

Evaluación de cuatro algoritmos de clasificación de imágenes satelitales Landsat-8 y Sentinel-2 para la identificación de cobertura boscosa en paisajes altamente fragmentados en Costa Rica

Ávila-Pérez, I.D. ^{*1,2}, Ortiz-Malavasi, E. ¹, Soto-Montoya, C. ¹, Vargas-Solano, Y. ², Aguilar-Arias, H. ², Miller-Granados, C. ²

¹ Escuela de Ingeniería Forestal, Instituto Tecnológico de Costa Rica, Apartado Postal: 159-7050, Cartago, Costa Rica.

² Laboratorio PRIAS, Centro Nacional de Alta Tecnología, San José, Costa Rica.

Resumen: Conocer y cartografiar los cambios del uso y cobertura de la tierra es esencial para la formulación de estrategias de manejo y conservación de los recursos naturales. Las herramientas que conforman la disciplina de la teledetección han sido extensamente usadas con este objetivo. Al comparar cuatro algoritmos de clasificación y dos tipos de imágenes satelitales, el objetivo de la investigación fue determinar el tipo de algoritmo e imagen satelital que permite obtener una mayor fiabilidad global en la identificación de la cobertura boscosa en paisajes de uso de la tierra con alta fragmentación. El estudio se desarrolló en la Zona Huetar Norte de Costa Rica, utilizando un diseño experimental de seis bloques con un arreglo de tratamientos con tres factores. El uso de imágenes Sentinel-2 fue superior al obtenido con Landsat-8. No existen diferencias significativas en la fiabilidad lograda con los algoritmos de clasificación de Máxima Verosimilitud, Máquinas de Vectores Soporte y Redes Neuronales, pero sí de estos con respecto a la clasificación por Mínima Distancia. No se detectó interacción entre tipo de imagen y algoritmo de clasificación, por lo que las imágenes de Sentinel-2 podrían usarse con cualquiera de los tres mejores algoritmos estudiados. Se analizó además el efecto que tuvo el mes en cada imagen adquirida, y se encontraron diferencias significativas debido a este factor, además se produce una interacción de este con el método de clasificación. Los mejores resultados se obtuvieron con imágenes de abril, y los más bajos con imágenes de septiembre, mes que coincide con la época lluviosa en la zona estudiada. Se concluye que la mayor fiabilidad en la identificación de la cobertura boscosa se logra mediante el uso de los algoritmos de Máxima Verosimilitud, Máquinas de Vectores Soporte y Redes Neuronales empleando imágenes Sentinel-2 tomadas en la temporada seca.

Palabras clave: Landsat 8, Sentinel-2, clasificación por máxima verosimilitud, máquinas de vectores soporte, clasificación por mínima distancia, clasificación por redes neuronales, Región Huetar Norte.

Evaluation of four classification algorithms of Landsat-8 and Sentinel-2 satellite images to identify forest cover in highly fragmented regions in Costa Rica

Abstract: Mapping of land use and forest cover and assessing their changes is essential in the design of strategies to manage and preserve the natural resources of a country, and remote sensing have been extensively used with this purpose. By comparing four classification algorithms and two types of satellite images, the objective

To cite this article: Ávila-Pérez, I.D., Ortiz-Malavasi, E., Soto-Montoya, C., Vargas-Solano, Y., Aguilar-Arias, H., Miller-Granados, C. 2020. Evaluation of four classification algorithms of Landsat-8 and Sentinel-2 satellite images to identify forest cover in highly fragmented regions in Costa Rica. *Revista de Teledetección*, 57, 37-49. <https://doi.org/10.4995/raet.2020.13340>

* Corresponding author: ivandimitri1995@gmail.com

of the research was to identify the type of algorithm and satellite image that allows higher global accuracy in the identification of forest cover in highly fragmented landscapes. The study included a treatment arrangement with three factors and six randomly selected blocks within the Huetar Norte Zone in Costa Rica. More accurate results were obtained for classifications based on Sentinel-2 images compared to Landsat-8 images. The best classification algorithms were Maximum Likelihood, Support Vector Machine or Neural Networks, and they yield better results than Minimum Distance Classification. There was no interaction among image type and classification methods, therefore, Sentinel-2 images can be used with any of the three best algorithms, but the best result was the combination of Sentinel-2 and Support Vector Machine. An additional factor included in the study was the image acquisition date. There were significant differences among months during which the image was acquired and an interaction between the classification algorithm and this factor was detected. The best results correspond to images obtained in April, and the lower to September, month that corresponds with the period of higher rainfall in the region studied. The higher global accuracy identifying forest cover is obtained with Sentinel-2 images from the dry season in combination with Maximum Likelihood, Support Vector Machine, and Neural Network image classification methods.

Key words: Landsat 8, Sentinel-2, Maximum likelihood classification (MLC), Minimum distance classification (MDC), Support vector machine (SVM), Neural net classification (NNC), Huetar Norte Zone.

1. Introducción

Diversas regiones del planeta han sido fuertemente deforestadas a consecuencia de que estas áreas albergan grandes poblaciones, poseen una agricultura dinámica o presentan una alta actividad forestal (Chazdon, 2014; Ponce, et al., 2017). En el caso específico de Costa Rica, se presentaron altas tasas de deforestación entre 1940 y 1980 (Sader y Joyce, 1988); sin embargo, a partir de los noventas la cobertura boscosa neta del país comenzó a incrementar (Sánchez et al., 2002), y actualmente se estima que un 50,2% de su territorio se encuentra bajo algún tipo de cobertura forestal. Se conoce, además, que el 25% se encuentra en grandes bloques dentro de áreas silvestres protegidas, y el otro 25% se encuentra inmerso dentro de una matriz de usos y cobertura de la tierra muy heterogénea, lo que dificulta su monitoreo por medio de imágenes satelitales de mediana resolución espacial de acceso libre.

Identificar los cambios en uso y cobertura de la tierra es esencial para la formulación de estrategias de manejo y conservación de los recursos naturales, y las herramientas que conforman la disciplina de la teledetección, han sido extensamente usadas con este objetivo (Yin et al., 2018; Pimple et al., 2017). La teledetección permite llevar a cabo estudios en grandes extensiones de terreno en un corto periodo de tiempo y a un bajo costo (Nhamo et al., 2018), y se puede entonces, conocer la dinámica espacial y temporal de las masas arbóreas (Vogeler et al., 2018). Sin

embargo, un aspecto importante a destacar en su uso es la fiabilidad de los mapas e información obtenidos, ya que esta puede variar dependiendo tanto del tipo de imágenes, como de los algoritmos de clasificación empleados (Ningthoujam et al., 2016), especialmente cuando la matriz de usos de la tierra evaluada es muy heterogénea.

Actualmente, existen una extensa variedad de imágenes satelitales (Yang et al., 2018) y algoritmos de clasificación (Shen et al., 2018) para generar información de uso y cobertura de la tierra a través de teledetección. Tradicionalmente, los estudios de cambio de uso y cobertura de la tierra se han realizado mediante imágenes del programa Landsat; no obstante, en el 2015 se inició el programa de satélites Sentinel, abriéndose de esta manera el espectro de disponibilidad de imágenes para estos estudios. El programa de monitoreo Landsat se inició aproximadamente hace 40 años (Zhao et al., 2018); por lo tanto, posee el registro temporal más largo y continuo de imágenes que muestran la cobertura del planeta. Además, la resolución espacial y especialmente la resolución espectral de las imágenes de estos satélites, son muy apropiadas para el seguimiento de las actividades humanas y su impacto al ambiente (Hermosilla et al., 2015).

