



Avaliação do Sentinel-2, NDVI e MLME para Mapeamento do Uso e Cobertura da Terra Evaluation of Sentinel-2, NDVI and MLME for Mapping Land Use and Land Cover

Juliana Maria Ferreira de Souza Diniz¹; Daniel Andrade Maciel¹;
Fabio Furlan Gama¹ & Marcos Adami²

¹Instituto Nacional de Pesquisas Espaciais, Divisão de Observação da Terra, Av. dos Astronautas 1758, Jardim da Granja, 12227-010, São José dos Campos, SP, Brasil

²Instituto Nacional de Pesquisas Espaciais, Centro Regional da Amazônia, Av. Perimetral 2651, Parque de Ciência e Tecnologia Guamá, 66077-830, Belém, PA, Brasil

E-mails: juju-dinizsvm@hotmail.com; daniel.maciel@inpe.br; fabio@dpi.inpe.br; marcos.adami@inpe.br

DOI: http://doi.org/10.11137/2020_2_381_391; Recebido: 13/08/2018 Aceito: 16/10/2019

Resumo

A floresta amazônica é considerada um dos maiores reservatórios de carbono da Terra. No entanto, mudanças antrópicas indiscriminadas no uso e cobertura da terra, como a conversão da floresta em áreas agrícolas e pastagens, provocam grandes impactos ambientais na floresta. A utilização de técnicas que auxiliam o mapeamento do uso e cobertura da terra se torna cada vez mais necessária. Índices como o NDVI (Índice de Vegetação por Diferença Normalizada) e MLME (Modelo Linear de Mistura Espectral) são amplamente utilizados para estudos da vegetação, por permitirem analisar e realçar parâmetros e feições em imagens de sensoriamento remoto. Desse modo, o objetivo deste trabalho foi avaliar o desempenho do mapeamento do uso e cobertura da terra (LULC), utilizando dados do satélite Sentinel-2B, adicionado com o índice de vegetação NDVI e com o MLME, utilizando o classificador *Random Forest* (RF). Para a realização deste estudo, foram utilizadas imagens do sensor MSI do Sentinel-2B e calculados os índices NDVI e MLME, derivados da imagem Sentinel-2B. A partir da segmentação da imagem, foi realizada a extração de atributos para cada segmento. A classificação foi realizada pelo método RF e a validação foi realizada através da simulação de Monte Carlo, observando-se os valores de índice Kappa e Acurácia Global (AG). Para avaliar a diferença obtida com a adição das variáveis NDVI e MLME, quatro cenários de classificação foram realizados. Notou-se que os cenários apresentaram resultados semelhantes de índice Kappa e AG, não apresentando diferença significativa entre eles. A utilização das faixas espectrais do Sentinel-2B/MSI se mostrou uma boa alternativa para realizar o mapeamento do uso e cobertura da terra, facilitando as etapas de processamento. No entanto, a inclusão do MLME para a separação da classe Floresta Degradada (FD), se mostrou significativa. Além disso, observou-se que a utilização do classificador RF apresenta bons resultados para o mapeamento do uso e cobertura da terra.

Palavras-chave: classificação orientada a objeto; Random Forest; simulação de Monte Carlo

Abstract

The Amazon Rainforest is considered one of the largest carbon reservoirs on Earth. However, indiscriminate anthropogenic land use and land cover changes, such as the conversion of forest to agricultural areas and pasture, generate large environmental impacts. The use of remote sensing techniques which helps mapping land use and land cover (LULC) becomes increasingly necessary. Vegetation indices such as NDVI (Normalized Difference Vegetation Index) and the Spectral Linear Mixing Model (MLME) are widely used for mapping and vegetation studies, because they allow analyzing and highlighting vegetation parameters and features in remotely sensed imagery. Thus, the aim of this paper was to evaluate the performance of land use and land cover (LULC) mapping using Sentinel-2B satellite data, added with the NDVI vegetation index and MLME using the Random Forest (RF) classifier. For this study, we used Sentinel-2B/MSI images and both NDVI and MLME were calculated from Sentinel-2B bands. From image segmentation, attribute extraction was performed for each segment. The classification was performed by the RF method and validated using a Monte Carlo Simulation, observing Kappa and Global Accuracy (GA) values. To evaluate the gain obtained with the addition of NDVI and MLME variables, four classification scenarios were performed. We noticed that these scenarios presented similar results of Kappa index and GA, with no significant difference between them. The use of the Sentinel-2B/MSI spectral bands showed a good alternative to mapping LULC, facilitating processing steps. However, the inclusion of the MLME for separation of the Degraded Forest (DF) class showed to be significant. In addition, it was shown that the use of the Random Forest classifier presents good results for the LULC mapping.

Keywords: object-based classification; Random Forest; Monte Carlo simulation

1 Introdução

A floresta amazônica é considerada um dos maiores reservatórios de carbono da Terra, armazenando cerca de 80 a 200 Pg de carbono em sua biomassa, além de abrigar grande parte da diversidade biológica mundial e desempenhar diversos serviços ecossistêmicos, sendo desta forma, uma área de intenso estudo e de debates relacionados às mudanças climáticas (Fearnside, 2007; Mitchard *et al.*, 2014; Nogueira *et al.*, 2015). No entanto, mudanças antrópicas indiscriminadas no uso e cobertura da terra, como a conversão da floresta em áreas agrícolas e pastagens, geram impactos ambientais negativos, como perda de biodiversidade e emissão de gases causadores do efeito estufa (Banco Mundial, 2010; Martin *et al.*, 2013).

A utilização de dados de sensoriamento remoto, devido às suas características sinópticas, tem permitido mapear o uso e cobertura da terra (LULC) de forma rápida e eficaz, possibilitando a identificação, avaliação e monitoramento em escalas espaciais e temporais (Engelbrecht *et al.*, 2017). Dentre as transformações que os dados de sensoriamento remoto podem ser submetidos, a conversão para índices de vegetação é amplamente utilizada. O Índice de Vegetação por Diferença Normalizada (NDVI; Rouse *et al.*, 1974) é amplamente utilizado para análises da vegetação, por estar diretamente relacionado à parâmetros biofísicos como biomassa, atividade fotossintética, índice de área foliar, entre outros (Acerbi-Júnior *et al.*, 2015; Silveira *et al.*, 2017).

O Modelo Linear de Mistura Espectral (MLME), proposto por Shimabukuro & Smith (1991), é outra técnica que permite realçar algumas feições da imagem, através da geração das imagens fração, sendo as mais usuais as frações: solo, vegetação e sombra. A utilização do MLME tem se mostrado uma técnica eficaz para o mapeamento de florestas degradadas, principalmente por possibilitar a separação entre as frações solo e vegetação (Chen *et al.*, 2015; Shimabukuro *et al.*, 2017). De acordo com Shimabukuro *et al.* (2014) a fração vegetação derivada do MLME apresenta características semelhantes ao NDVI, permitindo assim destacar a cobertura vegetal. Enquanto a fração solo

permite realçar áreas de solo exposto, facilitando a identificação de áreas onde ocorrem cortes seletivos e cortes rasos. Por outro lado, a fração sombra realça os corpos d'água e áreas cuja geometria de visada contemplem sombreamentos.

