



The Biologist (Lima)



ORIGINAL ARTICLE / ARTÍCULO ORIGINAL

COBERTURA BOSCOA AL 2021 EN LA PROVINCIA LEONCIO PRADO, PERÚ

FOREST COVER BY 2021 IN THE LEONCIO PRADO PROVINCE, PERU

Ronald Puerta-Tuesta^{1*} & Raí Fajardo-Gamarra¹

¹Universidad Nacional Agraria de la Selva. Tingo María, Perú.

*Corresponding author: ronald.puerta@unas.edu.pe

Ronald Puerta Tuesta:  <https://orcid.org/0000-0001-5777-7855>

Raí Fajardo Gamarra:  <https://orcid.org/0000-0003-1576-4970>

ABSTRACT

The loss of forests is one of the main environmental problems in Peru and in various parts of the world. The present work aims to calculate the forest cover by 2021 within the Leoncio Prado province, located in the Huánuco region, Peru. Sentinel-2 images were used, which were classified on the Google Earth Engine platform using the Random Forest artificial intelligence algorithm. Likewise, the thematic accuracy of the resulting classification was evaluated using high spatial resolution Planet images. As results, it was found that the study area includes 349,811.47 ha, which represents more than 70% of the total area, while the degraded and intervened areas add up to a total of 131,392.12 ha, which come mainly from the change in use of forest to agricultural areas. Regarding the metrics that evaluate the thematic accuracy of the classification, a value of 0.77 was found in the Kappa Index and 89.14% global accuracy. Therefore, it is concluded that the forest cover is the most predominant in the Leoncio Prado province, which was classified with high thematic accuracy.

Keywords: Artificial intelligence – deforestation – Google Earth Engine – Random Forest – Sentinel-2

doi:10.24039/rtb20222011319

RESUMEN

La pérdida de bosques es uno de los principales problemas ambientales en el Perú y en diversas partes del mundo, en ese sentido el presente trabajo tiene por objetivo calcular la cobertura boscosa al 2021 dentro de la provincia Leoncio Prado, ubicada en la región Huánuco, Perú. Para ello, se utilizó las imágenes Sentinel-2 que fueron clasificadas en la plataforma Google Earth Engine utilizando el algoritmo de inteligencia artificial Random Forest. Asimismo, se evaluó la exactitud temática de la clasificación resultante utilizando imágenes de alta resolución espacial Planet. Como resultados se encontró que la zona de estudio presenta 349 811,47 ha lo que representa más del 70% del área total, mientras que las áreas degradadas e intervenidas suman un total de 131 392,12 ha que proceden principalmente del cambio de uso de bosque a zonas agrícolas. Respecto a las métricas que evalúan la exactitud temática de la clasificación, se encontró un valor de 0,77 en el Índice de Kappa y 89,14% de exactitud global. Por lo que se concluye que la cobertura boscosa es la de mayor predominancia en la provincia Leoncio Prado, la cual fue clasificada con alta exactitud temática.

Palabras clave: Deforestación – Google Earth Engine – inteligencia artificial – Random Forest – Sentinel-2

INTRODUCCIÓN

La deforestación y degradación forestal avanza a una velocidad alarmante en todo el planeta. Se ha calculado que en las últimas cuatro décadas se han perdido en todo el mundo 420 millones de has de bosques (FAO & PNUMA, 2020) y el Perú no es ajeno a esta realidad, del 2010 al 2019 el promedio de la pérdida anual de bosques fue de 151 731 ha, sin embargo; en el 2020 alcanzó su pico más alto con 203 272 ha de bosques arrasados en un solo año (Ministerio del Ambiente - MINAM, 2021), lo que constituye una enorme amenaza para la conservación de la diversidad existentes en estos ecosistemas.

Si bien a nivel mundial la causa principal de la deforestación es la expansión agrícola (FAO & PNUMA, 2020), en la Amazonía peruana se ha podido determinar catalizadores específicos de la deforestación como el cultivo de la palma aceitera por parte de pequeños productores y las grandes industrias (Glinskis & Gutiérrez-Vélez, 2019); así como la minería de oro a escala artesanal (Caballero *et al.*, 2018). Mientras que dentro de la provincia Leoncio Prado se ha encontrado que la principal causa para la eliminación de la cobertura boscosa es la agricultura de subsistencia (Chahua, 2019).

