

Sistema multi-algoritmo para la clasificación de coberturas de la tierra en el bosque seco tropical del Área de Conservación Guanacaste, Costa Rica

Multi-algorithm system for land cover classification in tropical dry forest at Guanacaste Conservation Area, Costa Rica

Daniela Vargas-Sanabria¹, Carlos Campos-Vargas²

Fecha de recepción: 5 de mayo de 2017

Fecha de aprobación: 14 de agosto de 2017

Vargas-Sanabria, D; Campos-Vargas, C. Sistema multi-algoritmo para la clasificación de coberturas de la tierra en el bosque seco tropical del Área de Conservación Guanacaste, Costa Rica. *Tecnología en Marcha*. Vol. 31-1. Enero-Marzo 2018. Pág 58-69.

DOI: 10.18845/tm.v31i1.3497

1 Investigadora. Laboratorio de Investigación e Innovación Tecnológica. Vicerrectoría de Investigación, Universidad Estatal a Distancia. Costa Rica. Correo electrónico: dvargass@uned.ac.cr.

2 Investigador. Laboratorio de Investigación e Innovación Tecnológica. Vicerrectoría de Investigación, Universidad Estatal a Distancia. Costa Rica. Correo electrónico: ccamposv@uned.ac.cr.



Palabras clave

Multi-algoritmo; cobertura de la tierra; teledetección; clasificación supervisada.

Resumen

Por décadas la detección y el monitoreo de coberturas de la tierra se ha llevado a cabo por medio de teledetección aéreo-transportada y satelital. La habilidad de detectar y cuantificar coberturas de la tierra depende en gran medida de las capacidades del sensor y técnicas de clasificación entre las cuales destacan supervisada, no supervisada y mixta. El método supervisado se considera el más preciso; sin embargo, depende de la capacidad del algoritmo utilizado para discriminar las categorías. En las coberturas de la tierra asociadas al bosque seco tropical del Área de Conservación Guanacaste, Costa Rica se realizaron series de clasificaciones supervisadas, utilizando los algoritmos *Minimum Distance*, *Mahalanobies*, *Maximum Likelihood*, *Neural Network*, *Support Vector Machine* y *Parallelepiped* para determinar cuál algoritmo clasificaba mejor cada cobertura (bosque tardío, bosque temprano, bosque intermedio, bosque de galería, pastos, manglar) según puntos de control tomados mediante trabajo de campo. De acuerdo al índice de kappa y valores de precisión se destacó el rendimiento de *Maximum Likelihood* y *Neural Network* en la clasificación de las coberturas de la tierra. Este estudio demuestra que un esquema jerárquico y multi-algoritmo puede propulsar los resultados de la clasificación de coberturas de la tierra al contemplar las ventajas y limitaciones de cada algoritmo de clasificación; especialmente si se considera aspectos relativos al tamaño de muestra, resoluciones del sensor (temporal, espacial, radiométrica, espectral), condiciones atmosféricas y composición de la vegetación y paisaje.

Keywords

Multi-algorithm; land cover; remote sensing; supervised classification.

Abstract

For decades the detection and monitoring of land cover have been performed by aerial-transported remote sensing and satellites. Detecting and quantifying land cover relays on sensor capacities and classification techniques, such as supervised, unsupervised and mixed. The supervised method is the most accurate and depends on the ability of the algorithm used to discriminate the categories. On the land cover associated to the tropical dry forest at Guanacaste Conservation Area, Costa Rica, supervised classifications were used, using the *Minimum Distance*, *Mahalanobies*, *Maximum Likelihood*, *Neural Network*, *Support Vector Machine* and *Parallelepiped* algorithms to determine which algorithm classified the coverages better (late forest, early forest, intermediate forest, gallery forest, pasture, mangrove) according to control points taken through field work. According to the kappa index and precision values the performance of *Maximum Likelihood* and *Neural Network* was highlighted in the classification of land coverages. This study demonstrates that a hierarchical and multi-algorithm scheme can propel the results of the classification of land cover by considering the advantages and limitations of each classification algorithm, especially when considering aspects related to sample size, sensor resolutions (temporal, spatial, radiometric, spectral), atmospheric conditions and composition of vegetation and landscape.

Introducción

Por décadas la detección y monitoreo de las coberturas de la tierra se ha llevado a cabo por medio de teledetección aerotransportada o de satélites [1]. Los modelos globales de atmósfera-biosfera que miden el flujo de carbono, agua y energía [2], la creación de políticas ambientales y áreas de conservación [3] y la caracterización de los bosques secundarios [4], [5], [6] dependen de datos de teledetección.

En una imagen obtenida por un instrumento de teledetección, las respuestas espectrales de la cobertura de la tierra están representadas por una combinación compleja de propiedades de reflexión de un gran número de características tanto a nivel elemental como grupal. Por ejemplo, a nivel individual la respuesta de la vegetación responde a la interacción de la luz y las propiedades de las hojas [7].

