

INTEGRAÇÃO DE IMAGENS SENTINEL-1 E SENTINEL-2 PARA A CLASSIFICAÇÃO E MAPEAMENTO DE FLORESTA EM PARTE DA MESORREGIÃO SUDESTE PARAENSE

Yago Yguara Parente¹, Philipe Souza Simões², Ricardo José de Paula Souza e Guimarães³,
Christian Nunes da Silva⁴, Clístenes Pamplona Catete^{3,4},

¹Universidade Federal do Rio Grande do Sul, Av. Bento Gonçalves, 9500 – Agronomia – Porto Alegre – RS, Brasil, {yagoparente96@gmail.com}; ²Instituto Nacional de Pesquisas Espaciais, Av. dos Astronautas, 1758 – Jardim da Granja – São José dos Campos – SP, Brasil, {philipe.eca@gmail.com}; ³Laboratório de Geoprocessamento do Instituto Evandro Chagas/SCTIE/MS, Rodovia BR-316 km 7 s/n – Levilândia – Ananindeua – PA, Brasil, {ricardojpsg@gmail.com, ccatete@gmail.com}; ⁴Universidade Federal do Pará, Rua Augusto Corrêa, 01 – Guamá – Belém – PA, Brasil, {cnsgeo@gmail.com, ccatete@gmail.com}

RESUMO

A floresta Amazônica vem sofrendo intensamente com o desmatamento, principalmente nos últimos anos. A utilização de imagens ópticas integradas com SAR podem servir como uma excelente ferramenta para o monitoramento da floresta. O objetivo deste estudo foi determinar a melhor combinação de imagens ópticas / SAR para o mapeamento das áreas de florestas nativas no bioma amazônico. A metodologia utilizada nesse estudo consistiu na classificação supervisionada de imagens Sentinel 1 e 2, utilizando o classificador *Random forest*. A classificação que usou somente imagens SAR obteve as menores acurácias; as que usaram somente imagens ópticas adquiriram acurácias maiores; as que fizeram uso da integração de dados alcançaram as maiores acurácias. O uso de imagens SAR ainda se torna válido devido a capacidade desses sensores em ultrapassar as camadas de nuvens no período chuvoso.

Palavras-chave — Floresta amazônica, Classificação supervisionada, Monitoramento ambiental.

ABSTRACT

The Amazon rainforest has been suffering intensely from deforestation, especially in recent years. The use of optical images integrated with SAR can serve as an excellent tool for monitoring forest. The objective of this study was to determine the best combination of optical images / SAR for mapping native forest areas in the Amazon biome. The methodology used in this study consisted of the supervised classification of Sentinel 1 and 2 images, using the Random forest classifier. The classification that used only SAR images obtained the lowest accuracy; those that used only optical images acquired greater accuracy; those that made use of SAR and optical data integration achieved the highest accuracy. The use of SAR images still becomes valid due to the ability of these sensors to be able to pass through the cloud layers, they are of paramount importance for monitoring during the rainy season.

Key words — Amazon rainforest, Supervised classification, Environmental monitoring.

1. INTRODUÇÃO

O bioma Amazônia vem sofrendo intensamente com o desmatamento, sendo que até o ano de 2020 ocorreu uma redução da área de floresta nativa de 730 mil quilômetros quadrados, o que representa cerca de 20% da área do bioma [1]. A floresta amazônica tem sofrido com o aumento das taxas de desmatamento desde 2017, sendo que somente entre os anos de 2017 e 2020 ela perdeu 34,5 mil quilômetros quadrados de cobertura vegetal, cerca de 5% de todo desmatamento registrado [1]. Segundo [2], políticas e ações fiscalização com foco na proteção da floresta amazônica foram enfraquecidos, incentivando o desmatamento.

