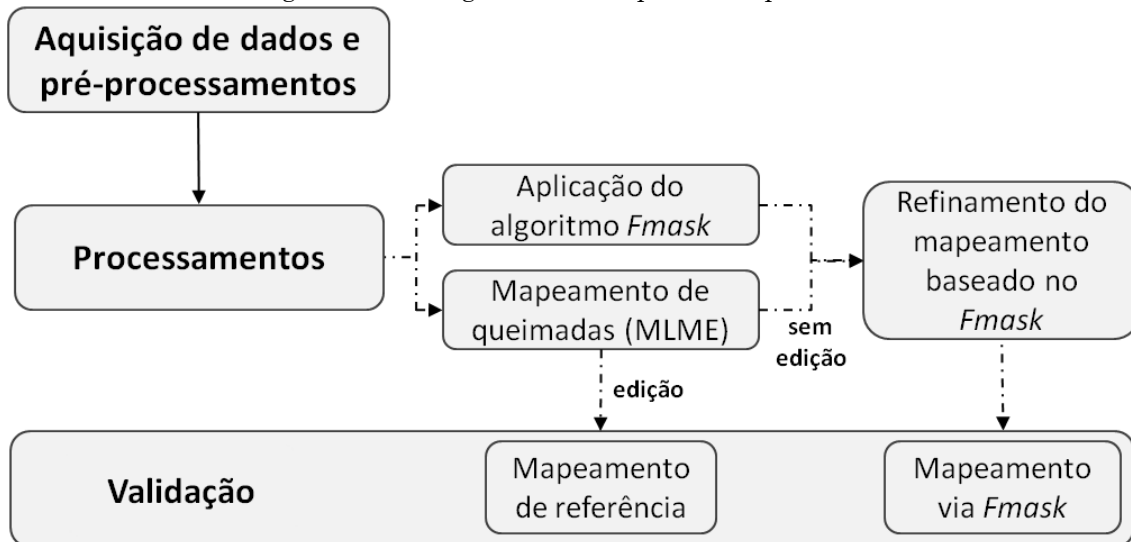
4.1 Aquisição e pré-processamento de dados

A cena OLI (Landsat 8) (WRS 2 - *Worldwide Reference System 2, Path/Row 224/66*) adquirida corresponde ao dia 27 de agosto de 2016 (às 13:31 UTC), através do sítio da USGS (Serviço Geológico dos Estados Unidos) (gratuitamente disponível em: <http://www.earthexplorer.usgs.gov/>) em dois níveis de processamento. O primeiro em superfície de reflectância *Bottom-Of-Atmosphere* (BOA), produto C1 *High-Level*, com correção radiométrica, geométrica e atmosférica (VERMOTE et al., 2016). O segundo

em *Top-Of-Atmosphere* (TOA), produto *C1 Level-1*, apenas com correção radiométrica e geométrica. Ambas no sistema de projeção cartográfica UTM/WGS84.

Duas cenas MSI (Sentinel-2A) foram adquiridas na mesma data que a imagem OLI (Landsat 8), no dia 27 de agosto de 2016 (entre 13:51 e 13:52 UTC), do sítio *Copernicus Scientific Data Hub* (Agência Espacial Europeia - ESA) (gratuitamente disponível em: <http://www.scihub.copernicus.eu/>) como produto TOA, *Level-1C* (L1C) com correção radiométrica e geométrica no sistema de projeção cartográfica UTM/WGS84.

Figura 2 – Fluxograma das etapas desempenhadas



Fonte: Elaborado pelos autores.

Para obter as cenas MSI (Sentinel-2A) em BOA, todas as bandas disponíveis foram importadas para a ferramenta SNAP (*Sentinel Application Platform*), disponibilizada pela ESA, e foram corrigidas atmosféricamente pelo processador Sen2Cor (MAIN-KNORN, et al., 2015; MÜLLER-WILM, 2016). Como resultado, um produto em superfície de reflectância (BOA) foi gerado e automaticamente reamostrado para uma resolução espacial de 20 m. Posteriormente, esse mesmo dado foi reamostrado para 30 m, por meio da técnica do vizinho mais próximo.

Assim, todo o conjunto de dados está na mesma resolução espacial, tornando compatíveis os procedimentos subsequentes. Em seguida, foi aplicada uma técnica de co-registro (*feature-based registration*) (FONSECA e MANJUNATH, 1996) nas imagens OLI (Landsat 8) e MSI (Sentinel-2A) para que em ambas as áreas de estudo os alvos e objetos se sobrepussem com baixo Erro Quadrático Médio (EQM) ($EQM = 0,2$). Este passo é essencial devido ao desalinhamento relativo em cada imagem com relação à outra, pois os sistemas de geolocalização dos sensores em ambos usam abordagens paramétricas distintas e diferentes modelos de controle de terra e elevação para refinar a geolocalização (YAN et al., 2016).