Sensores como Landsat 7 ETM+, ASTER, IKONOS, Quickbird, Hyperion y ALI registran una huella del paisaje cuya respuesta espectral depende la distribución espacial, la estructural del paisaje y la diversidad florística [8]. Sin embargo, la habilidad de detectar y cuantificar esos elementos del paisaje representados como coberturas de la tierra depende de las capacidades del sensor y las técnicas de clasificación. En específico, las capacidades del sensor de teledetección dependen directamente de la resolución espacial, espectral, radiométrica y temporal. Por ejemplo, si se compara la resolución espacial o tamaño de píxel de Landsat 8 OLI es 30m mientras tanto la de MODIS es 500m. Además, la resolución temporal o periodo de revisita de MODIS es de un día, mientras que Landsat 8 OLI es 27 días. En cuanto a la resolución espectral, MODIS posee 16 bandas, mientras que Landsat 8 OLI solo posee 10 bandas; no obstante, ambos cuentan con una resolución radiométrica de 16 bits.

Las técnicas clásicas de clasificación basada en píxeles pueden ser supervisada, no supervisada o mixta. El método supervisado a pesar de ser el más preciso al requerir una interpretación por medio de la delimitación de áreas de entrenamiento, lo que implica un arduo trabajo de recolección de muestras en campo [9]. Además, los resultados de una clasificación supervisada dependen no solo de la capacidad del algoritmo utilizado para discriminar las categorías; sino también de supuestos con respecto al comportamiento de las categorías. Por ejemplo, *Maximum Likelihood*, es un algoritmo que describe las categorías a partir de una función gaussiana (Se asume que los datos poseen una distribución normal), lo que lo hace más complejo que los otros algoritmos como *Minimum Distance* requiriendo así mayor volumen de cálculo [9].

Algoritmos como *Support Vector Machine* se caracterizan por separar de forma óptima un hiperplano n-dimensional en cuantos subespacios y clases se requieran [10]. En específico, para cada subespacio si es posible, se otorga un máximo margen de seguridad entendido como la distancia que existe entre la frontera de separación entre clases y el punto de entrenamiento más cercano a la misma [10]. Por otro lado, los algoritmos *Neural Network* se consideran semi-paramétricos al estimar la densidad de probabilidad de una categoría [11].

Por consiguiente, este artículo busca demostrar la viabilidad de un modelo multi-algoritmo y jerárquico de clasificación de coberturas de la tierra, donde los criterios de selección de los mejores resultados se basan en valores de Kappa, precisión del usuario, precisión del productor y precisión general. El impacto potencial de este modelo incluye el reporte de cambios de la cobertura forestal a nivel regional e incluso nacional si se adapta a la diversidad de ecosistemas.

Metodología

Área de estudio

El área analizada en se ubica en bosque seco tropical, abarcando los sectores: Santa Rosa, Murciélagos, Santa Elena (Parque Nacional Santa Rosa), Junquillal (Refugio Nacional de Vida Silvestre Bahía Junquillal), El Hacha y Pocosol (Parque Nacional Guanacaste), ubicados dentro del Área de Conservación Guanacaste, distrito de Santa Elena, cantón de La Cruz, en la provincia de Guanacaste, Costa Rica (figura 1).

El Área de Conservación Guanacaste (ACG) se caracteriza por tener una precipitación anual entre 900 y 2400 mm, con una época seca que se extiende desde diciembre hasta abril [12]. Por lo general, la escala de temperatura varía con rangos nocturnos de 16°C a 23°C, mientras que, en el día son de 26 a 38°C [13]. Existe una gran variedad de vegetación costera, riberas y bosques siempre verdes, tanto dentro del área protegida como a sus alrededores, sin embargo, la mayoría de los hábitats se han transformado, destruido y homogenizados debido a actividades de tala, quema, siembra de pastos y actividades agrícolas [13].