As técnicas de sensoriamento remoto oferecem diversos benefícios para o monitoramento da degradação florestal em áreas de difícil acesso, como em regiões de floresta tropical [3], além de reduzirem o custo dessa vigilância. Nesse panorama, o Instituto Nacional de Pesquisas Espaciais (INPE) conta com quatro programas de monitoramento da floresta Amazônica, são eles: PRODES, DETER, DETER Intenso e o DEGRAD. Destes apenas o DETER Intenso utiliza a integração de imagens ópticas e SAR.

O uso de imagens ópticas para o monitoramento da degradação florestal é uma ferramenta bastante utilizada por órgãos de fiscalização ambiental e em diversos estudos científicos. No entanto, esse tipo de dado é limitado na presença de nuvens e tempestades, as quais não podem ser penetradas pela radiação óptica. Uma alternativa é o uso de imagens SAR, que podem fornecer dados independentemente das condições climáticas [4]. A complementaridade das informações ópticas e de radar permite o desenvolvimento de procedimentos de classificação multisensores que exploram ambas as fontes simultaneamente [5].

A Classificação Supervisionada (CS) de imagens é uma técnica bastante utilizada para a avaliação da degradação ambiental, onde não há necessidade de medições de informações de solo de toda a paisagem para determinar as diferentes classes em análise [6]. Dentre as CS's, o *Random forest* vem ganhando destaque, pois apresenta excelentes resultados de suas classificações e apresenta uma ótima capacidade de selecionar as variáveis com as maiores distinções entre as classes em análise [7].

Desse modo, o objetivo foi determinar a melhor combinação de imagens ópticas e/ou SAR para o mapeamento das áreas de florestas nativas no bioma amazônico, em parte da mesorregião sudeste paraense.

2. MATERIAL E MÉTODOS

2.1. Área de estudo

A área de interesse é formada pela interseção de imagens SAR (*Sentinel 1*) e ópticas (*Sentinel 2*), ela está localizada em uma parte da mesorregião sudeste paraense. A área de interesse possui uma extensão de 9.768 km² e é formada pelos municípios de Tucumã, Ourilândia do Norte, São Felix do Xingu e Parauapebas, como pode ser observado na Figura 1.

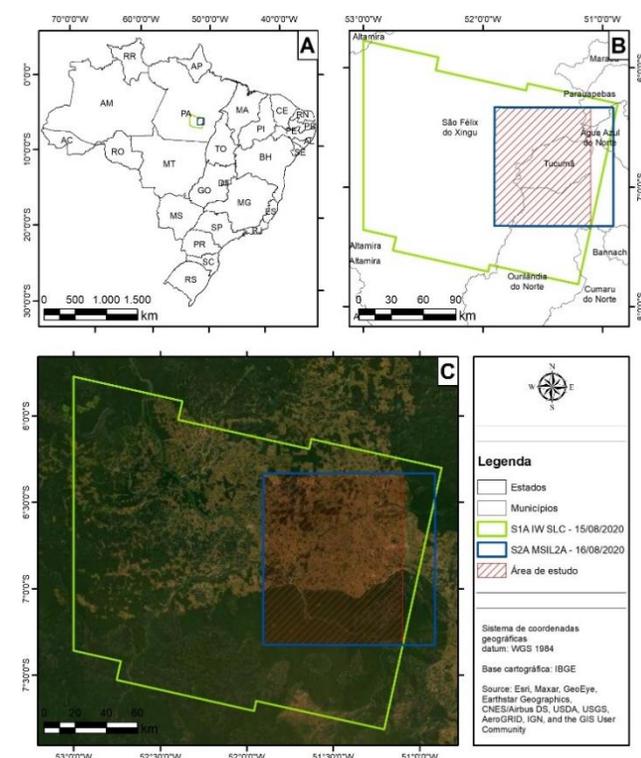


Figura 1. Mapa de localização da área de estudo.

2.2. Aquisição de dados

As imagens *Sentinel 1* e *Sentinel 2* foram adquiridas na plataforma *Copernicus open access hub*, que é uma iniciativa da Agência Espacial Europeia (ESA). O mosaico de imagens de alta resolução, utilizada na validação da classificação, foi acessado por meio do *software Google Earth*. A seleção das imagens *Sentinel 1* e *2* foi baseada na cobertura de nuvens inferior a 10%, para as imagens *Sentinel 2*, e a menor diferença de data, para as imagens *Sentinel 1*.