Os dados de Floresta e Não Floresta foram gerados com base nas cenas 225/066, 224/066, 224/067 do mapeamento realizado para o ano de 2016 pelo Projeto PRODES, o qual realiza o monitoramento por satélites do desmatamento por corte raso na Amazônia Legal (gratuitamente disponível em: <http://www.obt.inpe.br/prodes/index.php>).

4.2 Processamentos

O processamento dos dados foi realizado em três principais frentes. A primeira, refere-se ao desenvolvimento dos dados primários, sendo eles: a aplicação do algoritmo *Fmask* e o mapeamento de áreas queimadas por meio do MLME (Subseção 4.2.1). A segunda, consistiu na geração do mapeamento de referência (Subseção 4.2.2). Por fim, os dados primários foram integrados em uma álgebra de mapas, gerando o Mapeamento via *Fmask* a ser avaliado (Subseção 4.2.3).

4.2.1 Dados primários


O algoritmo *Fmask* foi aplicado baseado em Flood e Gillingham (2017), sendo que a resolução espacial dos dados de saída adotada neste estudo foi de 30 m nas cenas TOA do OLI e MSI. Entre os alvos disponíveis,

foram utilizados apenas os classificados segundo o *Fmask* como água e sombra de nuvem.

Para o mapeamento de áreas queimadas utilizando o MLME, a metodologia constou de duas etapas: elaboração das imagens fração (solo, vegetação e sombra) e classificação não supervisionada, conforme os trabalhos de Anderson et al. (2005), Shimabukuro et al. (2009) e Lima et al. (2012). Utilizando as bandas do vermelho, infravermelho próximo e médio de reflectância de superfície (BOA) dos sensores OLI e MSI, foi aplicado o MLME, proposto por Shimabukuro e Smith (1991), gerando imagens fração de solo, vegetação e sombra. As amostras para cada fração foram obtidas a partir de “pixels puros” diretamente das imagens (Figura 3 e 4).


A opção por utilizar a imagem fração sombra, é devido a sua capacidade de destacar as áreas queimadas, o que não ocorre com as frações vegetação e solo que apresentam baixa resposta nesses alvos (ANDERE et al., 2015). A partir da fração sombra, a imagem foi classificada por meio do classificador K-médias para gerar 10 classes de forma automática, utilizando 10 iterações.

Figura 3 – Curva espectral das amostras obtidas a partir da imagem do sensor OLI



Fonte: Elaborado pelos autores.

Figura 4 – Curva espectral das amostras obtidas a partir da imagem do sensor MSI



Fonte: Elaborado pelos autores.

4.2.2 Mapeamento de referência

Para obter o mapeamento de referência, foi necessário refinar o mapeamento a partir do MLME. Assim, as etapas a seguir foram executadas.

Obtida a classificação na etapa anterior, foram mantidas somente as classes correspondentes às áreas queimadas. Em seguida, foi realizada a etapa de edição manual por um especialista para diminuir os erros de omissão e comissão, devido à confusão espectral com outros alvos, tais como corpos hídricos e sombras de nuvens (ANDERSON et al., 2015; ANDERE et al., 2015; SILVA JUNIOR et al., 2017). Este dado foi considerado como o de maior acurácia e de confiança disponível para a área de estudo. Portanto, o dado de referência utilizado nas próximas etapas deriva da classificação da imagem fração sombra com edições manuais.

4.2.3 Mapeamento via *Fmask*

Para gerar o Mapeamento via *Fmask*, a fração sombra gerada pelo MLME foi refinada com base nos alvos classificados como água e sombra de nuvem segundo o *Fmask*.

4.3 Validação

Para a etapa de validação, o Mapeamento via *Fmask* foi comparado com o dado de referência estratificado para Floresta e Não Floresta. Dessa forma, o objetivo foi identificar possíveis variações na detecção nessas diferentes coberturas, bem como a acurácia do resultado do mapeamento de áreas queimadas, por meio da análise de sobreposição dos elementos. As ferramentas utilizadas foram as acurácias do produtor e usuário, referente aos erros de omissão e comissão, respectivamente (STORY e CONGALTON, 1986). O erro de omissão ocorre quando uma área é excluída de uma classe a qual pertence de acordo com o dado de referência, enquanto que o erro de comissão ocorre quando uma área é incluída erroneamente em uma classe (CONGALTON e GREEN, 2009). Além disso, também foi calculada a exatidão global, a qual representa os dados corretamente classificados dividido pelo total de unidades de mapeamento, bem como o índice Kappa, conforme recomendações de Congalton e Green (2009).

5 Resultados e Discussões

Os resultados e discussões apresentados a seguir foram organizados visando abordar os mapeamentos de áreas queimadas dos dados de referência e do Mapeamento via *Fmask* (Subseção 4.1), e as perguntas levantadas na introdução deste artigo (Subseção 4.2 ao 4.4).