Con la finalidad de reducir esta situación, se deben fortalecer las capacidades nacionales para realizar evaluaciones efectivas y cartografiar tierras degradadas tal como lo recomiendan los Objetivos de Desarrollo Sostenible (ODS) propuestos por las Naciones Unidas (Giuliani *et al.*, 2020). Ante esta necesidad, han surgido iniciativas globales que ofertan soluciones tecnológicas para monitorear la cobertura del bosque, utilizando métodos sofisticados y de acceso libre para obtener resultados más exactos y al alcance de todos (Puerta *et al.*, 2021). Por ejemplo, el Programa Copernicus dedicado a la observación de la Tierra cuenta con una constelación de satélites Sentinel y otras misiones que ofrecen servicios que abordan desafíos como alimentos, agua, energía, clima y seguridad civil (Aschbacher, 2017).

Otro de los avances en Teledetección es el desarrollo de algoritmos en base a la inteligencia artificial para la clasificación de imágenes satelitales. Estos clasificadores robustos están siendo utilizados para reagrupar píxeles de las imágenes Sentinel y otros productos para ubicar, delimitar y cuantificar la cobertura terrestre con enfoque en el aprendizaje de máquinas como es el caso de Random Forest que según la literatura científica es actualmente el algoritmo más utilizado (Hu *et al.*, 2020; Koskikala *et al.*, 2020), Máquinas de Vector de Soporte (Support vector

machine) (Parida & Kumar, 2020; Zhang *et al.*, 2019; Clark, 2020), Boosting (Pilaš *et al.*, 2020; Nink *et al.*, 2019) y Normal Bayes (Furuya *et al.*, 2020). Además, los especialistas recurren a las Redes Neuronales Artificiales (Neural network) basadas en procesos complejos como el aprendizaje profundo, para conseguir mapas de cobertura boscosa con exactitud temática muy alta (Miranda *et al.*, 2019; Nazarova *et al.*, 2020).

En este contexto, el monitoreo oportuno, continuo y sistemático de la dinámica forestal es importante para ajustar constantemente las políticas ambientales vigentes y desarrollar nuevas medidas de mitigación (Brovelli *et al.*, 2020). En esta misma línea la presente investigación se hace la siguiente pregunta ¿Cuánto es la cobertura boscosa de la provincia Leoncio Prado al 2021? Por lo que se planteó como objetivo estimar la cobertura boscosa al 2021 de la provincia Leoncio Prado, Perú clasificando imágenes Sentinel-2 con el algoritmo Random Forest así como evaluar su exactitud temática del mapa de cobertura boscosa producido.

MATERIALES Y MÉTODOS

Área de estudio

El área de estudio se encuentra localizada al nor centro de la región Huánuco, Perú, abarcando una extensión de 490 607,567 ha (Figura 1). Esta región

de selva alta peruana se clasifica en su mayor parte como Bosque muy húmedo Premontano Tropical (bmh-PT) (Oficina Nacional de Evaluación de Recursos Naturales (ONERN, 1976), presenta temperaturas superiores a los 24°C y precipitaciones superiores a los 3 000 mm/año, siendo el periodo comprendido entre noviembre a marzo el de lluvias prolongadas (Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI, 2021). En esta provincia se identifica paisajes muy variados como la planicie ondulada donde se encuentran principalmente la zona agrícola y urbana, el paisaje colinoso en el que se encuentra parte del Bosque de Producción Permanente Huánuco (Servicio Nacional Forestal y de Fauna Silvestre (SERFOR, 2021) y finalmente el paisaje montañoso donde se ubican las áreas protegidas como el Parque Nacional Tingo María y el Parque Nacional Cordillera Azul (Servicio Nacional de Áreas Naturales Protegidas (SERNANP, 2021).