En los últimos años se ha destacado el uso del sensor MSI a bordo del satélite Sentinel-2 de la Agencia Espacial Europea (ESA, por sus siglas en inglés) ya que ha sido de gran apoyo para el monitoreo de la tierra y en especial de los recursos forestales (Mura et al., 2018). Este sensor fue

lanzado en el 2015 (Li et al., 2018) y fue creado con el propósito de tomar datos para el programa de Monitoreo Global para la Seguridad Ambiental (GMES, por sus siglas en inglés) (Yang et al., 2017). Este sensor permite obtener imágenes con una resolución espacial de 10 m en las bandas RGB y NIR (Mura et al., 2018), y una resolución temporal de 5 días (Yang et al., 2017); por lo que se espera que sean utilizadas ampliamente en programas de monitoreo de la superficie terrestre, en especial si sus imágenes se complementan con información obtenida de otros satélites enviados por la ESA (Whyte et al., 2018).

Entre los métodos de interpretación de datos provenientes de sensores remotos se puede mencionar el uso de los algoritmos de clasificación supervisada los cuales presentan, por si mismos, un amplio espectro de posibilidades (Perumal y Bhaskaran, 2010). Por ejemplo, entre los algoritmos más antiguos se encuentra la Clasificación por Mínima Distancia (MDC, por sus siglas en inglés) (Del Toro et al., 2015). Este clasificador cuenta con la ventaja de que puede trabajar cuando se cuenta con un número limitado de áreas de entrenamiento (Walton, 2015); o bien, cuando los histogramas de las bandas de una imagen no cuentan con una distribución normal (Murtaza y Romshoo, 2014).

Por otro lado, la Clasificación por Máxima Verosimilitud (MLC, por sus siglas en inglés) es uno de los clasificadores que ha sido más amplia y exitosamente utilizado para la clasificación de coberturas y usos de la tierra (Shi y Xue, 2016). No obstante, en los últimos años, los algoritmos de inteligencia artificial (IA) y *Machine-Learning*, como Máquinas de Vectores Soporte (SVM, por sus siglas en inglés) y Redes Neuronales (NNC, por sus siglas en inglés), han presentado gran auge. En el caso de SVM, este muestra un buen rendimiento aun cuando se tiene una cantidad reducida de áreas de entrenamiento (Mountrakis et al., 2010). Por otro lado, los clasificadores basados en redes neuronales presentan la ventaja de que permiten trabajar con datos que no se ajustan completamente a distribuciones estadísticas (Ndehedehe et al., 2013).

La utilidad de un mapa creado a partir de una clasificación depende de su fiabilidad, ya que cualquier mapa realizado a través de detección remota se encuentra sujeto a errores de clasificación, y se conoce que estos errores varían dependiendo del

número de clases de uso y coberturas utilizadas, la resolución espacial y espectral de las imágenes, y de los algoritmos de clasificación utilizados (Olofsson et al., 2014, Ningthoujam et al., 2016).

Dado que actualmente existe la posibilidad de emplear imágenes satelitales de diferentes fuentes, y mayor variedad de algoritmos de clasificación de las mismas, el objetivo de la presente investigación fue comparar cuatro tipos de algoritmos de clasificación (MDC, MLC, SVM y NNC) combinados con dos tipos de imagen satelital de mediana resolución (Landsat-8 y Sentinel-2), en la identificación de la cobertura boscosa de regiones con alta diversidad de usos de la tierra en Costa Rica.

2. Materiales y métodos

2.1. Área de estudio

El área de estudio seleccionada correspondió a la Zona Huetar Norte de Costa Rica. Fue seleccionada esta región por que posee un alto desarrollo agropecuario que se traduce a un paisaje con una amplia variedad de usos y coberturas de la tierra (Chassot et al., 2010). El área de estudio cuenta con una extensión de 979 047 ha y se ubica entre las coordenadas geográficas 85°26'57" y 83°42'40" longitud Oeste y 11°05'03" y 10°10'47" latitud norte. El clima de esta zona presenta una temperatura media anual entre 14 y 28°C y una precipitación media anual que varía entre 1500 y 7000 mm. Según el sistema americano de clasificación de suelos, en la región de estudio los suelos más representativos son los correspondientes a los órdenes Andisoles, Entisoles, Histosoles, Inceptisoles y Ultisoles (Mata, et al., 2010). En cuanto a las zonas de vida, en la Zona Huetar Norte se encuentran bosques húmedos tropicales; bosques muy húmedos tropicales, premontanos y montanos bajos, además de bosques pluviales premontanos, montano bajos y montanos (CCT, 1993).

2.2. Muestreo de campo y diseño experimental

A partir de un mapa geográfico del área de estudio se estableció una malla de 19 cuadrículas de 15 km por 15 km (225 km²), de las cuales se seleccionaron aleatoriamente seis cuadrículas que se usaron

como repeticiones en un diseño experimental de bloques al azar. El diseño experimental, por tanto, consta de 6 bloques que actúan como repeticiones, y tres factores: 1. tipo de imagen (con 2 niveles), 2. Algoritmo de clasificación (con 4 niveles), y 3. Mes de adquisición de las imágenes (con 5 niveles). Con el fin de determinar el uso de la tierra en campo, se procedió a visitar dichas cuadrículas de muestreo recorriendo un 15% del área de estas utilizando los caminos y carreteras existentes. Las clases de uso y cobertura usadas en el estudio fueron las definidas por el Sistema de Monitoreo de la Cobertura y Uso de la Tierra y Ecosistemas (SIMOCUTE) desarrollado para Costa Rica (CENIGA, 2018), y posteriormente fueron reclasificadas en dos categorías: Bosque y No Bosque (Tabla 1). Aleatoriamente se seleccionó un 70% de las observaciones para la delimitación de áreas de entrenamiento, y el restante 30% de los puntos,

fueron utilizados en la validación de resultados. La Figura 1 detalla la ubicación espacial de los bloques del diseño experimental, así como la localización de las áreas de entrenamiento y validación utilizadas en el estudio.

2.3. Obtención y pre-procesamiento de imágenes

Se obtuvieron imágenes Landsat-8 y Sentinel-2 nivel 1, a través de la plataforma en línea Earth Explorer del Servicio Geológico de los Estados Unidos (USGS, por sus siglas en inglés) y el Centro de acceso abierto Copernicus de la ESA (Tabla 2).

Se seleccionó para cada cuadrícula la imagen de menor nubosidad disponible en el periodo anteriormente indicado. Dado que no existían

Tabla 1. Clasificación de las clases de uso del suelo según categorías en estudio.

Categoría	Clases de uso
Bosque	Bosque maduro, Bosque intervenido, Bosque secundario: Temprano, Medio y Tardío y plantaciones forestales y frutales.
No Bosque	Cultivos anuales, Cultivos permanentes, Pastos, Cuerpos de agua e Infraestructura.