Considerando a menor taxa de cobertura de nuvens, uma imagem *Sentinel 2A* nível L2A de 16 de agosto de 2020 com 0% de nuvens foi selecionada. O produto S2A já apresenta correção geométrica, radiométrica e atmosférica a nível do

solo. Esse produto possui 12 bandas espectrais de diferentes resoluções espaciais, de 10 até 60 metros.

Uma imagem *Sentinel 1A Interferometric Wide nível 1 Single Look Complex (S1A)* de 15 de agosto de 2020 foi selecionada. O S1A é um sensor SAR que disponibiliza suas imagens na banca C com duas polarizações (VV + VH). A resolução espacial da imagem é de aproximadamente 2x14 metros. Para realizar a avaliação acurácia das imagens classificadas foi utilizado o banco de imagens de alta resolução do *Google Earth*.

2.3. Procedimentos metodológicos

Todas as etapas do procedimento metodológico estão evidenciadas na Figura 2. Ela pode ser dividida em cinco etapas básicas, que são: a aquisição de dados, processamento, integração dos sensores SAR e ópticos, classificação supervisionada e avaliação da acurácia.

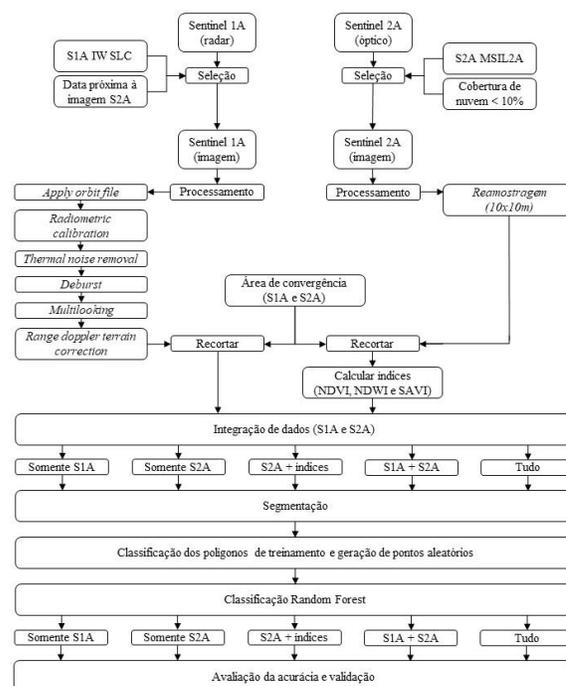


Figura 2. Fluxograma das etapas de aquisição ao processamento dos dados.

O tratamento das imagens foi desenvolvido no *software Sentinel Application Platform (SNAP)*. O pré-processamento das imagens S1A seguiu a metodologia amplamente difundida na literatura [6] [8]. O pré-processamento realizado na imagem S2A consistiu na reamostragem dos pixels para 10 metros. Nesse dado também foi calculado três índices radiométricos: Índice de Vegetação por Diferença Normalizada (NDVI), Índice de Água Diferença Normalizada (NDWI) e o Índice de Vegetação Ajustado pelo Solo (SAVI).

A integração foi executada com cinco combinações diferentes, são elas: i) somente S1A; ii) somente S2A; iii)

S2A com os índices radiométricos; iv) somente S1A e S2A; v) S1A com S2A com os índices radiométricos (tudo).

Foi feito a segmentação das imagens, que resultou em 419.364 segmentos. As amostras de treinamento foram definidas com base nos polígonos da segmentação. À vista disso, foram selecionados aleatoriamente 1% desses polígonos (4.194). Os segmentos selecionados foram interpretados visualmente e classificados em um dos três grupos estipulados para atender aos objetivos do presente estudo, que foram: floresta, não-floresta e hidrografia.

