

**INSTITUTO TECNOLÓGICO DE COSTA RICA**  
**VICERRECTORÍA DE INVESTIGACIÓN Y EXTENSIÓN**

**DIRECCIÓN DE PROYECTOS**

**ESCUELA DE INGENIERÍA FORESTAL**  
**CENTRO DE INVESTIGACIÓN EN INNOVACION FORESTAL**  
**INFORME FINAL DE PROYECTO DE INVESTIGACIÓN**

Derivación indirecta de la distribución espacial y estado de desarrollo de los bosques secundarios en Costa Rica usando imágenes satelitales de mediana resolución espacial

**Documento I**

Investigador Coordinador  
Dr. Edgar Ortiz Malavasi

**Junio, 2020**

## Contenido

1	Datos Generales del Proyecto .....	3
2	Resumen .....	4
3	Introducción .....	5
4	Marco Teórico .....	7
5	Metodología .....	12
6	Resultados y discusión .....	14
7	Conclusiones.....	16
8	Recomendaciones para futuras investigaciones.....	17
9	Aportes y beneficios inmediatos o futuros de los resultados obtenidos.....	18
10	Agradecimientos .....	19
11	Referencias.....	19
	Anexo 1.....	23
	Anexo 2.....	54

## 1 Datos Generales del Proyecto

**CODIGO DEL PROYECTO:** 1401-0077

**NOMBRE 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

**ESCUELA RESPONSABLE:** Escuela de Ingeniería Forestal / Centro de investigación en innovación forestal.

**INSTITUCIONES PARTICIPANTES EXTERNAS AL ITCR:** PRIAS-CENAT

### INVESTIGADORES

Nombre	Cargo	Institución	Correo
Dr. Edgar Ortiz Malavasi (Ph.D)	Coordinador	ITCR	eortiz@itcr.ac.cr
Ing. Casia Soto Montoya (M.P)	Investigadora	ITCR	csoto@itcr.ac.cr
Ing. Heileen Aguilar Arias (Lic.)	Investigadora	PRIAS-CENAT	haguilar@cenat.ac.cr
Ing. Cornelia Miller Granados (M.B.A)	Investigadora	PRIAS-CENAT	cgranados@cenat.ac.cr
Ing. Iván Ávila Pérez (Lic.)	Estudiante Maestría Ciencias Forestales	ITCR	iavila@cenat.ac.cr
Ing. Yerlin Vargas (Lic.)	Investigadora	PRIAS-CENAT	yvargas@cenat.ac.cr

**PERÍODO DE EJECUCIÓN:** Enero 2018 - Diciembre 2019.

## 2 Resumen

El objetivo de la presente investigación fue desarrollar una técnica indirecta para conocer la distribución espacial y estado de desarrollo de bosques secundarios usando sensores remotos de mediana resolución. La metodología fue probada en un sector de la Zona Huetar Norte de Costa Rica. Se realizó la clasificación de imágenes satelitales Landsat y Sentinel-2 de diferentes años: 2000, 2005, 2010 y 2017/2018. Se comparó la ubicación de las masas boscosas por año y se efectuó una reclasificación de las áreas donde se presentó ganancia de cobertura arbórea (bosques nuevos) identificándose cuáles de estas representan bosques secundarios. Se validaron los resultados y las exactitudes obtenidas se utilizaron como variables respuesta de un ANOVA. El método OBIA supera a MLC en la identificación de los bosques nuevos ( $pvalue=0,035$ ). El mes de la imagen influye en la exactitud del productor ya que produce una interacción con el método ( $pvalue= 0,027$ ) y con el tipo de imagen ( $pvalue= 0,008$ ). También se produce una interacción mes-imagen para la exactitud del usuario ( $pvalue= 0,042$ ) y la exactitud general de la clase de bosques secundarios ( $pvalue= 0,012$ ). La tendencia muestra que el mejor método para cuantificar y ubicar los bosques secundarios es la clasificación de imágenes Sentinel-2 de los meses de junio y julio mediante Análisis Basado en Objetos (OBIA).

**Palabras clave:** Bosques secundarios, Clasificación por Máxima, Verosimilitud, Clasificación Basada en Objetos, Landsat, Sentinel-2.

### Abstract

The objective of the present investigation was to develop an indirect technique to know the spatial distribution and development status of secondary forests using medium resolution remote sensors. The methodology was tested in a sector of the Northern Huetar Zone of Costa Rica. Landsat and Sentinel-2 images were classified for different years: 2000, 2005, 2010, 2017, and 2018. The location of the forest stands per year was compared and a reclassification of the areas where there was a gain in tree cover (new forests) was carried out, identifying which of these represent secondary forests. Results were validated and the accuracies obtained were used as ANOVA response variables. The OBIA method outperforms MLC in identifying new forests ( $pvalue = 0.035$ ). The month of the image influences the accuracy of the producer since it produces an interaction with the method ( $pvalue = 0.027$ ) and with the image type ( $pvalue = 0.008$ ). A month-image interaction also occurs for user accuracy ( $pvalue = 0.042$ ) and overall accuracy of secondary forest class ( $pvalue = 0.012$ ). The trend shows that the best method to quantify and locate secondary forests is the classification of Sentinel-2 images for the months of June and July using Object Based Analysis (OBIA).

**Key words:** Secondary Forests, Maximum Likelihood Classification, Object Base Classification, Landsat, Sentinel-2

### 3 Introducción

Durante la preparación del programa de reducción de emisiones por deforestación y degradación de bosques en Costa Rica (REDD+) se identificó que, aunque la tasa neta de deforestación en Costa Rica fue negativa durante el periodo 1997-2005, es decir se han recuperado más bosques de lo que se pierde, si ha existido deforestación en ese periodo, la cual proviene principalmente de cambios de uso de suelo de terrenos con bosques secundarios. La información de la dinámica de los bosques secundarios es escasa en Costa Rica, y es necesario reforzar este conocimiento, para contribuir al abastecimiento de madera sostenible en el país (OET *et al.*, 2008). La variabilidad por edades, la composición florística y la distribución geográfica del bosque secundario, influye en su potencial y no permite establecer criterios generalizados sobre su manejo.

Según el Inventario Nacional 2012-2013 existían cerca de 698000 hectáreas de bosques secundarios en Costa Rica. A esta cifra hay que sumar una cantidad de hectáreas aún no determinada derivada de los efectos del Huracán Otto principalmente en la Región Huetar Norte. Con la pérdida de bosques secundarios entonces el país desaprovecha la oportunidad de mitigación emisiones de carbono derivadas del crecimiento del bosque secundario, así como opciones para el desarrollo de nuevas fuentes de productos forestales.

Para contrarrestar la pérdida de bosques secundarios se ha identificado que es necesario desarrollar los conocimientos y técnicas para hacer más competitivo su manejo y conservación, y así poder incorporarlos dentro de los planes de desarrollo de clústeres de producción forestal previstos en el Plan Nacional de Desarrollo Forestal (PNDF), uno de los cuales fue el creado recientemente por el Ministerio de Ambiente y Energía en la Región Huetar Norte de Costa Rica.

Para conocer la productividad de los bosques secundarios, se requiere a su vez conocer su estado de desarrollo, y su distribución geográfica. El área y distribución geográfica de los bosques secundarios se puede conocer mediante el uso de imágenes de satélite de alta o mediana resolución espacial. Sin embargo, las imágenes de alta resolución son costosas, no cubren todo el país, y son relativamente recientes, por lo que debe usarse imágenes de mediana resolución y de acceso libre. Sin embargo, estudios anteriores muestran que con imágenes de mediana resolución se ha logrado alcanzar una exactitud que varía entre 70 y 77% en la identificación de bosques secundarios para un determinado año, por lo que el país no tiene realmente información confiable de la ubicación, área y estado de desarrollo de estos bosques, información que esencial para desarrollar estrategias de manejo y conservación de los mismos.

El problema que se enfrenta en la identificación de bosques secundarios con imágenes satélites de mediana resolución proviene de que estos poseen características similares a otros tipos de usos de la tierra, tal como bosques maduros, pastos arbolados, plantaciones forestales, y cultivos permanentes de frutales, bosques de palma, o caña. Sin embargo, actualmente se ampliado la disponibilidad de imágenes satélites de acceso libre de mediana resolución, así como el desarrollo de nuevos algoritmos de clasificación de las mismas, y existe entonces la necesidad de probar diferentes metodologías mediante diseño experimental sólido que permitiera identificar la combinación el método de clasificación y tipo de imagen adecuada para identificar bosques secundarios y conocer su estado de desarrollo en Costa Rica.

El objetivo de este proyecto fue desarrollar una técnica indirecta para conocer la distribución espacial y estado de desarrollo de bosques secundarios usando sensores remotos de mediana resolución. El plan de trabajo del proyecto incluyó tres pasos, a saber, a) el identificar el mejor algoritmo de clasificación de dos tipos de imágenes satelitales de media resolución y de libre acceso mediante un diseño experimental de bloques, con una arreglo factorial de dos factores y dos niveles cada uno (2x2), b) comparar clasificaciones de uso de la tierra de dos años para identificar áreas de cambio, dentro las cuales se encuentran tierras reforestadas que fueron denominadas como “bosques nuevos”, y c) dado

que está última clase incluye tanto plantaciones forestales como bosques secundarios, identificar las que corresponden a la subclase de interés. Este proceso puede repetirse comparando clasificaciones de uso de la tierra de diferentes periodos, 2000-2005, 2005-2010, 2010-2017, por lo que se puede conocer la edad aproximada de los bosques secundarios identificados. La mejor combinación de tratamientos se escogió mediante el uso de matrices de error usando datos de campo independientes.

## **4 Marco Teórico**

Las primeras actividades en el campo de la teledetección en Costa Rica iniciaron en 1940, con la adquisición de fotografías para planificar la construcción de la carretera interamericana. Sin embargo, los primeros en utilizar las imágenes satelitales Landsat fueron Sander y Joyce en 1988, quienes usaron estas imágenes para estimar las tasas de deforestación de Costa Rica entre 1940 y 1983.

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. En primera instancia disponíamos de las imágenes de los satélites LANDSAT 1, 2, y 3, que fueron lanzados en los años 1972, 1975 y 1978 respectivamente. LANDSAT-1 fue puesto fuera de operación en 1978 después del mal funcionamiento de un sensor y los LANDSAT-2 y 3 fueron puestos fuera de comunicación en 1983. Estos satélites tenían los mismos parámetros orbitales y transportan los mismos sensores, cada satélite proporcionaban imágenes de casi toda la tierra cada 18 días. La Administración Nacional Oceánica y Atmosférica (NOAA) con la cooperación de la NASA lanzó LANDSAT 4 y 5 en los años 1982 y 1984 respectivamente. Estos satélites proporcionaban imágenes casi toda la tierra cada 16 días. La principal diferencia con los LANDSAT 1,2 y 3, es que tenían una nueva generación de Mapeadores Temáticos (TM) con más bandas espectrales y una resolución terrestre mejorada (FAO, S.F.).

Los sensores colocados en los satélites para los estudios de cobertura de la tierra se han ido mejorando en resolución espacial, temporal y radiométrica. Por ejemplo, si se trabaja con

imágenes LANDSAT 8, el cual es fue lanzado en el 2013 por la NASA y el Servicio Geológico de los Estados Unidos (USGS), se puede contar con 11 bandas espectrales que abarcan longitudes de onda desde los 0.435 a los 12.51  $\mu\text{m}$ , con resoluciones espectrales de 30 metros para las bandas visibles e infrarrojas y 15 metros para la banda pancromática, y 100 m para las bandas termales (USGS, S.F.). En cuanto a la resolución radiométrica, el sensor OLI a bordo de Landsat 8 presenta una mayor resolución en comparación a los sensores TM y ETM+ a bordo de Landsat 5 y 7 respectivamente (Hoang y Koike, 2018). Gracias a estas características y la gran cantidad de información disponible, los investigadores de la teledetección se han enfocado en desarrollar técnicas para poder sacar el mejor provecho de estos sistemas (Hermosilla *et al*, 2015).

En el año 2015 se inició el programa de satélites Sentinel, abriéndose de esta manera el espectro de disponibilidad de imágenes para realizar estudios de cobertura de la tierra ya que estas son también de acceso libre. 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 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).

Las exactitudes en la clasificación de uso de la tierra cambian según el tipo de imágenes utilizadas, el procesamiento de estas, y el método clasificación empleado. Los métodos de clasificación de imágenes satelitales se pueden catalogar en los que usan como base la clasificación por píxeles, y los orientados a la clasificación por objetos, como lo sería el uso de segmentos de clasificación. La segmentación es un proceso que se aplica a una imagen para dividir la misma en regiones separadas que corresponden a diferentes objetos del

mundo real. Esta relación de la clasificación de imágenes orientada a objetos está basada en el hecho de que la información semántica necesaria para interpretar una imagen no está fundamentada sólo en la representación de un píxel; sino, en objetos de la imagen significativos y sus relaciones (Gamanya, De Maeyer, & De Dapper, 2007). De acuerdo con Alba, Rey y Docio (1999) la segmentación de imágenes trata de descomponer una escena en los principales objetos o regiones que la componen. Típicamente un proceso de segmentación de imágenes convierte una imagen de formato ráster a un formato vector, esto incluye dos pasos primordiales, primero una imagen se segmenta en objetos de imagen similares y luego los objetos se clasifican en función de los atributos e interrelaciones entre objetos segmentados (Liu, Guo, & Kelly, 2008).

Gamanya et al., (2007), aplicaron técnicas de segmentación región-fusionada incorporando propiedades espectrales y texturales de los objetos a detectar y su comportamiento en diferentes escalas utilizando “eCognition”. Este método mezclado con el Sistema de Clasificación de Cobertura y Uso de la Tierra de la FAO permitió obtener una metodología de clasificación estandarizada y automatizada sobre imágenes Landsat y Aster, utilizando clases mutuamente excluyentes. Los resultados de precisión global fueron de 92% para Aster y 89% para Landsat.