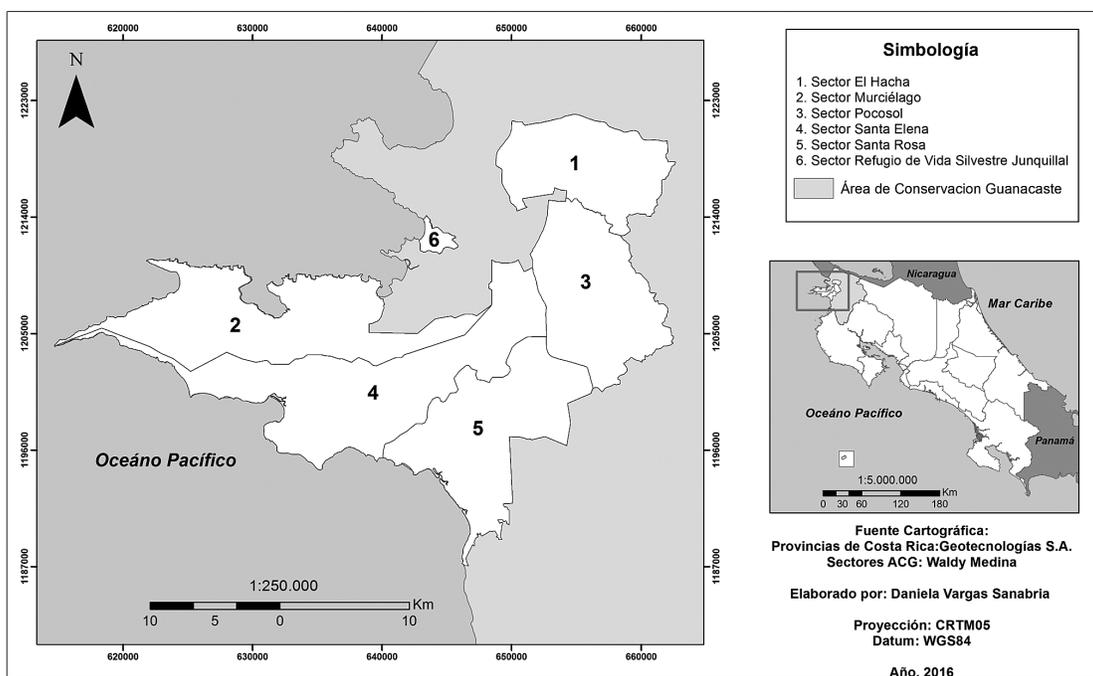


Figura 1. Ubicación de los sectores de estudio del Área de Conservación Guanacaste.

Selección y pre-procesamiento de imágenes satelitales

Para el estudio de la categorización de coberturas de la tierra con imagen satelital se aplicó la metodología descrita a continuación (figura 2). Se utilizó una imagen multispectral LANDSAT 8 OLI adquirida en Abril del año 2015, con un nivel de procesamiento L1T (disponible en <http://earthexplorer.usgs.gov/>, del Servicio Geológico de los Estados Unidos). La imagen seleccionada contó con una cobertura nubosa de 36.25% localizada fuera del área de estudio.

La calibración radiométrica se realizó para discriminar entre artefactos y la respuesta espectral de los elementos que están siendo monitoreados [14], [15]. Así como, para asegurar una

comparación estandarizada de datos entre la imagen utilizada y cualquier otra imagen adquirida en diferentes fechas o por diferentes sensores [14]. En específico, se transformó los valores de pixel de niveles digitales (ND) a unidades físicas de radianza ($W m^{-2} sr^{-1}$). Utilizando el software ENVI 5.1 se aplicaron los coeficientes de transformación reportados por Knight y Kvaran [16] y Markham [17] (cuadro 1); así mismo, la conversión de radianza a reflectancia se realizó mediante la extensión FLAASH (Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes) del programa ENVI 5.1, eliminando los artefactos o “ruidos” que son causados a la señal que llega al satélite y son reflejados en la imagen.

Cuadro 1. Parámetros utilizados en la corrección atmosférica

Parámetro	Característica
Tipo de Sensor	Multiespectral Landsat OLI
Altitud	705.00 Km
Modelo Atmosférico	Tropical
Modelo de Aerosol	Marítimo
Modelo de Aerosol Retrieval	2k Band T
Visibilidad Inicial	20 km

Procesamiento de imágenes y clasificación

Categorías de estudio

Para la fase de entrenamiento se establecieron 10 categorías de estudio correspondientes a las coberturas de la tierra: bosque tardío, bosque intermedio, bosque temprano, bosque de galería, manglar, bosque seco enano, infraestructura, laguna, sombras o nubes y sabana-pasto (estas dos coberturas se incluyeron en una sola debido a que presentan baja discriminación entre ambas ya que los píxeles y las firmas espectrales eran muy similares).

Selección de áreas de entrenamiento

Para determinar las áreas de entrenamiento se utilizaron como referencia puntos de control de campo (GCP) georeferenciados de las coberturas de la tierra, que fueron colectados mediante equipo de posicionamiento global (GPS) *Garmin GPSMAP 64*. Un total de 220 GCP fueron colectados; mediante la herramienta *puntos aleatorios* del programa *Quantum GIS 2.12* fueron seleccionados de donde de forma aleatoria 110 (50%) GCP para ser utilizados como puntos de entrenamiento de los algoritmos de clasificación; los restantes 110 puntos se utilizaron para la validación de la clasificación. Mediante el programa ENVI 5.1, los 110 puntos de entrenamiento se proyectaron sobre la imagen satelital Landsat y alrededor de cada punto se recolectaron los valores de reflectancia en ventanas de 3x3 píxeles, centradas en el punto de entrenamiento (figura 2). Posteriormente, se evaluó la separabilidad de las muestras de entrenamiento mediante el índice *Jeffries-Matusita*.

Aplicación de algoritmos de clasificación supervisada

En la imagen corregida fueron implementados en ENVI 5.1 los algoritmos de clasificación *Minimum Distance*, *Mahalanobies*, *Maximum Likelihood*, *Neural Network*, *Support Vector Machine* y *Parallelepiped* utilizando como entrenamiento los 110 GCP seleccionados.

Validación de la clasificación

Basado en la precisión de productor, la precisión del usuario y el índice Kappa se validaron las categorías clasificadas mediante una matriz de error utilizando los 110 GCP reservados para la validación. Los valores del índice Kappa representan una medida de concordancia o precisión que toma rangos desde -1 a +1 [18]. Landis y Koch [19] caracterizaron los posibles rangos de precisión en tres grupos: mayor a 0.80 *fuerte*, 0.40-0.80, *moderada* y menor a 0.40 *pobre*.