5.1 Mapeamentos de áreas queimadas

As áreas queimadas mapeadas de referência utilizando o sensor OLI totalizaram 197,5 km², sendo que cerca de 30% foram observados em áreas de floresta. O tamanho médio dos polígonos foi de 0,130 ± 1,089 km² por polígono. A área mínima observada foi de 0,001 km² e máxima de 29,413 km² (Figura 5-A).

O Mapeamento via *Fmask* utilizando o sensor OLI totalizou 213,112 km² de áreas queimadas, sendo que cerca de 31% foram observados em áreas de floresta. O tamanho médio dos polígonos foi $0,075 \pm 0,810$ km² por polígono. A área mínima observada foi de 0,0001 km² e a máxima de 29,413 km² (Figura 5-B).

O resultado do Mapeamento via *Fmask* para o sensor OLI apresentou cerca de 15 km² a mais de área de queimadas que o dado de referência, apesar de ter sido corretamente classificado dentro da estratificação de floresta. Além disso, o tamanho médio dos polígonos se mostrou menor, assim como a área mínima observada, embora a área máxima tenha se mostrado igual ao dado de referência.

Utilizando o sensor MSI, as áreas queimadas mapeadas de referência totalizaram 189,432 km², sendo que 33% foram observadas em áreas de floresta. O tamanho médio dos polígonos foi de $0,150 \pm 1,106$ km² por polígono. A área mínima observada foi de 0,001 km² e máxima de 23,504 km² (Figura 6-A).


Para o Mapeamento via *Fmask* utilizando o sensor MSI, as áreas queimadas mapeadas totalizaram 236,598 km², sendo que 34% foram observadas em áreas de floresta. O tamanho médio dos polígonos foi $0,057 \pm 0,603$ km² por polígono. A área mínima observada foi de 0,001 km² e máxima de 23,468 km² (Figura 6-B).

O resultado do Mapeamento via *Fmask* para o sensor MSI apresentou quase 50 km² a mais de área de queimadas que o mapeamento de referência, apesar de ter sido corretamente classificado dentro da estratificação de floresta. Além disso, o tamanho médio dos polígonos se mostrou menor, embora a área mínima e a área máxima observada tenham se mostrado idêntica ao dado de referência.

De forma geral, durante o processo de edição manual da classificação, os principais erros de inclusão ocorreram em áreas de sombra de nuvens e de relevo, além das bordas de corpos hídricos. Em relação aos erros de omissão, foram observados principalmente em áreas que visivelmente

queimaram fora da cobertura de Floresta (áreas de pasto, por exemplo), que devido ao tipo de vegetação (principalmente gramíneas) de alguma forma estavam em processo de regeneração, não sendo assim mapeado como áreas queimadas.

Figura 5 – Mapeamento de áreas queimadas realizado com o sensor OLI a bordo do Satélite Landsat 8.




Fonte: Elaborado pelos autores.

5.2A aplicação do algoritmo *Fmask* refina o mapeamento de áreas queimadas gerado pelo MLME?

Sim. A exatidão global da imagem OLI foi de 99,84%, e a do MSI de 99,51%. O Mapeamento via *Fmask* em ambos os sensores apresentou alta acurácia do produtor, acima de 97%. A acurácia do usuário da imagem OLI variou entre 87% e 100% (Quadro 1), enquanto que no MSI, esse valor variou entre 77% e 99% (Quadro 2).

O índice Kappa do Mapeamento via *Fmask* na imagem OLI em cobertura de Floresta foi de 0,93, enquanto que em cobertura de Não Floresta de 0,97. Já na imagem MSI em área de Floresta, esse valor é de 0,87 e em região de Não Floresta de 0,88. Nesse contexto, embora os dados apresentem melhores resultados no sensor OLI, o Kappa do mapeamento via sensor MSI também se mostrou adequado, permitindo minimizar a presença de elementos que não sejam queimadas e consequentemente dando suporte aos mapeamentos semi-automáticos por meio da integração do algoritmo *Fmask* com o MLME.

Figura 6 – Mapeamento de áreas queimadas realizado com o sensor MSI a bordo do Satélite Sentinel-2A. A - Dado de referência (azul); B - Mapeamento via *Fmask* (vermelho)



Fonte: Elaborado pelos autores.

5.3 Qual a exatidão de um modelo de classificação semi-automático de áreas queimadas baseado na integração do algoritmo *Fmask* ao MLME?

A confusão de algoritmos na discriminação de áreas queimadas dos alvos de nuvens, sombra de nuvens e de relevo, e bordas de cursos de água já foi reportada por Chuvieco e Congalton (1988) e posteriormente corroborada por Bastarrika et al. (2011). Apesar disso, no mapeamento da imagem OLI, na cobertura de Floresta, as áreas queimadas que não foram corretamente classificadas ocorrem principalmente devido às extensões de água não identificadas pelo algoritmo *Fmask*. Entretanto, a acurácia do usuário foi de quase 87%. Enquanto que as áreas queimadas em cobertura de Não Floresta que não foram classificadas corretamente localizavam-se na sua maioria em regiões que apresentam sombra devido ao relevo. Assim, o *Fmask* não conseguiu detectá-las. Apesar disso, a acurácia do usuário foi de mais de 95%.