A classificação supervisionada *Random forest* foi utilizada nesse estudo, no software *QGIS Desktop*. O classificador *Random forest* necessita de dois dados básicos (o número de árvores e suas profundidades), que foram baseadas em Tavares et al. (2019). Este autor mostra que a maior acurácia do classificador *Random forest* foi alcançada ao se utilizar 700 árvores e uma profundidade de 420.

A avaliação da acurácia foi usada para a determinação da melhor combinação, foram utilizadas 3 modelos: i) acurácia do usuário e do programa; ii) acurácia global; iii) índice Kappa. Para a determinação dos modelos de avaliação da acurácia, foram gerados 1.000 pontos aleatórios dentro das imagens classificadas. Esses pontos foram classificados tendo como referência as imagens do *software Google Earth*.

3. RESULTADOS

A Figura 3 apresenta os mapas de cada classificação desenvolvida, assim como, as três classes de cobertura da terra analisada (Floresta, Não-floresta e Hidrografia). No mapa é possível observar que os produtos da classificação do *Sentinel 1* apresentam uma espécie de ruído por toda imagem, sendo o responsável por diminuir a acurácia total do produto.

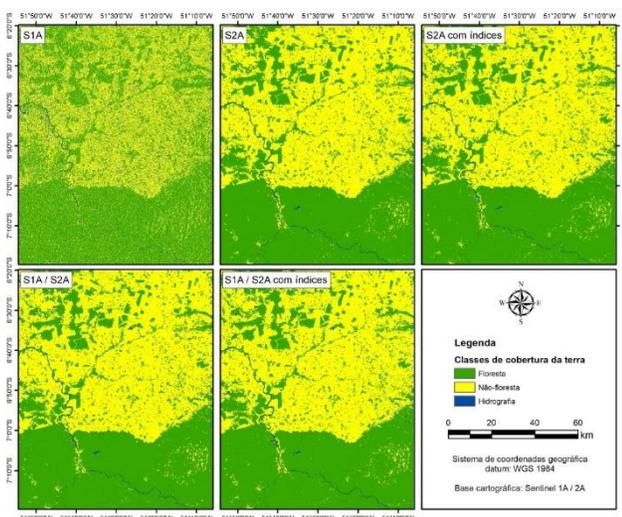


Figura 3. Mapa das combinações de imagens classificadas.

As classificações que integram dados *Sentinel 1* e 2 apresentaram boa separabilidade das classes de análise, destacando-se o contraste da hidrografia. Vale ressaltar que

as classificações ópticas e as sinérgicas não manifestaram grandes diferenças entre si, obtendo acurácia, área e precisão com valores semelhantes entre as classes mapeadas.

A Tabela 1 expõe a Acurácia do Usuário (UA) e a Acurácia do Produtor (PA) para cada uma das classes e para cada classificação. Os piores resultados são atribuídos a classificação que fez uso somente de imagens SAR. Desta, a classe de Hidrografia adquiriu as piores acurácias. Isso se deve principalmente a difícil distinção das classes de Hidrografia e Não-floresta por parte do classificador.

Tabela 1. Acurácia do produtor e do usuário.

Classes	S1A		S2A		S2A com índices		S1A/S2A		Tudo	
	PA (%)	UA (%)	PA (%)	UA (%)	PA (%)	UA (%)	PA (%)	UA (%)	PA (%)	UA (%)
Floresta	76,5	72,8	95,9	97,5	95,3	96,9	95,9	98,5	96,1	97,5
Não-Floresta	66,0	73,6	97,4	95,4	96,8	94,7	98,0	95,1	97,2	95,4
Hidrografia	50,0	21,7	75,0	83,3	75,0	88,2	75,0	83,3	75,0	83,3

As classificações que usam imagens ópticas obtiveram uma melhora de PA e UA, com destaque aquelas que fizeram uso da integração de dados. A classificação S2A com índices adquiriu os melhores resultados de UA, isso se deve ao fato que um dos índices utilizados era o NDWI, que garante uma boa distinção das áreas de hidrográfica e de solo.