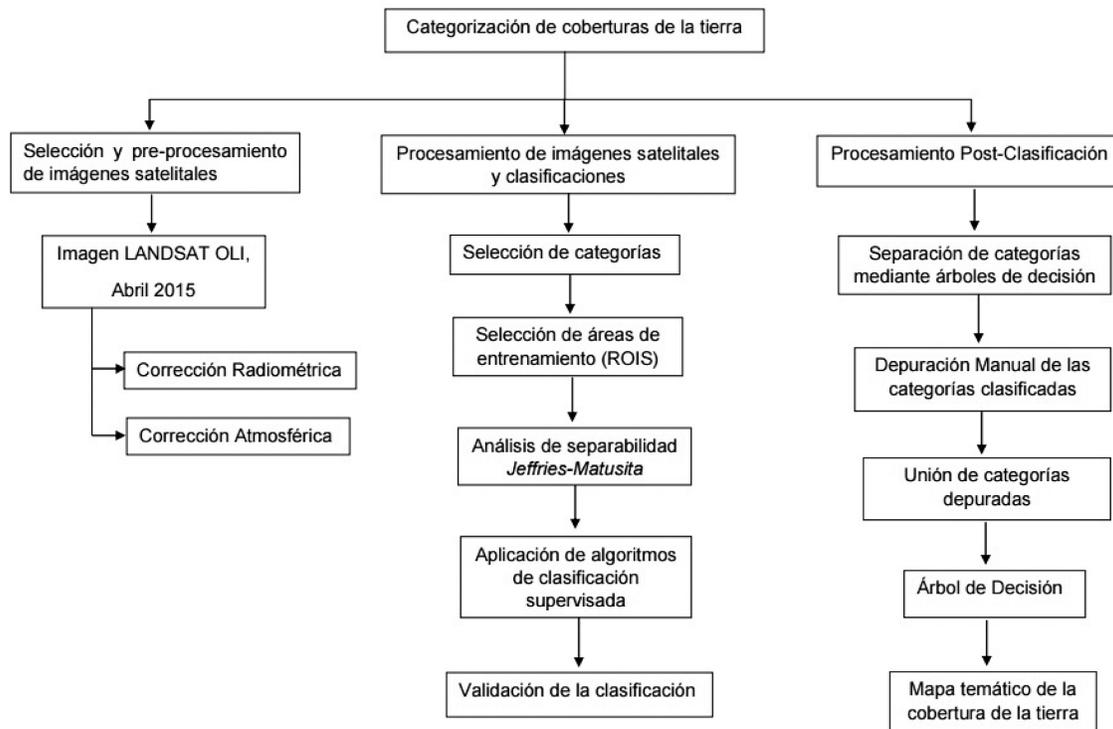


Figura 2. Metodología aplicada para la clasificación de la cobertura de la tierra.

Proceso de post-clasificación

Árboles de Decisión

Se utilizó la técnica de clasificación árbol de decisión (*Decision Tree Classifier*) para separar todas las categorías clasificadas, a nivel individual (figura 3a). Posteriormente, se depuró mediante fotointerpretación manual las categorías seleccionadas en el proceso de validación, eliminando las zonas que el algoritmo clasificó incorrectamente. Finalmente, se creó un nuevo árbol de forma jerárquica con todas las categorías depuradas (figura 3b), dando como resultado un mapa temático final con las coberturas de la tierra del año 2015.

Resultados

Clasificación de cobertura de la tierra

Como resultado se obtuvieron 10 categorías de cobertura de la tierra (figura 4): bosque de galería, bosque intermedio, bosque seco enano, bosque tardío, bosque temprano, infraestructura, laguna, sabana-pasto y sombras o nubes).



Figura 3. (a) Ejemplo de árboles de decisión para cada categoría; (b) Árbol de decisión