Quadro 1 – Matriz de confusão do Mapeamento via *Fmask* da Imagem OLI.
F: Floresta; NF: Não Floresta; Q: Queimada; NQ: Não Queimada

				Mapeamento via <i>Fmask</i> (km ²)				Total	Acurácia do Produto r (%)
				OLI					
				F		NF			
				Q	NQ	Q	NQ		
Dado de Referência (km ²)	OLI	F	Q	58,33	0,01	0,00	0,00	58,35	99,97
			NQ	8,75	5206,76	0,00	0,00	5215,51	99,83
		NF	Q	0,00	0,00	137,25	1,84	139,09	98,68
			NQ	0,00	0,00	7,05	5498,00	5505,05	99,87
Total				67,08	5206,78	144,29	5499,84	10917,99	
Acurácia do Usuário (%)				86,95	100,00	95,12	99,97		

Fonte: Elaborado pelos autores.


Quadro 2 – Matriz de confusão do Mapeamento via *Fmask* da Imagem MSI.
 F: Floresta; NF: Não Floresta; Q: Queimada; NQ: Não Queimada

				Mapeamento via <i>Fmask</i> (km ²)				Total	Acurácia do Produto r (%)
				MSI					
				F		NF			
				Q	NQ	Q	NQ		
Dado de Referência (km ²)	MSI	F	Q	62,81	0,72	0,00	0,00	63,53	98,87
			NQ	18,20	5192,33	0,00	0,00	5210,52	99,65
		NF	Q	0,00	0,00	125,87	3,17	129,04	97,54
			NQ	0,00	0,00	31,17	5487,00	5518,17	99,44
Total				81,01	5193,05	157,05	5490,17	10921,27	
Acurácia do Usuário (%)				77,54	99,99	80,15	99,94		

Fonte: Elaborado pelos autores.

De maneira análoga, a acurácia do usuário no mapeamento MSI nas áreas de cobertura de Floresta foi comprometida (menor que 78%) também devido às extensões de curso d'água não identificadas pelo algoritmo *Fmask*. Em ambos os sensores, isso ocorre já que este algoritmo é menos preciso que o MLME. Além disso, as áreas de transição entre nuvem e sombra de nuvem causaram uma confusão entre os limites destes atributos, conforme pode ser analisado na Figura 7. Desta forma, o algoritmo *Fmask* classificou certas áreas como nuvens (Figura 7-B), as quais não são eliminadas na etapa de refinamento do mapeamento baseado na fração sombra. Esse evento gerou erros de comissão (Figura 7-C) devido à sobreposição destes dados (Figura 7-D). Nesta vertente, caso o elemento nuvem fosse usado como um segundo critério de filtro, o valor de áreas erroneamente classificadas como queimada na cobertura de Floresta na imagem MSI cairia de 18,20 para 15,58 km², e a acurácia do usuário aumentaria de 77,54% para 80%. Esse mesmo evento também ocorre nas regiões de Não Floresta, onde o erro de comissão cairia de 31,17 para 23,27 km², e a acurácia aumentaria de 80,15% para cerca de 84%.

Figura 7 – Exemplificação da confusão entre os limiares dos atributos de nuvens e sombra de nuvens no mapeamento via *Fmask* de MSI. A - Cena do MSI (R11;G8A;B4); B - Mapeamento de nuvens segundo o algoritmo *Fmask* (azul); C - Área de baixa reflectância segundo o MLME (vermelho); D - Integração dos itens A, B e C.



Fonte: Elaborado pelos autores.

5.4O mapeamento refinado via *Fmask* é afetado pelo tipo de cobertura Floresta ou Não Floresta?

Ainda não foi possível responder essa questão. A exatidão global do mapeamento via *Fmask* na imagem OLI foi de 99,84%, enquanto que a do MSI foi de 99,51%, não demonstrando assim discrepância significativa entre ambos os sensores. Entretanto, destaca-se aqui que embora a acurácia do produtor entre as duas aplicações não tenha demonstrado diferenças relevantes, a acurácia do usuário na imagem OLI foi ligeiramente superior a do MSI. Em área de Floresta, essa diferença foi de 9,41%, enquanto que em área de Não Floresta, esse valor chegou a quase 15%. Esse fenômeno ocorreu, uma vez que a cena do MSI apresentou maior porcentagem de nuvens e sombra de nuvens, e não necessariamente devido às características inerentes de cada sensor propriamente dito. Embora as cenas do sensor OLI e MSI sejam do mesmo dia, há uma pequena diferença no horário de aquisição entre ambas, o que influenciou na maior presença dos alvos nuvem e sombra de nuvem na cena do MSI.