Yu et al. (2006), encontraron que, al aplicar segmentación con índices geométricos, compacidad y suavidad del mismo peso, el tamaño de los objetos dependía de la variación de los valores espectrales sobre los vecinos espaciales. Esto permitió identificar que los objetos eran más grandes en áreas con cubierta mayormente herbácea, y menores en áreas boscosas, debido a la diferente variación espacial en los valores espectrales entre estas clases. Por lo cual Yu et al (2006), aseguran que esta segmentación adaptativa puede reducir considerablemente la cantidad de datos para procesamiento y clasificación, conservando al mismo tiempo la información de la variación espectral.

La clasificación espectral por píxeles de imágenes satelitales consiste en agrupar píxeles en un número de clases en función de sus valores espectrales. Un píxel se asigna a una clase cuando cumple una serie de criterios calculados para esa clase. El resultado es un archivo

temático con valores que representan las clases. Existen dos tipos de clasificación espectral, la supervisada y la no supervisada (ERDAS, 2015).

La clasificación no supervisada, por medio del algoritmo ISODATA, agrupa los píxeles con valores espectrales similares en un número de clases que es definido por el usuario, este método tiene la ventaja de requerir pocos parámetros de configuración (clase-iteraciones), además requiere poco conocimiento de los datos y elimina los prejuicios humanos por ser automatizado. Una desventaja de este método es que la clasificación mejora conforme se aumenta el número de clases, pero esto hace que el trabajo de etiquetado de las clases con las coberturas reales sea más lento y requiera un nivel de experiencia y conocimiento del terreno mayor.

En la clasificación supervisada el usuario identifica los píxeles que representan patrones reconocibles (clases) o que son conocidos de otras fuentes, esto se hace por medio de la delimitación de áreas de entrenamiento. El software analiza las áreas de entrenamiento y determina los estadísticos que describen el comportamiento espectral de cada clase (firmas), con estos criterios asigna una clase a cada píxel de la imagen (Erdas, 2015). Las ventajas de este método es que permite tener un mayor control del proceso (Evaluación de firmas), sin embargo, es necesario tener conocimiento de los datos, las clases y el método de clasificación.

Existe un amplio espectro de algoritmos de clasificación supervisada (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). 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 el algoritmo de Machine-Learning, conocido como Máquinas de Soporte Vectorial (SVM, por

sus siglas en inglés), ha presentado gran auge, ya que muestra un buen rendimiento aun cuando se tiene una cantidad reducida de áreas de entrenamiento (Mountrakis et al., 2010). Además, este método es capaz de reducir los errores de la clasificación a través de un concepto de análisis de minimización del riesgo estructural (Tso y Mather, 2009).

Por otra parte, en los últimos años también se ha propuesto el uso de algoritmos de inteligencia artificial (IA) la clasificación de datos satelitales (Suliman y Zhang, 2015). De esta manera, la IA ha venido a solventar el problema de la clasificación con datos multifuente, esto es, no solo se emplea información espectral sino también información topográfica, mapas de cobertura y elevación, entre otros (Benediktsson et al., 1990). En este ámbito, los clasificadores a base de redes neuronales por su robustez y adaptabilidad, permiten estudiar modelos complejos de clasificación de imágenes como lo son los modelos discontinuos o no lineales.

En Costa Rica se han generado estudios de cobertura de la tierra con imágenes Landsat, Spot, y RapidEye, usando algoritmos de clasificación supervisada por píxeles y de segmentación de imágenes. 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. Los resultados indican que cuando se trabaja con muchas clases de uso de la tierra se tiene exactitudes bajas (70 a 80%), y que cuando se trabaja con menos clases se aumenta la exactitud, pasando de 89% con 10 clases a más de 94% en la exactitud global de la clasificación cuando se trabaja con tres clases de uso de la tierra, tal como bosque, no bosque y nubes-sombras (Costa Rica. SINAC-MINAE, 2015). Para la clase de bosque secundario se reportan exactitudes de usuario menores. En el caso del Inventario Forestal Nacional 2013-2014 (Costa Rica. SINAC-MINAE, 2015) se señala que para la clase bosques maduros, el 12% de los de datos de verificación independiente en campo eran en realidad bosques secundarios, lo que “reafirma los indicios de que existió en la clasificación una mezcla importante y una dificultad en separar bosques maduros de bosque

secundarios”. Por otro lado, en ese mismo proyecto se encontró una mezcla de importante entre bosques secundarios, plantaciones forestales y pastos arbolados lográndose una exactitud de usuario de solo el 63% para la clase plantaciones forestales.

Debido a todas las posibles combinaciones de tipo de imágenes, resolución espacial, número de clases a usar, preprocesamiento y tipos de clasificación se hace necesario investigar cuál es la mejor alternativa o combinación de factores para conocer la localización y estado de desarrollo de los bosques secundarios en una región.

## **5 Metodología**

Para desarrollar y probar la técnica indirecta propuesta para conocer la distribución espacial y estado de desarrollo de bosques secundarios usando sensores remotos de mediana resolución, se usó una zona piloto en la Región Huetar Norte de Costa Rica. La metodología incluye emplear un método de identificación indirecto en el cual se contrastan clasificaciones de cobertura de la tierra de diferentes años, en las cuales se ha identificado con alta exactitud solo cuatro categorías de cobertura, a saber: bosque, no bosque, nubes, y sombras.

Cuando se compare la clasificación de cobertura de la tierra de solo cuatro clases para diferentes años, se podrá identificar las áreas que tienen bosque actualmente, pero que no tenían bosque en una clasificación anterior, indicando que se trata de áreas de recuperación o “bosques nuevos”. El paso siguiente es usar información de campo, e imágenes de más alta resolución, para reclasificar la imagen de “bosques nuevos”, para así separar lo que es bosque secundario de lo que es reforestación por plantaciones forestales para un determinado año de referencia. Así mismo, se podrá conocer en qué año aproximadamente se dio la recuperación, que es un indicador de la edad y estado de desarrollo del bosque secundario.

La metodología del proyecto incluyó el cumplimiento de dos objetivos específicos:

**Objetivo Específico 1:** *Desarrollar una metodología para clasificar imágenes satelitales para separar bosque de no bosque con una exactitud de al menos 95%.*

**Objetivo específico 2:** *Escoger el mejor método para la identificación de bosque secundarios y según estado desarrollo.*

Para cumplir el objetivo específico 2 se realizaron dos actividades principales, estas fueron:

2.1 *Comparar dos métodos automatizados de validación de mapas de uso y cobertura de la tierra desarrollados con imágenes de mediana resolución en paisajes de uso y cobertura de la tierra muy heterogéneos.*

2.2 *Probar la eficiencia del método de identificación indirecta de bosque secundarios propuesto.*

La metodología seguida para cumplir con el primer objetivo se presenta en artículo presentado en el Anexo 1: *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.* Se usó un diseño con seis bloques o repeticiones, y ocho tratamientos derivados de la combinación de dos factores (2x4). El primer factor se denominó tipo de imágenes satelitales, y se compararon imágenes mediana resolución y acceso libre de Landsat-8, y de Sentinel-2 con nivel de procesamiento 1, capturadas entre el 01 de enero del 2017 y el 30 de abril del 2018. El segundo factor fue la clase de algoritmo de clasificación supervisada de píxeles, que tuvo cuatro niveles: Máxima Verosimilitud (MLC), Mínima Distancia (MDC), Máquinas de Soporte Vectorial (SVM) y el de Redes Neuronales (NNC). Este artículo fue enviado para publicación a la revista Teledetección en España.

Finalmente, en el Anexo 2 se incluye el artículo: *Derivación indirecta de la distribución espacial y estado de desarrollo de los bosques secundarios en Costa Rica usando imágenes satelitales de mediana resolución espacial.* En este artículo se describe el procedimiento

seguido para cumplir con el segundo objetivo específico. Al igual que en los casos anteriores se usó un diseño experimental con seis bloques, y en este caso se analizó la exactitud global calculada en la identificación de la capa de datos de “bosques nuevos”, y la de “bosques secundarios”, producidas usando dos algoritmos de clasificación de imágenes, MLC y Análisis Basado en Objetos (OBIA), para los periodos 2000-2017 empleando imágenes satelitales respectivamente Landsat 5 y Landsat 8, y el periodo 2000-2018 empleando imágenes de Landsat 5 del 2000, y Sentinel-2 del 2018.

En el análisis de datos derivados de todos los ensayos se usó como variable respuesta la exactitud global calculada con una matriz de errores. Se usó siempre una muestra de datos independientes para estimar la exactitud global, y los datos fueron estudiados usando primero la técnica de Análisis de la Varianza (ANDEVA) en el programa Infostat 2018e. En el caso de determinarse la existencia de diferencias significativas en alguno de los factores e interacciones, se realizaron comparaciones múltiples mediante la prueba de Tukey con el mismo software.

## 6 Resultados y discusión

**Objetivo Específico 1:** *Desarrollar una metodología para clasificar imágenes satelitales para separar bosque de no bosque con una exactitud de al menos 95%.*

Los resultados muestran que el uso de imágenes Sentinel-2 fue superior al obtenido con Landsat-8 ( $p=0,012$ ). No existen diferencias significativas en la exactitud lograda con los algoritmos de clasificación MLC, SVM y NNC, pero sí de estos con respecto al MDC. No se detectó que exista interacción entre tipo de imagen y algoritmo de clasificación ( $p=0,532$ ), 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 que cada imagen fue adquirida, y se encontraron diferencias significativas debido a este factor ( $p=0,0081$ ). Los mejores resultados se obtuvieron con imágenes de abril, y los más bajos con imágenes de setiembre, mes que coincide con la época lluviosa en la zona estudiada. Se concluye que la mayor exactitud en la identificación de la cobertura boscosa se logra

mediante el uso de los algoritmos MLC, SVM y NNC empleando imágenes Sentinel-2 tomadas en el inicio de la temporada de lluvias (ver Anexo 1).

Es importante mencionar que la validación llevada a cabo contempló la alta fragmentación del paisaje estudiado. La diversidad del mismo 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. Dado que la resolución espacial de las imágenes en estudio provoca que este tipo de píxeles sean comunes; 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.

**Objetivo específico 2:** *Escoger el mejor método para la identificación de bosque secundarios y según estado desarrollo.*

El método Análisis Basado en Objetos (OBIA) supera a MLC en la identificación de los bosques nuevos ( $pvalue=0,035$ ). El mes de la imagen influye en la exactitud del productor ya que produce una interacción con el método ( $pvalue= 0,027$ ) y con el tipo de imagen ( $pvalue= 0,008$ ). También se produce una interacción mes-imagen para la exactitud del usuario ( $pvalue= 0,042$ ) y la exactitud general de la clase de bosques secundarios ( $pvalue= 0,012$ ). La tendencia muestra que el mejor método para cuantificar y ubicar los bosques secundarios es la clasificación de imágenes Sentinel-2 de los meses de junio y julio mediante Análisis Basado en Objetos (OBIA) (ver Anexo 2).

El método OBIA redujo el efecto sal-pimienta en la imagen, lo que permitió una identificación más continua de las masas arbóreas y por ende de los bosques nuevos. Este elimina la existencia de píxeles aislados mal clasificados debido a que toma en cuenta tanto la textura como la forma y la posición de grupos de píxeles, de manera que cada segmento se compone de píxeles homogéneos y espacialmente unidos.

Los bajos valores de exactitud obtenidos en la identificación de los bosques nuevos pueden deberse a los vacíos de información en las imágenes que provocaron que ciertos bosques no

podieran ser identificados como cobertura forestal para los años 2005 y 2010, por ende, fueron identificados como bosques nuevos al llevar a cabo el análisis de cambios.

En el presente estudio, a pesar de que no se evidencian diferencias debido al tipo de imagen, se denota una tendencia a la mejor identificación de los bosques secundarios mediante las imágenes Sentinel-2, cuando se analiza la interacción entre el mes de la imagen en el año 1 y el tipo de imagen.

Se demuestra que las diferencias presentadas en las exactitudes de las clasificaciones se deben, en su mayoría, al mes de las imágenes en análisis. Lo anterior, concuerda con los últimos estudios en la rama de la teledetección enfocada en los análisis temporales y los cambios de las coberturas de la tierra a través del tiempo. Este tipo de estudios se basan en la idea de que, para mejorar la clasificación de los usos de la tierra vegetativos, se deben analizar imágenes en momentos claves del ciclo fenológico de la cobertura de interés de manera que se pueda separar con mayor facilidad de otros usos espectralmente similares.

Los estudios llevados a cabo en la presente investigación permiten inferir que, para reducir la posibilidad de semejanzas en la respuesta espectral entre los distintos tipos de bosque, los análisis deben llevarse a cabo mediante imágenes en la época donde la respuesta fotosintética de los árboles sea más estable, lo cual sucede en los primeros meses de la temporada de lluvias.

## **7 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 exactitud 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. 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.

El Análisis de Imágenes Basado en Objetos (OBIA) permitió obtener una mayor exactitud en la identificación de los bosques nuevos. Por otro lado, el mes en el que se capturaron las imágenes provoca diferencias significativas en la identificación de los bosques secundarios; debido a, la interacción de estos, tanto con el método de clasificación, como con el tipo de imagen utilizada. Además, se evidencia una tendencia a obtener mayores exactitudes cuando se utilizan imágenes Sentinel-2 en los meses al inicio de la temporada de lluvias. De manera que, el mejor método para cuantificar y ubicar los bosques secundarios corresponde a la clasificación de imágenes Sentinel-2 de los meses de junio y julio mediante Análisis Basado en Objetos (OBIA).

## **8 Recomendaciones para futuras investigaciones**

La investigación demuestra que el mes en que fue tomada la imagen afecta la identificación de bosques secundarios por la estacionalidad de los bosques, se recomienda llevar a cabo investigaciones donde se estudie el surgimiento de bosques nuevos mediante análisis de series temporales, de manera que se observen y contemplen con más detalle las variaciones debido a la estacionalidad en la zona de estudio.