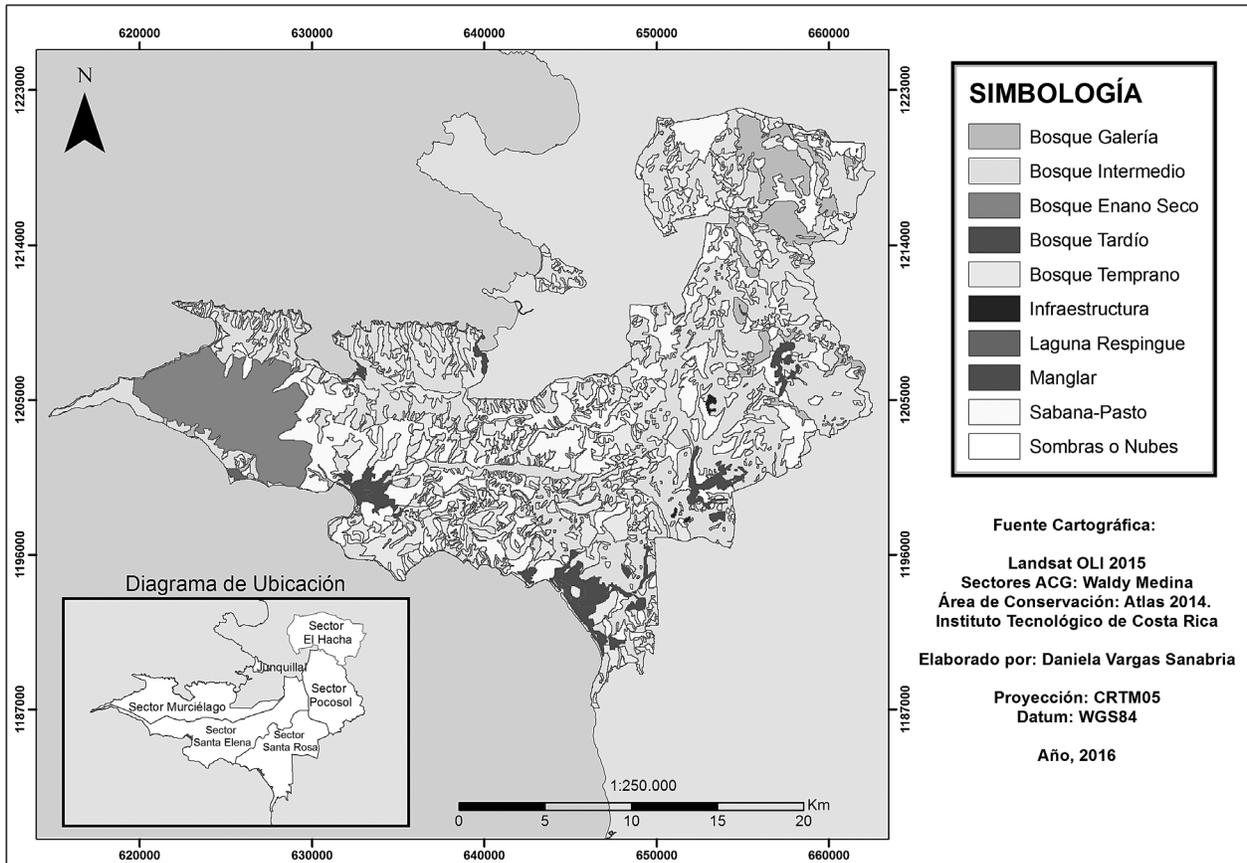


Figura 4. Mapa de cobertura de la tierra 2015 para los sectores del estudio del Área de Conservación Guanacaste.

Evaluación de la exactitud

La exactitud de la clasificación se evaluó de acuerdo al análisis de la matriz de error (cuadro 2). Para las coberturas de bosque intermedio, bosque temprano, bosque tardío, bosque de galería y sabana-pasto los mejores resultados se obtuvieron con el algoritmo *Maximum Likelihood*. Por otro lado, la cobertura de manglar tuvo mejores resultados de clasificación con el algoritmo *Neural Network*. Con respecto a los algoritmos de *Minimum Distance*, *Mahalanobis*, *Paralelepiped* y *Support Vector Machine* no se obtuvo calidad en la clasificación de las coberturas.

A nivel de cobertura, sabana-pasto y manglar obtuvieron un mayor porcentaje en la exactitud del productor; mientras que las coberturas forestales (bosque tardío, bosque intermedio y bosque temprano) presentaron resultados iguales entre la exactitud del productor. Las coberturas correspondientes a infraestructura, nubes, bosque enano seco y laguna fueron clasificadas de forma manual y su validación se realizó con trabajo de campo y criterio experto, por lo tanto, no se tomaron en cuenta a la hora de realizar la validación por matriz de confusión.

A nivel de rendimiento del algoritmo en el cuadro 3 se muestran los porcentajes obtenidos de la precisión y el índice kappa de los algoritmos de clasificación como resultado de la matriz de confusión. El algoritmo de *Maximum Likelihood* fue el que obtuvo mejores resultados en la clasificación de las coberturas con un 81.11% de precisión y un índice kappa de 0.77; mientras que el algoritmo de *Neural Network* obtuvo una precisión de 60.37% con un índice kappa de 0.54. En último lugar se encuentra el algoritmo *Paralelepiped* que no mostró buenos resultados en la clasificación de las coberturas obteniendo un 9.37% de precisión y un índice Kappa de 0.009. De acuerdo a la categorización sobre los rangos de precisión del índice Kappa realizada por Landis y Koch [19], los resultados obtenidos en la clasificación con los algoritmos *Maximum Likelihood* y *Neural Network*, responden a una precisión moderada.

Cuadro 2. Matriz de Confusión de algoritmos de clasificación supervisada

Clasificador	Exactitud	Tipo de Cobertura					
		Bosque Tardío	Bosque Intermedio	Bosque Temprano	Sabana-Pasto	Bosque de Galería	Manglar
Maximum Likelihood	Productor	77.78%	77.78%	77.78%	91.11%	73.33%	88.89%
	Usuario	83.33%	70.00%	67.31%	95.35%	82.50%	93.02%
Neural Network	Productor	55.56%	37.78%	80.00%	73.33%	24.44%	91.11%
	Usuario	51.02%	68.00%	42.86%	89.19%	61.11%	71.93%
Minimum Distance	Productor	0.00%	12.50%	33.33%	44.44%	0.00%	25.00%
	Usuario	0.00%	18.18%	25.00%	66.67%	0.00%	16.67%
Mahalanobis	Productor	0.00%	31.25%	37.50%	48.15%	40.00%	25.00%
	Usuario	0.00%	55.56%	42.86%	72.22%	10.53%	20.00%
Paralelepiped	Productor	0.00%	0.00%	16.67%	13.04%	0.00%	0.00%
	Usuario	0.00%	0.00%	27.27%	100%	0.00%	0.00%
Support Vector Machine	Productor	0.00%	12.50%	36.00%	37.71%	0.00%	33.33%
	Usuario	0.00%	28.57%	27.27%	66.67%	0.00%	40.00%