Além da utilização de técnicas de transformação dos dados de sensoriamento remoto para auxiliar no mapeamento do uso e cobertura da terra, a escolha do classificador também apresenta grande importância para a eficiência do mapeamento (Lu & Weng, 2007; Sothe *et al.*, 2017). Dentre os diversos algoritmos, o classificador *Random Forest* (RF) tem sido muito utilizado nas últimas décadas por apresentar bons resultados na classificação e agilidade no processamento dos dados (Breiman, 2001; Pal, 2005; Rodriguez-Galiano *et al.*, 2012; Du *et al.*, 2015; Belgiu & Drăgu, 2016). Assim como a utilização de técnicas de transformação dos dados e a escolha do classificador, a definição do sensor é fundamental para o mapeamento do uso e cobertura da terra. A missão Sentinel-2, desenvolvida pela Agência Espacial Europeia (ESA) é parte do programa espacial Copernicus, e tem como objetivo fornecer dados contínuos de alta-resolução temporal para o mapeamento e monitoramento da superfície terrestre (Gascon *et al.*, 2017).

Desse modo, o objetivo deste trabalho foi avaliar o desempenho do mapeamento do uso e cobertura da terra (LULC), utilizando dados do satélite Sentinel-2B, adicionado com o índice de vegetação NDVI e com o MLME, utilizando o classificador *Random Forest*.

2 Material e Métodos

A área de estudo de aproximadamente 4.500 km², está localizada na região de Ariquemes – RO, pertencente à região amazônica (Figura 1). De acordo com Carvalho *et al.*, (2016), a região apresenta temperatura média de 25,5° e precipitação anual em torno de 2.290 mm/ano, sendo caracterizada com clima tropical chuvoso, tipo Aw segundo a classificação de Köppen. Além disso, a região é caracterizada por um intenso processo de fragmentação florestal, que está diretamente relacionado ao início do processo de desmatamento na Amazônia Legal, nas décadas de 1960 e 1970 (Becker, 2005; Ferreira & Salati, 2005) e que perdura atuais.

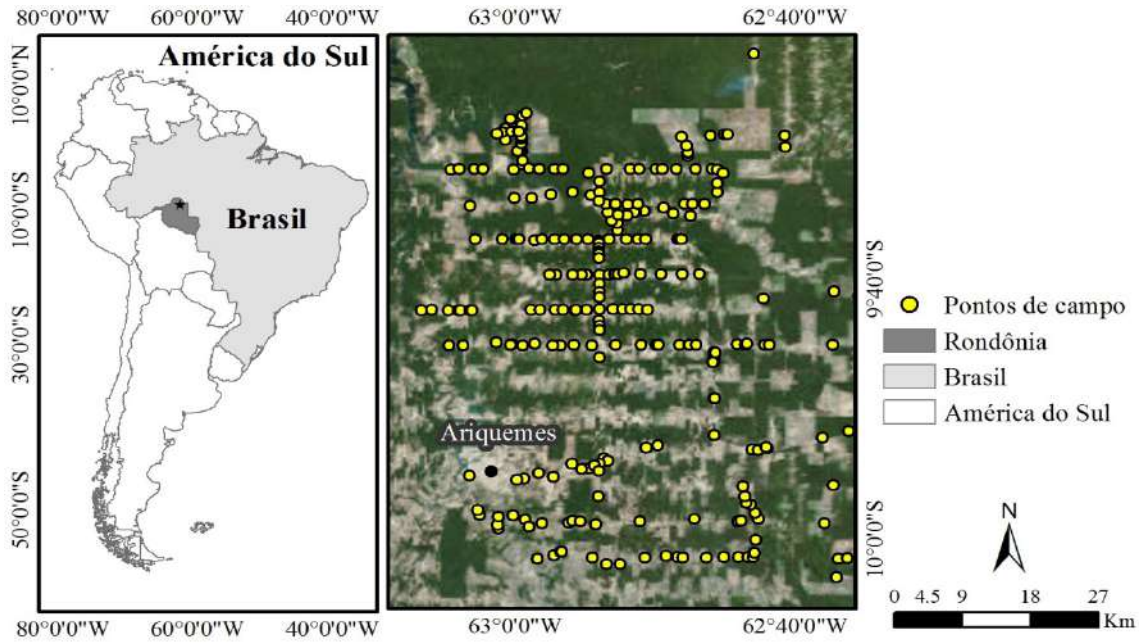


Figura 1 Localização geográfica da área de estudo na região de Ariquemes-RO com a distribuição dos pontos coletados em campo.

As etapas para realização deste trabalho podem ser sintetizadas nos seguintes processos:
 1) aquisição da imagem; 2) pré-processamento; 3)

extração dos atributos; 4) repetições; 5) mapeamento e; 6) validação (Figura 2).

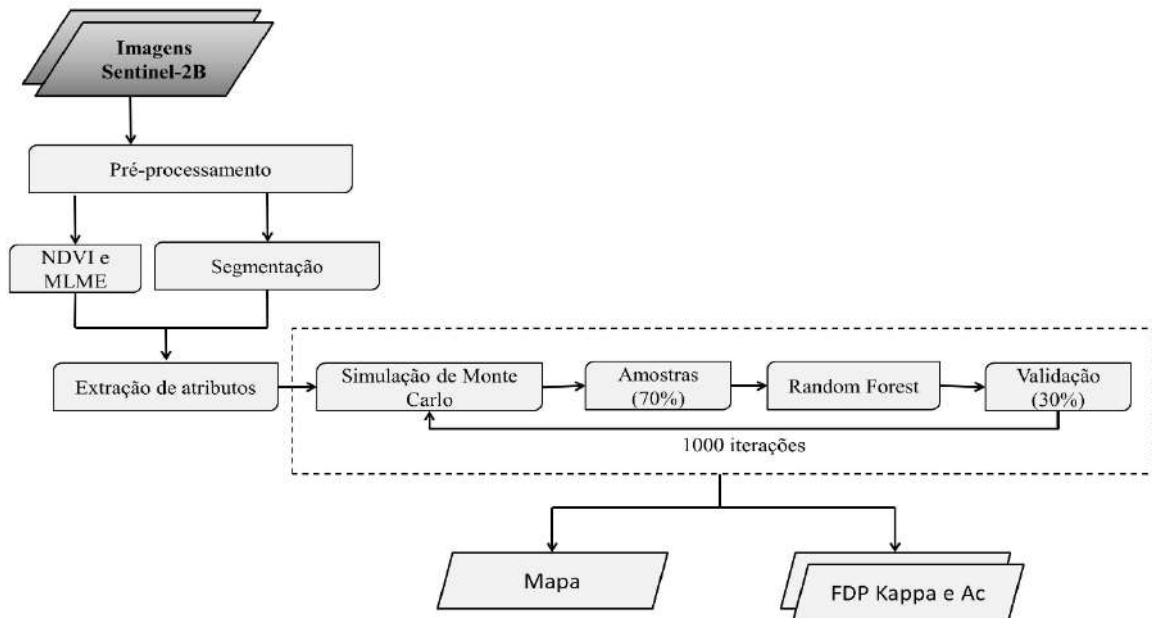


Figura 2 Fluxograma das etapas metodológicas.