Além disso, embora a acurácia do usuário tenha sido maior em cobertura de Não Floresta (chegando a ser 8% mais preciso no mapeamento via *Fmask* da imagem OLI), as áreas de cobertura de Floresta apresentam a maior quantidade de corpos hídricos, gerando assim maiores confusões nos mapeamentos.

6 Conclusões

Tendo em vista que as queimadas podem influenciar nas emissões de carbono e potencialmente apresentar implicações nos níveis de CO₂ na atmosfera (ARAGÃO et al., 2016), a identificação dessas áreas, bem como a sua análise espaço-temporal é de grande relevância. Nesse contexto, ferramentas que auxiliem esse monitoramento se fazem necessárias. Assim, a integração das abordagens *Fmask* e MLME se apresenta como uma nova alternativa viável em estudos de detecção de áreas queimadas, refinando dados e dando suporte a mapeamentos semi-automáticos com alta acurácia. Além disso, foi possível confirmar que a metodologia é satisfatória dentro de uma perspectiva de multi-sensores, possibilitando assim aumentar a disponibilidade de dados com média resolução espacial para uma mesma região em intervalos menores de revisita, com a integração de imagens da Série Landsat e Sentinel-2. Entretanto, as condições da atmosfera no momento da aquisição dos dados de diferentes plataformas podem influenciar na aplicação do *Fmask*.

O uso do algoritmo *Fmask* aperfeiçoa o processo de detecção de queimadas dentro da abordagem do MLME e reduz significativamente a confusão entre elementos na classificação, uma vez que o algoritmo refina os dados previamente. Apesar disso, a sua precisão é baixa se comparada ao MLME com edição manual, uma vez que este modelo analisa elementos em nível de sub-pixel e foi refinado com base na interpretação de um especialista. Uma possibilidade de refinamento do resultado seria a aplicação de um segundo filtro com os atributos de nuvens, também identificados pelo algoritmo *Fmask*, já que existe certa confusão no conceito de nuvens e sombra de nuvens, bem como os limites destes elementos, entre o *Fmask* e o MLME.

Considerando que as coberturas de floresta apresentaram cursos d'água que o *Fmask* não pôde detectar com exatidão, mais estudos são requeridos para analisar a real influência do tipo de cobertura florestal no

algoritmo *Fmask*. Além disso, os trabalhos futuros indicados também incluem a análise de outras abordagens que possam também refinar o mapeamento baseado na fração sombra, bem como a avaliação de outros sensores para tornar ainda mais robusta a disponibilidade de dados para a Amazônia Brasileira.

Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), processos 131241/2016-8, 140377/2018-2, 309247/2016-0 e 16/02018-2, e à Comissão de Aperfeiçoamento de Pessoal do Nível Superior (CAPES) - código de financiamento 001, pelo suporte financeiro.

Referências

- ANDERE, L.; ANDERSON, L. O.; DUARTE, V.; ARAI, E.; ARAGÃO, J. R. L.; ARAGÃO, L. E. O. C. Dados multitemporais do sensor MODIS para o mapeamento de queimadas na Amazônia. **Anais do XVII Simpósio Brasileiro de Sensoriamento Remoto (SBSR)**, João Pessoa, 2015. pp. 3534-3541.
- ANDERSON, L. O.; ARAGÃO, L. E. O. C.; LIMA, A. D.; SHIMABUKURO, Y. E. Detecção de cicatrizes de áreas queimadas baseada no modelo linear de mistura espectral e imagens índice de vegetação utilizando dados multitemporais do sensor MODIS. **TERRA no Estado do Mato Grosso, Amazônia Brasileira. Acta Amazonica**, v. 35, n. 4, 2005. pp. 445-456.
- ANDERSON, L. O.; ARAGÃO, L. E. O. C.; GLOOR, M.; ARAI, E.; ADAMI, M.; SAATCHI, S. S.; MALHI, Y.; SHIMABUKURO, Y. E.; BARLOW, J.; BERENQUER, E.; DUARTE, V. Disentangling the contribution of multiple land covers to fire-mediated carbon emissions in Amazonia during the 2010 drought. **Global biogeochemical cycles**, v. 29, n. 10, 2015. pp. 1739-1753.