Insumos cartográficos

Se utilizó como insumo principal imágenes del satélite óptico Sentinel-2, del Nivel 2A que son imágenes de reflectancia en el fondo de la atmósfera (BOA). Se procesó imágenes capturadas en el periodo comprendido entre los meses de agosto a octubre, que corresponde a la época de menor precipitación en la zona de estudio.

Procedimiento

El proceso se inició con el acceso a la plataforma

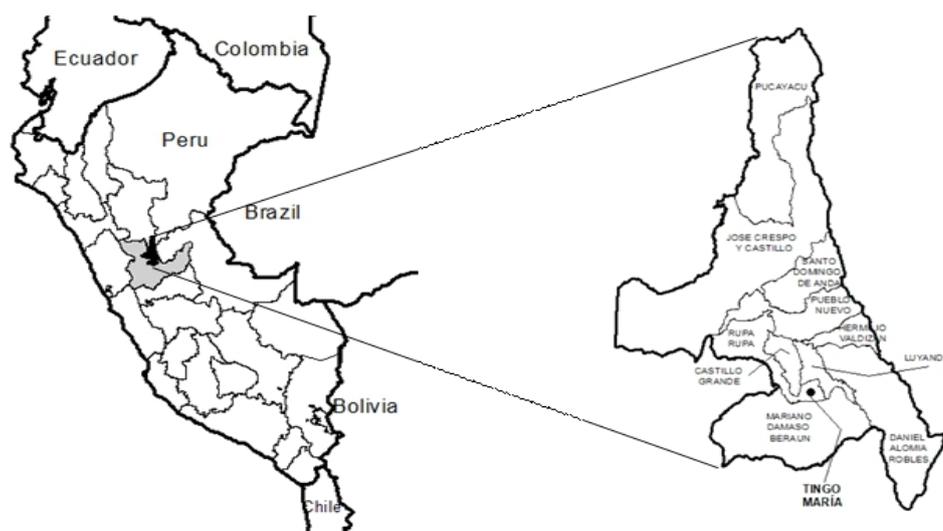


Figura 1. Ubicación política del área de estudio.

Google Earth Engine (GEE) para acceder a los datos del satélite Sentinel-2. Utilizando las bandas B11, B8 y B4 se aplicaron dos filtros: un filtro de nubes que deja las observaciones con una nubosidad del 10% y un filtro de tiempo de las observaciones para un rango de tiempo predeterminado, desde el 01 de agosto hasta el 17 de octubre del 2021. La imagen obtenida fue exportada a Google Drive para su respectiva descarga. Se eligió la plataforma GEE por su gran flexibilidad para proporcionar imágenes con poca nubosidad (Brovelli *et al.*, 2020) que es típico en los bosques tropicales húmedos. La clasificación

supervisada de la imagen se realizó en el software libre SNAP, creado por Copernicus para procesar los productos Sentinel, para ello se aplicó el algoritmo de inteligencia artificial Random Forest. La definición de los datos de entrenamiento se realizó a través de la interpretación visual de las imágenes Sentinel-2, donde se implementó un muestreo estratificado simple. Se definió cinco coberturas (Tabla 1): bosque, intervenido, degradado, hidrografía y urbano. Las áreas de entrenamiento para la clasificación se obtuvieron mediante análisis visual de la imagen Sentinel-2.

Tabla 1. Clases de coberturas en la zona de estudio.

Cobertura	Definición en la imagen
Bosque	Área con cobertura boscosa de formación natural o antrópica.
Intervenido	Áreas con vegetación secundaria, cultivos o pastos
Degradado	Áreas sin cobertura vegetal, suelos desnudos y/o degradados
Hidrografía	Cursos y cuerpos de agua
Urbano	Ciudades, caseríos, centros poblados y otros

Para verificar la fiabilidad de la clasificación sobre la imagen, se realizó calculó la exactitud temática utilizando la matriz de confusión también conocida como tabla de contingencia, que corresponde a una matriz de doble entrada, cuyos valores en diagonal expresan la concordancia entre el mapa producido y la realidad. Las clases encontradas en la clasificación supervisada fueron contrastadas con imágenes Planet, que cuenta con una resolución espacial entre 3 a 5 m (Roy *et al.*, 2021).