Foram utilizadas imagens do sensor *Multispectral Instrument* (MSI) a bordo do satélite Sentinel-2B obtidas no dia 29/08/2017, correspondentes aos *Tiles*: T20LMQ e T20LNQ. As imagens foram disponibilizadas gratuitamente pelo site da Agência Espacial Europeia (ESA). Na etapa

de pré-processamento foi realizada a conversão dos valores de nível de cinza (ND) para refletância no topo da atmosfera e posterior correção atmosférica das imagens utilizando-se o método *Dark Object Subtraction 1* (DOS1) proposto por Chavez Júnior (1988), utilizando-se o *plugin Semi-Automatic*

Classification Plugin Documentation (Congedo, 2017), disponível no *software* QGIS 3.0.1. A partir das imagens corrigidas foi gerado um mosaico das duas cenas e posteriormente o recorte da área de estudo.

Para a classificação do uso e cobertura da terra, realizou-se inicialmente a segmentação do mosaico da área de estudo, através de um algoritmo de segmentação por crescimento de regiões, utilizando-se as faixas espectrais 2, 3, 4 e 8 do sensor MSI, que apresentam a resolução espacial de 10 m. Foram utilizadas as faixas espectrais originais para garantir que o NDVI e MLME fossem avaliados *per si*. A segmentação foi realizada no *software* SPRING 5.5.2 (Câmara *et al.*, 1996), onde foram definidos os parâmetros de similaridade e área mínima em pixels iguais a 15 e 150, respectivamente. Os índices NDVI (Equação 1) e MLME (Equação 2) foram calculados no *software* ENVI 4.8 utilizando-se as faixas espectrais 2, 3, 4 e 8 do sensor MSI.

$$NDVI = (NIR-RED) / (NIR+RED) \quad (1)$$

Onde: NIR = refletância na faixa espectral do Infravermelho Próximo (Banda 8) e RED = refletância na faixa espectral do vermelho (Banda 4).

$$r_i = a * vege_i + b * solo_i + c * \acute{a}gua_i + e_i \quad (2)$$

Onde: r_i = resposta do pixel na banda i ; a , b e c = proporções de vegetação, solo e água (ou sombra), respectivamente; $vege_i$ = resposta espectral da componente vegetação na banda i ; $solo_i$ = resposta espectral do componente solo na banda i ; $\acute{a}gua_i$ = resposta espectral da componente água ou sombra na banda i ; e_i = erro na banda i ; e i = bandas do sensor MSI.

Para a realização das classificações foram utilizadas as variáveis: bandas do sensor MSI do Sentinel-2B (13 bandas), NDVI, e frações vegetação, solo e sombra do MLME. Então, foram extraídos os atributos dos segmentos para cada uma das variáveis: média, valor mínimo e máximo, amplitude, desvio padrão e soma para cada variável e cada segmento. A partir da extração de atributos foi realizada a classificação orientada a objeto utilizando-se o classificador RF (Liaw & Wiener, 2002) no *software* R 3.3.2 (R Core Team, 2018). O método RF define o número de árvores de decisão (Ntree) e o número de variáveis a serem testadas (Mtry). Neste estudo foi utilizado um Ntree igual a 500 e o Mtry foi correspondente à raiz quadrada

do número de variáveis de entrada (Gislason *et al.*, 2006). Além disso, o RF possibilita calcular a importância das variáveis através do índice *Mean Decrease Gini* (MDG) durante o processamento do modelo (Breiman, 2002; Calle & Urrea, 2011). Foram mapeadas as seguintes classes de uso e cobertura da terra: Agricultura (AG), Área urbana (AU), Cursos d'água (CA), Floresta Primária (FP), Floresta Degradada (FD), Floresta Queimada (FQ), Mineração (MI), Pastagem (PA) e Sucessões Secundárias (SS).

Para avaliar a diferença obtida com a introdução das variáveis NDVI e MLME, foram realizados os diferentes cenários de classificações (Tabela 1), onde a utilização das bandas do Sentinel-2B engloba as 13 bandas espectrais e no MLME estão incluídas as três frações (vegetação, solo e sombra).

Tabela 1 Descrição dos cenários de classificações realizados.

Cenários	Descrição
Sent	13 Bandas do Sentinel-2B
SentN	Sent + NDVI
SentM	Sent + MLME
SentNM	Sent + NDVI + MLME

A validação dos cenários de classificações empregados foi realizada através de uma simulação de Monte Carlo com 1000 iterações. A cada iteração, foram definidas aleatoriamente, 70% das amostras para treinamento e 30% para validação em cada classe temática, utilizando-se um total de 242 amostras de campo (Figura 1). A simulação de Monte Carlo é uma técnica que busca simular um sistema real, a partir de experimentos aleatórios, tendo como base a teoria de grandes amostras (Rubinstein, 1981; Almeida *et al.*, 2010; Saito *et al.*, 2011; Moreira *et al.*, 2016).

A partir das amostras de validação para cada iteração, foram calculados os valores de Índice Kappa (Congalton & Green, 2009) e Acurácia Global, resultando em uma função de distribuição de probabilidades (FDP) para ambos os índices. Através da distribuição dos valores de Kappa e Acurácia Global, foi possível determinar um intervalo de credibilidade, onde se desprezou 2,5% dos maiores e menores valores, de forma a garantir que 95% dos dados estejam contidos neste intervalo. A partir da FDP foram extraídos os valores mais frequentes de

Kappa e Acurácia Global para cada cenário.

Para avaliar a diferença nos resultados das classificações, foi realizada a subtração dos valores estimados de Kappa e Acurácia Global para cada iteração da simulação de Monte Carlo para cada um dos cenários. Após isto, os resultados foram comparados através de um gráfico *boxplot* com os valores da diferença. A discriminação entre as classes temáticas foi avaliada através das acurácias do produtor e usuário, calculadas através da matriz de confusão, utilizando-se os valores mais frequentes observados nas 1000 iterações.

Tabela 2 Resultados obtidos com os diferentes cenários de classificação.

Cenários	Kappa	Acurácia	Intervalos de Credibilidade (95%)	
			Kappa (k)	Acurácia Global (AG)
Sent	0,77	0,81	$0,69 \leq k \leq 0,85$	$0,74 \leq AG \leq 0,88$
SentN	0,77	0,81	$0,69 \leq k \leq 0,85$	$0,74 \leq AG \leq 0,88$
SentM	0,78	0,81	$0,68 \leq k \leq 0,84$	$0,73 \leq AG \leq 0,87$
SentNM	0,76	0,80	$0,68 \leq k \leq 0,84$	$0,73 \leq AG \leq 0,87$

A partir da simulação de Monte Carlo, foi possível obter as funções de distribuição de probabilidade (FDP) do Kappa e da Acurácia Global (Figura 3). Nota-se que os cenários apresentaram comportamento semelhante tanto na FDP do

3 Resultados e Discussões

A partir dos resultados das classificações realizadas (Tabela 2) foi possível observar que o cenário SentM obteve o maior valor de índice Kappa (0,78), no entanto, em uma análise geral, nota-se que não houve diferença entre os cenários. Pode-se afirmar que o valor de Kappa em média foi de 0,77 e a Acurácia Global foi de 0,81, quando contabilizadas todas as simulações. É interessante realçar a baixa amplitude da variação destes índices, o que indica a estabilidade dos resultados da classificação.