- ANDERSON, L. O.; CHEEK, D.; ARAGÃO, L. E.; ANDERE, L.; DUARTE, B. Development of a Point-based Method for Map Validation and Confidence Interval Estimation: A Case Study of Burned Areas in Amazonia. **Journal of Remote Sensing & GIS**, v. 6, n. 193, 2017. pp. 1-9.
- ALENCAR, A.; NEPSTAD, D.; DIAZ, M. C. V. Forest understory fire in the Brazilian Amazon in ENSO and non-ENSO years: area burned and committed carbon emissions. **Earth Interactions**, v. 10, n. 6, 2006. pp. 1-17.
- ALMEIDA, C. A. D.; COUTINHO, A. C.; ESQUERDO, J. C. D. M.; ADAMI, M.; VENTURIERI, A.; DINIZ, C. G., DESSAY, N.; DURIEUX, L.; GOMES, A. R. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. **Acta Amazonica**, v. 46, n. 3, 2016. pp. 291-302.
- ARAGÃO, L. E. O. C.; SHIMABUKURO, M.; CARDOSO, L. O.; ANDERSON, A.; LIMA, B. P. Frequência de queimadas durante secas recentes. In: **Secas na Amazônia: Causas e Consequências**. Oficina de textos, 2013. pp. 259–279.
- ARAGÃO, L. E.; POULTER, B.; BARLOW, J. B.; ANDERSON, L. O.; MALHI, Y.; SAATCHI, S.; PHILLIPS, O. L.; GLOOR, E. Environmental change and the carbon balance of Amazonian forests. **Biological Reviews**, v. 89, n. 4, 2014, pp. 913-931.
- ARAGÃO, L. E. O. C.; ANDERSON, L. O.; LIMA, A.; ARAI, E. Fires in Amazonia. In: **Interactions Between Biosphere, Atmosphere and Human Land Use in the Amazon Basin**. Springer Berlin Heidelberg, 2016, pp. 301-329.
- AZZARI, G.; LOBELL, D. B. Landsat-based classification in the cloud: An opportunity for a paradigm shift in land cover monitoring. **Remote Sensing of Environment**, v. 202, 2017. pp. 64-74.
- BASTARRIKA, A.; CHUVIECO, E.; MARTÍN, M. P. Mapping burned areas from Landsat TM/ETM+ data with a two-phase algorithm: Balancing omission and commission errors. **Remote Sensing of Environment**, v. 115, n. 4, 2011. pp. 1003-1012.
- BUSH, M. B.; SILMAN, M. R.; TOLEDO, M. B.; LISTOPAD, C.; GOSLING, W. D.; WILLIAMS, C.; OLIVEIRA, P. E.; KRISSEL, C.. Holocene fire and occupation in Amazonia: records from two lake districts. **Philosophical Transactions**

- of the **Royal Society B-Biological Sciences**, v. 362, n. 1478, 2007. pp. 209-218.
- CARDOZO, F. S.; PEREIRA, G.; SHIMABUKURO, Y. E.; MORAES, E. C. Análise do uso do Modelo Linear de Mistura Espectral (MLME) para o mapeamento das áreas queimadas no Estado de Rondônia no ano de 2010. **Anais do XVI Simpósio Brasileiro de Sensoriamento Remoto (SBSR)**, Foz do Iguaçu, 2013. pp. 7265-7272.
- CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. 2nd ed. (Boca Raton, FL: CRC Press), 2009. 183p.
- DRUSCH, M.; DEL BELLO, U.; CARLIER, S.; COLIN, O.; FERNANDEZ, V.; GASCON, F.; HOERSCH, B.; ISOLA, C.; LABERINTI, P.; MARTIMORT, P.; MEYGRET, A.; SPOTO, F.; SY, O.; MARCHESE, F.; BARGELLINI, P. Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. **Remote Sensing of Environment**, v. 120, 2012. pp. 25-36.
- EHLERS, M.; JANOWSKY, R.; GAEHLER, M. New remote sensing concepts for environmental monitoring. In: **Proc. SPIE**, 2002. pp. 1-12.
- FLOOD, N.; GILLINGHAM, S. **Python Fmask Documentation: Release 0.4.5**. Disponível em: <<http://pythonfmask.org>>. Acessado em agosto de 2017.
- FOGA, S. C.; SCARAMUZZA, P.; GUO, S.; ZHU, Z.; DILLEY, R.; BECKMANN, T.; SCHMIDT, G. L.; DWYER, J. L.; HUGHES, M. J.; LAUE, B. Cloud detection algorithm comparison and validation for operational Landsat data products. **Remote Sensing of Environment**, v. 194, 2017. pp. 379-390.
- FONSECA, L. M.; MANJUNATH, B. S. Registration techniques for multisensor remotely sensed imagery. **PE & RS- Photogrammetric Engineering & Remote Sensing**, v. 62, n. 9, 1996. pp. 1049-1056.
- GATTI, L. V.; GLOOR, M.; MILLER, J. B.; DOUGHTY, C. E.; MALHI, Y.; DOMINGUES, L. G.; BASSO, L. S.; MARTINEWSKI, A.; CORREIA, C. S. C.; BORGES, V. F.; FREITAS, S.; BRAZ, R.; ANDERSON, L. O.; GRACE, J.; PHILLIPS, O. L.; LLOYD, J. Drought sensitivity of Amazonian carbon balance revealed by atmospheric measurements. **Nature**, v. 506, 2014. pp. 76-80.