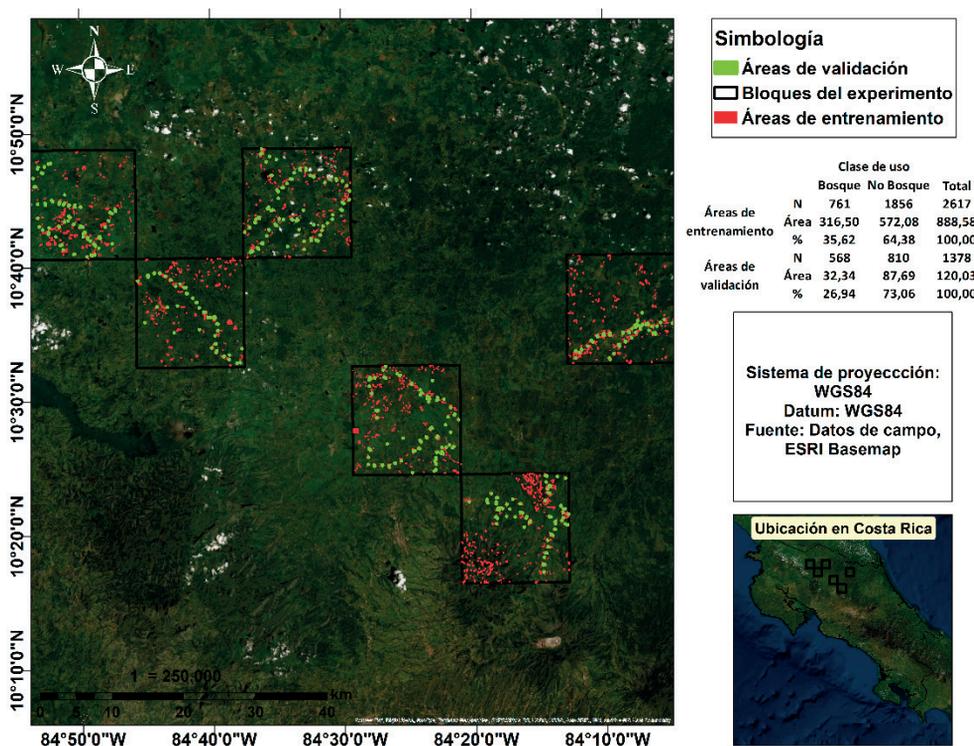


Figura 1. Ubicación de los bloques del experimento junto con de las áreas de entrenamiento y validación.

Tabla 2. Características de las imágenes analizadas en el estudio.

Identificador de la imagen	Tipo de imagen	Fecha de la imagen	Cobertura de nubes (%)
LC08_L1TP_015053_20170211_20170228_01_T1	Landsat 8	11-feb	13,85
LC08_L1TP_015053_20170331_20170414_01_T1	Landsat 8	31-mar	14,8
LC08_L1TP_015053_20170907_20170926_01_T1	Landsat 8	7-sep	56,86
LC08_L1TP_016053_20171219_20180125_01_T1	Landsat 8	19-dic	5,61
S2A_MSIL1C_20180401T160511_N0206_R054_T16PGS_20180401T222634	Sentinel-2	1-abr	2,05
S2B_MSIL1C_20180208T160419_N0206_R097_T16PGS_20180208T192852	Sentinel-2	8-feb	18,71

imágenes para un mismo mes libre de nubes para todos los bloques, en el experimento se introdujo un factor adicional a analizar que corresponde al mes en que se obtuvo la imagen.

En el caso de las imágenes Landsat seleccionadas, se obtuvieron los valores de reflectancia de la superficie a través de una corrección atmosférica de todas las imágenes mediante el algoritmo FLAASH (Matthew et al., 2000) en el software ENVI 5.5. Para las imágenes Sentinel-2, debido a que las imágenes descargadas de nivel 1 ya se encontraban en valores de reflectancia arriba de la atmósfera (TOA por sus siglas en inglés) (ESA, 2020); el preprocesado de estas no incluyó correcciones atmosféricas, sino, únicamente una modificación de la resolución espacial de las bandas 1, 5, 6, 7 8a, 9, 10, 11 y 12 a 10 m de manera para que todas estas tuvieran un píxel con la misma resolución (10 m), y luego se procedió a la unión de dichas bandas mediante el software SNAP desarrollado por la Agencia Espacial Europea (ESA, por sus siglas en inglés). Seguidamente, a partir de todas las imágenes seleccionadas y corregidas, se seleccionaron y extrajeron las secciones con menor presencia de nubes para cada cuadrícula de muestreo (escenas) mediante la herramienta “Clipper” del programa Qgis 3.8, y finalmente se procedió a la eliminación de las nubes y las sombras de nubes mediante el algoritmo MFMask 4.0 (Qiu et al., 2017).

2.4. Clasificación de imágenes

Para la determinación de la cobertura boscosa en cada una de las cuadrículas de muestreo, se dibujaron áreas de entrenamiento (ROIs) usando el programa ENVI 5.5. Las áreas de entrenamiento se crearon a partir de la información de los puntos

tomados en la fase de muestreo de campo y la fotointerpretación de las imágenes de alta resolución más cercanas a los años de estudio disponibles en la plataforma de Google Earth. En caso de observarse en las imágenes, clases de uso no identificadas en las visitas de campo, se procedió a la creación de áreas de entrenamiento para estas clases.

2.5. Algoritmos de clasificación utilizados

En la clasificación de las imágenes se usaron cuatro tipos de algoritmos, a saber: los que utilizan la Máxima Verosimilitud (MLC), los de Mínima Distancia (MDC), los de Máquinas de Vectores Soporte (SVM) y el de Redes Neuronales (NNC). Las características de cada uno de los algoritmos utilizados están descritas respectivamente por Shi y Xue (2016), Wacker y Landgrebe (1972), Adankon y Cheriet (2015), y Ndehedehe et al., (2013).

El alcance de la investigación no se enfocó en la evaluación y optimización de cada uno de los parámetros requeridos por los algoritmos, por lo que los valores utilizados corresponden a los datos por defecto del programa ENVI 5.5. En el caso de MLC se utilizó un factor de escala de uno y no se implementó un umbral de probabilidad. Para MDC no se establecieron valores máximos para el umbral de la desviación estándar ni para el error de distancia máximo. El tipo de *kernel* implementado en SVM fue la Función de Base Radial; los valores por defecto utilizados son detallados por Harris GeoSpatial Solution (2020). Por último, se utilizó una red neuronal prealimentada de tipo perceptrón multicapa. Los valores por defecto implementados para NNC pueden encontrarse en el estudio llevado a cabo por Kupková et al. (2017).

2.6. Validación de las clasificaciones

A cada uno de los puntos separados para la validación se le asoció las clases de uso de tierra identificadas en campo, la clasificación obtenida para cada tipo de imagen satelital, mes en que se obtuvo la misma, y el algoritmo de clasificación usado. Debido a la alta heterogeneidad del paisaje bajo estudio y para corregir los errores derivados del desplazamiento de las imágenes, así como el error derivado del uso de GPS para identificar los puntos de control en el campo, a cada punto se le creó una zona de amortiguamiento de 30 metros de radio. Se calculó la moda de las clases uso de la tierra de los píxeles dentro de dicha zona de amortiguamiento. Este dato fue luego usado para construir las matrices de error de cada una las clasificaciones del experimento.