índice Kappa quanto da AG, o que é comprovado observando-se os gráficos *boxplot* (Figura 4) que representam as diferenças obtidas entre as distribuições dos cenários analisados, mostrando que não houve diferença significativa entre os cenários.

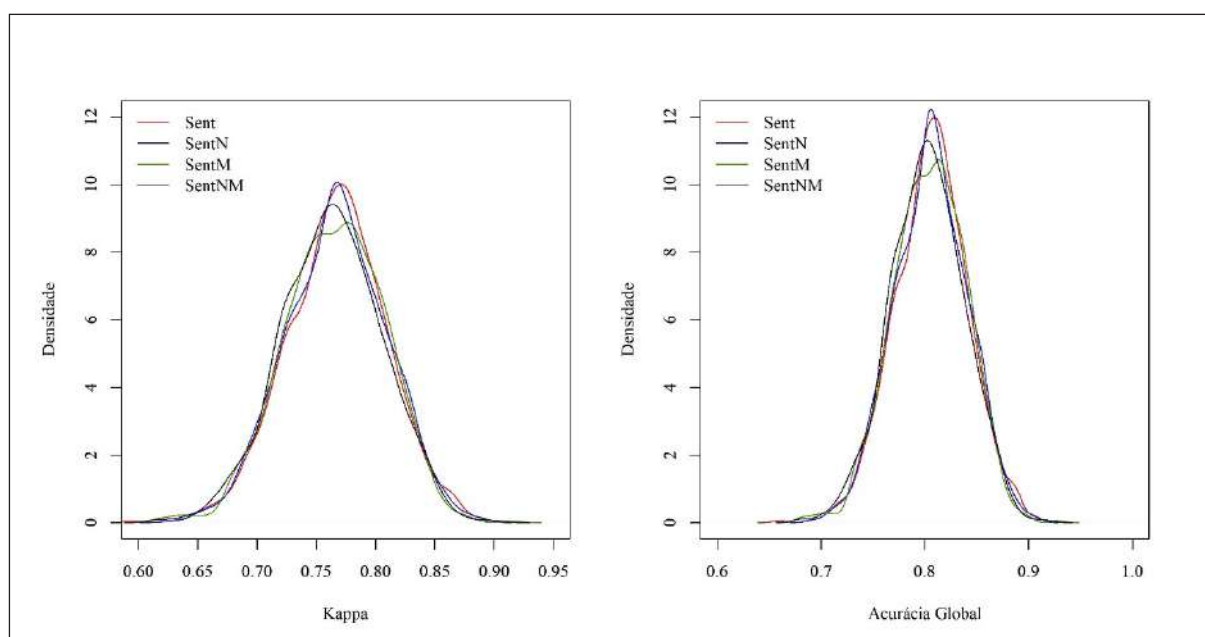


Figura 3 Função de distribuição de probabilidade (FDP) para os valores de Kappa e Acurácia Global.

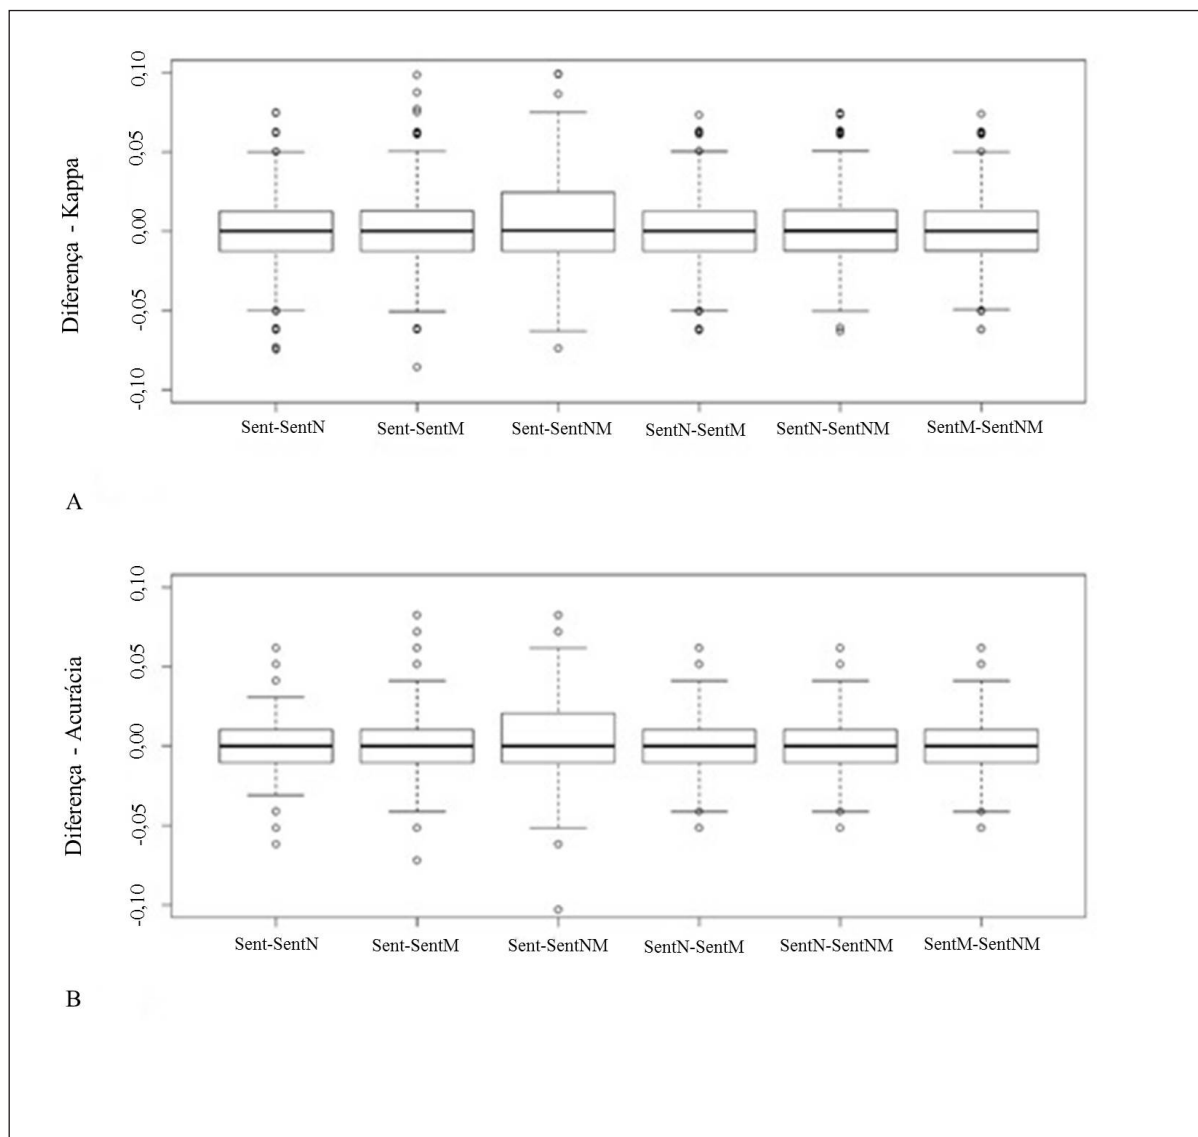


Figura 4 A B Gráficos Boxplot com os valores de diferença observados para as subtrações dos valores obtidos para cada repetição da simulação de Monte Carlo para o índice Kappa e Acurácia Global, respectivamente.