Para lo cual se realizó un muestreo estratificado al azar, donde las coberturas encontradas en la imagen corresponden a los estratos de muestreo. Según lo mencionado por Congalton (1991) si la superficie del área de estudio supera la 400 000 ha sugiere evaluar de 75 a 100 sitios por categorías. Por lo tanto, se evaluaron 345 puntos de muestreo para determinar la exactitud temática; 100 puntos para bosques, 75 para la zona intervenida, 75 para degradado, 75 para hidrografía y 20 para la zona urbana.

Aspectos éticos: Los autores señalan que durante la ejecución del presente trabajo se han cumplido con todos los aspectos éticos nacionales e internacionales.

RESULTADOS Y DISCUSIÓN

Cobertura boscosa en la provincia Leoncio Prado

En la Tabla 2 se muestra la superficie de las coberturas encontradas en la provincia Leoncio Prado a octubre del 2021. Se puede observar que la cobertura boscosa abarca más del 70% de la superficie total del área de estudio (Figura 2), lo que deduce que existe una gran cantidad de bosques, esto se debe principalmente que dentro de la provincia existen dos áreas naturales protegidas con carácter de intangible; el Parque Nacional Tingo María que se encuentra íntegramente dentro de la provincia con 4 777 ha y el Parque Nacional

Cordillera Azul que es compartido con otras tres regiones, de las cuales 79 959,84 ha se encuentran dentro de la provincia (SERNANP, 2021). El establecimiento de áreas naturales protegidas se ha

convertido en una manera eficiente de conservar bosques en esta parte del Perú como en otras partes del mundo (Nguyen *et al.*, 2019; Fokeng *et al.*, 2020).

Tabla 2. Superficie de las coberturas en la provincia Leoncio Prado al 2021.

Cobertura	Superficie (ha)	Ocupación (%)
Bosques	349 811,47	71,30
Degradado	95 872,40	19,54
Intervenido	35 519,72	7,24
Hidrografía	4 175,16	0,85
Urbano	1 411,92	0,29
Sin información	3 816,89	0,78
Total	490 607,57	100,00

Respecto a las zonas intervenidas, están representadas principalmente por vegetación secundaria en sucesión producto de la fuerte presión antrópica que hubo sobre los bosques en décadas pasadas para establecer cultivos ilícitos de hoja de coca, muchas de las cuales se han convertido en plantaciones forestales, agroforestería y otros sistemas de producción. Mientras que la clase degradado corresponde a pérdidas de bosque más recientes, las que están destinadas a ampliar la frontera agrícola, que es el principal motor de la deforestación a nivel mundial (FAO & PNUMA, 2020). Estas dos clases ocupan zonas con fisiografía plana a ondulada cerca de los ejes carreteros, mientras que los bosques se encuentran preferentemente en zonas montañosas y de difícil acceso a la población.

Las áreas deforestadas o fuertemente intervenidas en la zona de estudio son mucho menor en comparación a otras provincias como Puerto Inca, donde el principal motor de destrucción de bosques es el establecimiento de pasturas para ganado vacuno (MINAM, 2021). No obstante, se dificulta la comparación, teniendo en cuenta que la información de deforestación que brindan los principales geoportales a la fecha solo figura lo correspondiente al 2020.

Por otro lado, se realizó el análisis por distrito, siendo el distrito José Crespo y Castillo el de mayor superficie boscosa fue José Crespo y Castillo con 112 019,63 ha de bosques considerando que es el distrito más grande de la provincia con 149 792,71

ha lo que representa el 30,5% del total del área de estudio, en cambio Castillo Grande, el distrito más pequeño sólo presentó 6 458,08 ha de bosques (Tabla 3).