A classificação que usou somente imagens SAR obteve as menores acurácias (Tabela 2). As que utilizaram somente imagens ópticas, adquiriram acurácias significativamente maiores quando comparadas à classificação S1A. Enquanto que as classificações que fizeram uso da integração de dados SAR e ópticos alcançaram as maiores acurácias.

Vale destacar que a classificação S2A com índices alcançou menor acurácia do que a classificação S2A, assim como a classificação “Tudo” obteve acurácia menor do que a S1A/S2A. Observou-se também que a classificação “Tudo” e S2A obtiveram as mesmas acurácias. Isso mostra que os índices são responsáveis por diminuir a acurácia do estudo.

Tabela 2. Acurácia global (AG) e índice Kappa (K).

	S1A	S2A	S1A / S2A	S2A - índices	Tudo
K	45,1%	92,7%	93,2%	91,5%	92,7%
AG	70,8%	96,2%	96,5%	95,6%	96,2%

4. DISCUSSÃO

A Tabela 3 apresenta os resultados de acurácia global de alguns autores que realizaram a classificação supervisionada de imagens *Sentinel 1* e 2 com o classificador *Random forest* (RF) e outros (Classification and Regression Tree – CART; Support Vector Machine – SVM; Simple Non-Iterative Clustering – SNIC; k-Nearest Neighbor - KNN).

Tabela 3. Comparação de acurácias nos estudos de CS com o uso de imagens Sentinel 1 e 2.

Autor	Classificador	Acurácia Global				Tudo
		SAR	Óptico	Óptico com índices	Óptico com SAR	
[6]	RF	0,56	0,90	0,89	0,91	0,87
[8]	RF	-	0,70	-	0,78	-
	SVM	-	0,69	-	0,76	-
[9]	RF	0,20	-	0,48	-	0,56
	SVM	0,31	-	0,73	-	0,89
	KNN	0,17	-	0,38	-	0,39
[10]	CART	0,81	0,90	0,89	0,90	0,90
	RF	0,86	0,91	0,92	0,93	0,94
	SVM	0,87	0,90	0,94	0,94	0,94
[11]	RF	0,79	0,84	-	0,88	-
	SNIC	0,73	0,77	-	0,79	-
[12]	RF	0,47 - 0,76	0,39 - 0,78	-	0,53 - 0,82	-
Esse estudo	RF	0,708	0,962	0,956	0,965	0,962

Segundo a Tabela 3, as classificações SAR obtiveram as menores acurácias globais, destacando-se o estudo de [9], onde a acurácia SAR variou entre 17% a 31%. Também é possível notar que a utilização de imagens ópticas, isoladas ou em conjunto com imagens SAR, fornecem um aumento da acurácia..

A utilização de índices ópticos foi responsável por diminuir a acurácia global dos resultados de [6]. Em seu trabalho as classificações ópticas e a integração adquiriram acurácias maiores quando comparadas com as classificações que fizeram o uso dos índices ópticos (NDVI, NDWI e SAVI). Contudo, os resultados de [10] mostram que em apenas um classificador (CART) os índices ópticos reduziram a acurácia, nos demais classificadores os índices aumentaram a acurácia da classificação.

Apesar da baixa acurácia fornecida pelo uso isolado das imagens SAR, a sua integração com imagens ópticas forneceram um aumento da acurácia global da classificação. As maiores acurácias foram fornecidas pelas classificações que usaram o produto da sinergia. A integração de imagens gerou acurácias superiores quando comparadas ao uso isolado de imagens SAR. Contudo, ao se comparar com o uso isolado de imagens ópticas, as acurácias da integração apresentaram resultados um pouco maiores.

5. CONCLUSÕES

Os melhores resultados de acurácia global alcançados foram através da integração de imagens ópticas e SAR. A utilização dos índices ópticos resultaram na diminuição da acurácia. Enquanto que as piores acurácias foram fornecidas o uso isolado de imagens SAR.