Cuadro 3. Resultados de la exactitud

Clasificador	Índice Kappa	Precisión
Maximum Likelihood	0.77	81.11%
Neural Network	0.54	60.37%
Mahalanobis	0.21	36.58%
Minimum Distance	0.06	28.04%
Support Vector Machine	0.07	26.43%
Paralelepipedo	0.009	9.37%

Discusión

Los algoritmos de clasificación supervisada *Maximum Likelihood* y *Neural Network*, presentaron los mejores resultados en la clasificación de coberturas basados en puntos de control de campo. Lo que respalda que *Maximum Likelihood* sea utilizado de forma frecuente en teledetección [20], [21], [22]; ya que, es fácil de implementar. No obstante, en algunas ocasiones éste método puede fallar al identificar categorías de uso del suelo debido a que este clasificador asume una distribución normal de las categorías, ya que, toma en cuenta información espectral píxel a píxel utilizando solo una parte pequeña de la información contenida en la imagen [23], lo cual no necesariamente representa el comportamiento de las coberturas de la tierra a nivel de paisaje o gran escala [24].

Los resultados de la clasificación de la cobertura de manglar por el algoritmo *Neural Network* corroboran lo mencionado por Shafri, Suhaili y Mansor [25], que en la utilización de este algoritmo sucede una mayor precisión cuando el límite de decisión de distribución de píxeles de la categoría es menos definido, por lo general, cuando las categorías referentes a especies tienen menos separabilidad de forma espectral. Estudios recientes también plantean que la clasificación de imágenes satelitales con este algoritmo muchas veces presenta más ventajas con respecto a los clasificadores tradicionales, ya que, existe una mayor flexibilidad y adaptabilidad a los resultados debido a que presenta tolerancia ante niveles altos de información [26]. Sin embargo, para el caso de ciertas coberturas la discriminación de las muestras de áreas de entrenamiento se adecuan mejor a los clasificadores convencionales, así mismo influye la cantidad de bandas y categorías analizadas, ya que, si son muchas suelen dar resultados no tan precisos [9].

Los algoritmos basados en *Minimum Distance* se emplean con frecuencia por ser sencillos y rápidos de ejecutar, logrando asignar píxeles a una categoría cercana que logre minimizar la distancia entre el píxel y el centroide de la clase. No obstante, al existir una clase cercana y no dejar píxeles sin clasificación puede provocar errores de comisión [9]. Wacker y Landgrebe [27] precisan en que los problemas generados en la utilización de *Minimum Distance* se basan en la distribución de las clases y que en la clasificación de datos multispectrales es frecuente que surjan dos inconvenientes: que las distribuciones que se encuentran asociadas a cualquier caso sean muy grandes, lo que impide intentar almacenar las distribuciones de subclases posibles y que las distribuciones de las diferentes clases sean a menudo muy similares, por lo que, el número de muestras requeridas para distinguirlas deberían ser muy grandes.

De acuerdo a Moreno [28] estos métodos tienen menos precisión que los métodos de *Máximum Likelihood*, debido a que *Máximum Likelihood* no presenta restricciones respecto a la cantidad

de muestras utilizadas y suele adaptarse a la disposición original de los datos [9]. Sin embargo, cae en la simplicidad de algoritmos como *Paralelepiped*, donde el diseño de dominio de áreas de clasificación puede implicar que existan píxeles en zonas comunes a dos categorías o que los píxeles queden sin clasificar así mismo, lo que implica que puedan existir píxeles que se hayan asignado a varias clases [9].

Huang *et al* [29] reportaron que el algoritmo *Support Vector Machine* obtuvo valores crecientes en la precisión frente al aumento del tamaño de la muestra, en comparación con otros algoritmos. Sin embargo, este algoritmo no obtuvo mayor precisión en la asignación de píxeles a una categoría en nuestra investigación, pudiendo ser la causa el tamaño de los datos, lo que provocó que fueran insuficientes para la clasificación. Así mismo Plaza *et al* [30] mencionan que con un conjunto de entrenamiento limitado, la precisión de la clasificación tenderá a disminuir a medida que aumenta el número de características, aunque Argañarez y Entraigas [31] señalan que *Support Vector Machine* genera buenos resultados en la clasificación, aun cuando se cuenta con volúmenes de datos de entrenamiento pequeños. Foody y Mathur [32] plantean que debido al escaso número de muestras de entrenamiento y el gran número de características de las aplicaciones de teledetección, la estimación confiable de los parámetros de las clases estadísticas se vuelve una meta difícil.

La adaptación de la técnica de clasificación por *Árbol de Decisión* permitió solucionar algunos problemas obtenidos en la implementación del sistema de clasificación de las coberturas por los algoritmos *Maximum Likelihood* y *Neural Network*. Así mismo, se logró incluir otras categorías mediante el árbol las categorías de bosque seco enano, laguna, nubes o sombras e infraestructura que se habían digitalizado y validado de forma manual. Pal y Mather [33] refuerzan esta tendencia de utilizar herramientas alternativas como *Árboles de Decisión* para solucionar problemas generados por algoritmos a la hora de discriminar clases debido a que clasifican de forma más eficiente los datos. No obstante, el éxito de una clasificación de imágenes satelitales depende de factores como la disponibilidad del número de muestras, la alta calidad de las imágenes, el diseño del sistema de clasificación y las habilidades y experiencia del analista [34].