O gráfico de importância das variáveis (Figura 5) mostra a participação de cada variável dentro do processo de classificação. Neste caso, nota-se que as variáveis relacionadas à vegetação foram as que receberam o maior valor de importância. No cenário Sent, a variável que apresentou a maior importância, com um valor de MDG de 7,54 foi a média da banda 5, que se encontra na faixa espectral *red-edge* (705 nm). Já no cenário SentN, a variável com maior importância foi a média do NDVI (7,88), enquanto nos cenários SentM e SentNM a média da fração vegetação do MLME apresentou a maior importância, com 7,06 e 6,25 do valor de MDG, respectivamente.

As bandas da faixa espectral *red-edge* são caracterizadas por apresentarem um forte aumento na refletância da vegetação (Filella & Penuelas, 1994), e se mostraram importantes para aplicações nas áreas agrícolas, florestal, mapeamento do uso e cobertura da terra e outras (Forkuor *et al.*, 2018). Para o mapeamento do uso e cobertura da terra, a presença das bandas *red-edge* tem apresentado melhora na acurácia e na discriminação entre as classes de vegetação (Schuster *et al.*, 2012; Forkuor *et al.*, 2018). Este comportamento também foi observado pelo gráfico de importância (Figura 5), onde a faixa espectral da banda 5, obteve altos valores de importância em todos os cenários analisados.

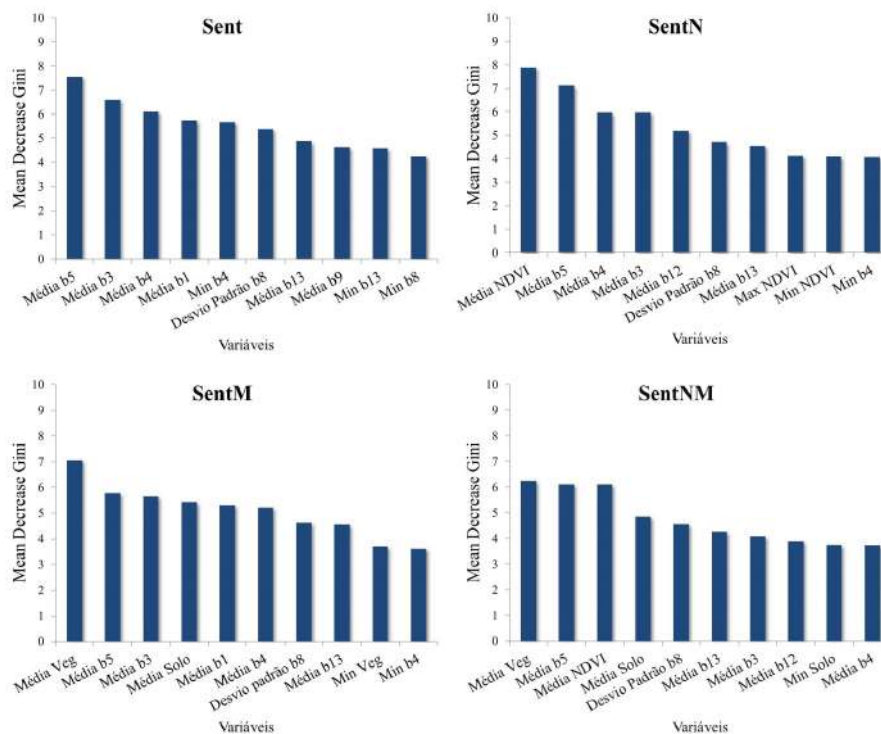


Figura 5 Gráficos de importância das variáveis para cada cenário empregado.

Analisando-se a discriminação entre as classes temáticas, através das acurácias do produtor e usuário (Figura 6), nota-se que houve um comportamento semelhante para todos os cenários empregados, com uma boa discriminação das classes AU, FQ, MI e CA em todos os cenários, apresentando valores de Acurácia do Produtor e Usuário iguais

a 100%. Observa-se que os cenários Sent e SentN apresentaram comportamento semelhante. A classe agricultura apresentou boa discriminação em todos os cenários, apresentando valores de Acurácia do Usuário de 90%, enquanto a Acurácia do Produtor variou de 79% a 83%.

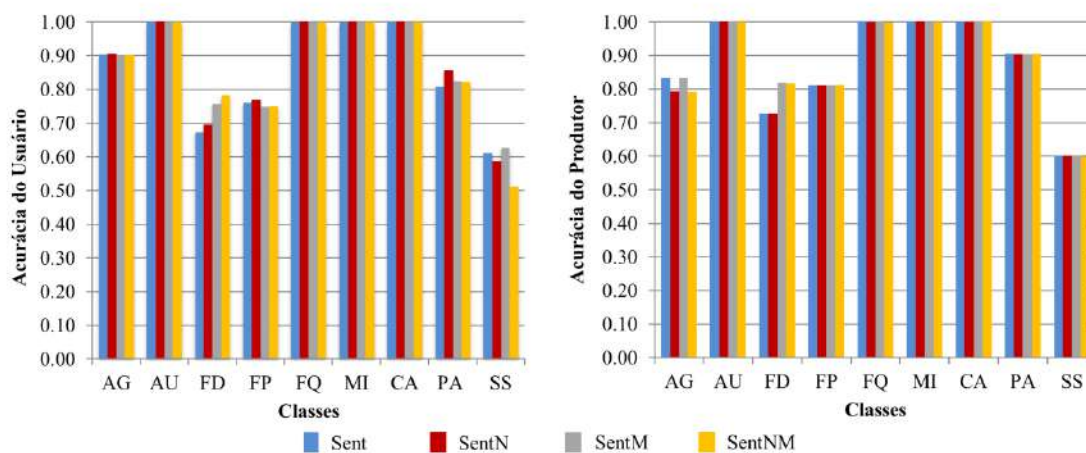


Figura 6 Valor modal das acurácias do produtor e usuário para as classes temáticas analisadas. Legenda: AG: Agricultura; AU: Área Urbana; FD: Floresta Degradada; FP: Floresta Primária; FQ: Floresta Queimada; MI: Mineração; CA: Cursos d'água; PA: Pastagem; SS: Sucessão Secundária.