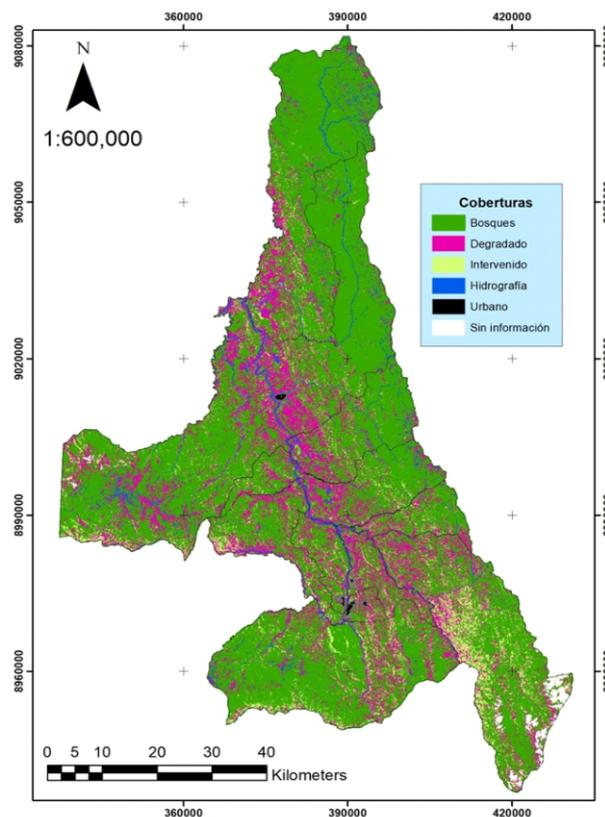
Además, en los resultados se ha incluido la cobertura Sin datos, que corresponde a las zonas identificadas como nubes y las sombras que producen éstas, las cuales se han identificado en los distritos José Crespo y Castillo, así como Daniel Alomía Robles que están muy cercanos a la cordillera Azul. Una de las limitantes a los que se enfrentan los usuarios de Sentinel-2 al clasificar cobertura boscosa en zonas tropicales es conseguir imágenes sin nubes (Hościło & Lewandowska, 2019) por lo que muchos cartógrafos optan por combinar los datos S-2 con un las del sensor activo Sentinel-1 para obtener mejores resultados (Veerabhadraswamy *et al.*, 2021; Biswas *et al.*, 2020).

Exactitud temática

En la evaluación de la clasificación realizada a la imagen Sentinel-2 se obtuvo un índice Kappa de 0,77 y una exactitud global del 89,14% y lo que significó una clasificación considerable al utilizar el algoritmo de inteligencia artificial Random Forest. Valores similares fueron obtenidos en otros tipos de bosques utilizando la misma imagen y el mismo clasificador (Kovačević *et al.*, 2020). De la matriz de confusión también se obtuvo valores de exactitud del usuario y productor para Bosques de 88 y 86,8% respectivamente lo que indica una clasificación aceptable (Tabla 4).

Tabla 3. Superficie en hectáreas de las coberturas por distrito en la provincia Leoncio Prado.

Distrito	Bosques	Degradado	Intervenido	Hidrografía	Urbano	Nubes
José Crespo Castillo	112 019,63	28 605,07	6 993,02	1 623,97	304,19	246,83
Pucayacu Mariano Dámaso Beraún Daniel Alomia Robles	61 186,66	11 088,72	3 267,71	421,07	54,24	0,00
Pueblo Nuevo Santo Domingo de Anda	55 860,76	11 822,82	6 433,88	277,71	51,45	0,00
Rupa Rupa Hermilio Valdizán Padre Felipe Luyando Castillo Grande	41 002,60	14 300,76	11 036,53	165,16	46,13	3 570,00
	22 590,16	7 199,88	1 696,89	471,00	63,52	0,00
	21 270,98	5 299,79	1 172,63	229,78	88,03	0,00
	15 506,27	7 579,43	2 477,72	369,74	443,08	0,00
	8 394,44	2 800,16	847,98	83,47	64,15	0,00
	5 521,91	4 344,51	847,19	253,6	111,24	0,00
	6 458,08	2 831,27	746,17	279,66	185,90	0,00

**Figura 2.** Mapa de la cobertura boscosa de la provincia Leoncio Prado al 2021, incluye otras coberturas. Se utiliza la Proyección UTM, Zona 18s y Datum WGS 1984.