Conclusiones

La clasificación de tipos de cobertura de la tierra por medio de imágenes satelitales en el bosque seco tropical puede presentar limitaciones por factores como la resolución (espacial, espectral, temporal y radiométrica), condiciones atmosféricas, estructura y composición de la vegetación, paisaje y tamaño de la muestra de datos, sin embargo, la metodología aplicada en el estudio de un sistema multi-algoritmo apuntó a una mejora en la clasificación de imágenes de satélite generando información con mayor exactitud y disminuyendo algunos errores que se derivan de la clasificación. El estudio demostró que es posible utilizar un sistema multi-algoritmo para mejorar la clasificación de categorías, logrando identificar y separar de manera más eficiente los tipos de cobertura de la tierra presentes en seis sectores del Área de Conservación Guanacaste.

Referencias

- [1] R.S. Allison, J.M. Johnston, G. Craig y S. Jennings, "Airborne optical and thermal remote sensing for wildfire detection and monitoring", *Sensors*, vol. 16, no.8, August 2016.
- [2] M. Schlerf, C. Atzberger y J. Hill, "Remote sensing of forest biophysical variables using HyMap imaging spectrometer data", *Remote Sensing of Environment*. vol. 95, no. 2, pp.177-194, Mar. 2005.

- [3] A.S.P. Pfaff y G.A. Sánchez-Azofeifa, (2004) "Deforestation pressure and biological reserve planning: a conceptual approach and an illustrative application for Costa Rica", *Resource and Energy Economics*. vol. 26, pp.237–254, Jun. 2004.
- [4] B. Hilje, J. Calvo-Alvarado, C. Jiménez-Rodríguez y G.A. Sánchez-Azofeifa, "Tree Species Composition, Breeding Systems, and Pollination and Dispersal Syndromes in Three Forest Successional Stages in a Tropical Dry Forest in Mesoamerica." *Mongabay.com Open Access Journal -Tropical Conservation Science*, vol. 88, no. 11, pp. 76–94, Mar. 2015.
- [5] C. Sen, Q. Yu, G.A. Sánchez-Azofeifa, J. Feng, B. Rivard y Z. Gu, "Mapping Tropical Dry Forest Succession Using Multiple Criteria Spectral Mixture Analysis ", *ISPRS*, vol. 109, pp. 17–29, Nov. 2015.
- [6] J.P. Arroyo-Mora, G.A. Sánchez-Azofeifa, M.E.R. Kalacska, B. Rivard, J. Calvo-Alvarado y D.H. Janzen, "Secondary Forest Detection in a Neotropical Dry Forest Landscape Using Landsat 7 ETM + and IKONOS Imagery", *BIOTROPICA*, vol. 37, no. 4, pp. 497-507, Dec. 2005.
- [7] K. Castro-Esau, G.A. Sánchez-Azofeifa, B. Rivard, S.J. Wright y M. Quesada. (2006) "Variability in leaf optical properties of Mesoamerican trees and the potential for species classification", *Am.J.Bot.*, vol. 93, no. 4, pp. 517-530, April. 2006.
- [8] M. Kalacska, G.A. Sánchez-Azofeifa, B. Rivard, T. Caelli, H.P. White, J.C. Calvo-Alvarado, "Ecological Fingerprinting of Ecosystem Succession: Estimating Secondary Tropical Dry Forest Structure and Diversity Using Imaging Spectroscopy" *Remote Sensing of Environment*, vol. 108, no, 1, pp. 82–96, May. 2007.
- [9] E. Chuvieco, "*Teledetección Ambiental. La observación de la tierra desde el espacio*" Editorial Planeta S.A, Barcelona, España, 591 pp, 2010.
- [10] D. Madroñal, "Implementación de una Support Vector Machine en RVC-CAL para imágenes hiperespectrales" Trabajo de Investigación de Maestría, Universidad Politécnica de Madrid, Madrid, España, 2015.
- [11] M.J. Canty, "Image analysis, classification, and change detection in remote sensing: with algorithms for ENVI/IDL", CRC Press Taylor & Francis Group, Florida, United States of America, 2010.
- [12] R. Villalobos, J.A. Retana y A. Acuña, "El niño y los incendios forestales en Costa Rica", *Top. Meteor. Oceanogr.*, vol. 7, no. 1, pp. 1-20, 2000.
- [13] D.H. Janzen, (1986). *Parque Nacional Guanacaste: Restauración Ecológica y Cultural en el Trópico*, San José, Costa Rica, 1986.
- [14] G. Chander, B.L. Markham y D.L. Helder, "Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors", *Remote Sensing of Environment*, vol. 113, no. 5, pp. 893-903, May. 2009.
- [15] D. Roy, J. Borak, S. Devadiga, R. Wolfe, M. Zheng y J. Descloitres, "The MODIS land product quality assessment approach", *Remote Sensing of Environment*, vol. 83, pp. 62-76, 2002.
- [16] E.J. Knight y G. Kvaran, "Landsat-8 Operational Land Imager Design, Characterization and Performance", *Remote Sensing*, vol. 6, no. 11, pp. 10286-10305, Oct. 2014.
- [17] B. Markham, J. Barsi, G. Kvaran, L. Ong, E. Kaita, S. Biggar, J. Czaplá-Myers, N. Mishra y D. Helder, D, "Landsat-8 Operational Land Imager Radiometric Calibration and Stability", *Remote Sensing*, vol. 6, no. 12, pp. 12275-12308, Dec. 2014.
- [18] R. Congalton y K. Green, "*Assessing the accuracy of remotely sensed data. Principles and practices*", Second edition, Taylor & Francis Group LLC, 179pp, 2009.
- [19] J.R. Landis y G.G. Koch, "The Measurement of Observer Agreement for Categorical Data", *Biometrics*, vol. 33, no. 1, pp. 159-174, Mar.1977.
- [20] A.M. Dean y G.M. Smith, "An evaluation of per-parcel landcover mapping using maximum likelihood class probabilities", *International Journal of Remote Sensing*, vol. 24, no. 14, pp. 2905-2920, 2003.
- [21] P. Zorogastúa, R. Quirós, y J. Garatuzá, "Evaluación de cambio en la cobertura y uso de la Tierra con imágenes de satélite en Piura-Perú", *Ecología Aplicada*, vol. 10, no. 1, pp. 13-22, 2011.
- [22] A.M. Dewan y Y. Yamaguchi, "Using remote sensing and GIS to detect and monitor land use and land cover change in Dhaka Metropolitan of Bangladesh during 1960-2005", *Environ. Monit. Assess*, vol. 150, no 1-4, pp. 237-249, Mar. 2009.
- [23] T.J. García-Mora y J.F. Mas, "Comparación de metodologías para el mapeo de la cobertura y uso del suelo en el sureste de México", *Invest. Geog.*, vol. 67, pp. 7-19, Sep. 2008.