Se recomienda no usar las imágenes Landsat 7 SLC-OFF (a partir del 2003). Los vacíos de información en dichas imágenes producen dificultades a la hora de identificar los usos de la tierra que realmente se encuentran en la superficie terrestre, provocando además falsos positivos en la identificación de bosques nuevos. Por tanto, no se recomienda usar imágenes entre junio del 2003 y enero del 2013 ya que todas estas presentan datos faltantes.

Las plataformas de internet Google Earth Engine o Sepal generan mosaicos de imágenes cuyo uso se debe investigar. Este tipo de mosaicos toman la información de diversas

imágenes en un periodo de tiempo dado y analiza pixel a pixel cual de todas las imágenes contiene la mejor información para formar la imagen final.

El porcentaje de nubosidad afecta la identificación de bosques secundarios por lo que se recomienda llevar a cabo un análisis de las herramientas de identificación de nubes basado en análisis multitemporales ya que la literatura reporta un mejor rendimiento de este tipo de algoritmos en comparación con las herramientas que utilizan imágenes puntuales.

Para uso del sistema de clasificación de OBIA se recomienda utilizar segmentaciones con una cantidad de segmentos entre 165 y 250 polígonos por kilómetro cuadrado para las imágenes Landsat, y entre 230 y 450 polígonos por kilómetro cuadrado para las imágenes Sentinel-2, ya que una menor cantidad de segmentos provoca que algunos usos de la tierra en una matriz fragmentada no sean identificados.

## **9 Aportes y beneficios inmediatos o futuros de los resultados obtenidos**

Según el Inventario Nacional 2013-2014, existían cerca de 702 366 hectáreas de bosques secundarios en Costa Rica (Costa Rica-SINAC-MINAE, 2015). A esta cifra hay que sumar una cantidad de hectáreas aún no determinada derivada de los efectos del Huracán Otto, principalmente en la Zona Huetar Norte. Con la pérdida de bosques secundarios, el país desaprovecha la oportunidad de la mitigación de emisiones de carbono derivadas del crecimiento de dichos bosques, así como opciones para el desarrollo de nuevas fuentes de productos forestales.

Para conocer la productividad de los bosques secundarios, se requiere a su vez conocer su estado de desarrollo y distribución geográfica. El área y distribución geográfica de los bosques secundarios se puede conocer mediante el uso de sensores remotos utilizando imágenes de satélite de alta o mediana resolución. Sin embargo, son pocos los estudios que contemplan y comparan los métodos de clasificación y las imágenes disponibles a partir de

los diferentes tipos de satélites, con el fin de aumentar la exactitud en la predicción de la ubicación de dichos bosques.

La elaboración de mapas que ubiquen y cuantifiquen tanto los bosques secundarios como el paisaje en general son la piedra angular de muchas actividades científicas, de manejo y de conservación. Para la generación de dichos mapas la detección remota y las imágenes satelitales son una herramienta esencial, ya que permiten la adquisición de información geográfica de manera sistemática.

El presente estudio desarrolló conocimientos y técnicas para facilitar la ubicación geográfica y conocer el estado de desarrollo de los bosques secundarios. Así, será posible incorporarlos dentro de los planes de desarrollo de clústeres de producción forestal previstos en el Plan Nacional de Desarrollo Forestal (PNDF) (MINAET, 2011). Uno de estos centros de encadenamiento de producción forestal es el creado recientemente por el Ministerio de Ambiente y Energía en la Zona Huetar Norte de Costa Rica.

## **10 Agradecimientos**

Los autores agradecen a la Vicerrectoría de Investigación y Extensión del Instituto Tecnológico de Costa Rica por el apoyo financiero y administrativo para la realización de este proyecto. Así mismo, al programa de becas CeNAT-CONARE y al Laboratorio PRIAS del Centro Nacional de Alta Tecnología de Costa Rica, por la facilitación de los equipos de cómputo de avanzada y el uso de las licencias de los programas requeridos para llevar a cabo esta investigación.

## **11 Referencias**

Alba, J. L., Rey, S. M., & Docio, L. (1999). An adaptive image segmentation neural network : application to Landsat images, 3812(July), 233-240.

Benediktsson, J. A., Swain, P. H., & Ersoy, O. K. (1990). Neural network approaches versus statistical methods in classification of multisource remote sensing data. *IEEE Transactions on Geoscience and Remote Sensing*, 28(4): 540-552.

Costa Rica. SINAC-MINAE. 2015. Cartografía base para el inventario forestal nacional de Costa Rica 2013-2014. Volumen 1. Preparado por Dr. Edgar Ortiz-Malavasi. SINAC-Programa REDD-CCAD-GIZ-FONAFIFO. San José, Costa Rica. 52 p.

Del Toro, N., Gomariz, F., Cánovas, F. and 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.

ERDAS. (2015). Clasificación Multiespectral. ERDAS. Presentación de Power Point. Curso ERDAS IMAGINE Fundamentals I. Transmisión directa de GeoInn Geospatial Innovations.

FAO. (S.F.). Aplicación de la tecnología de percepción remota a las pesquerías marinas. Sección 5. Satélites Ambientales. Recuperado el 19 de 7 de 2017, de <http://www.fao.org/docrep/003/T0355S/T0355S05.htm>

Gamanya, R., De Maeyer, P., & De Dapper, M. (2007). An automated satellite image classification design using object-oriented segmentation algorithms: A move towards standardization. *Expert Systems with Applications*, 32(2), 616-624. <https://doi.org/10.1016/j.eswa.2006.01.055>

Hermosilla, T., Wulder, M., White, J., Coops, N. and 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.

Hoang, N., Koike, K. (2018). Comparison of hyperspectral transformation accuracies of multispectral landsat TM, ETM+, OLI and EO-1 ALI images for detecting minerals in a

geothermal prospect area. *ISPRS Journal of Photogrammetry and Remote Sensing* 137: 15-28 p. doi:10.1016/j.isprsjprs.2018.01.007

Liu, Y., Guo, Q., & Kelly, M. (2008). A framework of region-based spatial relations for non-overlapping features and its application in object based image analysis, 63, 461-475. <https://doi.org/10.1016/j.isprsjprs.2008.01.007>

Mountrakis, G., Im, J., and Ogole, C. 2011. Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66 (3): 247–259.

Mura, M., Bottalico, F., Giannetti, F., Bertani, R., Giannini, R., Mancini, M., Orlandini, S., Travaglini, D. and 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.

Murtaza, K. and 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.

OET; CRUSA; CATIE. (2008). *El Abastecimiento Sostenible de la Madera en Costa Rica*. OET; CRUSA ISBN 978-9968-9717-6-8

Perumal, K. and Bhaskaran, R. (2010), Supervised classification performance of multispectral images. *Journal of computing*, 2(2): 124-129.

Sader, S. and A. Joyce. 1988. Deforestation rates and trends in Costa Rica, 1940 to 1983. *Biotropica*, 20: 11–19.

Shen, H., Lin, Y., Tian, Q., Xu, K., and 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.

Shi, X. and 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.

Suliman, A., & Zhang, Y. (2015). A review on back-propagation neural networks in the application of remote sensing image classification. *Journal of Earth Science and Engineerin*, 5: 52-65.

Tso, B. and Mather, P. (2009). *Classification methods for remotely sensed data*. Boca Ratón, Florida, EE.UU. CRC Press.

USGS. (S.F.). Landsat 8. Recuperado el 19 de 7 de 2017, de <https://landsat.usgs.gov/landsat-8>

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.

Yang, H., Pan, B., Wu, W. and 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.

Yang, X., Zhao, S., Qin, X., Zhao, N. and 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.

Yu, Q., Gong, P., Clinton, N., Biging, G., Kelly, M., & Schirokauer, D. (2006). Object-based Detailed Vegetation Classification with Airborne High Spatial Resolution Remote Sensing Imagery, 72(7), 799-811.

## Anexo 1

Buenos días

Les remito el correo oficial de la revista donde se indica que ya recibieron nuestro artículo.

Saludos,

----- Forwarded message -----

De: **Luis Ángel Ruiz Fernández** <[laruiz@cgf.upv.es](mailto:laruiz@cgf.upv.es)>

Date: mié., 25 de mar. de 2020 a la(s) 16:26

Subject: [RAET] Submission Acknowledgement

To: Iván Dimitri Ávila Pérez <[ivandimitri1995@gmail.com](mailto:ivandimitri1995@gmail.com)>

Iván Dimitri Ávila Pérez:

Thank you for submitting the manuscript, "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" to Revista de Teledetección. With the online journal management system that we are using, you will be able to track its progress through the editorial process by logging in to the journal web site:

Manuscript URL:

<https://polipapers.upv.es/index.php/raet/author/submission/13340>

Username: ivanavilaperez

If you have any questions, please contact me. Thank you for considering this journal as a venue for your work.

Luis Ángel Ruiz Fernández  
Revista de Teledetección

---

Revista de Teledetección  
<http://polipapers.upv.es/index.php/raet>

# **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**

Iván Dimitri Ávila-Pérez\*<sup>1</sup>, Édgar Ortiz-Malavasi<sup>2</sup>, Casia Soto-Montoya<sup>3</sup>, Yerlin Vargas-Solano<sup>4</sup>, Heileen Aguilar-Arias<sup>5</sup>, Cornelia Miller-Granados<sup>6</sup>

\* Correo electrónico del autor de contacto: [ivandimitri1995@gmail.com](mailto:ivandimitri1995@gmail.com)

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

<sup>2</sup> Escuela de Ingeniería Forestal, Instituto Tecnológico de Costa Rica, Apartado Postal: 159-7050, Cartago, Costa Rica.

<sup>3</sup> Escuela de Ingeniería Forestal, Instituto Tecnológico de Costa Rica, Apartado Postal: 159-7050 Cartago, Costa Rica.

<sup>4</sup> Laboratorio PRIAS, Centro Nacional de Alta Tecnología, San José, Costa Rica.

<sup>5</sup> Laboratorio PRIAS, Centro Nacional de Alta Tecnología, San José, Costa Rica.

<sup>6</sup> Laboratorio PRIAS, Centro Nacional de Alta Tecnología, San José, Costa Rica.

## **Resumen**

Conocer y mapear los cambios del 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. 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 exactitud 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 ( $p=0,0136$ ). No existen diferencias significativas en la exactitud lograda con los algoritmos de clasificación de Máxima Verosimilitud, Máquinas de Soporte Vectorial 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 ( $p=0,532$ ), 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 ( $p=0,0081$ ). 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 exactitud en la identificación de la cobertura boscosa se logra mediante el uso de los algoritmos de Máxima Verosimilitud, Máquinas de Soporte Vectorial y Redes Neuronales empleando imágenes Sentinel-2 tomadas en la temporada seca.

***Palabras clave: Landsat 8, Sentinel-2, Clasificación por máxima verosimilitud, Máquinas de soporte vectorial, 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 of the research was to identify the type of algorithm and satellite image that allows higher global exactitude 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. The classifications using Sentinel-2 were better than the ones obtained with Landsat-8 ( $p$ -value=0.0136). The best classification algorithms were Maximum Likelihood, Support Vector Machine or Neural Networks, and they yield better results than Minimum Distance Classification ( $p$ -value=0.0136). There was no interaction among image type and classification methods ( $p$ -value= 0.532), 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 ( $p$ -value=0.0081). 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 exactitude identifying forest cover is obtained with Sentinel-2

images from the dry season in combination with Maximum Likelihood, Support Vector Machine, and Neural Net 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 noventa 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 o percepción remota, 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 exactitud 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 Soporte Vectorial (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 a base de redes neuronales por su robustez y adaptabilidad permiten estudiar modelos complejos de clasificación de imágenes como lo son los modelos discontinuos o no lineales (Benediktsson et al., 1990).

La utilidad de un mapa creado a partir de una clasificación depende de su exactitud, 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 1.500 y 7.000 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 km<sup>2</sup>), 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.

*“Insertar Tabla 1 aquí”*

*“Insertar Figura 1 aquí”*

### **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).

*“Insertar Tabla 2 aquí”*

Se seleccionó para cada cuadrícula la imagen de menor nubosidad disponible en el periodo anteriormente indicado. Dado que no existían 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 se modificó la resolución espacial de las bandas 1, 5, 6, 7 8a, 9, 10, 11 y 12 a 10 m de manera para que todas las bandas tuvieran un pixel con la misma resolución (10 m) y 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, mediante fotointerpretación de las imágenes a clasificar y las imágenes de alta resolución disponibles en Google Earth.

## **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 Soporte Vectorial (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 Benediktsson et al. (1990).

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, 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, y se le calculó el uso de la tierra modal, el cual fue 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 las exactitudes de los tratamientos utilizados se llevó a cabo un Análisis de la Varianza (ANOVA, por sus siglas en inglés) en el programa Infostat 2018e basado en un ensayo de bloques. 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 homoestabilidad. 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, en caso de determinarse la existencia de diferencias entre alguno de los factores e interacciones se realizaron comparaciones mediante la prueba de Tukey con el software Infostat 2018e.

### **3. Presentación de 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 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 confiabilidad de 98,64% ( $p\text{-valor}=0,0136$ ) que existen diferencias significativas para la exactitud total debido al tipo de imagen utilizada. La tabla 3 muestra una superioridad de la exactitud lograda con las imágenes satelitales de Sentinel-2.

*“Insertar Figura 2 aquí”*

*“Insertar Tabla 3 aquí”*

### **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 Soporte Vectorial (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 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 exactitud que se muestran en la tabla 4. Es posible determinar con una confiabilidad 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 si existe una ligera superioridad de la combinación del uso las imágenes de Sentinel-2 con el algoritmo SVM.

*“Insertar Figura 3 aquí”*

*“Insertar Tabla 4 aquí”*

### **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 exactitud 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 lograron las exactitudes más bajas, y aunque no existe diferencias en la exactitud para los meses de septiembre a diciembre, la prueba 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.