Exactitud temática

En la evaluación de la clasificación realizada a la imagen Sentinel-2 se obtuvo un índice Kappa de 0,77 y una exactitud global del 89,14% y lo que significó una clasificación considerable al utilizar el algoritmo de inteligencia artificial Random Forest. Valores similares fueron obtenidos en otros

tipos de bosques utilizando la misma imagen y el mismo clasificador (Kovačević *et al.*, 2020). De la matriz de confusión también se obtuvo valores de exactitud del usuario y productor para Bosques de 88 y 86,8% respectivamente lo que indica una clasificación aceptable (Tabla 4).

Tabla 4. Matriz de confusión y métricas de confiabilidad

Cobertura encontrada	Cobertura en la imagen Planet		Total	Exactitud del usuario
	Bosque	No bosque		
Bosque	66	9	75	88%
No Bosque	10	90	100	90%
Total	76	99	175	
Exactitud del productor	86,8%	90,90%		
Índice de Kappa	0,77	Exactitud global	89,14%	

La alta exactitud temática obtenida en el mapa de cobertura en el presente trabajo, se debe entre otros atributos a la resolución espacial de 10 x 10 m de las imágenes Sentinel-2, que lo han convertido en una verdadera alternativa para obtener información espacial actualizada y confiable para ubicar, delimitar y cuantificar la cobertura boscosa y otros usos del suelo (Phiri *et al.*, 2020), con todo y lo anterior el uso de los productos S-2 por ser una tecnología relativamente nueva recientemente es utilizada en el Perú por parte de las instituciones encargadas del monitoreo de los bosques.

Finalmente, la alta confiabilidad obtenida en los resultados se debe al uso del algoritmo Random Forest, el cual ha sido implementado con inteligencia artificial. Con el avance de la tecnología en las geociencias, es posible utilizar clasificadores con enfoque en aprendizaje de máquinas que permite obtener exactitudes superiores al 80% cuando se clasifica bosques (Yu *et al.*, 2020; Duan *et al.*, 2019; Liu *et al.*, 2018).

AGRADECIMIENTO

La presente investigación se concluyó bajo el contexto del programa de Iniciación Científica de la Universidad Nacional Agraria de la Selva propuesto por el Vicerrectorado de Investigación de esta casa superior de estudios. Asimismo, los autores agradecen a los docentes de la Facultad de

Recursos Naturales Renovables de la UNAS por sus aportes durante la concepción, ejecución y culminación del presente artículo.

REFERENCIAS BIBLIOGRÁFICAS

- Aschbacher, J. 2017. *ESA's Earth Observation Strategy and Copernicus*. En: Onoda, M. & O. R. Young (Eds.), *Satellite Earth Observations and Their Impact on Society and Policy* (pp. 81-86). Springer.
- Biswas, S.; Huang, Q.; Anand, A., Mon, M.S.; Arnold, F.E. & Leimgruber, P. 2020. A multi sensor approach to forest type mapping for advancing monitoring of sustainable development goals (SDG) in Myanmar. *Remote Sensing*, 12: 3220.
- Brovelli, M. A.; Sun, Y. & Yordanov, V. 2020. Monitoring forest change in the Amazon using multi-temporal remote sensing data and machine learning classification on Google Earth Engine. *ISPRS International Journal of Geo-Information*, 9: 580.
- Caballero, J.; Messinger, M.; Román, F.; Ascorra, C.; Fernandez, L.E. & Silman, M. 2018. Deforestation and forest degradation due to gold mining in the Peruvian Amazon: A 34-year perspective. *Remote Sensing*, 10: 1903.
- Chahua, E. 2019. *Análisis de la deforestación en el*