- [24] M.G. Turner, (2005). "Landscape Ecology: What is the state of the Science", *Annu. Rev. Ecol. Evol. Syst.*, vol. 36, pp. 319-344, 2005.
- [25] H. Shafri, A. Suhaili y S. Mansor, "The performance of Maximum Likelihood Spectral Angle Mapper, Neural Network and Decision Tree Classifiers in Hyperspectral Imagen Analysis", *Journal of Computer Science*, vol. 3, no. 6, pp. 419-423, June. 2007.
- [26] L. Giraldo y J.P. Barrero, "Implementación de una red neuronal para la clasificación de coberturas terrestres en imágenes MODIS", Anteproyecto. Universidad San Buenaventura Seccional Medellín, Medellín, Colombia, 2012.
- [27] A. G. Wacker y D.A. Landgrebe, "Minimum Distance Classification in Remote Sensing", *LARS. Technical Reports*, vol 1, No. 1, pp 1-20, 1972.
- [28] J.F. Moreno, "Discriminación y Clasificación" en: Teledetección en el seguimiento de los fenómenos naturales. Recursos Renovables: Agricultura, S. Gandía y J. Meliá, Eds, Universitat de Valencia, 1991, pp. 241-275.
- [29] C. Huang, L.S. Davis y J.R.G. Townshend, "An assessment support vector machines for land cover classification" *International Journal of Remote Sensing*, vol. 23, no. 4, pp. 725-749. 2002.
- [30] A. Plaza, J.A. Benediktsson, J.W. Boardman, J. Brazile, L. Bruzzone, G. Campos-Valls, J. Chanussot, M. Fauvel, P. Gamba, A. Gualtieri, M. Marconcini, J.C. Tilton y G. Trianni, "Recent advances in techniques for hyperspectral image processing", *Remote Sensing of Environment*, vol. 113, pp. S110-S122, 2009.
- [31] J.P. Argañaraz y I. Entraigas, "Análisis comparativo entre máquinas de vectores soporte y el clasificador de máxima probabilidad para la discriminación de cubiertas de suelo" *Revista de Teledetección*, vol. 36, pp. 26-39, 2011.
- [32] G. Foody y A. Mathur, "Toward intelligent training of supervised image classifications: directing training data acquisition for SVM classification", *Remote Sensing of Environment*, vol. 93, no. 1-2, pp. 107-117, Oct. 2004.
- [33] M. Pal, y P.M. Mather, "Decision Tree based classification for remotely sensed data", in *22nd Asian Conference on Remote Sensing*, Singapore, Nov. 2001.
- [34] D. Lu y Q. Weng, "A survey of image classification methods and techniques for improving classification performance", *International Journal of Remote Sensing*, vol. 28, no. 5, pp. 823-870, Mar. 2007.

Anexos

Anexo 1. Coordenadas geográficas y hectáreas de los sectores de estudio del Área de Conservación Guanacaste.

Sector	Coordenadas Geográficas	Hectáreas (ha)
Santa Rosa	10,8577389 N – 85,7270306 W	11.066,737
Murciélagos	10,8870000 N – 85,8445111 W	12.937,423
Santa Elena	10,8938250 N – 85,7645167 W	15.288
El Hacha	11,0026111 N – 85,5400722 W	7.981,854
Pocosol	10,8918722 N – 85,5992417 W	9.847,841
RVS Junquillal	10,9739861 N – 85,647811 W	438,463