Em relação à classe Floresta Degradada, nota-se que o cenário SentNM apresentou uma melhor discriminação, com valores da Acurácia do Produtor e Usuário iguais a 82% e 78%, respectivamente. Nesse caso, houve uma diminuição no erro de omissão e comissão de 9% e 11%, respectivamente,

em relação ao cenário Sent. Ao se analisar a Acurácia do Usuário, percebe-se um ganho crescente com a adição dos índices NDVI e do MLME, no entanto, em relação à acurácia do produtor nota-se que os cenários SentM e SentNM apresentaram resultados superiores, mostrando que a inclusão do MLME

foi significativa para o mapeamento da classe Floresta Degradada, principalmente por possibilitar a separação entre as frações solo e vegetação, o que também foi observado por Chen *et al.* (2015) e Shimabukuro *et al.* (2017).

O cenário SentN apresentou uma melhora de 5% na Acurácia do Usuário em relação ao Sent para a discriminação da classe pastagem, no entanto, não apresentou diferença dos demais cenários em relação à acurácia do produtor.

Dentre as classes temáticas analisadas, a classe Sucessão Secundária foi a que apresentou os menores valores de Acurácia do Produtor e Usuário. O cenário SentM apresentou o melhor valor de Acurácia do Usuário (63%), o que representou uma melhora de 4% em relação ao cenário SentN, mas uma melhora de 12% em relação ao cenário SentNM. Esta queda nos cenários SentN e SentNM pode estar relacionada à adição do NDVI, presente nesses cenários. Vieira *et al.* (2003), realizando uma classificação das sucessões florestais utilizando imagens Landsat, observaram que não houve variação do NDVI significativamente entre as classes sucessionais, enquanto Sader *et al.* (1989), observaram que o NDVI não representa um bom preditor da estrutura de povoamentos florestais.

Além disso, nota-se que a classe SS apresenta altos erros de omissão e comissão (40% e 37%, respectivamente) no cenário SentM, o que está relacionado à facilidade com que esta classe pode ser confundida com as classes FP e FD, apresentando

uma grande dificuldade para a sua discriminação, mesmo em campo. Carreiras *et al.* (2014) observaram que o aumento no erro de omissão no mapeamento das florestas secundárias está relacionado com a alta dinâmica do uso e cobertura da terra na região, o que também é observado neste trabalho, onde a região apresenta um intenso processo de antropização. Além disso, os autores observaram que as florestas secundárias no estágio inicial, apresentam uma maior confusão com áreas agrícolas e pastagens, enquanto as florestas secundárias que se encontram no estágio avançado se confundem com as florestas primárias (Steininger, 2000; Lucas *et al.*, 2000; Carreiras *et al.*, 2014).

Observando-se o mapa de uso e cobertura da terra obtido com o cenário Sent (Figura 7), percebe-se uma boa discriminação entre as classes de vegetação e as classes de uso antrópico, ao se analisar o zoom da imagem é possível notar que as áreas de agricultura e pastagem foram bem diferenciadas das áreas de floresta nativa. No entanto, observando-se o grande fragmento de área florestal na parte superior da imagem, que corresponde a área da Floresta Nacional do Jamari, nota-se uma grande confusão entre as classes de Floresta Degradada e Floresta Primária, além de algumas manchas de Sucessão Secundária, sendo que esta região, por se tratar de um Parque Nacional é formada majoritariamente por Floresta Primária. Este resultado é esperado, visto que ao se avaliar as Acurácias do Produtor e do Usuário dessas classes, notou-se essas confusões.

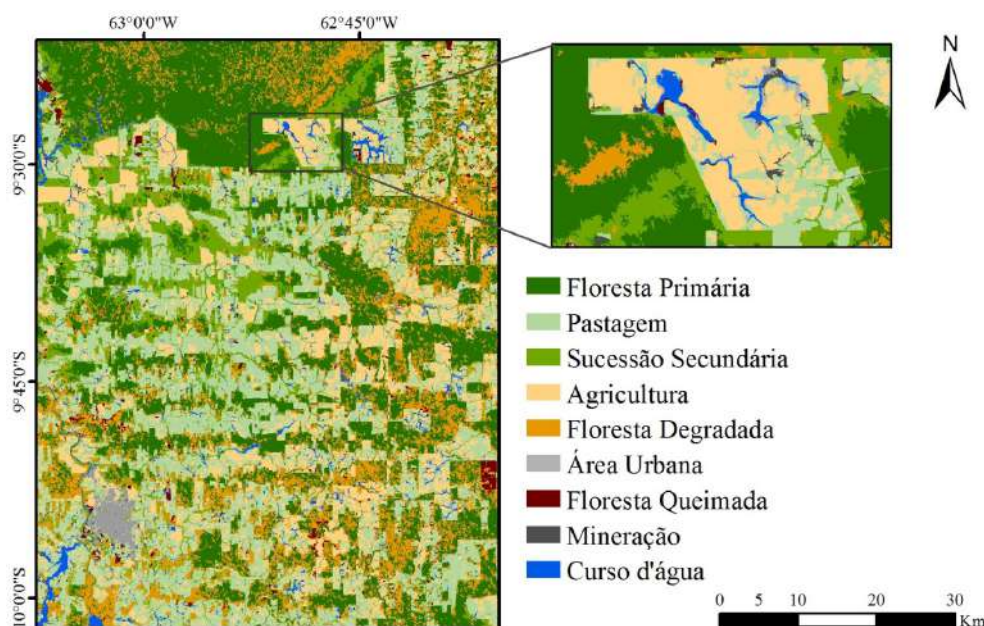


Figura 7 Mapa de uso e cobertura da terra com o cenário Sent.

Os resultados obtidos demonstraram que o classificador RF foi capaz de realizar os mapeamentos com os diferentes métodos obtendo altos valores de acurácias e índice Kappa, como também foi observado nos trabalhos de vários autores ao se realizar o mapeamento do uso e cobertura da terra, obtendo resultados satisfatórios (Rodriguez-Galiano *et al.*, 2012; Sothe *et al.*, 2017; Furkuor *et al.*, 2018).

Muitos estudos empregaram o MLME para o mapeamento do uso e cobertura da terra (Souza Júnior *et al.*, 2003; Santiago *et al.*, 2014; Hirye *et al.*, 2015; Shimabukuro *et al.*, 2017) e outros empregaram o NDVI (Vieira *et al.*, 2003; Usman *et al.*, 2015; Sothe *et al.*, 2017). No entanto, poucos estudos verificaram a efetividade da utilização direta de cada um deles para o mapeamento, como foi empregado na metodologia deste estudo, onde foi possível comparar e diferenciar os benefícios obtidos com a utilização do MLME e do NDVI para a região amazônica e com a utilização do sensor Sentinel-2B.

4 Conclusão

Foi possível obter bons resultados de Acurácia Global e Índice Kappa para os quatro cenários analisados, sendo que não houve diferença significativa entre eles. Nesse caso, nota-se que a utilização do cenário Sent, que utiliza as faixas espectrais do Sentinel-2B / MSI se mostra uma boa alternativa para realizar o mapeamento do uso e cobertura da terra, facilitando as etapas de processamento.

Houve uma boa discriminação entre as classes temáticas analisadas, havendo uma maior confusão entre as classes Floresta Primária, Floresta Degradada e Sucessão Secundária, sendo que a inclusão do MLME apresentou melhores resultados para a discriminação da classe Floresta Degradada. Além disso, verificou-se que o classificador *Random Forest* apresentou bons resultados para o mapeamento do uso e cobertura da terra.