- periodo 2006 – 2018 del distrito Daniel Alomía Robles* [Tesis de grado, Universidad Nacional Agraria de la Selva]. Repositorio Institucional. http://repositorio.unas.edu.pe/handle/UNA_S/1686.
- Clark, M. 2020. Comparison of multi-seasonal Landsat 8, Sentinel-2 and hyperspectral images for mapping forest alliances in Northern California. *ISPRS Journal of Photogrammetry and Remote Sensing*, 159: 26-40.
- Congalton, R.G. 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37: 35-46.
- Duan, Q.; Tan, M.; Guo, Y.; Wang, X. & Xin, L. 2019. Understanding the spatial distribution of urban forests in China using Sentinel-2 images with Google Earth Engine. *Forests*, 10: 729.
- FAO & PNUMA (Food and Agriculture Organization & Programa de las Naciones Unidas para el Medio Ambiente). 2020. *El estado de los bosques del mundo 2020*. Los bosques, la biodiversidad y las personas. Roma. <https://doi.org/10.4060/ca8642es>.
- Fokeng, R.M.; Forje, W.G.; Meli, V.M. & Bodzemo, B.N. 2020. Multi-temporal forest cover change detection in the Metchie-Ngoum Protection Forest Reserve, West Region of Cameroon. *The Egyptian Journal of Remote Sensing and Space Science*, 23: 113-124.
- Furuya, D.E.G.; Aguiar, J.A.F.; Estrabis, N.V.; Pinheiro, M.M.F.; Furuya, M.T.G.; Pereira, D.R.; Gonçalves, W.N.; Liesenberg, V.; Li, J.; Marcato-Junior, J.; Prado-Osco, L. & Ramos, A.P.M. 2020. A Machine Learning Approach for Mapping Forest Vegetation in Riparian Zones in an Atlantic Biome Environment Using Sentinel-2 Imagery. *Remote Sensing*, 12: 4086.
- Giuliani, G.; Mazzetti, P.; Santoro, M.; Nativi, S.; Van Bemmelen, J.; Colangeli, G. & Lehmann, A. 2020. Knowledge generation using satellite earth observations to support sustainable development goals (SDG): A use case on Land degradation. *International Journal of Applied Earth Observation and Geoinformation*, 88: 102068.
- Glinskis, E.A. & Gutiérrez-Vélez, V.H. 2019. Quantifying and understanding land cover changes by large and small oil palm expansion regimes in the Peruvian Amazon. *Land Use Policy*, 80: 95-106.
- Hościło, A. & Lewandowska, A. 2019. Mapping forest type and tree species on a regional scale using multi-temporal Sentinel-2 data. *Remote Sensing*, 11: 929.
- Hu, L.; Xu, N.; Liang, J.; Li, Z.; Chen, L. & Zhao, F. 2020. Advancing the Mapping of Mangrove Forests at National-Scale Using Sentinel-1 and Sentinel-2 Time-Series Data with Google Earth Engine: A Case Study in China. *Remote Sensing*, 12: 3120.
- Koskikala, J.; Kukkonen, M. & Käyhkö, N. 2020. Mapping Natural Forest Remnants with Multi-Source and Multi-Temporal Remote Sensing Data for More Informed Management of Global Biodiversity Hotspots. *Remote Sensing*, 12: 1429.
- Kovačević, J.; Cvijetinić, Ž.; Lakušić, D.; Kuzmanović, N.; Šinžar-Sekulić, J.; Mitrović, M.; Stančić, N.; Brodić, N. & Mihajlović, D. 2020. Spatio-Temporal Classification Framework for Mapping Woody Vegetation from Multi-Temporal Sentinel-2 Imagery. *Remote Sensing*, 12: 2845.
- Liu, Y.; Gong, W.; Hu, X. & Gong, J. 2018. Forest type identification with random forest using Sentinel-1A, Sentinel-2A, multi-temporal Landsat-8 and DEM data. *Remote Sensing*, 10: 946.
- MINAM (Ministerio del Ambiente). 2021. *Bosques y pérdida de bosques*. Recuperado el 21 de julio de 2020 de <http://geobosques.minam.gob.pe/geobosque/view/perdida.php>.
- Miranda, E.; Mutiara, A. & Ernastuti, W. 2019. Forest classification method based on convolutional neural networks and Sentinel-2 satellite imagery. *International Journal of Fuzzy Logic and Intelligent Systems*, 19: 272-282.
- Nazarova, T.; Martin, P. & Giuliani, G. 2020. Monitoring vegetation change in the presence of high cloud cover with Sentinel-2 in a Lowland Tropical Forest Region in Brazil. *Remote Sensing*, 12: 1829.
- Nguyen, L.D.; Nguyen, C.T.; Le, H.S. & Tran, B.Q. 2019. Mangrove mapping and above-ground biomass change detection using