*“Insertar Figura 4 aquí”*

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 la combinación menos satisfactoria corresponde al uso del algoritmo MDC con imágenes de septiembre, y que la mejor combinación corresponde a MLC con imágenes de marzo (Tukey DMS=5,11,  $\alpha=0,05$ ).

*“Insertar Figura 5 aquí”*

## **4. Discusión de resultados**

En el caso de las diferencias en las exactitudes debido al tipo de imagen analizada (Tabla 3), los resultados observados en la exactitud 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 exactitudes 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 alrededor del globo. 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 exactitud total 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 exactitud total 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 exactitud total 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; y 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 exactitud 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 exactitud de 91,67% en comparación al valor de 78,33% de exactitud 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 exactitud general fue cercana al 78% para MLC; mientras que para SVM se obtuvo una exactitud global superior al 90%.

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 sobre el que reportó menores exactitudes es el único que se encuentra en medio de la estación de lluvias.

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). Dado que la resolución espacial de las imágenes en estudio provoca que este tipo de píxeles sean comunes (Lu y Weng, 2007); 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 exactitud 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. 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. and Cheriet, M., 2015. "Support Vector Machine". En *Encyclopedia of Biometrics*, Editada por Stan Z. Li and Anil K. Jain, London: Springer.

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](https://web.archive.org/web/20140309040649/http://www.procomer.com/contenido/descargables/investigaciones_economicas/2008/Region_Huetar_Norte_final.pdf)

Benediktsson, J., Swain, P., Ersoy, O., 1990. Neural network approaches versus statistical methods in classification of multisource remote sensing data. *IEEE Transactions on Geoscience and Remote Sensing*, 28(4), 540-552.

Booth, D., and 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.

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.

Chazdon, R., 2014. *Second growth: the promise of tropical forest regeneration in an age of deforestation*. Chicago, University of Chicago Press.

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.

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

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.

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.

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.

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.

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.

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.

Mondal, A., Kundu, S., Kumar, S., Shukla, R. and 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.

Mura, M., Bottalico, 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.

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.

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.

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.

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.

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.

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.

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.

Sader, S., A. Joyce., 1988. Deforestation rates and trends in Costa Rica, 1940 to 1983. *Biotropica*, 20, 11–19.

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.

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.

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.

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.

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.

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.

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.

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 Environmen*, 209, 312–326.

Zhu, Z., Woodcock, C., 2012. Object-based cloud and cloud shadow detection in Landsat imagery. *Remote Sensing of Environment*, 118, 83–94.

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.

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

Identificador de la imagen	Fecha de la imagen	Cobertura de nubes (%)
----------------------------	--------------------	------------------------

LC08_L1TP_015053_20170211_20170228_01_T1	11-feb	13,85
LC08_L1TP_015053_20170331_20170414_01_T1	31-mar	14,8
LC08_L1TP_015053_20170907_20170926_01_T1	7-sep	56,86
LC08_L1TP_016053_20171219_20180125_01_T1	19-dic	5,61
S2A_MSIL1C_20180401T160511_N0206_R054_T16PGS_20180401T222634	1-abr	2,05
S2B_MSIL1C_20180208T160419_N0206_R097_T16PGS_20180208T192852	8-feb	18,71

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

Tipo de imagen satelital	Exactitud 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 ( $p < 0,05$ )

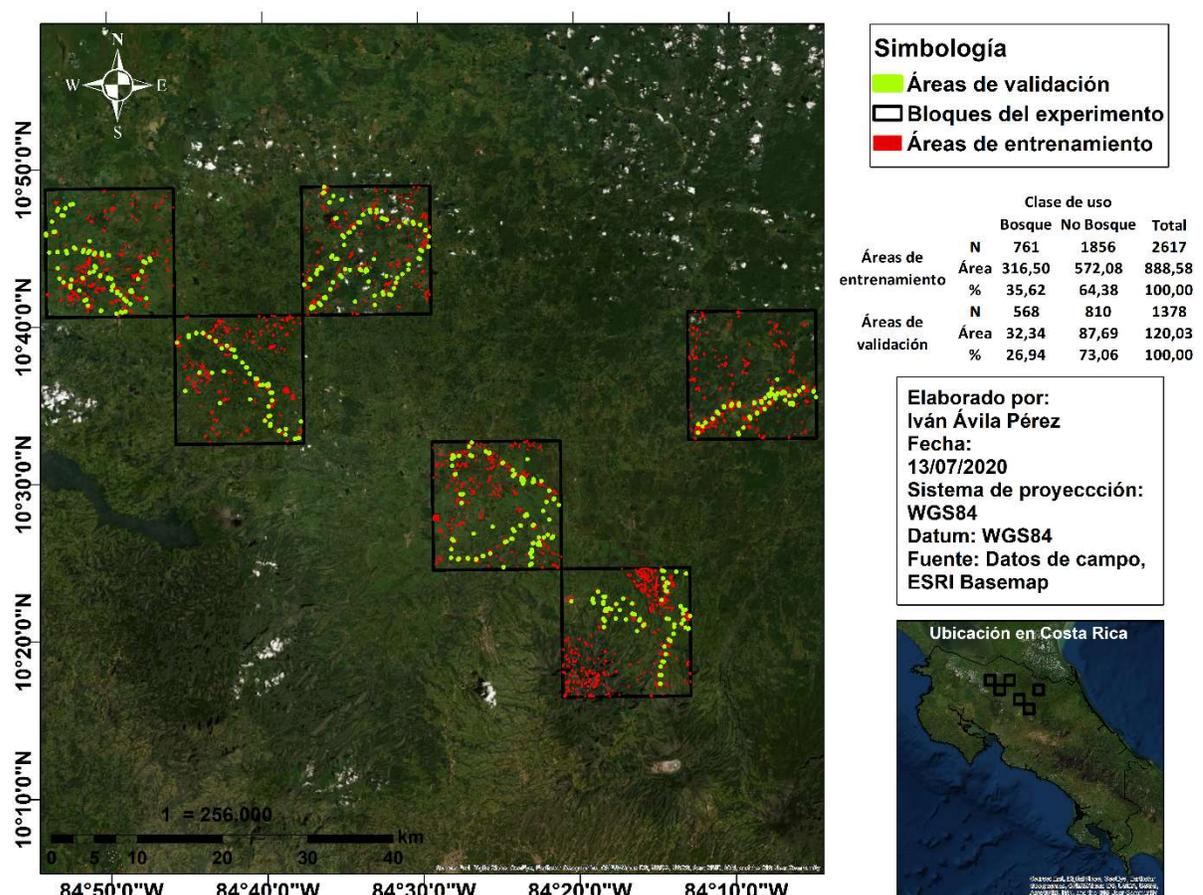


Figura 1. Ubicación de los bloques del experimento junto con de las áreas de entrenamiento y validación

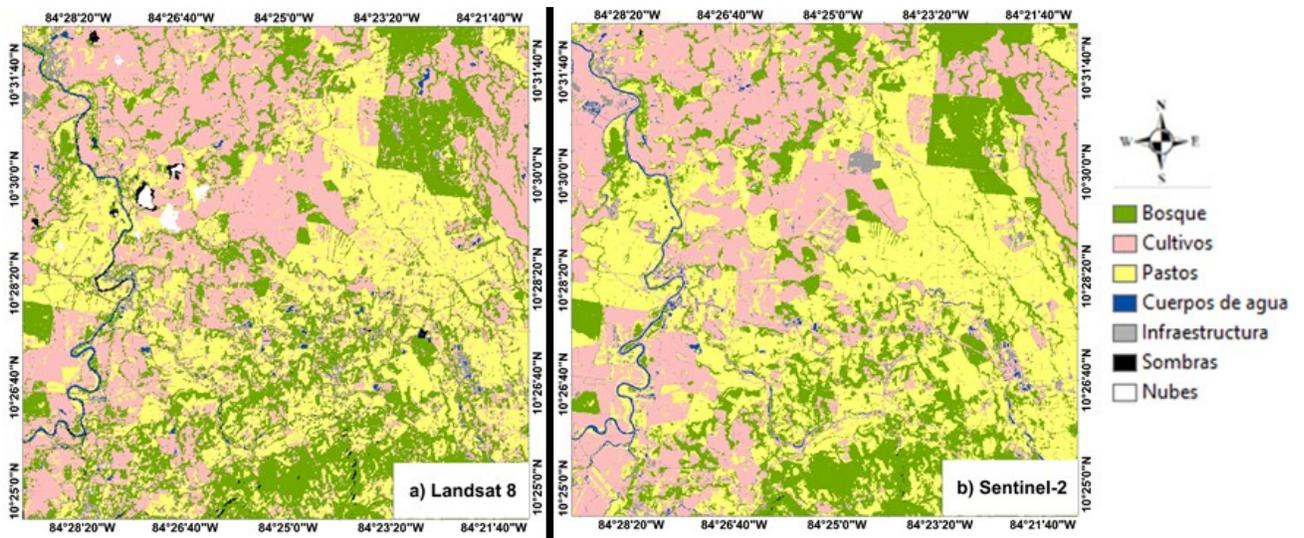


Figura 2. Comparación de los resultados de clasificación según tipo de imagen satelital

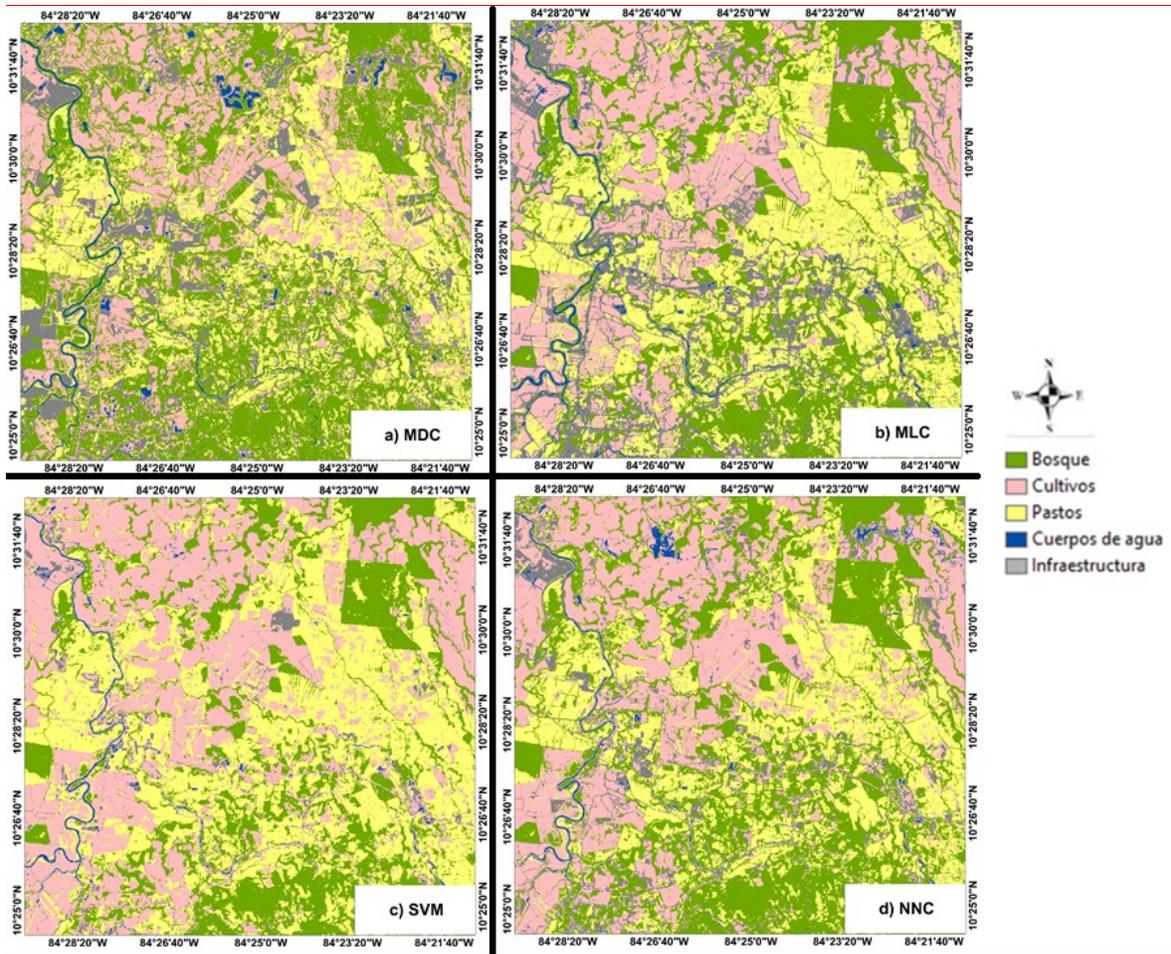
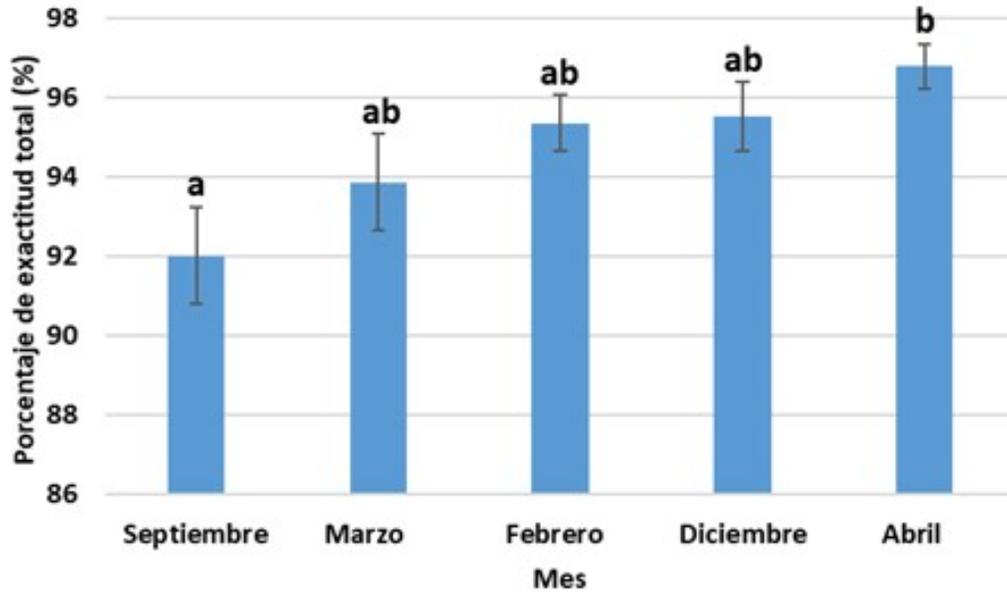