2.7. Análisis de datos

Para determinar la existencia de diferencias en la fiabilidad de los tratamientos utilizados se llevó a cabo un Análisis de la Varianza (ANOVA, por sus siglas en inglés) en el programa “R” e Infostat 2018e basado en un ensayo de bloques. Los tratamientos probados consistieron en los factores descritos anteriormente en la sección “Muestreo de campo y diseño experimental” así como las respectivas interacciones entre cada nivel de cada factor. La variable respuesta seleccionada fue la fiabilidad global obtenida para cada tratamiento. Para evaluar los requisitos estadísticos del ANOVA se usó la prueba de Shapiro-Wilks (SK)

para evaluar normalidad dado que la muestra es menor a 50, y la prueba de Levene para evaluar homocedasticidad. La prueba de Levene indica igualdad de varianzas ($p=0.10$), y la prueba de SK fue significativa al 4% ($p=0,04$). Para corroborar este último resultado se decidió también usar la prueba de normalidad de Jarque-Bera disponible en R, la cual cuantifica que tanto se desvían los coeficientes de asimetría y curtosis de los esperados en una distribución normal. Esta última prueba no fue significativa para rechazar la hipótesis de normalidad, obteniéndose un valor de Chi-cuadrado de 4,09, y un $p=0,129$. Según estos resultados se decidió entonces no hacer ninguna transformación en los datos. Finalmente, para analizar las diferencias encontradas entre algunos de los factores e interacciones se llevaron a cabo pruebas de comparaciones de medias de Tukey en los software R e Infostat 2018e. La variable respuesta utilizada para estas pruebas fue la fiabilidad global de cada tratamiento.

3. Resultados

3.1. Análisis de los resultados de la clasificación según tipo de imagen

La comparación visual de las clasificaciones de cobertura mediante los dos tipos de imágenes muestra resultados semejantes. Las áreas clasificadas como bosques en las imágenes analizadas comparten en su mayoría la localización espacial y los límites. Por ejemplo, en la Figura 2 se comparan los resultados de las clasificaciones para

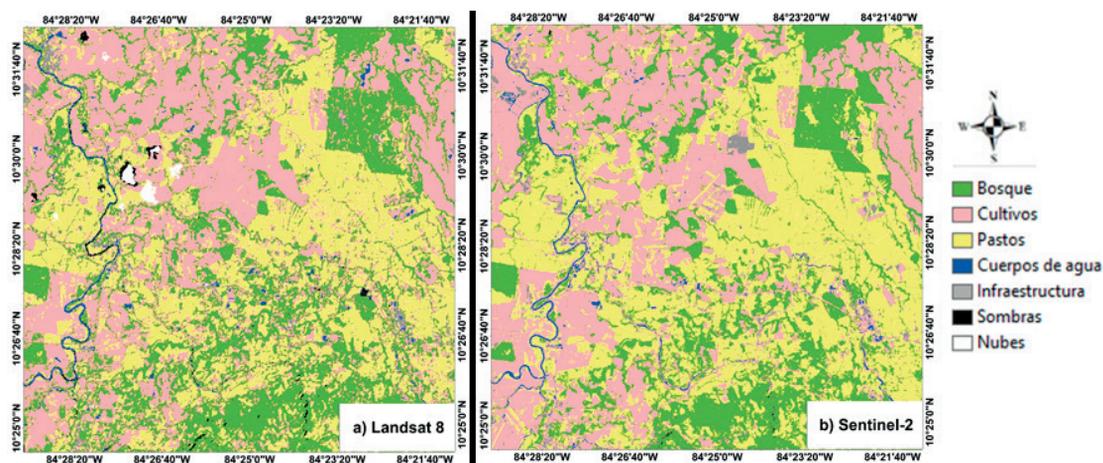


Figura 2. Comparación de los resultados de clasificación según tipo de imagen satelital.

Tabla 3. Promedios de fiabilidad global de las clasificaciones de cobertura forestal según tipo de imagen satelital

Tipo de imagen satelital	Fiabilidad promedio	n	Error estándar	Prueba de Tukey $\alpha=0,05$
Landsat-8	94,72	24	0,44	A
Sentinel-2	96,43	24	0,44	B

Nota: Medias con una letra desigual son significativamente diferentes ($p < 0,05$)

el bloque seis, y en la sección noreste de ambas imágenes, se observa la forma del área boscosa con la misma localización y forma, sin embargo, se puede también notar que existe mayor definición de las áreas en la Figura 2b, debido a que las imágenes de Sentinel-2 poseen mayor resolución espacial. El p -valor obtenido para este factor permite determinar con una fiabilidad de 98,64% (p -valor=0,0136) que existen diferencias significativas para fiabilidad global debido al tipo de imagen utilizada. La Tabla 3 muestra una superioridad de la fiabilidad lograda con las imágenes satelitales de Sentinel-2.

3.2. Análisis de los resultados de la clasificación según algoritmo de clasificación

La comparación visual de los resultados del uso de los algoritmos de clasificación muestra que las clasificaciones obtenidas por los métodos de Máxima Verosimilitud (MLC), Máquinas de Vectores Soporte (SVM), y Redes Neuronales (NNC) presentan resultados muy similares (Figura 3b, 3c y 3d), mientras que la clasificación por Mínima Distancia (MDC) difiere de los anteriores (Figura 3a). Por ejemplo, se puede observar en la