- GÓMEZ, C.; WHITE, J. C.; WULDER, M. A. Optical remotely sensed time series data for land cover classification: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 116, 2016. pp. 55-72.
- HAWBAKER, T. J.; VANDERHOOF, M. K.; BEAL, Y. J.; TAKACS, J. D.; SCHMIDT, G. L.; FALGOUT, J. T.; WILLIAMS, B.; FAIRAUX, N. M.; CALDWELL, M. K.; PICOTTE, J. J.; HOWARD, S. M.; STITT, S.; DWYER, J. L. Mapping burned areas using dense time-series of Landsat data. **Remote Sensing of Environment**, v. 198, 2017. pp. 504-522.
- HERMOSILLA, T.; WULDER, M. A.; WHITE, J. C.; COOPS, N. C.; HOBART, G. W. Regional detection, characterization, and attribution of annual forest change from 1984 to 2012 using Landsat-derived time-series metrics. **Remote Sensing of Environment**, v. 170, 2015, pp. 121-132.
- INPE, INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Manuais - Tutorial de Geoprocessamento: Modelos de Mistura**. 2006. Disponível em: <<http://www.dpi.inpe.br/spring/portugues/tutorial/modelos.html>>. Acessado em junho de 2017.
- INPE, INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Programa de Monitoramento de Queimadas. Focos de calor**. 2017. Disponível em: <<http://www.inpe.br/queimadas/portal>>. Acessado em: jun-2017.
- ITERPA. **Povos Indígenas**. Disponível em: <<http://www.iterpa.pa.gov.br/content/povos-indigenas>>. Acessado em 14 outubro de 2017.
- JIMÉNEZ-MUÑOZ, J. C.; MATTAR, C.; BARICHIVICH, J.; SANTAMARÍA-ARTIGAS, A.; TAKAHASHI, K.; MALHI, Y.; SOBRINO, J. A.; SCHRIER, G. V. Record-breaking warming and extreme drought in the Amazon rainforest during the course of El Niño 2015–2016. **Scientific Reports**, v. 6, n. September, 2016. 33130p.
- KEY, C. H.; BENSON, N. C. **Landscape assessment (LA)**, 2006. Disponível em: <https://www.researchgate.net/profile/Nate_Benson/publication/241688462_Landscape_Assessment_LA_Sampling_and_Analysis_Methods/links/5772f39408aeeec38954173c/Landscape-Assessment-LA-Sampling-and-Analysis-Methods.pdf>. Acessado em agosto de 2017.

- KLEIN, I.; GESSNER, U.; DIETZ, A. J.; KUENZER, C. Global WaterPack – A 250m resolution dataset revealing the daily dynamics of global inland water bodies. **Remote Sensing of Environment**, v. 198, 2017. pp. 345-362.
- LASHOF, D. A. The contribution of biomass burning to global warming: an integrated assessment. In: **Global biomass burning. Atmospheric, climatic, and biospheric implications**. 1991.
- LIMA, A.; SILVA, T. S. F.; FEITAS, R. M.; ADAMI, M.; FORMAGGIO, A. R.; SHIMABUKURO, Y. E. Land use and land cover changes determine the spatial relationship between fire and deforestation in the Brazilian Amazon. **Applied Geography**, v. 34, 2012. pp. 239-246.
- MAIN-KNORN, M.; PFLUG, B.; DEBAECKER, V.; LOUIS, J. Calibration and validation plan for the L2a processor and products of the Sentinel-2 mission. **The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 40, n. 7, 2015. 1249p.
- MARINO, E.; RANZ, P.; TOMÉ, J. L.; NORIEGA, M. Á.; ESTEBAN, J.; MADRIGAL, J. Generation of high-resolution fuel model maps from discrete airborne laser scanner and Landsat-8 OLI: A low-cost and highly updated methodology for large areas. **Remote Sensing of Environment**, v. 187, 2016. pp. 267-280.
- MÜLLER-WILM U. **Sentinel-2 MSI—Level-2A Prototype Processor Installation and User Manual**. Telespazio VEGA Deutschland GmbH: Darmstadt, Germany, 2016. 51p.
- PADILLA, M.; STEHMAN, S. V.; RAMO, R.; CORTI, D.; HANTSON, S.; OLIVA, P.; ALONSO-CANAS, I.; BRADLEY, A. V.; TANSEY, K.; MOTA, B.; PEREIRA, J. M.; CHUVIECO, E. Comparing the accuracies of remote sensing global burned area products using stratified random sampling and estimation. **Remote Sensing of Environment**, v. 160, 2015. pp. 114-121.
- PADILLA, M.; OLOFSSON, P.; STEHMAN, S. V.; TANSEY, K.; CHUVIECO, E. Stratification and sample allocation for reference burned area data. **Remote Sensing of Environment**, v. 203, 2017. pp. 240-255.
- PENHA, T. V.; PLETSCH, M. A. J. S.; SILVA JUNIOR, C. H. L.; KORTING, T. S.; FONSECA, L. M. G. Detecção e delimitação automática de corpos hídricos em imagens Sentinel-2: uma proposta de integração do algoritmo Fmask aos