Neste contexto, o classificador *Random forest* foi capaz de gerar ótimos produtos. Dessa forma, a utilização desse classificador para o monitoramento da floresta no bioma amazônico se demonstrou válido. Apesar dos piores valores de acurácia incidirem sobre as imagens SAR, o seu uso ainda,

assim se torna valido em regiões que apresentam alto índice pluviométrico e grande coberturas de nuvens. Pois, devido a capacidade dos sensores SAR em conseguir atravessar as camadas de nuvens e tempestades, eles são relevantes para o monitoramento da floresta amazônica, no mapeamento dos Recursos Naturais, e também, do uso e cobertura da Terra.

Por fim, essa pesquisa foi capaz de fornecer dados consistentes e coerentes sobre o monitoramento da floresta amazônica nativa, através da utilização de dados gratuitos e de domínio público.

8. REFERÊNCIAS

- [1] Instituto Nacional de Pesquisas Espaciais (INPE). Terrabrasilis. 2020. Disponível em: <<http://terrabrasilis.dpi.inpe.br/en/home-page/>>. Acesso em: 15/4/2021.
- [2] Carvalho, W. D.; Mustin, K.; Hilário, R. R.; Vasconcelos, I. M.; Eilers, V.; Fearnside, P.M. Deforestation control in the Brazilian Amazon: A conservation struggle being lost as agreements and regulations are subverted and bypassed. *Perspect Ecol Conser*, v. 17, p. 122-130. 2019.
- [3] Herold, M.; Skutsch, M. Monitoring, reporting and verification for national REDD + programmes: Two proposals. *Environmental Research Letters*, v. 6, n. 1, 2011.
- [4] Pereira, L. O.; Freitas, C. C.; Santaanna, S. J. S.; Reis, M. S. Evaluation of Optical and Radar Images Integration Methods for LULC Classification in Amazon Region. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 11, n. 9, p. 3062–3074, 2018.
- [5] Joshi, N.; Baumann, M.; Ehammer, A.; et al. A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. *Remote Sensing*, v. 8, n. 1, p. 1–23, 2016.
- [6] Tavares, P. A.; Beltrão, N. E. S.; Guimarães, U. S.; Teodoro, A. C. Integration of *sentinel-1* and *sentinel-2* for classification and LULC mapping in the urban area of Belém, eastern Brazilian Amazon. *Sensors*, v. 19, n. 5, 2019.
- [7] Belgiu, M.; Drăgu, L. *Random forest* in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 114, p. 24–31, 2016.
- [8] Whyte, A.; Ferentinos, K. P.; Petropoulos, G. P. A new synergistic approach for monitoring wetlands using *Sentinels -1* and *2* data with object-based machine learning algorithms. *Environmental Modelling and Software*, v. 104, p. 40–54, 2018.
- [9] Clerici, N.; Valbuena Calderón, C. A.; Posada, J. M. Fusion of *sentinel-1a* and *sentinel-2A* data for land cover mapping: A case study in the lower Magdalena region, Colombia. *Journal of Maps*, v. 13, n. 2, p. 718–726, 2017.
- [10] Lu, L.; Tao, Y.; Di, L. Object-based plastic-mulched landcover extraction using integrated *Sentinel-1* and *Sentinel-2* data. *Remote Sensing*, v. 10, n. 11, p. 1–18, 2018.
- [11] Mahdianpari, M.; Salehi, B.; Mohammadimanesh, F.; Homayouni, S.; Gill, E. The first wetland inventory map of newfoundland at a spatial resolution of 10 m using *sentinel-1* and *sentinel-2* data on the *Google Earth Engine* cloud computing platform. *Remote Sensing*, v. 11, n. 1, 2019.
- [12] Van Tricht, K.; Gobin, A.; Gilliams, S.; Piccard, I. Synergistic use of radar *sentinel-1* and optical *sentinel-2* imagery for crop mapping: A case study for Belgium. *Remote Sensing*, v. 10, n. 10, p. 1–22, 2018.