Figura 3. Comparación de los resultados de clasificación según algoritmo de clasificación

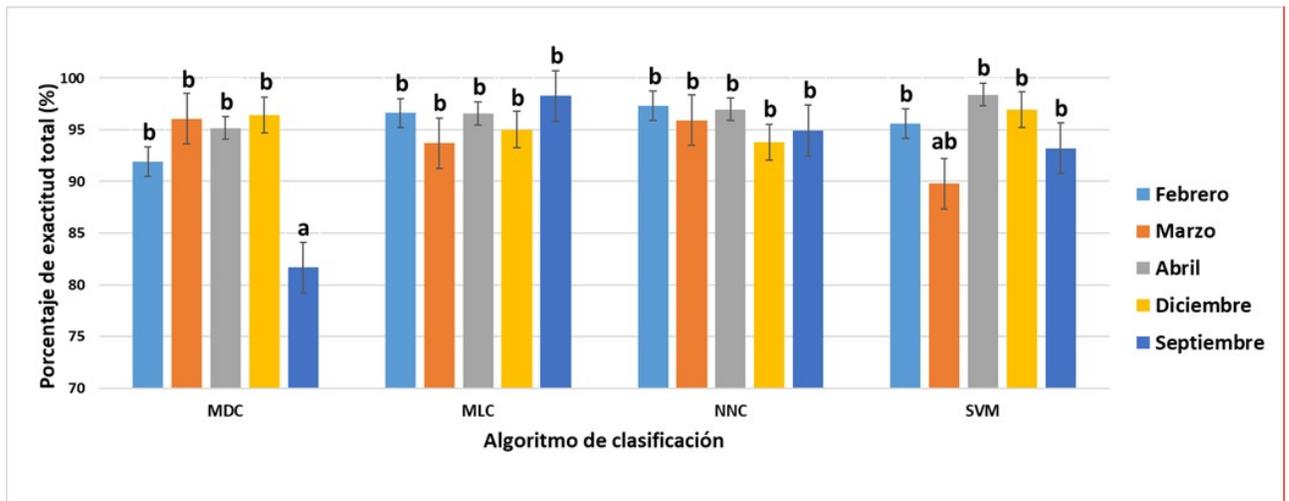
Tabla 4. Promedios de exactitud global de las clasificaciones de cobertura forestal según algoritmo de clasificación

Algoritmo de clasificación	Exactitud promedio (%)	n	Error estándar	Prueba de Tukey $\alpha=0,05$
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 ( $p < 0,05$ )



Nota: Medias con una letra desigual son significativamente diferentes ( $p < 0,05$ )  
 Figura 4. Comparación de los resultados de exactitudes globales de las clasificaciones según mes de toma de la imagen.



Nota: Medias con una letra desigual son significativamente diferentes ( $p < 0,05$ )  
 Figura 5. Comparación de los resultados de exactitudes globales de la clasificación según mes de toma de la imagen y algoritmo de clasificación.

## Anexo 2

# **Derivación indirecta de la distribución espacial y estado de desarrollo de los bosques secundarios en Costa Rica usando imágenes satelitales de mediana resolución espacial.**

Iván Dimitri Ávila-Pérez\*<sup>1</sup>, Édgar Ortiz-Malavasi<sup>2</sup>, Casia Soto-Montoya<sup>3</sup>, Heileen Aguilar-Arias<sup>4</sup>, Cornelia Miller-Granados<sup>5</sup>

\* Correo electrónico del autor de contacto: [ivandimitri1995@gmail.com](mailto:ivandimitri1995@gmail.com)

<sup>1</sup> Escuela de Ingeniería Forestal, Instituto Tecnológico de Costa Rica, Cartago, Costa Rica.

<sup>2</sup> Escuela de Ingeniería Forestal, Instituto Tecnológico de Costa Rica, Cartago, Costa Rica.

<sup>3</sup> Escuela de Ingeniería Forestal, Instituto Tecnológico de Costa Rica, Cartago, Costa Rica.

<sup>4</sup> Laboratorio PRIAS, Centro Nacional de Alta Tecnología, San José, Costa Rica.

<sup>5</sup> Laboratorio PRIAS, Centro Nacional de Alta Tecnología, San José, Costa Rica.

### **Resumen**

Los bosques secundarios son un elemento relevante en las diferentes sociedades, por lo que su cuantificación es de gran importancia para su preservación, manejo y restauración. El objetivo de la presente investigación es desarrollar una técnica indirecta para conocer la distribución espacial y estado de desarrollo de bosques secundarios usando sensores remotos de mediana resolución. La metodología fue probada en un sector de la Zona Huetar Norte de Costa Rica. Se realizó la clasificación de imágenes para cuatro períodos: 2000, 2005, 2010 y 2017/2018. Se comparó la ubicación de las masas boscosas por año y se efectuó una reclasificación de las áreas donde se presentó ganancia de cobertura arbórea (bosques nuevos) identificándose cuáles de estas representan bosques secundarios. Se validaron los resultados y las exactitudes obtenidas se utilizaron como variables respuesta del ANOVA. El método OBIA supera a MLC en la identificación de los bosques nuevos (pvalue=0,035). El mes de la imagen influye en la exactitud del productor ya que produce

una interacción con el método (pvalue= 0,027) y con el tipo de imagen (pvalue= 0,008). También se produce una interacción mes-imagen para la exactitud del usuario (pvalue= 0,042) y la exactitud general de la clase de bosques secundarios (pvalue= 0,012). La tendencia muestra que el mejor método para cuantificar y ubicar los bosques secundarios es la clasificación de imágenes Sentinel-2 de los meses de junio y julio mediante Análisis Basado en Objetos (OBIA).

*Palabras clave: Sensores remotos, Bosques secundarios, Clasificación por Máxima Verosimilitud, Clasificación Basada en Objetos, Landsat, Sentinel-2, Análisis de exactitud.*

## **Indirect derivation of the spatial distribution and development status of secondary forests in Costa Rica using medium spatial resolution satellite imagery**

### **Abstract**

Secondary forests are a relevant element in different societies, so their quantification is of great importance for their preservation, management and restoration. The objective of the present investigation is to develop an indirect technique to know the spatial distribution and development status of secondary forests using medium resolution remote sensors. The methodology was tested in a sector of the Northern Huetar Zone of Costa Rica. Images were classified for four periods: 2000, 2005, 2010 and 2017/2018. The location of the forest stands per year was compared and a reclassification of the areas where there was a gain in tree cover (new forests) was carried out, identifying which of these represent secondary forests. Results were validated and the accuracies obtained were used as ANOVA response variables. The OBIA method outperforms MLC in identifying new forests (pvalue = 0.035). The month of the image influences the accuracy of the producer since it produces an interaction with the method (pvalue = 0.027) and with the image type (pvalue = 0.008). A month-image interaction also occurs for user accuracy (pvalue = 0.042) and overall accuracy of secondary forest class (pvalue = 0.012). The trend shows that the

best method to quantify and locate secondary forests is the classification of Sentinel-2 images for the months of June and July using Object Based Analysis (OBIA).

***Keywords: Remote Sensing, Secondary forests, Maximum Likelihood Classification, Object Based Classification, Landsat, Sentinel-2, Accuracy assessment.***

## **1. Introducción**

En los últimos años se ha demostrado que la regeneración de bosques siempre se presenta junto con la deforestación, (Sloan, Goosem & Laurance, 2015). Alrededor de un tercio de los bosques maduros que son talados en los trópicos inician una sucesión secundaria natural al año, lo que provoca un incremento de la cobertura de los bosques secundarios en el planeta (Arroyo et al, 2015). Debido a la fuerte expansión de estos bosques en Costa Rica y el mundo, en los últimos 20 años se ha elevado el interés sobre el rol que juegan los bosques secundarios en las economías locales, la conservación de las especies y el cambio climático (Taylor et al, 2017).

Aun cuando las investigaciones en bosques secundarios son abundantes, el conocimiento actual de estos se encuentra limitado tanto a nivel espacial como temporal. La información acerca de los bosques en recuperación es escasa (Goosem et al, 2016). En la actualidad no existen investigaciones dirigidas a combinar el conocimiento actual de los bosques secundarios, la fragmentación de parches arbóreos y la ecología del paisaje, para determinar los elementos que moldean la sucesión ecológica en múltiples niveles espaciales (Arroyo et al, 2015).

Para solventar dicho vacío de información, las herramientas de la detección remota han sido de vital importancia para ampliar el conocimiento de los bosques y su funcionamiento (Boyd & Danson, 2005). Esta disciplina, 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). Esto ha provocado que sea muy utilizada en el mapeo de los cambios en los usos y coberturas de la tierra (Yin et al, 2018), en donde se destaca su aplicación en la ubicación y clasificación de bosques (Pimple et al, 2017).

Un aspecto importante de mencionar en el uso de los sensores remotos es la exactitud de la información de la cobertura boscosa que brindan, ya que esta puede variar debido al tipo de

equipo y los métodos utilizados (Ningthoujam et al, 2016). En cuanto a los métodos, destacan las clasificaciones por píxeles o basadas en objetos (Toure et al, 2018). Dentro de la clasificación por píxeles, la Clasificación por Máxima Verosimilitud (MLC, por sus siglas en inglés) se reconoce como uno de los clasificadores que ha sido más utilizado para la clasificación de coberturas y usos de la tierra (Shi and Xue 2016).

El análisis de imágenes basado en objetos (OBIA, por sus siglas en inglés) ha surgido en los últimos años como una subdisciplina de la ciencia de la teledetección dedicada al análisis de procesamiento de imágenes satelitales de muy alta resolución (Csillik, 2017). La principal característica del OBIA es que en lugar de analizar cada uno de los píxeles en la imagen de manera individual, estos son primero agrupados en objetos que representan de mejor manera los atributos reales de la superficie terrestre (Wężyk et al, 2016).

Los satélites Landsat, de la Administración Nacional de la Aeronáutica y del Espacio (NASA, por sus siglas en inglés) y los satélites Sentinel-2 de la Agencia Espacial Europea (ESA, por sus siglas en inglés) destacan entre los sensores más utilizados. Las imágenes Landsat más utilizadas provienen de las plataformas Landsat 5, 7 y 8 con una resolución espacial mínima de 30 metros (Sayão et al, 2018) y temporal de 16 días. Los satélites Sentinel 2 poseen cuatro bandas con datos a partir de 10 m, seis bandas con 20 m y tres bandas a partir de 60 m (Mura et al, 2018); a través de, un sistema bi-satelital, posee una resolución temporal de cinco días (Yang et al, 2017).

Es de vital importancia realizar una evaluación de la exactitud con la que se identifiquen los errores en el mapa (Olofsson et al 2014). Tal como lo mencionan Piazza et al (2016); los cuales compararon el rendimiento de los métodos de análisis basado en objetos (OBIA) y la clasificación tradicional basada en píxeles en la clasificación de bosques sucesionales en el sur de Brasil. Dicho estudio determinó que el análisis OBIA produjo exactitudes más altas (entre 89 y 91%) mientras que para el análisis basado en píxeles se reportaron exactitudes de tan solo 62-63%.

Lu et al (2014) compararon los resultados de cinco métodos de clasificación y el uso individual y combinado de sensores pasivos (Landsat 5) y activos (PALSAR), en la ubicación y delimitación de bosques secundarios en diferentes estadios de sucesión en la Amazonia Brasileña. Dichos autores determinaron que la exactitud de la clasificación depende del método y la imagen que se utilice ya que si se utiliza solo las imágenes

Landsat o Palsar el mejor método es el OBC con una exactitud del 77,2% y 48,3% respectivamente; mientras que si se combinan los datos de estos dos sensores el método que presenta la mejor exactitud es el KNN con 79%. Basado en lo anterior, este estudio busca desarrollar una técnica indirecta para conocer la distribución espacial y estado de desarrollo de bosques secundarios usando sensores remotos de mediana resolución espacial.

## **2. Materiales y métodos**

### **2.1 Área de estudio**

Este estudio se llevó a cabo en la Zona Huetar Norte de Costa Rica, debido al alto desarrollo del comercio forestal y la matriz de paisaje, que presenta una amplia variedad de usos y coberturas de la tierra (Chassot et al 2010). El área de estudio cuenta con una extensión de 979047,2 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 se caracteriza por 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 la zona Huetar Norte se encuentran las siguientes zonas de vida: bosques húmedos tropicales, bosques muy húmedos tropicales, premontanos y montano bajo, además de bosques pluviales premontanos, montano bajos y montanos (CCT, 1993)

### **2.2 Muestreo de campo**

Se estableció una malla de 19 cuadrículas de 15 km por 15 km (225 km<sup>2</sup>) en el área de estudio. Se seleccionaron de forma aleatoria seis cuadrículas, en las cuales se estableció la ubicación espacial de los bloques del ensayo. La cantidad y el tamaño de las cuadrículas se definió en función de la representación de diversos usos y coberturas de la tierra, para lo cual se obtuvo una intensidad de muestreo mayor al 10%.

Para determinar el uso del suelo y la cobertura de la tierra en campo, se visitaron las cuadrículas de muestreo con un recorrido del 15% del área de estas, para lo cual se utilizaron los caminos y carreteras disponibles en el área de estudio. En cada vía se tomaron cada kilómetro, tres puntos a las distancias de 50, 100 y 150 m a cada lado de la vía.