Em relação à metodologia abordada, percebe-se que a utilização de cenários de classificação pode auxiliar na tomada de decisão quanto à escolha do método a ser empregado em uma nova classificação, destacando os resultados obtidos em cada abordagem, com a utilização das bandas espectrais do Sentinel-2, do NDVI e do MLME, o que se diferencia das demais abordagens

observadas na literatura.

5 Agradecimentos

Os autores agradecem ao projeto “Monitoramento Ambiental por Satélite no Bioma Amazônia” pelo apoio durante à coleta de dados em campo. O primeiro autor agradece a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, bem como o segundo autor agradece ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro recebido durante a pesquisa. Adicionalmente os autores agradecem ao Dr. Camilo Daleles Rennó e Gabriela Banon pela orientação nas análises estatísticas.

6 Referências

- Acerbi-Junior, F.W.; Silveira, E.M.O.; Mello, J.M.; Mello, C.R. & Scolforo, J.R.S. 2015. Change Detection in Brazilian Savannas using semivariograms derived from NDVI images. *Ciência e Agrotecnologia*, 39: 103-109.
- Almeida, C.A.; Valeriano, D.M.; Escada, M.I.S. & Rennó, C.D. 2010. Estimativa de área de vegetação secundária na Amazônia Legal Brasileira. *Acta Amazônica*, 40(2): 289-302.
- Banco Mundial. 2010. Banco Internacional para Reconstrução e Desenvolvimento. *Estudo de Baixo Carbono para o Brasil - Relatório de Síntese Técnica*. Washington D.C, 292 p.
- Becker, B.K. 2005. Geopolítica da Amazônia. *Estudos Avançados*, 19(53): 71-86.
- Belgiu, M. & Drăgu, L. 2016. Random Forest in Remote Sensing: A Review of Applications and Future Directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114: 24-31.
- Breiman, L. 2001. Random forests. *Machine Learning*, 45(1): 5-32.
- Breiman, L. 2002. Manual on Setting Up, Using, and Understanding Random Forests, *V3.1*. 33p.
- Calle, M.L. & Urrea, V. 2011. Letter to the Editor: Stability of Random Forest Importance Measures. *Briefings in Bioinformatics*, 12(1): 86-89.
- Câmara, G.; Souza, R.C.M.; Freitas, U.M. & Garrido, J. 1996. SPRING: Integrating remote sensing and GIS by object-oriented data modelling. *Computers & Graphics*, 20(3): 395-403.
- Carvalho, R.L.S.; Nascimento, B.I.S.; Querino, C.A.S.; Silva, M.J.G. & Delgado, A.R.S. 2016. Comportamento das séries temporais de temperatura do ar, umidade e pre-

- cipitação pluviométrica no município de Ariquemes (Rondônia-Brasil). *Revista Brasileira de Climatologia*, 18(12): 123-142.
- Carreiras, J.M.B.; Jones, J.; Lucas, R.M. & Gabriel, C. 2014. Land Use and Land Cover Change Dynamics across the Brazilian Amazon: Insights from Extensive Time-Series Analysis of Remote Sensing Data. *PLoS ONE*, 9(8): 1-20.
- Chavez Júnior, P.S. 1988. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. *Remote Sensing of Environment*, 24: 459-479.
- Chen, G.; Powers, R.P.; Carvalho, L.M.T. & Mora, B. 2015. Spatiotemporal patterns of tropical deforestation and forest degradation in response to the operation of the Tucuruí hydroelectric dam in the Amazon basin. *Applied Geography*, 63: 1-8.
- Congalton, R.G. & Green, K. 2009. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. 2º Ed. CRC/Taylor & Francis, Boca Raton, 183p.
- Congedo, L. 2017. Semi-Automatic Classification Plugin Documentation Release 5.3.2.1.
- Du, P.; Samat, A.; Waske, B.; Liu, S. & Li, Z. 2015. Random Forest and Rotation Forest for fully polarized SAR image classification using polarimetric and spatial features. *Journal of Photogrammetry and Remote Sensing*, 105: 38-53.
- Engelbrecht, J.; Theron, A.; Vhengani, L. & Kemp, J. 2017. A Simple Normalized Difference Approach to Burnt Area Mapping Using Multi-Polarisation C-Band SAR. *Remote Sensing*, 9(8): 1-13.
- Fearnside, P.M. 2007. Brazil's Cuiabá-Santarém (BR-163) Highway: The Environmental Cost of Paving a Soybean Corridor Through the Amazon. *Environmental Management*, 39(5): 601-614.
- Ferreira, A.M.M. & Salati, E. 2005. Forças de transformação do ecossistema amazônico. *Estudos Avançados*, 19(54): 25-44.
- Filella, I. & Penuelas, J. 1994. The Red Edge Position and Shape as Indicator of Plant Chlorophyll Content, Biomass and Hydric Status. *International Journal Remote Sensing*, 15(7): 1459-1470.
- Forkuor, G.; Dimobe, K.; Serme, I. & Tondoh, J.E. 2018. Landsat-8 vs. Sentinel-2: examining the added of sentinel-2's red-edge bands to land-use and land-cover mapping in Burkina Faso. *GIScience & Remote Sensing*, 55(3): 331-354.
- Gascon, F.; Bouzinac, C.; Thépaut, O.; Jung, M.; Francesconi, B.; Louis, J.; Lonjou, V.; Lafrance, B.; Massera, S.; Gaudel-Vacaresse, A.; Languille, F.; Alhammoud, B.; Viallefont, F.; Pflug, B.; Bieniarz, J.; Clerc, S.; Pessirot, L.; Trémas, T.; Cadau, E.; Bonis, R.; Isola, C.; Martimort, P. & Fernandez, V. 2017. Copernicus Sentinel-2A Calibration and Products Validation Status. *Remote Sensing*, 9(6): 1-81.
- Gislason, P.O.; Benediktsson, J.A. & Sveinsson, J.R. 2006. Random Forests for land cover classification. *Pattern Recognition Letters*, 27(4): 294-300.
- Hirye, M.C.M.; Alves, D.S. & Kux, H.J.H. 2015. Mapeamento da cobertura da terra na cidade de Altamira (PA) em 2000 e 2010, com a utilização do Modelo Linear de Mistura Espectral de imagens do sensor TM. *Revista Brasileira de Cartografia*, 67(1): 157-168.
- Liaw, A. & Wiener, M. 2002. Classification and Regression by randomForest. *R News – The Newsletter of the R Project*, 2(3): 18-22.
- Lu, D. & Weng, Q. 2007. A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28: 823-870.
- Lucas, R.M.; Honzák, M.; Curran, P.J.; Foody, G.M.; Milne, R.; Brown, T. & Amaral, S. 2000. Mapping the regional extent of tropical forest regeneration stages in the Brazilian Legal Amazon using NOAA AVHRR data. *International Journal of Remote Sensing*, 21(15): 2855-2881.
- Martin, P.A.; Newton, A.C. & Bullock, J.M. 2013. Carbon pools recover more quickly than plant biodiversity in tropical secondary forests. *Proceedings of the Royal Society B*, 280:1-8.
- Mitchard, E.T.A.; Feldpausch, T.R.; Brien, R.J.W.; Lopez-Gonzalez, G.; Monteagudo, A.; Baker, T.R.; Lewis, S.L.; Lloyd, J.; Quesada, C.A.; Gloor, M.; Steege, H.; Meir, P.; Alvarez, E.; Araujo-Murakami, A.; Aragão, L.E.O.C.; Arroyo, L.; Aymard, G.; Bank, O.; Bonal, D.; Brown, S.; Brown, F.I.; Cerón, C.E.; Moscoso, V.C.; Chave, J.; Comiskey, J.A.; Cornejo, F.; Medina, M.C.; Costa, L.; Costa, F.R.C.; Fiore, A.D.; Domingues, T.F.; Erwin, T.L.; Frederickson, T.; Higuchi, N.; Coronado, E.N.H.; Killen, T.J.; Laurance, W.F.; Levis, C.; Magnusson, W.E.; Marimon, B.S.; Marimon Junior, B.H.; Polo, I.M.; Mishra, P.; Nascimento, M.T.; Neill, D.; Vargas, M.P.N.; Palacios, W.A.; Parada, A.; Molina, G.P.; Peña-Claros, M.; Pitman, N.; Peres, C.A.; Poorter, L.; Prieto, A.; Ramirez-Angulo, H.; Correa, Z.R.; Roopsind, A.; Roucoux, K.H.; Rudas, A.; Salomão, R.P.; Schiatti, J.; Silveira, M.; Souza, P.F.; Steininger, M.K.; Stropp, J.; Terborgh, J.; Thomas, R.; Toledo, M.; Torres-Le-