- satellite images in coastal areas of Thai Binh Province, Vietnam. *Forest and Society*, 3: 248-261.
- Nink, S.; Hill, J.; Stoffels, J.; Buddenbaum, H.; Frantz, D. & Langshausen, J. 2019. Using Landsat and Sentinel-2 Data for the generation of continuously updated forest type information layers in a cross-border region. *Remote Sensing*, 11: 2337.
- ONERN (Oficina Nacional de Evaluación de Recursos Naturales). 1976. *Guía explicativa del Mapa ecológico del Perú*. Oficina Nacional de Evaluación de Recursos Naturales. 146 p. Recuperado de <https://www.repositorio.ana.gob.pe/>
- Parida, B.R. & Kumar, P. 2020. Mapping and dynamic analysis of mangrove forest during 2009–2019 using landsat–5 and sentinel–2 satellite data along Odisha Coast. *Tropical Ecology*, 61: 538-549.
- Phiri, D.; Simwanda, M.; Salekin, S.; Nyirenda, V.R.; Murayama, Y. & Ranagalage, M. 2020. Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing*, 12: 2291.
- Pilaš, I.; Gašparović, M.; Novkinić, A. & Klobučar, D. 2020. Mapping of the canopy openings in mixed beech–fir Forest at Sentinel-2 subpixel level using UAV and machine learning approach. *Remote Sensing*, 12: 3925.
- Puerta, R.; Esenarro, D.; Minga, C.; Rodriguez, C. & Aylas, C. 2021. Open-Access geographic sources and data for the study and management of natural resources. *Journal of Contemporary Issues in Business and Government*, 27: 849-857.
- Roy, D. P.; Huang, H.; Houborg, R. & Martins, V. S. 2021. A global analysis of the temporal availability of PlanetScope high spatial resolution multi-spectral imagery. *Remote Sensing of Environment*, 264: 112586.
- SERNANP (Servicio Nacional de Áreas Naturales Protegidas por el Estado). 2021. *Geo ANP*. <https://geo.sernanp.gob.pe/visorsernanp/>.
- SENAMHI (Servicio Nacional de Meteorología e Hidrología del Perú). 2021. *Descarga de datos meteorológicos a nivel nacional*. <https://www.senamhi.gob.pe/>
- SERFOR (Servicio Nacional Forestal y de Fauna Silvestre). 2021. *Visor Cartográfico – G E O S E R F O R* . <http://geo.serfor.gob.pe/visor/>
- Veerabhadraswamy, N.; Devagiri, G.M. & Khaple, A.K. 2021. Fusion of complementary information of SAR and optical data for forest cover mapping using random forest algorithm. *Current Science*, 120: 193-199.
- Yu, X.; Lu, D.; Jiang, X.; Li, G.; Chen, Y.; Li, D. & Chen, E. 2020. Examining the Roles of Spectral, Spatial, and Topographic Features in Improving Land-Cover and Forest Classifications in a Subtropical Region. *Remote Sensing*, 12: 2907.
- Zhang, W.; Brandt, M.; Wang, Q.; Prishchepov, A. V.; Tucker, C. J.; Li, Y.; Lyu, H. & Fensholt, R. 2019. From woody cover to woody canopies: How Sentinel-1 and Sentinel-2 data advance the mapping of woody plants in savannas. *Remote Sensing of Environment*, 234: 111465.

Received January 4, 2022.
Accepted February 6, 2022.