- índices espectrais NDWI e MNDWI. **Anais do XVIII GEOINFO**, Salvador, 2017. pp. 340-345.
- ROY, D. P.; BOSCHETTI, L.; JUSTICE, C. O.; JU, J. The collection 5 MODIS burned area product—Global evaluation by comparison with the MODIS active fire product. **Remote Sensing of Environment**, v. 112, n. 9, 2008. pp. 3690-3707.
- SATO, L. Y. **Tecnologia LIDAR para quantificação dos impactos de incêndios na estrutura**. 2016. Tese de doutoramento. Instituto Nacional de Pesquisas Espaciais (INPE), Pós-Graduação em Sensoriamento Remoto, São José dos Campos, 2016. 98p.
- SAN-MIGUEL, I.; ANDISON, D. W.; COOPS, N. C. Characterizing historical fire patterns as a guide for harvesting planning using landscape metrics derived from long term satellite imagery. **Forest Ecology and Management**, v. 399, 2017. pp. 155-165.
- SEONG, J. C.; HWANG, C. S.; GIBBS, R.; ROH, K.; MEHDI, M. R.; OH, C.; JEONG, J. J. Landsat big data analysis for detecting long-term water quality changes: a case study in the Han River, South Korea. **ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences**, v. 4, 2017. pp.83-89.
- 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, 1991. pp. 16-20.
- SHIMABUKURO, Y. E.; DUARTE, V.; ARAI, E.; FREITAS, R. M.; LIMA, A.; VALERIANO, D. M.; BROWN, I. F.; MALDONADO, M. L. R. Fraction images derived from Terra Modis data for mapping burnt areas in Brazilian Amazonia. **International Journal of Remote Sensing**, v. 30, n. 6, 2009. pp. 1537-1546.
- SHIMABUKURO, Y. E.; MIETTINEN, J.; BEUCHLE, R.; GRECCHI, R. C.; SIMONETTI, D.; ACHARD, F. Estimating burned area in Mato Grosso, Brazil, using an object-based classification method on a systematic sample of medium resolution satellite images. **IEEE Journal of Selected Topics in**

- Applied Earth Observations and Remote Sensing**, v. 8, n. 9, 2015. pp. 4502-4508.
- SILVA, M. P. S.; CAMARA, G.; ESCADA, M. I. S.; SOUZA, R. C. M. Remote-sensing image mining: detecting agents of land-use change in tropical forest areas. **International Journal of Remote Sensing**, v. 29, n. 16, 2008. p. 4803-4822.
- SILVA JUNIOR, C. H. L.; ARAGÃO, L. E. O. C.; ANDERSON, L. O.; PENHA, T. V. Mapeamento de queimadas na Amazônia Legal brasileira utilizando dados MODIS e VIIRS: resultados preliminares. **Anais do XVIII Simpósio Brasileiro De Sensoriamento Remoto (SBSR)**, Santos, 2017. pp. 3475-3482.
- STORY, M.; CONGALTON, R. G. Accuracy assessment: a user's perspective. **Photogrammetric Engineering and Remote Sensing**, v. 52, n. 3, 1986. pp. 397-399.
- SUN, L.; MI, X.; WEI, J.; WANG, J.; TIAN, X.; YU, H.; GAN, P. A cloud detection algorithm-generating method for remote sensing data at visible to short-wave infrared wavelengths. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 124, 2017. pp. 70-88.
- USGS, UNITED STATES GEOLOGICAL SURVEY. **Landsat 8 (L8) Data Users Handbook America**. 2016. Disponível em: <<https://landsat.usgs.gov/documents/Landsat8DataUsersHandbook.pdf>>. Acessado em agosto de 2017.
- VERMOTE, E.; JUSTICE, C.; CLAVERIE, M.; FRANCH, B. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, 2016. pp. 46-56.
- VUOLO, F.; NG, W. T.; ATZBERGER, C. Smoothing and gap-filling of high resolution multi-spectral time series: Example of Landsat data. **International Journal of Applied Earth Observation and Geoinformation**, v. 57, 2017. pp. 202-213.
- ZHU, Z.; WOODCOCK, C. E. Object-based cloud and cloud shadow detection in Landsat imagery. **Remote Sensing of Environment**, v. 118, 2012. pp. 83-94.

- 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, 2015. pp. 269-277.
- WALKER, K. L. Seasonal mixing in forest-cover maps for humid tropics and impact of fluctuations in spectral properties of low vegetation. **Remote Sensing of Environment**, v. 179, 2016. pp. 79-88.
- 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, 2012. pp. 2-10.
- YAN, L.; ROY, D. P.; ZHANG, H.; LI, J.; HUANG, H. An automated approach for sub-pixel registration of Landsat-8 Operational Land Imager (OLI) and Sentinel-2 Multi Spectral Instrument (MSI) imagery. **Remote Sensing**, v. 8, n. 6, 2016. pp. 520.