Las clases de uso y cobertura de la tierra utilizadas 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). Estas clases fueron clasificadas para su validación según dos categorías: Bosque, No Bosque, Nubes y Sombras de Nubes. Todas las observaciones de los puntos fueron separadas por clase de uso de la tierra y luego estos fueron separados en dos partes: 70% de los datos para utilizar en las aéreas de entrenamiento y el restante 30% de los puntos, escogidos de forma aleatoria, fueron utilizados en la validación de resultados.

### **2.3 Procesos computacionales**

En la siguiente figura se detalla el flujo de procesos llevados a cabo con el equipo de cómputo:

*“Insertar figura 1 aquí”*

### **2.4 Obtención y preprocesamiento de imágenes:**

Se obtuvieron imágenes de mediana resolución de los satélites Landsat 8 y Sentinel-2 nivel 1, capturadas entre el 1 de enero del 2017 y el 30 de abril del 2018. Para cada cuadrícula, se seleccionó la imagen de menor nubosidad disponible en el periodo antes indicado. Las imágenes Landsat 7 fueron corregidas con la herramienta “Gap Fill” del programa Qgis 3.8, con el fin de eliminar los vacíos de información que presentan estas imágenes debido a un fallo en el Corrector de Escaneo de Línea (SLC, por sus siglas en inglés).

A las imágenes Landsat seleccionadas, se les aplicó el proceso de corrección atmosférica descrito por Aguilar et al (2014), con el algoritmo FLAASH en el programa ENVI 5.5. A las imágenes Sentinel-2 se les aplicó la unión de bandas con el programa SNAP. A partir de todas las imágenes seleccionadas y corregidas, se seleccionaron y extrajeron para cada año las secciones con menor presencia de nubes para cada cuadrícula de muestreo (escenas), mediante la herramienta “Clipper” del programa QGis 3.8. Se procedió a la eliminación de las nubes y las sombras de nubes mediante el algoritmo MFMask 4.0.

### **2.5 Identificación de usos de la tierra:**

Para la determinación de los usos de la tierra en cada una de las cuadrículas de muestreo, se crearon áreas de entrenamiento 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 el programa 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, mediante fotointerpretación de las imágenes a clasificar. Una vez definidas las áreas de entrenamiento, se llevó a cabo la clasificación de las imágenes antes preprocesadas con el algoritmo “Maximum Likelihood Classification” disponible en el programa ENVI 5.5.

Para la clasificación basada en objetos se procedió a la segmentación de cada escena a través del motor de segmentación Berkeley (Martin, Fowlkes & Malik, 2004). Se extrajeron y asociaron en la tabla de atributos de los polígonos generados, las clases previamente asignadas mediante MLC a los píxeles dentro de cada segmento. Se calculó la moda de cada segmento a través de la herramienta “Estadísticas de Zona” del software QGIS 3.8

## **2.6 Validación de la identificación de usos de la tierra:**

En cada uno de los puntos separados anteriormente para la validación (puntos de control de campo), se generó una zona de amortiguamiento (buffer) en el programa QGIS 3.8 con un área equivalente al tamaño del píxel de la imagen clasificada (30 m para Landsat y 10 m para Sentinel-2). Se transformaron los archivos raster de las clasificaciones generadas a archivo vectorial. En las áreas de amortiguamiento, se asociaron las clases de uso de la tierra evaluadas en campo a las clases de uso en las que fueron clasificados los píxeles dentro de los límites de cada área, a través de una intersección en el programa QGIS 3.8. Se analizó la información mediante el programa Excel 2016 a través de matrices de error generadas para cada clasificación; donde, si al menos uno de los píxeles en el área de amortiguamiento fue clasificado en la misma clase de uso que se identificó en campo, se aceptó el punto como bien clasificado. Por último, se calculó la exactitud total de la clasificación general para cada una de las clasificaciones desarrolladas.

## **2.7 Identificación y reclasificación de bosques nuevos:**

Las áreas con cobertura boscosa identificadas para los años 2000, 2005 y 2010 (año 1) se compararon con las áreas de bosque determinadas para los años 2017 y 2018 (año 2). Los resultados obtenidos mediante la clasificación por píxeles se compararon mediante álgebra de mapas con la herramienta “Calculadora Raster” del ArcMap 10.5. Los resultados del análisis basado en objetos se compararon mediante la herramienta “Intersección” del mismo programa y la calculadora de campo de la tabla de atributos. De esta forma, se identificaron áreas que en el 2017/2018 son bosque, pero que no lo eran en los años 2000, 2005 y 2010, denominándose dichas áreas como “Bosques Nuevos”.

Se llevó a cabo la división de los bosques nuevos, identificados en cada cuadrícula de muestreo a través de cada método, mediante clasificaciones por máxima verosimilitud en el programa ENVI 5.5. Las áreas de entrenamiento para esta clasificación se levantaron a partir de la información tomada en campo y la fotointerpretación de fotografías aéreas de alta resolución. De esta manera, fue posible determinar las áreas de bosques nuevos que pertenecen a plantaciones forestales y a bosques secundarios; así como, corregir algunos errores de clasificación de la primera iteración de categorización.

## **2.8 Validación de las reclasificaciones de bosques nuevos:**

Se seleccionaron de forma aleatoria seis polígonos por clase de uso del suelo identificada tras la reclasificación de los bosques nuevos y estos fueron utilizados como área de validación. Se determinó mediante análisis puntual el tipo de uso de suelo de dichos polígonos seleccionados. Se asociaron los resultados de las clasificaciones de las áreas de bosques nuevos en cada cuadrícula de muestreo con la información en las áreas de validación mediante la tabla de atributos del programa Qgis3.8. Se analizó la información mediante el programa Excel 2016 y matrices de validación. Con dichas matrices se calculó la exactitud general de los bosques nuevos, además de la exactitud del productor, del usuario y general de la clase de bosques secundarios.

## **2.9 Análisis de datos:**

Para determinar la existencia de diferencias estadísticas en las exactitudes de los tratamientos utilizados se llevó a cabo un Análisis de la Varianza (ANDEVA) en el programa Infostat 2018e basado en un ensayo de bloques, pero desbalanceado en las celdas

debido a la introducción del factor mes en que se obtuvo la imagen satelital, tanto para la imagen del año uno, como para la imagen del año dos. El diseño experimental constaba de seis repeticiones (bloques), dos tipos de imágenes satelitales, cuatro algoritmos de clasificación, tres años base de comparación (2000, 2005 y 2010) y un factor adicional que corresponde al mes en que fue tomada la imagen satelital de cada año en el análisis. Para determinar la existencia de diferencias entre los niveles de alguno de los factores se realizaron comparaciones mediante la prueba de Tukey en el programa Infostat 2018e.

### **3. Resultados**

Los resultados muestran que el método OBIA al identificar de una manera más continua los bosques nuevos, produce una mejor identificación de estos. Lo que concuerdan con los resultados del análisis estadístico, mostrados en el cuadro 1.

*“Insertar Cuadro 1 aquí”*

Los bajos valores de exactitud obtenidos pueden deberse a los errores en el reconocimiento de los bosques nuevos, en consecuencia, a los problemas de vacíos de información en las imágenes Landsat 7 que provocaron que bosques maduros o intervenidos fueran identificados como bosques en regeneración. La exactitud obtenida en las imágenes Sentinel-2 es superior a los resultados de las imágenes Landsat ( $pvalue=3437$ ), no obstante, esta diferencia no es significativa al 5% de confiabilidad

Los resultados obtenidos demuestran que existen diferencias significativas ( $pvalue=0,0075$ ), en la exactitud del reconocimiento de los bosques nuevos, debido al mes en que se tomó la imagen en el año 1 de estudio (2000, 2005 o 2010). La prueba de Tukey ( $alpha=0,05$ ,  $DMS=9,68$ ) dicta que existen diferencias entre las imágenes de junio y mayo (figura 2), lo cual demuestra que existe un cambio marcado entre el último mes de la época seca (mayo) y el mes en que se dan las primeras precipitaciones (junio).

*“Insertar figura 2 aquí”*

Se denota una superioridad de la exactitud del productor de la clase de bosques secundarios mediante MLC y Sentinel-2 a pesar de que los resultados demuestran que no existen

diferencias ( $\alpha=0,05$ ) debido al método (pvalue=0,1949), al tipo de imagen (pvalue=0,4594) y al año base de comparación (pvalue=0,6346).

Los errores de exclusión en la identificación de los bosques secundarios se deben en especial al mes en que fue tomada la imagen en el año base de comparación (año 1) (pvalue= 0,003). Los resultados obtenidos a través de la prueba de Tukey (alfa= 0,05, DMS= 17,14) se muestran en la figura 3.

*“Insertar figura 3 aquí”*

Se produce una interacción método-mes de la imagen (cuadro 2). Tanto para MLC como para OBIA se presenta una coincidencia con lo presentado en la figura 3. Existe una tendencia donde los meses que presentaron menos exclusión de la clase de bosques secundarios son los meses de mayor precipitación en el estudio (junio, septiembre y noviembre) mientras que en los meses más secos (enero, mayo y febrero) se dio una mayor omisión en la identificación de este tipo de masas arbóreas.

*“Insertar Cuadro 2 aquí”*

La menor omisión de bosques en regeneración se da a través del método MLC para los tres meses más lluviosos (cuadro 2). Los resultados demuestran que también se da una interacción entre el tipo de imagen clasificada y el mes de la imagen en el año 1 (cuadro 3).

*“Insertar Cuadro 3 aquí”*

Se mantiene la tendencia a obtener mejores resultados en los meses con mayor precipitación. Para un mismo tipo de imagen (Sentinel-2) se da tanto la mejor exactitud, cuando la clasificación se dio en un mes lluvioso, como la exactitud más baja, la cual se obtiene en uno de los meses al final de la época de lluvias. Este patrón se denota menos marcado si se compara con lo presentado para la interacción método-mes del año 1.

Los errores de comisión en la clase de bosques muestran una superioridad de las imágenes Sentinel-2 (pvalue=0,1413) a pesar de que las diferencias no sean significativas al 5% de confiabilidad. La exactitud del usuario presenta diferencias estadísticas (pvalue= 0,03) a razón del mes en que fue tomada la imagen en el año 2 (2017/2018). Los resultados

obtenidos a través de la prueba de Tukey ( $\alpha= 0,05$ ,  $DMS= 25,27$ ) se muestran en la figura 4.

*“Insertar figura 4 aquí”*

Los mayores errores de inclusión se presentan en el mes más lluvioso del año (setiembre), sin embargo, no existen diferencias estadísticas ( $\alpha= 0,05$ ) con los demás meses a excepción del mes de febrero el cual corresponde al último mes de la temporada de precipitaciones.

Al igual que para la exactitud del productor, la exactitud del usuario se ve influenciada por una interacción entre el mes en que fue tomada la imagen en el año 1 y el tipo de dicha fotografía. Los resultados obtenidos se presentan en el siguiente cuadro (cuadro 4).

*“Insertar Cuadro 4 aquí”*

Los mejores resultados se obtienen con los primeros meses de cada estación, mayo y junio, para las épocas seca y lluviosa respectivamente. Esto indica que para que se dé una menor inclusión de otras clases de uso como bosques secundarios, las clasificaciones no deben llevarse a cabo ni en meses con mucha precipitación ni en temporadas de estrés hídrico.

Lo anterior, coincide con el estadístico general calculado para la clase de bosques secundarios, ya que los mejores resultados se obtienen con los meses en los extremos de la época de precipitaciones (el primer mes, junio y el último mes, febrero) (cuadro 5).

*“Insertar Cuadro 5 aquí”*

Al igual que con las demás variables respuesta, a través de las imágenes Sentinel-2 se obtienen las mejores exactitudes generales de la clase de bosques secundarios, por lo que es posible aseverar que con este tipo de imágenes se obtiene una mejor identificación de los bosques secundarios. Como se denota en los cuadros 5, 4 y 3, a pesar de no existir diferencias estadísticas marcadas con la mayoría de los meses del año, existe una tendencia a que el mes de junio en las imágenes Sentinel 2 produzca los mejores resultados en la identificación de los bosques secundarios.

#### **4. Discusión**

El análisis estadístico llevado a cabo para la identificación de los bosques nuevos demuestra que, el mejor método para identificar dichas zonas de ganancia forestal viene dado por el análisis de imágenes basado en objetos (OBIA). El método OBIA redujo el efecto sal-pimienta en la imagen, lo que permitió una identificación más continua de las masas arbóreas y por ende de los bosques nuevos. De acuerdo con Li et al (2014), el OBIA elimina la existencia de píxeles aislados mal clasificados debido a que toma en cuenta tanto la textura como la forma y la posición de grupos de píxeles, de manera que cada segmento se compone de píxeles homogéneos y espacialmente unidos.

Son pocos los estudios dedicados al análisis de cambios en los usos de la tierra que comparan las diferencias entre el análisis por píxeles tradicional y el análisis basado en objetos. No obstante, son varios los estudios que comparan los resultados de clasificaciones puntuales mediante estas dos metodologías. Singh et al (2019) realizaron clasificaciones de imágenes Sentinel-2 en el territorio de Delhi, India, a partir de cinco categorías de uso: Cuerpos de agua, Agricultura, Bosque y Vegetación Natural, Áreas Urbanas Densa y Áreas Urbanas Dispersas. Estos autores compararon tres diferentes algoritmos de clasificación: Árboles de decisión, Perceptron Multi-Capa y Random Forest, tanto en su versión por píxeles como con segmentación. Dichos autores obtuvieron mediante OBIA exactitudes globales iguales a 73,82%, 76,17% y 76,31% en comparación a los valores de 71,53%, 74,89% y 71,45% obtenidos a través del método tradicional para los clasificadores Árbol de Decisión, Perceptron Multi-Capa y Random Forest, respectivamente, lo que concuerda con los hallazgos de este estudio.