- zama, A.; van Andel, T.R.; van der Heijden, G.M.F.; Vieira, I.C.G.; Vieira, S.; Vilanova-Torre, E.; Vos, V.A.; Wang, O.; Zartman, C.E.; Malhi, Y. & Phillips, O.L. 2014. Markedly divergent estimates of Amazon forest carbon density from ground plots and satellites. *Global Ecology and Biogeography*, 23: 935-946.
- Moreira, E.P.; Valeriano, M.M.; Rennó, C.D. & França, H. 2016. Efeito da topografia sobre a classificação do uso e cobertura da terra por análise de imagens baseada em objetos. *Revista Brasileira de Cartografia*, 68(3): 505-517.
- Nogueira, E.M.; Yanai, A.M.; Fonseca, F.O.R. & Fearnside, P.M. 2015. Carbon stock loss from deforestation through 2013 in Brazilian Amazonia. *Global Change Biology*, 21:1271-1292.
- Pal, M. 2005. Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26: 217-222.
- R Core Team. 2018. R: A language and environment for statistical computing. Vienna: R Foundation for Statistical Computing.
- Rodriguez-Galiano, V.F.; Ghimire, B.; Rogan, J.; Chica-Olmo, M. & Rigol-Sanchez, J.P. 2012. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67: 93-104.
- Rouse, J.W.; Hass, R.H.; Schell, J.A.; Deering, D.W. & Harlan, J.C. 1974. Monitoring the vernal advancements and retrogradation (greenwave effect) of natural vegetation. NASA/GSFC, Type III, Final Report, *Greenbelt*, MD. p.1-371.
- Rubistein, R.Y. *Simulation and the Monte Carlo method*. Canada: John Wiley & Sons, 1981, 282 p.
- Sader, S.; Waide, R.; Lawrence, W. & Joyce, A. 1989. Tropical forest biomass and successional age class relationships to a vegetation index derived from Landsat TM data. *Remote Sensing of Environment*, 28: 143-156.
- Saito, E.A.; Fonseca, L.M.G.; Escada, M.I.S. & Korting, T.S. 2011. Efeitos da mudança de escala em padrões de desmatamento na Amazônia. *Revista Brasileira de Cartografia*, 63(3): 401-414.
- Santiago, A.R.; Almeida, A.C.; Pinheiro, L.B.A.; Clevelario Junior, J. & Silva, S.S. 2014. Proposta metodológica para o mapeamento da vegetação brasileira utilizando o Modelo Linear de Mistura Espectral. *Revista Brasileira de Cartografia*, 66(3): 681-690.
- Schuster, C.; Förster, M. & Kleinschmit, B. 2012. Testing the Red Edge Channel for Improving Land-Use Classifications Based on High-Resolution Multi-Spectral Satellite Data. *International Journal of Remote Sensing*, 33(17): 5583-5599.
- Silveira, E.M.O.; Acerbi-Junior, F.W.; Mello, J.M. & Bueno, I.T. 2017. Object-based change detection using semi-variogram indices derived from NDVI images: The environmental disaster in Mariana, Brazil. *Ciência e Agrotecnologia*, 41: 554-564.
- Shimabukuro, Y.E. & Smith, J.A. 1991. The Least-Squares Mixing Models to Generate Fraction Images Derived From Remote Sensing Multispectral Data. *IEEE Transactions on Geoscience and Remote Sensing*, 29(1): 16-20.
- Shimabukuro, Y.E.; Beuchle, R.; Grecchi, R.C. & Achard, F. 2014. Assessment of forest degradation in Brazilian Amazon due to selective logging and fires using time series of fraction images derived from Landsat ETM+ images. 2014. *Remote Sensing Letters*, 5(9): 773-782.
- Shimabukuro, Y.E.; Arai, E.; Anderson, L.O.; Aragão, L.E.O.C. & Duarte, V. 2017. Mapping degraded forest areas caused by fires during the year 2010 in Mato Grosso State, Brazilian Legal Amazon using Landsat-5 TM fraction images. *Revista Brasileira de Cartografia*, 69(1): 23-32.
- Sothe, C.; Liesenberg, V.; Almeida, C.M. & Schimalski, M.B. 2017. Abordagens para classificação do estágio sucessional da vegetação do Parque Nacional de São Joaquim empregando imagens Landsat-8 e Rapideye. *Bulletim of Geodetic Sciences*, 23(3): 389-404.
- Souza Júnior, C.; Firestone, L.; Silva, L.M. & Roberts, D. 2003. Mapping forest degradation in the Easter Amazon from SPOT 4 through spectral mixture models. *Remote Sensing and Environment*, 87: 494-506.
- Steininger, M.K. 2000. Secondary forest structure and biomass following short and extended land-use in central and southern Amazonia. *Journal of Tropical Ecology*, 16(5):689-708.
- Usman, M.; Liedl, R.; Shahid, M.A. & Abbas, A. 2015. Land use/land cover classification and its change detection using multi-temporal MODIS NDVI data. *Journal of Geographical Sciences*, 25(12): 1479-1506.
- Vieira, I.C.G.; Almeida, A.S.; Davidson, E.A.; Stone, T.A.; Carvalho, C.J.R. & Guerrero, J.B. 2003. Classifying successional forests using Landsat spectral properties and ecological characteristics in eastern Amazônia. *Remote Sensing of Environment*, 87: 470-481.