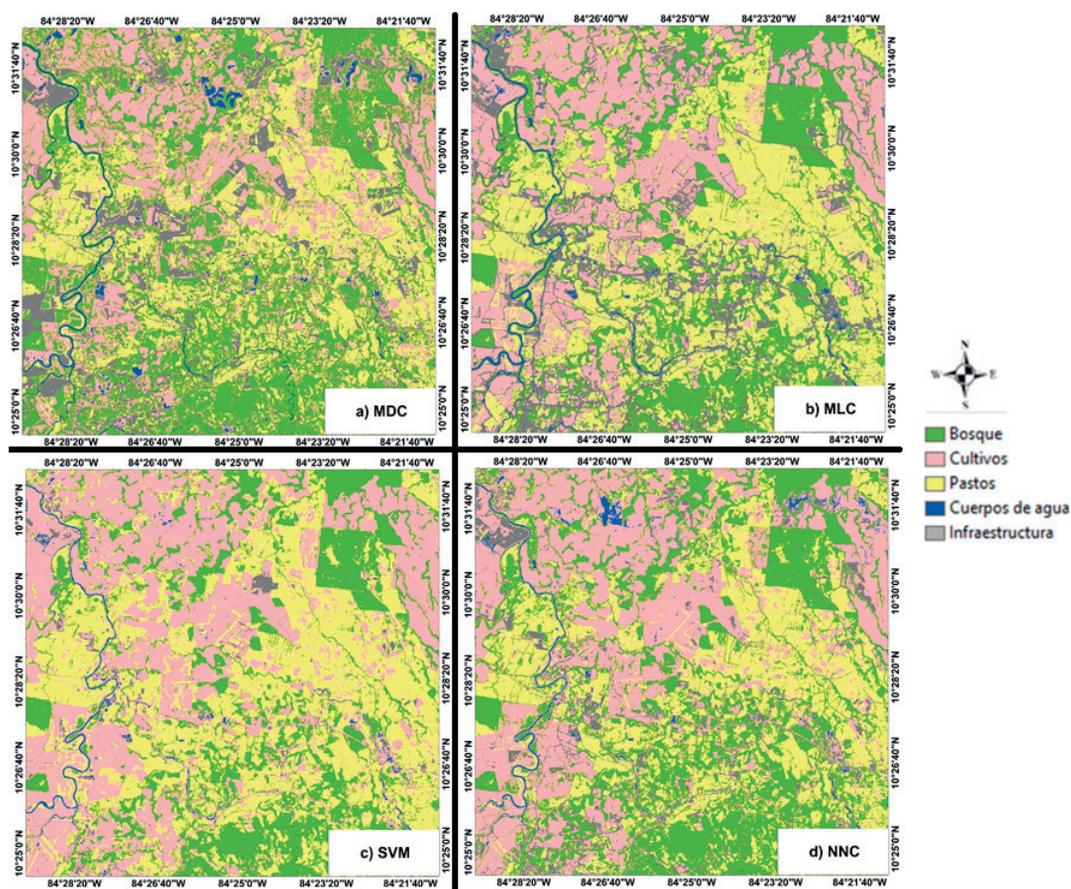


Figura 3. Comparación de los resultados de clasificación según algoritmo de clasificación.

Tabla 4. Promedios de fiabilidad global de las clasificaciones de cobertura forestal según algoritmo de clasificación.

Algoritmo de clasificación	Fiabilidad promedio			Prueba de Tukey $\alpha=0,05$
	(%)	n	Error estándar	
MDC	93,51	12	0,63	A
MLC	96,23	12	0,63	B
NNC	96,26	12	0,63	B
SVM	96,3	12	0,63	B

Nota: Medias con una letra diferente son significativamente diferentes ($p < 0,05$).

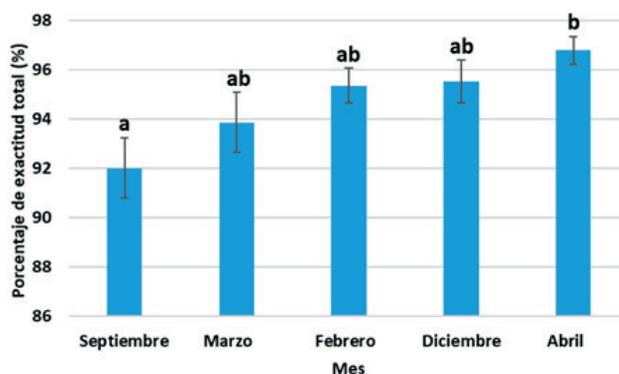
sección este de las clasificaciones por MLC, SVM y NNC (Figura 3b, 3c y 3d) que las áreas identificadas corresponden en su mayoría a pastos; sin embargo, la clasificación por MDC cataloga como bosques dichas zonas (Figura 3a). Esto concuerda con los estadísticos de fiabilidad que se muestran en la Tabla 4. Es posible determinar con una fiabilidad de 98,8% (p -valor=0,012) que para los algoritmos MLC, SVM y NNC no se presentan diferencias significativas entre sí, pero son estadísticamente superiores a los obtenidos con el algoritmo de MDC. Por otro lado, el análisis de varianza muestra que no existe interacción entre los factores tipo de imagen y algoritmo de clasificación (p -valor=0,53), pero es posible obtener resultados con una precisión ligeramente mayor mediante la combinación del uso las imágenes de Sentinel-2 con el algoritmo SVM.

3.3. Análisis de los resultados de la clasificación según mes de la imagen

Los resultados obtenidos demuestran que existen diferencias significativas (p -valor=0,066),

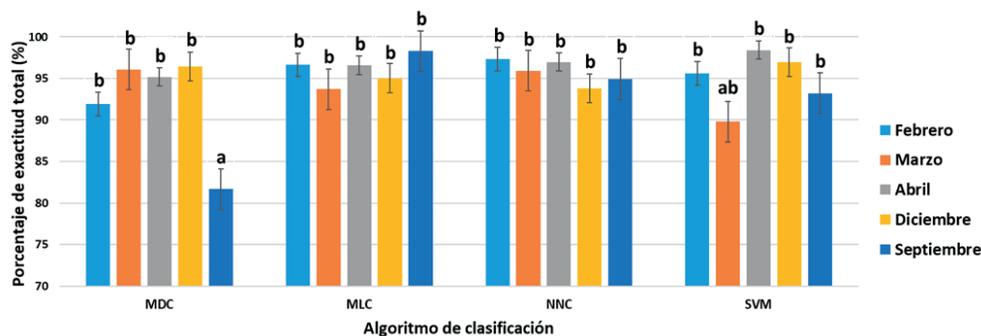
en la fiabilidad global debido al mes en que se tomó la imagen, por ejemplo, la Figura 4 muestra que con el uso de imágenes de septiembre se logra una menor fiabilidad, y aunque no existe diferencias en la fiabilidad para los meses de septiembre a diciembre, la prueba de comparaciones múltiples de Tukey ($\alpha=0,05$, DMS=3,61) muestra que existe diferencias entre las imágenes de septiembre y abril, lo cual podría explicarse como diferencias de calidad y nubosidad de las imágenes, ya que septiembre coincide con la época lluviosa en la zona de estudio, y abril con la época seca.

El análisis de varianza señala que existe interacción entre algoritmo de clasificación y mes en que se tomó la imagen ($p=0,0081$). La Tabla 5 muestra que en los resultados de los métodos MLC y NNC no varían debido al mes, mientras que la combinación menos satisfactoria corresponde al uso del algoritmo MDC con imágenes de septiembre. (Tukey DMS=5,11, $\alpha=0,05$).



Nota: Según prueba de comparaciones múltiples de Tukey, medias con una letra desigual son significativamente diferentes ($p < 0,05$).

Figura 4. Comparación de los resultados de fiabilidad global de las clasificaciones según mes de toma de la imagen.



Nota: Según prueba de comparaciones múltiples de Tukey, medias con una letra desigual son significativamente diferentes ($p < 0,05$).

Figura 5. Comparación de los resultados de fiabilidad global de la clasificación para la interacción de los factores mes de toma de la imagen y algoritmo de clasificación.

4. Discusión

En el caso de las diferencias en la fiabilidad debido al tipo de imagen analizada (Tabla 3), los resultados observados implican que con las imágenes Sentinel-2 se obtiene una mejor identificación de la cobertura boscosa. Este resultado coincide con lo reportado por Topaloğlu et al. (2016) quienes compararon el comportamiento de los algoritmos MLC y SVM en imágenes Landsat-8 y Sentinel-2 de la región de Estambul, Turquía. Estos autores determinaron que las clasificaciones más exactas se obtenían con las imágenes Sentinel-2, y obtuvieron una fiabilidad entre 3% y 8% mayores en comparación con las alcanzadas a través de la información del satélite Landsat-8.

El funcionamiento del clasificador MDC en el presente estudio concuerda con diversas investigaciones en diversas zonas del planeta. Por ejemplo, Madhura y Venkatachalam (2015) clasificaron una imagen Landsat-8 del sur de India mediante tres algoritmos de clasificación entre los que se encontraron MLC y MDC. Dichos autores obtuvieron para MLC una fiabilidad global de 93,33% mientras que para MDC el valor obtenido correspondió a 85,72%. De igual forma, Booth y Oldfield (1989) trabajaron imágenes Landsat de Derbyshire, Inglaterra mediante cuatro clasificadores entre los que se encontraron MDC y MLC. En dicho estudio se obtuvieron valores de 87% de fiabilidad global para MLC mientras que para el algoritmo MDC el resultado obtenido fue igual a 85,5%. En la presente investigación se obtuvo el mismo comportamiento ya que el clasificador

MDC presentó valores de fiabilidad global menores (93,5%) en relación con el resultado obtenido para el algoritmo MLC (96,2%).

No se encontraron diferencias significativas entre los promedios obtenidos mediante los algoritmos MLC, SVM y NNC; este resultado difiere con el de otras investigaciones. Por ejemplo, Guo et al. (2008) en un estudio realizado en China compararon el rendimiento de cuatro algoritmos de clasificación entre los que se encontraban MLC y SVM. Dichos autores indican que el clasificador MLC es más rápido y estable que otros. Además, señalan como otra ventaja, que el algoritmo MLC es menos influenciado por el tamaño de la muestra de entrenamiento.

De igual forma, Deilmai et al. (2014) compararon la fiabilidad obtenida mediante clasificaciones por MLC y SVM en imágenes Landsat del estado de Johor en Malasia e identificaron el algoritmo SVM como el de mejor rendimiento al obtener valores de fiabilidad de 91,67% en comparación al valor de 78,33% de fiabilidad obtenido mediante el algoritmo MLC. De igual manera, se obtuvieron mayores valores con SVM en comparación con MLC en otro estudio de clasificación de usos de la tierra de imágenes Landsat del estado en Odisha, India (Mondal et al., 2012). En dicha investigación la fiabilidad general fue cercana al 78% para MLC; mientras que para SVM se obtuvo una fiabilidad global superior al 90%.

Es importante aclarar que se puede garantizar una mayor fiabilidad de los algoritmos SVM y NNC al analizar diferentes arquitecturas de redes

y diferentes conjuntos de parámetros (Kupková et al., 2017); por lo que de llevarse a cabo esta optimización, se podrían presentar diferencias estadísticas de estos algoritmos en relación con MLC. No obstante, debido a que al utilizar los parámetros base del software utilizado, se obtuvo una fiabilidad mayor a 90% para todos los métodos, se decidió no incluir en el alcance de la presente investigación la evaluación y optimización de cada uno de los parámetros requeridos por los algoritmos.

En cuanto a las diferencias a razón del mes en que se obtuvieron las imágenes, se observa que estas se corresponden con comportamiento de la estación lluviosa y seca en el área de estudio. Los meses con mayor precipitación son de mayo a febrero, mientras que la época seca se da tan solo entre los meses de marzo a mayo (Barrientos y Chaves, 2008). Las imágenes utilizadas en este estudio provenían de meses al final de la temporada lluviosa o bien en periodo seco, y el mes en que se reportó una menor fiabilidad es el único que se encuentra en medio de la estación de lluvias.

El efecto de la época lluviosa puede deberse a dos razones: Los ciclos fenológicos de la vegetación en el área de estudio y la alta presencia de nubes en la temporada de precipitaciones. En cuanto a los ciclos fenológicos, diversas investigaciones han demostrado como la actividad fotosintética de las plantas a través del año puede variar la firma espectral de los diferentes usos de la tierra.

Un estudio realizado entre 2001 y 2016 en bosques de la cuenca Piaxtla-Elota-Quelite y el área protegida Meseta de Cacaxtla, México mediante imágenes MODIS detectó etapas fenológicas muy marcadas que coinciden con lo observado en la presente investigación: la etapa fotosintética empieza en junio con las primeras lluvias, luego el NDVI alcanza sus máximos valores en el mes más lluvioso (septiembre), con un decrecimiento de la actividad fotosintética entre los meses de octubre y abril; por último, en el mes de mayo se presenta la menor actividad fisiológica (Berlanga, Cervantes y Murúa, 2018).

Vega y Alvarado (2019) demostraron que existen meses con una amplia variación en la firma espectral para un mismo mes en años diferentes. Entre los meses que presentan mayor variación se encuentran marzo y abril, dos meses en medio

de la época seca y octubre, el cual es un mes en medio de la temporada de lluvias. Los meses con la respuesta espectral más estable a través de los años fueron aquellos al inicio de la temporada de lluvias, junio y julio.

La temporada de precipitaciones se encuentra ligada a la presencia de nubes, las cuales se reportan como uno de los principales obstáculos en el análisis de la superficie terrestre (Kristollari y Karathanassi, 2019). Esto se debe a que el efecto de brillo de las nubes y el efecto de oscurecimiento de sus sombras causa ruido en los datos, provocando errores en la detección de los usos del suelo, así como, en los cambios de cobertura (Zhu y Woodcock, 2012). De esta manera, a pesar de que se llevó a cabo la extracción de las nubes, estas no pudieron ser eliminadas en un 100%, lo que afectó los resultados de las imágenes del mes más nuboso, septiembre. De igual forma, el efecto de oscurecimiento comentado por Zhu y Woodcock (2012) afectó en mayor medida al algoritmo MDC, ya que algunas coberturas, al presentarse más oscuras por la presencia de sombras de nubes, fueron reconocidas como bosques por este clasificador el cual, como se comentó anteriormente, tiende a dar una sobrestimación de las coberturas forestales.

Finalmente, es importante mencionar que la validación llevada a cabo contempló la alta fragmentación del paisaje estudiado (Chassot et al., 2010). La diversidad de este provocó que una gran cantidad de puntos de validación se encontraran en bordes de masas arbóreas, por lo que se ubicaban sobre píxeles mixtos. Por tanto, los valores identificados por este tipo de píxel pueden no representar adecuadamente los usos de la tierra en el área (Choodarathnakara et al., 2012). La resolución espacial de las imágenes en estudio provoca que este tipo de píxeles sean comunes (Lu y Weng, 2007); por tanto, la validación no se realizó de manera puntual, sino que se contempló el entorno en el que se encontraba el punto, de forma que no se produjeran errores debido a la existencia de los píxeles mixtos.

5. Conclusiones

Mediante el estudio de los dos tipos de imágenes satelitales y los cuatro diferentes algoritmos de clasificación analizados, los resultados obtenidos

permiten concluir que se logra una mayor fiabilidad en la identificación de la cobertura boscosa en paisajes altamente fragmentados mediante los algoritmos MLC, SVM y NNC, siendo SVM, el algoritmo que tiende a presentar resultados ligeramente superiores cuando se trabajan sobre imágenes Sentinel-2. Sin embargo, no hay diferencia estadística en relación con las otras técnicas, siempre y cuando no se lleve una optimización de los parámetros de los algoritmos NNC y SVM. Además, el algoritmo MDC muestra que no es apropiado, ya que produce una sobreestimación del área de bosques. Por otro lado, en cuanto al tipo de imagen, los resultados obtenidos reflejan que se logra una mejor identificación de la cobertura boscosa mediante las imágenes Sentinel-2.

Agradecimientos

Los autores agradecen a la Vice-Rectoría de Investigación y Extensión del ITCR por el apoyo financiero y administrativo para la realización del proyecto: *Derivación indirecta de la distribución espacial y estado de desarrollo de los bosques secundarios en Costa Rica usando imágenes satelitales de mediana resolución espacial*. Igualmente se agradece al programa de becas CeNAT-CONARE y al laboratorio PRIAS del Centro Nacional de Alta Tecnología (CeNAT) de Costa Rica por la facilitación de los equipos de cómputo de avanzada y el uso de las licencias de los softwares requeridos para llevar a cabo esta investigación.

Referencias

Adankon, M., Cheriet, M. 2015. Support Vector Machine. En *Encyclopedia of Biometrics*, Editada por Stan Z. Li and Anil K. Jain, London: Springer. https://doi.org/10.1007/978-1-4899-7488-4_299

Barrientos, O., Chaves, G. 2008. Región Huetar Norte. Oferta exportada actual y oferta potencial de productos agropecuarios alternativos. Último acceso: 18 de marzo, 2020, de: https://web.archive.org/web/20140309040649/http://www.procomer.com/contenido/descargables/investigaciones_economicas/2008/Region_Huetar_Norte_final.pdf

Berlanga, C., Cervantes, A., Murúa, E. 2018. Estacionalidad y tendencias del bosque tropical caducifolio de la cuenca Piaxtla-Elota-Quelite y el área protegida Meseta de Cacaxtla, México. *Madera y bosques*, 24(3), 1-16. <https://doi.org/10.21829/myb.2018.2431576>

Booth, D., Oldfield, R. 1989. A comparison of classification algorithms in terms of speed and accuracy after the application of a post-classification modal filter. *International Journal of Remote Sensing*, 10(7), 1271-1276. <https://doi.org/10.1080/01431168908903965>

CCT. 1993. Mapa Ecológico de Costa Rica, según el sistema de clasificación de Zonas de Vida del mundo de L. R. Holdridge. Bolaños, R; Watson; V. 1993 / Centro Científico Tropical (CCT) / esc: 1: 200 000). En *Atlas Digital de Costa Rica 2014*. Editado por E. Ortiz. ITCR, Cartago, Costa Rica.

Centro Nacional de Información Geoambiental (CENIGA). 2018. *Sistema de Definición de Clases de los Usos y Coberturas de la Tierra de Costa Rica*. San José, Costa Rica.

Chassot, O., Chaves, H., Finengan, B., Monge, G. 2010. Dinámica de paisaje en la Zona Norte de Costa Rica: implicaciones para la conservación del bosque tropical muy húmedo. *Revista De Ciencias Ambientales*, 39(1), 37-53. <https://doi.org/10.15359/rca.39-1.5>

Chazdon, R. 2014. *Second growth: the promise of tropical forest regeneration in an age of deforestation*. Chicago, University of Chicago Press. <https://doi.org/10.7208/chicago/9780226118109.001.0001>

Choodarathnakara, A., Ashok, T., Koliwad, S., Patil, C. 2012. Mixed pixels: a challenge in remote sensing data classification for improving performance. *International Journal of Advanced Research in Computer Engineering and Technology (IJARCET)*, 1(9), 261-271.

Deilmai, B., Ahmad, B., Zabihi, H. 2014. Comparison of two classification methods (MLC and SVM) to extract land use and land cover in Johor Malaysia. En *IOP Conference Series: Earth and Environmental Science*, Volume 20, 7th IGRSM International Remote Sensing & GIS Conference and Exhibition. Kuala Lumpur, Malaysia, 22-23 de April. pp 1-7.

Del Toro, N., Gomariz, F., Cánovas, F., Alonso, F. 2015. Comparación de métodos de clasificación de imágenes de satélite en la cuenca del Río Argos (Región de Murcia). *Boletín de la Asociación de Geógrafos Españoles*, 67, 327-347.

European Space Agency (ESA). 2020. *Sentinel Online, Level C-1*. Último acceso: 15 de setiembre, 2020, de <https://www.harrisgeospatial.com/docs/SupportVectorMachine.html>

- Guo, J., Zhang, J., Zhang, Y., Cao, Y. 2008. Study on the comparison of the land cover classification for multitemporal MODIS images. Paper presented at the *fifth International Workshop on Earth Observation and Remote Sensing Applications*, Xi'an, China, 18-20 de Junio. pp 1-6. <https://doi.org/10.1109/EORSA.2008.4620305>
- Harris Geospatial Solutions, Inc. 2020. *Support Vector Machine*. Último acceso: 9 de julio, 2020, de <https://www.harrisgeospatial.com/docs/SupportVectorMachine.html>
- Hermosilla, T., Wulder, M., White, J., Coops, N., Hobart, G. 2015. An integrated landsat time series protocol for change detection and generation of annual gap-free surface reflectance composites. *Remote Sensing of Environment*, 158, 220-234. <https://doi.org/10.1016/j.rse.2014.11.005>
- Kristollari, V., Karathanassi, V. 2020. Artificial neural networks for cloud masking of Sentinel-2 ocean images with noise and sunglint. *International Journal of Remote Sensing*, 41(11), 4102-4135. <https://doi.org/10.1080/01431161.2020.1714776>
- Kupková, L., Červená, L., Suchá, R., Jakešová, L., Zagajewski, B., Březina, S., Albrechtová, J. 2017. Classification of Tundra Vegetation in the Krkonoše Mts. National Park Using APEX, AISA Dual and Sentinel-2A Data. *European Journal of Remote Sensing*, 50(1), 29-46. <https://doi.org/10.1080/22797254.2017.1274573>
- Li, J., Yang, X., Maffei, C., Tooth, S., Yao, G. 2018. Applying independent component analysis on Sentinel-2 imagery to characterize geomorphological responses to an extreme flood event near the non-vegetated Río Colorado terminus, Salar de Uyuni, Bolivia. *Remote Sensing*, 10(5), 725-743. <https://doi.org/10.3390/rs10050725>
- Lu, D., Weng, Q. 2007. A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5), 823-870. <https://doi.org/10.1080/01431160600746456>
- Madhura, M., Venkatachalam, S. 2015. Comparison of supervised classification methods on remote sensed satellite data: an application in Chennai, South India. *International Journal of Science and Research (IJSR)*, 4(2), 1407-1411.
- Mata, R., Rosales, A., Vásquez, A., Sandoval, D. 2010. Mapa digital de suelos, órdenes y subórdenes, escala 1:200 000. Centro de investigaciones Agronómicas (CIA), Facultad de Ciencias Agroalimentarias. UCR. En *Atlas Digital de Costa Rica* 2014. Editado por: E. Ortiz, ITCR, Cartago, Costa Rica.
- Matthew, M., Adler-Golden, S., Berk, A., Richtsmeier, S., Levine, R., Bernstein L., Acharya, P., Anderson, G., Felde, G., Hoke, M., Ratkowski, A., Burke, H., Kaiser, R., Miller, D. 2000. Status of Atmospheric Correction Using a MODTRAN4-based Algorithm. *SPIE Proceedings, Algorithms for Multispectral, Hyperspectral, and Ultraspectral Imagery VI*, 4049: 199-207. <https://doi.org/10.1117/12.410341>
- Mondal, A., Kundu, S., Kumar, S., Shukla, R., Mishra, P. 2012. Comparison of support vector machine and maximum likelihood classification technique using satellite imagery. *International Journal of Remote Sensing and GIS*, 1(2), 116-123.
- Mountrakis, G., Im, J., Ogole, C. 2011. Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247-259. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- Mura, M., Botalico, F., Giannetti, F., Bertani, R., Giannini, R., Mancini, M., Orlandini, S., Travaglini, D., Chirici, G. 2018. Exploiting the capabilities of the sentinel-2 multi spectral instrument for predicting growing stock volume in forest ecosystems. *International Journal of Applied Earth Observation and Geoinformation*, 66, 126-134. <https://doi.org/10.1016/j.jag.2017.11.013>
- Murtaza, K., Romshoo, S. 2014. Determining the suitability and accuracy of various statistical algorithms for satellite data classification. *International Journal of Geomatics and Geosciences*, 4(4), 585-599.
- Ndehedehe, C., Ekpa, A., Simeon, O., Nse, O. 2013. Understanding the Neural Network Technique for Classification of Remote Sensing Data Sets. *New York Science Journal*, 6(8), 26-33.
- Nhamo, L., van Dijk, R., Magidi, J., Wiberg, D., Tshikolomo, K. 2018. Improving the accuracy of remotely sensed irrigated areas using post-classification enhancement through UAV capability. *Remote Sensing*, 10(5), 712-723. <https://doi.org/10.3390/rs10050712>
- Ningthoujam, R., Tansey, K., Balzter, H., Morrison, K., Johnson, S., Gerard, F., George, C., Burbidge, G., Doody, S., Veck, N., Llewellyn, G., Blythe, T. 2016. Mapping forest cover and forest cover change with airborne s-band radar. *Remote Sensing*, 8(7), 577-597. <https://doi.org/10.3390/rs8070577>
- Olofsson, P., Foody, G., Herold, M., Stehman, S., Woodcock, C., Wulder, M. 2014. Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, 148, 42-57. <https://doi.org/10.1016/j.rse.2014.02.015>

- Perumal, K., Bhaskaran, R. 2010. Supervised classification performance of multispectral images. *Journal of computing*, 2(2), 124-129.
- Pimple, U., Sitthi, A., Simonetti, D., Pungkul, S., Leadprathom, K., Chidthaisong, A. 2017. Topographic correction of Landsat TM-5 And Landsat OLI-8 imagery to improve the performance of forest classification in the mountainous terrain of northeast Thailand. *Sustainability*, 9(2), 258-283. <https://doi.org/10.3390/su9020258>
- Ponce, D., Donoso, P., Salas-Eljatib, C. 2017. Differentiating structural and compositional attributes across successional stages in Chilean temperate rainforests. *Forests*, 8(9), 329-343. <https://doi.org/10.3390/f8090329>
- Qiu, S., He, B., Zhu, Z., Liao, Z., Quan, X. 2017. Improving Fmask cloud and cloud shadow detection in mountainous area for Landsats 4-8 images. *Remote Sensing of Environment*, 199, 107-119. <https://doi.org/10.1016/j.rse.2017.07.002>
- Sader, S., Joyce, A. 1988. Deforestation rates and trends in Costa Rica, 1940 to 1983. *Biotropica*, 20, 11-19. <https://doi.org/10.2307/2388421>
- Sánchez, G., Rivard, B., Calvo, J., Moorthy, I. 2002. Dynamics of tropical deforestation around national parks: remote sensing of forest change on the Osa Peninsula of Costa Rica. *Mountain Research and Development*, 22(4), 352-358. [https://doi.org/10.1659/0276-4741\(2002\)022\[0352:DOTDAN\]2.0.CO;2](https://doi.org/10.1659/0276-4741(2002)022[0352:DOTDAN]2.0.CO;2)
- Shen, H., Lin, Y., Tian, Q., Xu, K., Jiao, J. 2018. A comparison of multiple classifier combinations using different voting-weights for remote sensing image classification. *International Journal of Remote Sensing*, 39(11), 3705-3722. <https://doi.org/10.1080/01431161.2018.1446566>
- Shi, X., Xue, B. 2016. Parallelizing maximum likelihood classification on computer cluster and graphics processing unit for supervised image classification. *International Journal of Digital Earth*, 10(7), 737-748.
- Topaloğlu, R., Sertel, E., Musaoğlu, N., 2016. Assessment of classification accuracies of sentinel-2 and landsat-8 data for land cover/use mapping. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B8, 1055-1059. <https://doi.org/10.5194/isprsarchives-XLI-B8-1055-2016>
- Vega, M., Alvarado, R. 2019. Análisis de las series de tiempo de variables biofísicas para cuatro ecorregiones de Guanacaste, Costa Rica. *Revista de Ciencias Ambientales*, 53(2), 60-96. <https://doi.org/10.15359/rca.53-2.4>
- Vogeler, J., Braaten, J., Slesak, R., Falkowski, M. 2018. Extracting the full value of the Landsat archive: Inter-sensor harmonization for the mapping of Minnesota forest canopy cover (1973-2015). *Remote Sensing of Environment*, 209, 363-374. <https://doi.org/10.1016/j.rse.2018.02.046>
- Wacker, A., Langrebe, D. 1972. Minimum Distance Classification in Remote Sensing. En *1st Canadian Symposium for Remote Sensing*. Montreal, Canada, 7-9 de febrero. spp.
- Walton, A. 2015. *Assessing the performance of different classification methods to detect inland surface water extent*. Bachelor Thesis. Institute of Geodesy, Universidad de Stuttgart; Alemania.
- Whyte, A., Ferentinos, K., Petropoulos, G. 2018. A new synergistic approach for monitoring wetlands using sentinels-1 and 2 data with object-based machine learning algorithms. *Environmental Modelling and Software*, 104, 40-54.
- Yang, H., Pan, B., Wu, W., Tai, J. 2018. Field-based rice classification in Wuhua county through integration of multi-temporal sentinel-1A and landsat-8 OLI data. *International Journal of Applied Earth Observation and Geoinformation*, 69, 226-236. <https://doi.org/10.1016/j.jag.2018.02.019>
- Yang, X., Zhao, S., Qin, X., Zhao, N., Liang, L. 2017. Mapping of urban surface water bodies from Sentinel-2 MSI imagery at 10 m resolution via NDWI-based image sharpening. *Remote Sensing*, 9(6), 596-603. <https://doi.org/10.3390/rs9060596>
- Yin, H., Pflugmacher, D., Li, A., Li, Z., Hostert, P. 2018. Land use and land cover change in inner Mongolia-understanding the effects of china's re-vegetation programs. *Remote Sensing of Environment*, 204, 918-930. <https://doi.org/10.1016/j.rse.2017.08.030>
- Zhao, F., Huang, C., Goward, S., Schleeweis, K., Rishmawi, K., Lindsey, M., Denning, E., Keddell, L., Cohen, W., Yang, Z., Dungan, J., Michaelis, A. 2018. Development of Landsat-based annual US forest disturbance history maps (1986-2010) in support of the North American Carbon Program (NACP). *Remote Sensing of Environment*, 209, 312-326. <https://doi.org/10.1016/j.rse.2018.02.035>
- Zhu, Z., Woodcock, C. 2012. Object-based cloud and cloud shadow detection in Landsat imagery. *Remote Sensing of Environment*, 118, 83-94. <https://doi.org/10.1016/j.rse.2011.10.028>