Los bajos valores de exactitud obtenidos en la identificación de los bosques nuevos pueden deberse a los vacíos de información en las imágenes que provocaron que ciertos bosques no pudieran ser identificados como cobertura forestal para los años 2005 y 2010, por ende, fueron identificados como bosques nuevos al llevar a cabo el análisis de cambios. Wulder et al (2008), en un estudio llevado a cabo en Columbia Británica, Canadá, evaluaron los cambios en la cobertura forestal entre una imagen Landsat 7 SLC-ON de 1999 y una imagen Landsat 5 del 2003, además de una imagen Landsat 7 SLC-OFF del mismo año.

Estos autores realizaron para la imagen Landsat 7 SLC-OFF estudios de cambio a partir de la imagen con los vacíos de información, con los vacíos corregidos por el método de relación de los histogramas (predicción basada en datos Landsat multitemporales) y con los

vacíos corregidos mediante el método de interpolación con segmentación. Con la imagen sin correcciones, se dieron errores de omisión de cambios de alrededor de 35%, mientras que los errores de comisión de cambios fueron de 30%. En el caso de la imagen corregida mediante relación de los histogramas, los errores de omisión de cambios fueron de 23% mientras que el error de comisión fue de 29%. En cuanto a la imagen corregida mediante interpolación con segmentación los errores de omisión de cambios fueron de 21%, mientras que los errores de comisión fueron de 29%.

En el presente estudio, a pesar de que no se evidencian diferencias debido al tipo de imagen, se denota una tendencia a la mejor identificación de los bosques secundarios mediante las imágenes Sentinel-2, cuando se analiza la interacción entre el mes de la imagen en el año 1 y el tipo de imagen. Esto coincide con los resultados encontrados Sothe et al (2017) en un estudio conducido en la sección norte del Parque Nacional Sao Joaquim, Santa Catarina, Brasil.

Sothe et al, contrastaron la capacidad de las imágenes Sentinel-2 y Landsat 8 de identificar bosques secundarios dentro de dicha zona protegida en tres estadios de sucesión: Temprano, Intermedio y Tardío. Además de analizar las diferencias debido al tipo de imagen, también compararon los resultados entre dos algoritmos de clasificación, Random Forest y Máquinas de Soporte Vectorial; y el efecto de proporcionar a los algoritmos diversas variables de textura y de índices de vegetación en adición al uso único de los datos espectrales de las imágenes.

Estos autores obtuvieron clasificaciones con exactitudes superiores a 90%, tanto para las capas creadas mediante Random Forest como para las elaboradas por Máquinas de Soporte Vectorial. Para ambos métodos, los resultados obtenidos con el sensor MSI fueron superiores a lo obtenido mediante el sensor OLI. En dicho estudio, se logró una exactitud igual a 100% al analizar las imágenes Sentinel-2 con un total de 16 variables, entre las que se pueden mencionar el índice normalizado de vegetación (NDVI) y el índice diferenciado de vegetación (DVI).

En la presente investigación se demuestra que las diferencias presentadas en las exactitudes de las clasificaciones se deben, en su mayoría, al mes de las imágenes en análisis. Lo anterior, concuerda con los últimos estudios en la rama de la teledetección enfocada en los análisis temporales y los cambios de las coberturas de la tierra a través del tiempo. Este tipo

de estudios se basan en la idea de que, para mejorar la clasificación de los usos de la tierra vegetativos, se deben analizar imágenes en momentos claves del ciclo fenológico de la cobertura de interés de manera que se pueda separar con mayor facilidad de otros usos espectralmente similares (Chuvieco, 1998).

En la presente investigación se evidenció una tendencia a que se den menores errores de omisión en la clasificación de los bosques secundarios en los meses de mayor precipitación. Esto puede darse debido a que en presencia de humedad en el ambiente los bosques secundarios se desarrollan a plenitud. En los meses secos puede existir un déficit hídrico que provocaría una similitud del espectro de estas masas boscosas, sobre todo para aquellas en etapas tempranas de sucesión, con la firma espectral de los pastos arbolados. Esto puede provocar que dichos bosques sean clasificados como “No Bosque” y aumenten los errores de exclusión para estas masas en regeneración.

Caso similar se observa para la exactitud del productor que mide los errores de inclusión de otros usos de la tierra como bosques secundarios. Existe una tendencia a que se produzcan menos errores de comisión en los meses transicionales entre la época seca y lluviosa. Este comportamiento puede deberse a que en los meses secos se dé un cambio en la firma espectral de los bosques maduros e intervenidos, que provoca que éstos se asemejen espectralmente a los bosques secundarios, en especial a aquellos en estadios más avanzados de sucesión.

En meses con exceso de lluvias se puede dar un aumento en la vigorosidad de las copas de los árboles en pasturas. Esto puede provocar que pastos muy arbolados se asemejen espectralmente a bosques secundarios, en especial a aquellos en etapas tempranas de desarrollo. Este tipo de cambios en la apariencia espectral de los bosques se encuentran bien documentados en diversos estudios tanto a nivel internacional como nacional.

Berlanga, Cervantes y Murúa (2018) llevaron a cabo una investigación de las tendencias estacionales de los bosques en la cuenca Piaxtla-Elota-Quelite y el área protegida Meseta de Cacaxtla, México. Estos autores utilizaron las imágenes del satélite Modis Terra y efectuaron un análisis bi-mensual del Índice Normalizado de Vegetación (NDVI) desde 2001 al 2016. En dicho estudio detectaron 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

(setiembre), 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.

A nivel nacional, Vega y Alvarado (2019) condujeron un estudio en la provincia de Guanacaste en el cual estudiaron cuatro ecoregiones de la provincia: dos tipos de bosques húmedos estacionales, un bosque seco y un bosque montano; a través del sensor MODIS y el cálculo del NDVI en series de tiempo del 2002 al 2017. El estudio demostró que existen meses con una amplia variación en la firma espectral para un mismo mes en años diferentes. Entre los meses que presentaron 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.

Los estudios llevados a cabo tanto por Berlanga, Cervantes y Murúa; así como por Vega y Alvarado, respaldan los hallazgos de la presente investigación. A su vez, permiten inferir que, para reducir la posibilidad de semejanzas en la respuesta espectral entre los distintos tipos de bosque, los análisis deben llevarse a cabo mediante imágenes en la época donde la respuesta fotosintética de los árboles sea más estable, lo cual sucede en los primeros meses de la temporada de lluvias.

## **5. Conclusiones**

El Análisis de Imágenes Basado en Objetos (OBIA) permitió obtener una mayor exactitud en la identificación de los bosques nuevos. Por otro lado, el mes en el que se capturaron las imágenes provoca diferencias significativas en la identificación de los bosques secundarios; debido a, la interacción de estos, tanto con el método de clasificación, como con el tipo de imagen utilizada. Además, se evidencia una tendencia a obtener mayores exactitudes cuando se utilizan imágenes Sentinel-2 en los meses al inicio de la temporada de lluvias. De manera que, el mejor método para cuantificar y ubicar los bosques secundarios corresponde a la clasificación de imágenes Sentinel-2 de los meses de junio y julio mediante Análisis Basado en Objetos (OBIA).

## **Agradecimientos**

Los autores agradecen a la Vice-Rectoría de Investigación y Extensión del Instituto Tecnológico de Costa Rica por el apoyo financiero y administrativo para la realización de este proyecto. Así mismo, al programa de becas CeNAT-CONARE y al Laboratorio PRIAS del Centro Nacional de Alta Tecnología de Costa Rica, por la facilitación de los equipos de cómputo de avanzada y el uso de las licencias de los programas requeridos para llevar a cabo esta investigación.

## Referencias

- Aguilar, H., Vargas, C., Mora, R., 2014. Metodología para la corrección atmosférica de imágenes Aster, RapidEye, Spot 2 y Landsat 8 con el módulo FLAASH del software ENVI. *Revista Geográfica de América Central*, (53), 39-59.
- Arroyo, V., Melo, F., Martínez, M., Bongers, F., Chazdon, R., Meave, J., Tabarelli, M. (2015). Multiple successional pathways in human-modified tropical landscapes: new insights from forest succession, forest fragmentation and landscape ecology research. *Biological Reviews* 92: 326-340 p. doi:10.1111/brv.12231
- 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). doi: 10.21829/myb.2018.2431576
- Boyd, D., & Danson, F. (2005). *Satellite remote sensing of forest resources: Three decades of research development. Progress in Physical Geography: Earth and Environment*, 29(1), 1-26 p. doi:10.1191/0309133305pp432ra
- Centro Científico Tropical (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. 64 p.
- Chassot, O., Chaves, H., Finengan, B., and 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.  
Doi:10.15359/rca.39-1.5
- Chuvieco, E. (1998). *El factor temporal en teledetección: evolución fenomenológica y análisis de cambios*. *Revista de Teledetección* 10. Recuperado de: [http://telenet.uva.es/promotores/revista/revista\\_10/AET10\\_4.pdf](http://telenet.uva.es/promotores/revista/revista_10/AET10_4.pdf)
- Csillik, O. (2017). Fast segmentation and classification of very high resolution remote sensing data using SLIC superpixels. *Remote Sensing* 9(3): 243-261 p. doi:10.3390/rs9030243
- ESRI. (2018). *GIS Dictionary*. Recuperado de: <https://support.esri.com/en/other-resources/gis-dictionary/search/>
- Goosem, M., Paz, C., Fensham, R., Preece, N., Goosem, S., Laurance, S., Zobel, M. (2016). *Forest age and isolation affect the rate of recovery of plant species diversity and community composition in secondary rain forests in tropical Australia*. *Journal of Vegetation Science* 27(7): 504-514 p. doi:10.1111/jvs.12376
- Hernández, G., Barquero, A., Hernández, W., Méndez, A. and Sánchez, H. 2017. *Informe estado de la nación en desarrollo humano sostenible 2017: Gestión de los recursos forestales en Costa Rica*. *Estado de la Nación: San José, Costa Rica*. [https://estadonacion.or.cr/files/biblioteca\\_virtual/023/Ambientales/Hernandez\\_G\\_et\\_al\\_2017.pdf](https://estadonacion.or.cr/files/biblioteca_virtual/023/Ambientales/Hernandez_G_et_al_2017.pdf)
- Li, M., Zang, S., Zhang, B., Li, S., & Wu, C. (2014). *A Review of Remote Sensing Image Classification Techniques: the Role of Spatio-contextual Information*. *European Journal of Remote Sensing*, 47(1): 389–411 p. doi:10.5721/eujrs20144723
- Lu, D., Li, G., Moran, E. and Kuang, W. 2014. A comparative analysis of approaches for successional vegetation classification in the brazilian amazon. *GIScience and Remote Sensing* 51 (6): 695–709. doi:10.1080/15481603.2014.983338
- Martin, D., Fowlkes, C., Malik, J. (2004) Learning to Detect Natural Image Boundaries Using Local Brightness, Color and Texture Cues. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 26(5): 530–549 p. doi:10.1109/TPAMI.2004.1273918
- 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)*,

*Faculta de Ciencias Agroalimentarias. UCR. En Atlas Digital de Costa Rica 2014.  
Editado por: E. Ortiz, ITCR, Cartago, Costa Rica.*

- Mura, M., Bottalico, F., Giannetti, F., Bertani, R., Giannini, R., Mancini, M., Orlandini, S., Travaglini, D. and 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. doi:10.1016/j.jag.2017.11.013
- Nhamo, L., van Dijk, R., Magidi, J., Wiberg, D. and Tshikolomo, K. 2018. Improving the accuracy of remotely sensed irrigated areas using post-classification enhancement through UAV capability. *Remote Sensing* 10 (5): 712-723. doi:10.3390/rs10050712
- Ningthoujam, R., Tansey, K., Balzter, H., Morrison, K., Johnson, S., Gerard, F., George, C. et al. 2016. Mapping forest cover and forest cover change with airborne s-band radar. *Remote Sensing* 8 (7): 577-597. doi:10.3390/rs8070577
- Olofsson, P., Foody, G. M., Herold, M., Stehman, S., Woodcock, C. and Wulder, M. 2014. Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, 148: 42-57. doi:10.1016/j.rse.2014.02.015
- Ortiz, E. 2014. "Data from: Digital Atlas of Costa Rica" (dataset). (1st ed.). Cartago, Costa Rica: ITCR.
- Piazza, G., Vibrans, A., Liesenberg, V., Refosco, J. (2016). *Object-oriented and pixel-based classification approaches to classify tropical successional stages using airborne high-spatial resolution images. GIScience & Remote Sensing*, 53(2): 206-226 p. doi:10.1080/15481603.2015.1130589
- 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 p. doi:10.3390/su9020258
- Sader, S., A. Joyce. (1988). *Deforestation rates and trends in Costa Rica, 1940 to 1983. Biotropica* 20: 11-19 p. doi: 10.2307/2388421
- Sanchez, 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 p. doi: 10.1659/0276-4741(2002)022[0352:DOTDAN]2.0.CO;2
- Sayão, V., Demattê, J., Bedin, L., Nanni, M., Rizzo, R. (2018). Satellite land surface temperature and reflectance related with soil attributes. *Geoderma* 325: 125-140 p. doi:10.1016/j.geoderma.2018.03.026
- 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. doi:10.1080/17538947.2016.1251502
- Singh, G., Aakanksha., Wasay, S., Singh, R. (2019). A Comparison Of Pixel Based And Object Based Image Analysis With Machine Learning Algorithms For Land Use/ Land Cover Classification. *Our Heritage* 67(4): 286-294 p.
- Sloan, S., Goosem, M., Laurance, S. (2015). Tropical forest regeneration following land abandonment is driven by primary rainforest distribution in an old pastoral region. *Landscape Ecology* 31: 601-619 p. doi:/10.1007/s10980-015-0267-4
- Sothe, C., Almeida, C., Liesenberg, V., Schimalski, M. (2017) Evaluating Sentinel-2 and Landsat-8 Data to Map Sucessional Forest Stages in a Subtropical Forest in Southern Brazil. *Remote Sensing* 9: 838-860 p. doi:10.3390/rs9080838
- Taylor, B., Chazdon, R., Bachelot, B., Menge, D. (2017). Nitrogen-fixing trees inhibit growth of regenerating costa rican rainforests. *Proceedings of the National Academy of Sciences* 114(33): 8817–8822 p. doi:10.1073/pnas.1707094114
- Toure, S., Stow, D., Shih, H., Weeks, J., Lopez-Carr, D. (2018). Land cover and land use change analysis using multi-spatial resolution data and object-based image analysis. *Remote Sensing of Environment* 210: 259-268 p. doi:10.1016/j.rse.2018.03.023
- 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 p. doi:10.15359/rca.53-2.4
- Wężyk, P., Hawryło, P., Szostak, M., Pierzchalski, M., De Kok, R. (2016). Using geobia and data fusion approach for land use and land cover mapping. *Quaestiones Geographicae* 35(1): 93–104 p. doi: 10.1515/quageo-2016-0009

- Wulder, M., Orllepp, S., White, J., & Maxwell, S. (2008). *Evaluation of Landsat-7 SLC-off image products for forest change detection. Canadian Journal of Remote Sensing, 34(2), 93–99 p. doi:10.5589/m08-020*
- 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 p. doi: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: Pages 918-930 p. doi:10.1016/j.rse.2017.08.030*

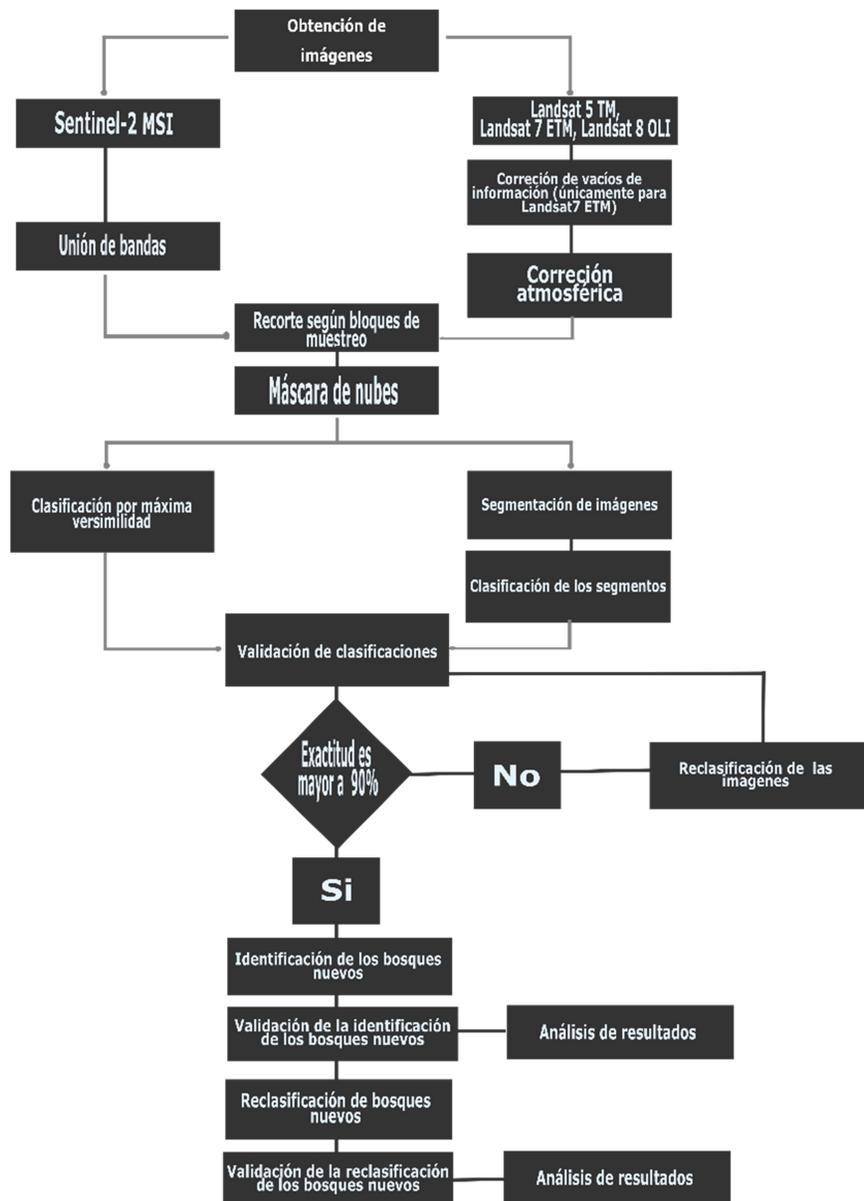


Figura 1. Flujo de trabajo de la investigación.

Cuadro 1. Promedios de exactitud de bosques nuevos según método de clasificación

Método de clasificación	Exactitud promedio (%)	N	Error estándar	Prueba de Tukey Alfa= 0,05 DMS= 3,004
MLC	38,5	36	1,09	A
OBIA	41,74	36	1,09	B

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ )

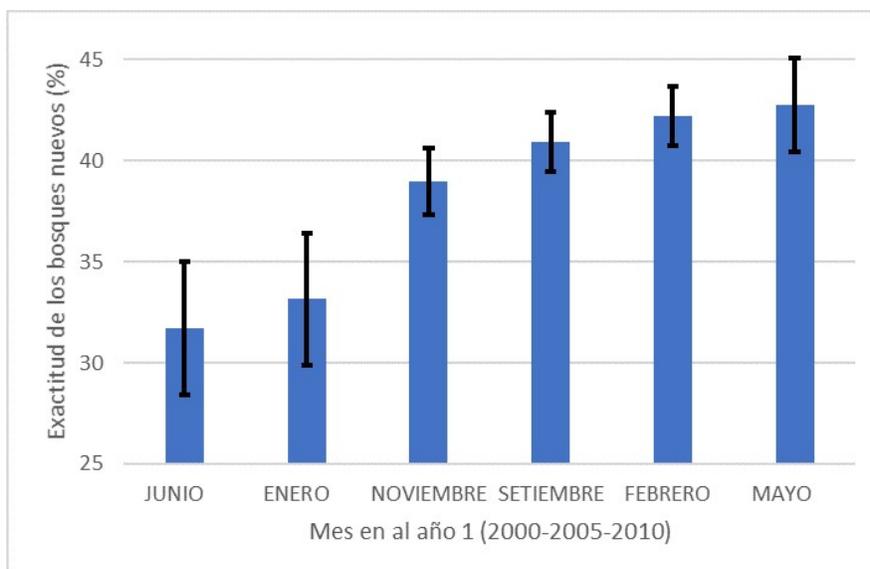


Figura 2. Comparación de los resultados de exactitud en la identificación de bosques nuevos según mes de toma de la imagen en el año 1 (2000, 2005 y 2010).

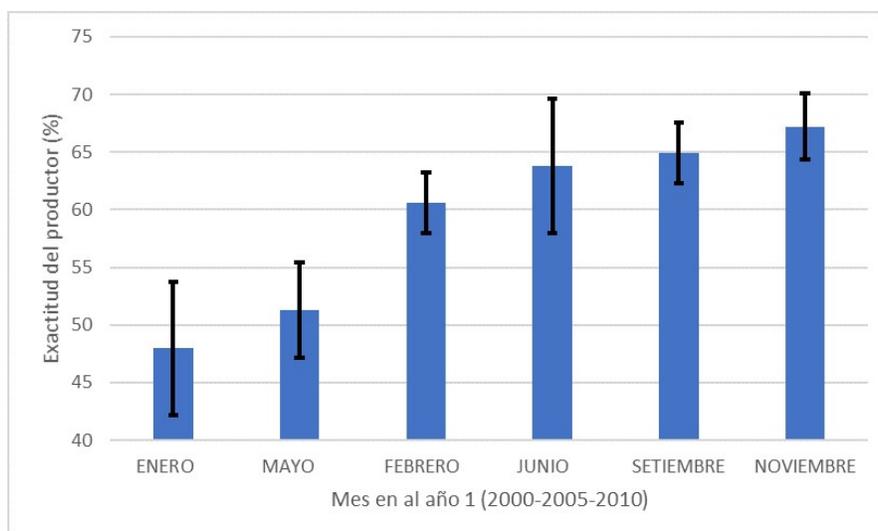


Figura 3. Comparación de los resultados de exactitud del productor de la clase de Bosques Secundarios según mes de toma de la imagen en el año 1 (2000, 2005 y 2010).

Cuadro 2. Promedios de exactitud del productor de la clase de bosques secundarios según método de clasificación y mes de la imagen en el año 1.

Método de clasificación	Mes de la imagen del año 1	Exactitud del productor promedio	n	Error estándar	Prueba de Tukey Alfa=0,05 DMS=28,11
MLC	ENERO	34,03	2	8,22	A
OBIA	MAYO	49,54	4	5,81	A -B

MLC	MAYO	53,01	4	5,81	A -B
MLC	FEBRERO	58,4	10	3,67	A -B
OBIA	JUNIO	59,72	2	8,22	A -B
OBIA	SETIEMBRE	60,34	10	3,67	A -B
OBIA	NOVIEMBRE	60,84	8	4,11	A -B
OBIA	ENERO	61,9	2	8,22	A -B
OBIA	FEBRERO	62,78	10	3,67	B
MLC	JUNIO	67,86	2	8,22	B
MLC	SETIEMBRE	69,54	10	3,67	B
MLC	NOVIEMBRE	73,61	8	4,11	B

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ )

Cuadro 3. Promedios de exactitud del productor de la clase de bosques secundarios según tipo de imagen y mes en el año 1 en que fue tomada.

Tipo de Imagen	Mes de la imagen del año 1	Exactitud del productor promedio	n	Error estándar	Prueba de Tukey Alfa=0,05 DMS=28,11
SENTINEL	ENERO	34,82	2	8,22	A
LANDSAT	JUNIO	47,22	2	8,22	A -B
SENTINEL	MAYO	47,86	4	5,81	A -B
LANDSAT	FEBRERO	53,04	10	3,67	A -B -C
LANDSAT	MAYO	54,68	4	5,81	A -B -C
SENTINEL	SETIEMBRE	60,37	10	3,67	A -B -C
LANDSAT	ENERO	61,11	2	8,22	A -B -C
LANDSAT	NOVIEMBRE	65,68	8	4,11	B -C
SENTINEL	FEBRERO	68,14	10	3,67	B -C
SENTINEL	NOVIEMBRE	68,78	8	4,11	B -C
LANDSAT	SETIEMBRE	69,52	10	3,67	B -C
SENTINEL	JUNIO	80,36	2	8,22	C

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ )

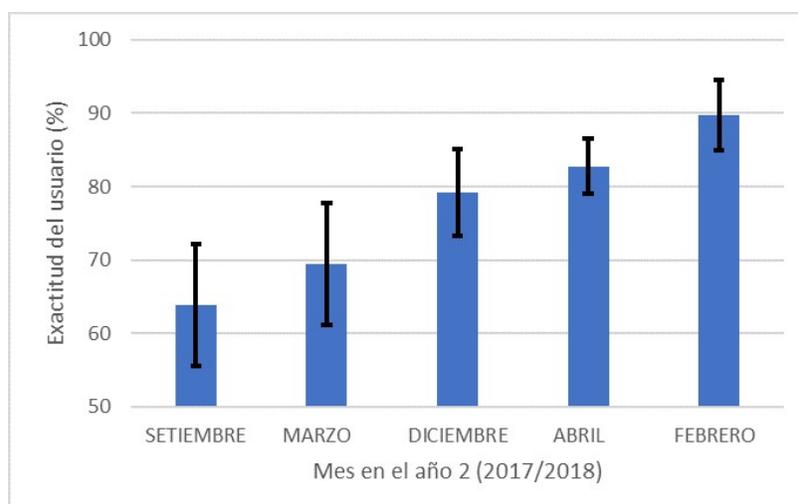


Figura 4. Comparación de los resultados de exactitud del usuario de la clase de Bosques Secundarios según mes de toma de la imagen en el año 2 (2017/2018).

Cuadro 4. Promedios de exactitud del usuario de la clase de bosques secundarios según tipo de imagen y mes de la imagen en el año 1.

Tipo de Imagen	Mes de la imagen del año 1	Exactitud del usuario promedio	n	Error estándar	Prueba de Tukey Alfa=0,05 DMS=49,48
Sentinel	Enero	41,67	2	14,46	A
Landsat	Junio	58,33	2	14,46	A -B
Landsat	Setiembre	75	10	6,47	A -B
Landsat	Mayo	75	4	10,22	A -B
Landsat	Febrero	78,33	10	6,47	A -B
Landsat	Noviembre	83,33	8	7,23	A -B
Sentinel	Setiembre	83,33	10	6,47	A -B
Sentinel	Noviembre	83,33	8	7,23	A -B
Sentinel	Febrero	90	10	6,47	A -B
Landsat	Enero	91,67	2	14,46	B
Sentinel	Mayo	91,67	4	10,22	B
Sentinel	Junio	100	2	14,46	B

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ )

Cuadro 5. Promedios de exactitud general de la clase de bosques secundarios según tipo de imagen y mes de la imagen en el año 1.

Tipo de Imagen	Mes de la imagen del año 1	Exactitud general promedio de la clase de bosques	n	Error estándar	Prueba de Tukey Alfa=0,05 DMS=33,38
Sentinel	Enero	38,24	2	9,75	A
Landsat	Junio	52,78	2	9,75	A -B
Landsat	Mayo	64,84	4	6,9	A -B -C
Landsat	Febrero	65,69	10	4,36	A -B -C
Sentinel	Mayo	69,76	4	6,9	A -B -C
Sentinel	Setiembre	71,85	10	4,36	B -C
Landsat	Setiembre	72,26	10	4,36	B -C
Landsat	Noviembre	74,51	8	4,88	B -C
Sentinel	Noviembre	76,06	8	4,88	B -C
Landsat	Enero	76,39	2	9,75	B -C
Sentinel	Febrero	79,07	10	4,36	B -C
Sentinel	Junio	90,18	2	9,75	C

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ )