

Operational implications of spatial resolution of drone imagery in vegetation mapping for forest management

Implicaciones operativas de la resolución espacial de imágenes de drones en el mapeo de la vegetación para el manejo forestal

Casimiro Ordóñez-Prado¹; José René Valdez-Lazalde^{1*}; Héctor Flores-Magdaleno¹; Gregorio Ángeles-Pérez¹; Héctor M. de los Santos-Posadas¹; Enrique Buendía-Rodríguez²

¹Colegio de Postgraduados. Carretera México-Texcoco km 36.5. C. P. 56264. Montecillo, Texcoco, Estado de México, México.

²Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP), Centro de Investigación Regional Centro, Campo Experimental Valle de México. Carretera Texcoco-Los Reyes km 13.5. C. P. 56250. Coatlinchán, Texcoco, Estado de México, México.

*Corresponding author: valdez@colpos.mx; tel.: +52 595 952 0200 ext. 1483.

Abstract

Introduction: Drones allow collecting high-spatial resolution images useful for monitoring forest vegetation dynamics in managed forests. There are, however, doubts about the most effective way to use them concerning spatial resolution.

Objective: To identify the optimal spatial resolution of multispectral images captured by drones for mapping land cover types in managed temperate forests in Hidalgo, Mexico.

Materials and methods. Spectral images were preprocessed at spatial resolutions from 0.2 to 2.5 m, at 0.1 m intervals. Pine, oak, other broad-leaved trees, herbs and bare soil cover were classified with the Random Forest algorithm. The effect of spatial resolution on land cover classification was evaluated using the Kruskal-Wallis non-parametric test followed by a Mann-Whitney-Wilcoxon post-hoc comparison ($P < 0.05$). Classification errors of land cover classes were analyzed graphically.

Results. 0.2 m spatial resolution images provided the highest land cover classification accuracy (96 %) but was statistically similar to that of 0.7 m ($P = 0.3984$). The lowest accuracy (82 %) was obtained with 2.5 m spatial resolution imagery. Omission and commission errors were lower and consistent in classifications with 0.2 to 1.2 m spatial resolution images.

Conclusion. Multispectral images (0.7 m resolution), acquired with a fixed-wing drone, allowed us to classify the land cover/vegetation types and the exact spatial distribution of pine, oak and other hardwood species in a temperate forest under forest management.

Keywords: forest cover; vegetation classification; multispectral images; kappa index; Random Forest.

Resumen

Introducción. Los drones aportan imágenes de alta resolución espacial para el seguimiento de la dinámica de la vegetación en bosques bajo manejo forestal; sin embargo, existen dudas sobre la forma más eficaz de utilizarlas con respecto a la resolución espacial.

Objetivo. Determinar la resolución espacial más apropiada de las imágenes multiespectrales obtenidas por drones, para mapear los tipos de cobertura del suelo en bosques templados bajo manejo forestal de Hidalgo, México.

Materiales y métodos. Las imágenes espectrales se preprocesaron en resoluciones espaciales desde 0.2 hasta 2.5 m, a intervalos de 0.1 m. La cobertura de pinos, encinos, otras latifoliadas, herbáceas y suelo desnudo se clasificaron con el algoritmo Random Forest. El efecto de la resolución espacial en la clasificación de la cobertura terrestre se evaluó mediante la prueba no paramétrica de Kruskal-Wallis seguida de una comparación post-hoc Mann-Whitney-Wilcoxon ($P < 0.05$). Los errores de clasificación de las clases de cobertura se analizaron gráficamente.

Resultados. Las imágenes de 0.2 m de resolución espacial proporcionaron la mayor precisión de clasificación de la cobertura del suelo (96 %), pero fue estadísticamente similar que la de 0.7 m ($P = 0.3984$). La precisión más baja (82 %) se obtuvo con imágenes de 2.5 m de resolución espacial. Los errores de omisión y comisión fueron menores y constantes en las clasificaciones con imágenes de resolución espacial de 0.2 a 1.2 m.

Conclusión. Las imágenes multiespectrales (0.7 m de resolución), adquiridas con un dron de ala fija, permitieron la clasificación precisa de los tipos de cobertura y la distribución espacial exacta de pinos, encinos y otras especies de latifoliadas de un bosque templado bajo manejo forestal.

Palabras clave: cobertura forestal; clasificación de vegetación; imágenes multiespectrales; índice kappa; Random Forest.

Introduction

Small remotely piloted aircraft systems (RPAS) or drones have become an efficient and viable alternative for the transport of remote sensors that provide geospatial information on land cover (Coelho-Eugenio et al., 2021; Guevara-Bonilla et al. 2020). Photogrammetric processes using high spatial resolution images taken with this technology generate precise and updated information on vegetation conditions and changes (Tang & Shao, 2015). Specifically, information on the composition of forest cover is fundamental for the planning and practical use of resources (Cárdenas-Tristán et al., 2013) and is the basis for stand definition of areas under forest management.

High-resolution spatial images obtained by sensors on drones have the same purpose as those acquired from satellite platforms, but at a substantially lower cost, and therefore, available to small forest producers (Paneque-Gálvez et al., 2014). Consequently, the incorporation of this technology into cartographic work for mining, civil engineering, and agriculture is more common nowadays (Fernández-Lozano & Gutiérrez-Alonso, 2016; García-Martínez et al., 2020; Khan et al., 2021).

The availability of drones has led to research in fields like forestry, ecology, and forest fire monitoring (Al-Kaff et al., 2020; Banu et al., 2016; Ivosevic et al., 2015). Gallardo-Salazar et al. (2020) noted that over the past decade alone, there have been 117 scientific articles exploring drone applications in forestry. Hamilton et al. (2020), Bhatnagar et al. (2020), Jiang et al. (2020), and Kedia et al. (2021) have demonstrated the potential of drone-captured images for vegetation classification in different ecosystems, identifying tree species groups, individual trees, and even low-lying vegetation like the herbaceous layer. Despite advancements, the full practical potential of drone-acquired images for forest management is still unknown. However, it can be affirmed that their similarity to satellite aerial images, but with more accessible acquisition, offers advantages in tasks such as abundance analysis, diversity assessment, forest dynamics, ecological conservation, and vegetation mapping (Veneros et al., 2020). In addition, multispectral sensor imagery can be used for forest cover classification, change detection and estimation of forest attributes, and in the modeling of spatially explicit processes (Khan et al., 2021; Torres-Rojas et al., 2017).

Images spatial resolution play an important role in vegetation mapping. The higher the resolution, the greater the ability to accurately detect small objects, which is relevant when mapping trees at genus or species level (Yu et al., 2006). But getting higher spatial resolution images imply flying a drone at a lower

Introducción

Los pequeños sistemas de aeronaves pilotadas a distancia (Remotely Piloted Aircraft Systems [RPAS]) o drones se han convertido en una alternativa eficiente y viable para el transporte de sensores remotos que aportan información geoespacial sobre la cobertura del suelo (Coelho-Eugenio et al., 2021; Guevara-Bonilla et al. 2020). Los procesos fotogramétricos que utilizan imágenes de alta resolución espacial, tomadas con esta tecnología, generan información precisa y actualizada de las condiciones y cambios de la vegetación (Tang & Shao, 2015). Específicamente, la información de la composición de la cobertura forestal es fundamental para la planificación y aprovechamiento práctico de los recursos (Cárdenas-Tristán et al., 2013) y es la base para la zonificación/rodalización de áreas bajo manejo forestal.

Las imágenes de alta resolución espacial, obtenidas por sensores acoplados a drones, sirven para el mismo propósito que las adquiridas de plataformas satelitales, pero a un costo sustancialmente inferior y, por tanto, al alcance de los pequeños productores forestales (Paneque-Gálvez et al., 2014). En consecuencia, la incorporación de esta tecnología en trabajos cartográficos de minería, ingeniería civil y agricultura es más común en la actualidad (Fernández-Lozano & Gutiérrez-Alonso, 2016; García-Martínez et al., 2020; Khan et al., 2021).

La disponibilidad de drones también ha suscitado investigaciones en ámbitos como la silvicultura, ecología y vigilancia de incendios forestales (Al-Kaff et al., 2020; Banu et al., 2016; Ivosevic et al., 2015). Gallardo-Salazar et al. (2020) informaron que, tan solo en la última década, se generaron 117 artículos científicos sobre aplicaciones de drones en temas forestales. Al respecto, Hamilton et al. (2020), Bhatnagar et al. (2020), Jiang et al. (2020) y Kedia et al. (2021) han demostrado el potencial de las imágenes captadas con drones para la clasificación de la vegetación en diversos ecosistemas. Dichos autores han identificado desde grupos de especies arbóreas hasta individuos, así como clases de vegetación de baja presencia como el estrato herbáceo. A pesar de los avances, aún se desconoce todo el potencial práctico de las imágenes obtenidas con drones para el manejo forestal. No obstante, se puede afirmar que, su similitud con las imágenes aéreas satelitales, pero de obtención más accesible, representa ventajas en tareas como el análisis de la abundancia, diversidad, dinámica de los bosques, conservación ecológica y cartografía de la vegetación (Veneros et al., 2020). Además, las imágenes de sensores multiespectrales pueden ser utilizadas para la clasificación de la cobertura forestal, detección de cambios y estimación de los atributos de los bosques, y en la modelización de procesos espacialmente explícitos (Khan et al., 2021; Torres-Rojas et al., 2017).

altitude, which results on longer fly time and higher cost. Besides, a greater amount of data is collected, meaning more computer processing time. Even though high-resolution images are now available to more people, studies on the impact of spatial resolution on vegetation detection are scarce; especially those images obtained with drones that usually have submetric spatial resolution. Liu et al. (2020) found that, by using this type of information, vegetation can be adequately classified within highly fragmented plantations, and suggested that the sharpest resolution is not always adequate to classify vegetation. The same may also be true when managing natural forests, since natural processes and the extraction of wood generates discontinuities in the forest canopy, creating different conditions in the vegetation (Sánchez-Medor et al., 2015). Therefore, it is relevant to analyze whether drone taken aerial photographs can be a suitable alternative for vegetation mapping of managed forests, which is one of the main and mandatory inputs for forest management planning. Regarding the above, the objective of this study was to determine the appropriate spatial resolution of drone-derived multispectral imagery to map land cover types in managed temperate forests of Hidalgo, Mexico.

Materials and Methods

Study Area

The study was carried out at the Intensive CO₂ Monitoring Site (SMIC by its acronym in Spanish) located between coordinates 20° 35' 00"- 20°38' 30" N and 98° 34' 00"- 98° 38' 00" W, in the southeast of the municipality of Zacualtipán, Hidalgo, Mexico. The SMIC covers an area of 900 ha; however, given the scope of the fixed-wing drone's range, the present study was carried out in its central 100 ha (Figure 1). This region is rich in humidity, the average annual rainfall ranges between 700 mm and 2050 mm, and it is common to have cloudy days throughout the year. Although the rainy season occurs from June to October, winter has high humidity, a result of cold fronts coming from the north, which is why the region's climate is classified as humid temperate (C(fm)w"b(e)g) (Ortiz-Reyes et al., 2015).

The SMIC is managed for wood production by applying even-aged silviculture, so it is organized in even-aged stands of different ages, from four to 88 years. The dominant tree species are *Pinus patula* Schl. et Cham., *Quercus crassifolia* Humb. & Bonpl., *Q. affinis* Scheidw., *Q. laurina* Bonpl., *Q. sartori* Liebm., *Q. excelsa* Liebm., *Q. xalapensis* Bonpl., *Clethra mexicana* DC., *Cornus disciflora* DC., *Viburnum* spp., *Cleyera theaoides* (Sw.) Choisy, *Arbutus xalapensis* Kunth, *Prunus serotina* Kunth and *Vaccinium leucanthum* Schltl. (Chávez-Aguilar et al., 2023).

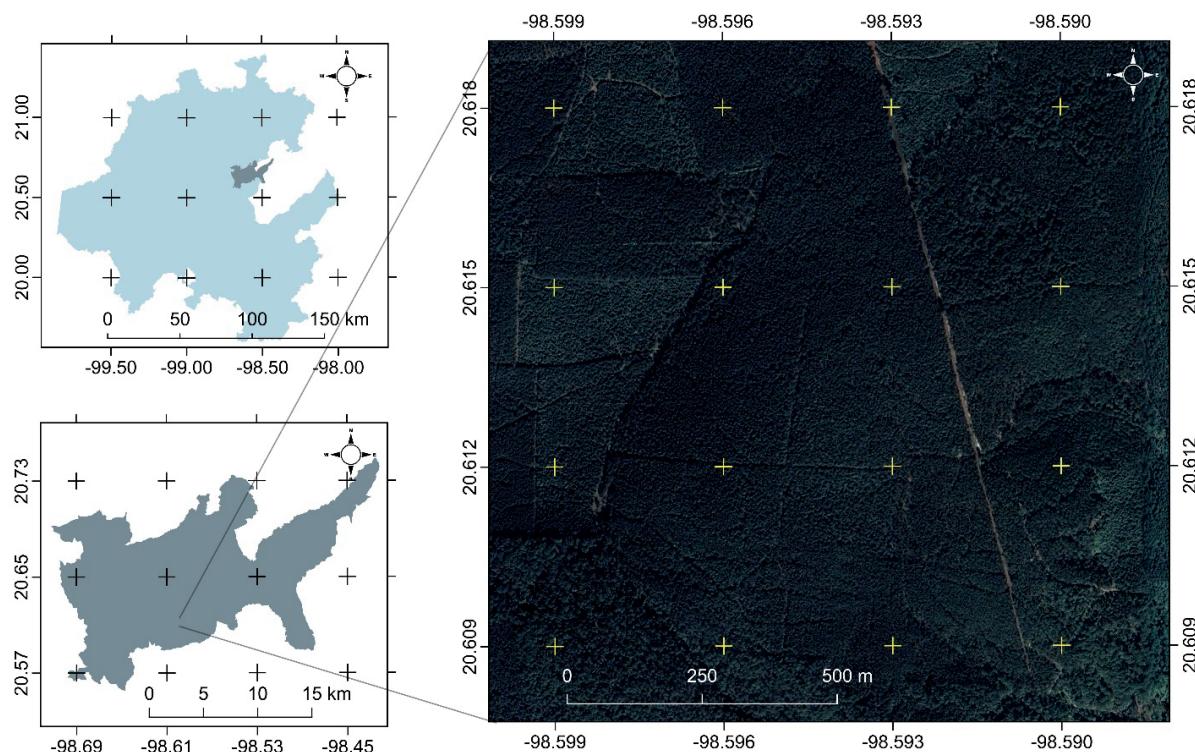
La resolución espacial de las imágenes desempeña un papel importante en el mapeo de la vegetación. Cuanto mayor sea la resolución, mayor será la capacidad de detectar objetos pequeños con precisión, lo que es relevante a la hora de cartografiar árboles a nivel de género o especie (Yu et al., 2006). No obstante, las imágenes de mayor resolución espacial implican el vuelo de un dron a menor altitud, lo que resulta en un tiempo mayor y costo más elevado; además, se recoge mayor cantidad de datos que requieren más tiempo de procesamiento informático. Si bien las imágenes de alta resolución están ahora al alcance de más personas, los estudios sobre el impacto de la resolución espacial en la detección de la vegetación son escasos; especialmente las imágenes obtenidas con drones que suelen tener una resolución espacial submétrica. Liu et al. (2020) encontraron que la clasificación adecuada de la vegetación en plantaciones muy fragmentadas se logra con este tipo de información y sugieren que la resolución más nítida no siempre es la mejor. Lo mismo puede ocurrir en la gestión de los bosques, ya que los procesos naturales y la cosecha de madera generan discontinuidades en el dosel forestal y crean condiciones diferentes en la vegetación (Sánchez-Medor et al., 2015). Por lo tanto, es relevante analizar si las fotografías aéreas tomadas con drones pueden ser una alternativa adecuada para el mapeo de vegetación de bosques, el cual es uno de los insumos principales y obligatorios para la planificación del manejo forestal. Teniendo en cuenta lo anterior, el objetivo de este estudio fue determinar la resolución espacial apropiada de las imágenes multiespectrales obtenidas por drones para mapear los tipos de cobertura del suelo en bosques templados bajo manejo forestal de Hidalgo, México.

Materiales y métodos

Área de estudio

El estudio se realizó en el Sitio de Monitoreo Intensivo de CO₂ (SMIC), ubicado entre las coordenadas 20° 35' 00"- 20° 38' 30" N y 98° 34' 00"- 98° 38' 00" O, al sureste del municipio de Zacualtipán, Hidalgo, México. El SMIC comprende una superficie de 900 ha; sin embargo, por el alcance del dron de ala fija, el presente estudio se limita a sus 100 ha centrales (Figura 1). Esta región es rica en humedad, su precipitación media anual oscila entre 700 mm y 2050 mm y es común encontrar días nublados a lo largo del año. Si bien, la estación de lluvia se presenta de junio a octubre, el invierno tiene una humedad elevada como resultado de los frentes fríos procedentes del norte, por lo que el clima de la región es clasificado como templado húmedo (C(fm)w"b(e)g) (Ortiz-Reyes et al., 2015).

El manejo del SMIC se enfoca en la producción de madera mediante silvicultura coetánea, por lo que se



Simbology / Simbología

- Stands / Rodales
- Zacualtipán Municipality / Municipio de Zacualtipán
- Hidalgo State / Estado de Hidalgo

Figure 1. The study area is in the municipality of Zacualtipán, Hidalgo, Mexico. Forest organization in stands is shown.

Figura 1. Ubicación geográfica del área de estudio en el municipio de Zacualtipán, Hidalgo, México. Se muestra la organización del bosque en rodales.

Image acquisition

A total of 2752 images were taken with a senseFly eBee X® model of a fixed-wing drone equipped with a Parrot Sequoia® multispectral sensor, which has four 12-megapixel monochrome channels, each corresponding to the following bands: green, with a central wavelength (CW) of 550 nm and a bandwidth (BW) of 40 nm; red with a CW of 660 and a BW of 40 nm; red edge with a CW of 735 nm and a BW of 40 nm; and near infrared (NIR) with a CW of 790 nm and a BW of 40 nm.

The autonomous flight plan for taking images was developed with the eMotion® software (senseFly, 2018), determining a flight height at 125 m above the ground, and overlaps of 75 % between images and 65 % between flight lines. The flight took place between 11:00 a. m. and 12:00 p. m., with a clear sky and a wind speed under 8 m·s⁻¹. Before the drone's takeoff and immediately after landing, the Sequoia® (AIRINOV) calibration panel was set up to register the light conditions used in the

organiza en rodales de edades que van desde los cuatro hasta los 88 años. Las especies arbóreas dominantes son *Pinus patula* Schl. et Cham., *Quercus crassifolia* Humb. & Bonpl., *Q. affinis* Scheidw., *Q. laurina* Bonpl., *Q. sartori* Liebm., *Q. excelsa* Liebm., *Q. xalapensis* Bonpl., *Clethra mexicana* DC., *Cornus disciflora* DC., *Viburnum* spp., *Cleyera theaooides* (Sw.) Choisy, *Arbutus xalapensis* Kunth, *Prunus serotina* Kunth y *Vaccinium leucanthum* Schltdl. (Chávez-Aguilar et al., 2023).

Adquisición de imágenes

Se tomaron 2 752 imágenes con un dron de ala fija modelo senseFly eBee X® equipado con un sensor multiespectral Parrot Sequoia® que dispone de cuatro canales monocromos de 12 megápixeles, cada uno de los cuales corresponde a las bandas siguientes: verde, con una longitud de onda central (CW) de 550 nm y ancho de banda (BW) de 40 nm; rojo, con CW de 660 y BW de 40 nm; borde del rojo, con CW de 735 nm y BW de 40 nm; e infrarrojo cercano (NIR), con CW de 790 nm y BW de 40 nm.

radiometric calibration and reflectance corrections of the Sequoia camera bands (Franzini et al., 2019). The geographical position of the aerial photographs was rectified with a V90 PLUS RTK (Real Time Kinematics) global satellite navigation system.

Photogrammetric processing

The 2752 captured images were processed with Pix4Dmapper® version 4.1 software. The average deviation of the images' geolocation was 15 cm in longitude, 14 cm in latitude, and 18 cm in altitude. Initially, orthomosaics were obtained from the green, red, redEdge, and near-infrared monochromatic bands with a spatial resolution of 0.16 m per pixel within a 100-ha forested area. Subsequently, each image was resampled with the QGIS resampling tool (Quantum GIS Team Development, 2021) to obtain information layers with spatial resolutions of 0.2 to 2.5 m at 0.1 m intervals.

Ground truth data: training fields

We visited the different stands of the forest assisted by an orthomosaic generated from digital photographs (RGB). This allowed us to identify six cover classes: pine, oaks, other broad-leaved trees, herbs, bare soil, and others (mainly shaded areas that can belong to any other class). Training fields were then generated by digitizing polygons for each cover class and distributed in the different stages of development (stand age) of the forest mass: 100 for pine, 40 for oaks, 40 for other broad-leaved trees, 40 for herbaceous, 40 for bare soil and 50 for others. Finally, by the QGIS semi-automated classification tool, we determined the spectral signatures of each class to ensure the separability among them (Figure 2). Although the spectral signatures of oaks and other broad-leaved trees were similar, and they could be grouped into a single class, we decided to evaluate them separately, since oaks are timber species of commercial interest in forest management.

Image classification

We used the Random Forest machine learning algorithm for classification and regression developed by Breiman (2001), a method used in recent years to classify vegetation at the macro-scale level (Mellor et al. 2013). The Random Forest algorithm generates and combines predictive trees, characterized by their capability to select random vectors from the sample, with equal distributions. Each tree is trained with a random sample drawn from the original training data, using the mean of each resampling with replacement (Medina-Merino & Ñique-Chacón, 2017). In the present study, 100 predictive trees were used.

El plan de vuelo autónomo para la toma de imágenes se diseñó en el software eMotion® (senseFly, 2018) con una altura de vuelo de 125 m sobre el suelo y solapamientos de 75 % entre imágenes y 65 % entre líneas de vuelo. El vuelo se realizó entre las 11:00 A. M. y las 12:00 P. M. con cielo despejado y velocidad del viento inferior a 8 m·s⁻¹. Antes del despegue del dron y al aterrizar, se configuró el panel de calibración Sequoia® (AIRINOV) para el registro de las condiciones lumínicas utilizadas en la calibración radiométrica y las correcciones de reflectancia de las bandas de la cámara Sequoia (Franzini et al., 2019). La posición geográfica de las fotografías aéreas se rectificó con el sistema global de navegación por satélite V90 PLUS RTK (Real Time Kinematics).

Procesamiento de las fotografías

Las 2752 imágenes se procesaron con el software Pix4Dmapper® versión 4.1 (Pix4D, S. A., 2017). La desviación media de la geolocalización de las imágenes fue de 15 cm en longitud, 14 cm en latitud y 18 cm en altitud. Inicialmente, se obtuvieron ortomosaicos de las bandas monocromáticas verde, roja, de borde rojo e infrarrojo cercano con una resolución espacial de 0.16 m por píxel en un área boscosa de 100 ha. Posteriormente, cada imagen se remuestreó con la herramienta QGIS (Quantum GIS Team Development, 2021) para obtener capas de información con resoluciones espaciales de 0.2 a 2.5 m a intervalos de 0.1 m.

Datos reales: campos de entrenamiento

En los rodales del bosque se hicieron recorridos asistidos por el ortomosaico generado a partir de fotografías digitales RGB (Red-Green-Blue, por sus siglas en inglés). Esto permitió la identificación de seis clases de cobertura vegetal: pinos, encinos, otras latifoliadas, herbáceas, suelo desnudo y otras (principalmente zonas de sombra que pueden pertenecer a cualquier otra clase). Se generaron campos de entrenamiento mediante la digitalización de polígonos para cada clase de cobertura, distribuidos en los estadios de desarrollo (edad) de la masa forestal: 100 para pinos, 40 para encinos, 40 para otras latifoliadas, 40 para herbáceas, 40 para suelo desnudo y 50 para otros. Por último, mediante la herramienta de clasificación semiautomatizada de QGIS, se determinaron las firmas espectrales de cada clase para asegurar la separabilidad entre ellas (Figura 2). Las firmas espectrales de los encinos y otras latifoliadas fueron muy similares y pudieron agruparse en una sola clase; sin embargo, se evaluaron por separado, ya que los encinos son especies maderables de interés comercial en la región de estudio.

Clasificación de imágenes

El algoritmo de aprendizaje automático de clasificación y regresión Random Forest, desarrollado por Breiman

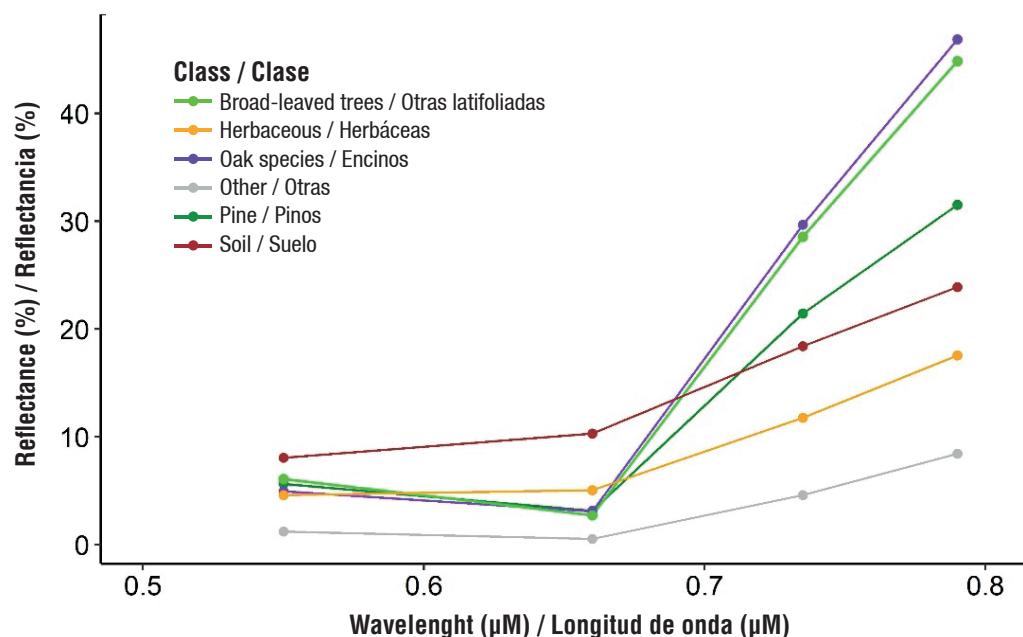


Figure 2. Reflectance of land cover types at different wavelengths. Images obtained by the Sequoia® sensor mounted on a fixed-wing drone at the CO₂ Intensive Monitoring Site in Zacualtipán, Hidalgo.

Figura 2. Reflectancia de los tipos de cobertura terrestre en longitudes de onda. Imágenes obtenidas por el sensor Sequoia® montado en un dron de ala fija en el Sitio de Monitoreo Intensivo de CO₂ en Zacualtipán, Hidalgo.

The algorithm was trained by randomly taking 50 % of 319 training fields identified for classification. The remaining 50 % were used to evaluate the performance of the classifier through a cross-validation of k iterations (k -fold cross-validation). This method divides the total data into k subsets, in such a way that the model uses a different subset each time to validate it $k-1$ (Zhong et al., 2020). In the present study, a $k = 10$ was used. The same classification process was carried out for each orthomosaic, of different spatial resolution, using the randomForest library of the R® open-source software (R Development Core Team, 2021).

For each classification, the accuracy and kappa index were estimated using the confusion matrix (Congalton & Green 2009). The accuracy was obtained by dividing the number of pixels correctly identified for a vegetation class by the total number of pixels that the model predicted for the same class (Abraira, 2001). The kappa index (κ), is the ratio between the proportion of times in which the appraisers agree and the maximum proportion of times in which the appraisers could agree, which in turn are corrected to bring concordance to the probabilities (Abraira, 2001): $\kappa = \frac{P_o - P_e}{1 - P_e}$; where, P_o is the proportion of observed agreements and P_e is the proportion of expected agreements.

Through the confusion matrix, the accuracy of the producer and the user was estimated, with their respective omission and commission errors for each

(2001), se utilizó para la clasificar la vegetación a nivel macroescala (Mellor et al., 2013). El algoritmo genera y combina árboles predictivos, caracterizados por su capacidad para la selección de vectores aleatorios de la muestra con distribuciones iguales. Cada árbol se entrena con una muestra aleatoria extraída de los datos de entrenamiento originales, usando la media de cada remuestreo con reemplazo (Medina-Merino & Nique-Chacón, 2017). En el presente estudio se utilizaron 100 árboles predictivos.

El algoritmo se entrenó tomando aleatoriamente 50 % de los 319 campos de entrenamiento identificados para la clasificación; el restante (50 %) se utilizó para evaluar el rendimiento del clasificador mediante una validación cruzada de k iteraciones (k -fold validación-cruzada). Este método divide los datos totales en k subconjuntos, de forma que el modelo utiliza un subconjunto diferente cada vez para validarlos $k-1$ (Zhong et al., 2020). En el presente estudio se utilizó $k = 10$. El mismo proceso de clasificación se utilizó para cada ortomosaico de resolución espacial diferente, en la librería ‘randomForest’ del software de código abierto R® (R Development Core Team, 2021).

Para cada clasificación se estimó la precisión y el índice kappa utilizando matrices de confusión (Congalton & Green, 2008). La precisión se obtuvo dividiendo el número de píxeles identificados correctamente para una clase de vegetación por el número total de píxeles que el modelo

cover class. The omission error corresponds to the pixels of a cover class that were not classified in this way, whereas the commission error corresponds to the pixels classified as a cover class to which they do not belong (Sánchez-Muñoz, 2016).

The effect of image spatial resolution on land cover classification was evaluated by means of a multiple comparison of means, using spatial resolution as the independent variable and accuracy and k as the dependent variable. This comparison was made using the non-parametric Kruskal-Wallis statistical test, followed by a *post-hoc* Mann-Whitney-Wilcoxon ($P < 0.05$) test, where spatial resolution was considered a grouping factor. Additionally, the graphic behavior of the commission and omission errors for the land cover classes were analyzed. Both for the comparison of means and for the elaboration of graphs, the free software R® was used. Finally, for each image spatial resolution evaluated, surface areas were estimated by cover type in the study area.

Land cover mapping

A land cover map was generated with the images whose spatial resolution showed the highest accuracy and kappa index, as well as the lowest omission and commission errors. For this, the raster layer resulting from the land cover classification process was transformed into a vector format layer and silvicultural and tree measurement information, relevant for forest management was added.

Results

Vegetation classification

Figure 3 shows a clear effect of spatial resolution of the images on the accuracy of land cover classification and the kappa index; both classification quality statistics decreased when the spatial resolution was lower. Based on the interactions defined in the k -fold cross-validation, it was observed that in centimeter-scale resolution images, the land cover classification results are distributed in a smaller range; on the contrary, in images with resolutions greater than 1 meter, the range of distribution of accuracy and the kappa index increased.

The land cover classification accuracy at all spatial resolutions were acceptable because they were higher than current standards ($>80\%$ — Ahmed et al., 2017; Diaz-Varela et al., 2018; Liu et al., 2020; Xu et al., 2018). The highest accuracy was 96% with 0.2 m spatial resolution images and the lowest was 82% with 2.5 m images (Figure 3a). Regarding the kappa index, the highest values of concordance in the

predijo para la misma clase (Abraira, 2001). El índice kappa (k) es la relación entre la proporción de veces en que los calificadores están de acuerdo y la proporción máxima de veces en que los calificadores podrían estar de acuerdo, que a su vez se corrigen para que haya concordancia con las probabilidades (Abraira, 2001): $k = \frac{P_o - P_e}{1 - P_e}$; donde, P_o es la proporción de acuerdos observados y P_e es la proporción de acuerdos esperados.

A través de la matriz de confusión se estimó la precisión del productor y del usuario con sus respectivos errores de omisión y comisión para cada clase de cobertura. El error de omisión corresponde a los píxeles de una clase de cobertura que no fueron clasificados de esta forma, mientras que el error de comisión corresponde a los píxeles clasificados como una clase de cobertura a la que no pertenecen (Sánchez-Muñoz, 2016).

El efecto de la resolución espacial de las imágenes en la clasificación de la cobertura terrestre se evaluó mediante una comparación múltiple de medias, utilizando la resolución espacial como variable independiente y la precisión y k como variables dependientes. Esta comparación se realizó mediante la prueba no paramétrica de Kruskal-Wallis seguida de una comparación *post-hoc* Mann-Whitney-Wilcoxon ($P < 0.05$), donde la resolución espacial se consideró factor de agrupación. Adicionalmente, se analizó el comportamiento gráfico de los errores de comisión y omisión para las clases de cobertura del suelo. Tanto para la comparación de medias, como para la elaboración de gráficos se utilizó el software libre R®. Finalmente, para cada resolución espacial de imagen, se estimaron las superficies por tipo de cobertura en el área de estudio.

Mapeo de la cobertura del suelo

Se generó un mapa de cobertura del suelo con las imágenes cuya resolución espacial presentaba la mayor precisión e índice kappa, así como los menores errores de omisión y comisión. Para ello, la capa raster resultante del proceso de clasificación de la cobertura terrestre se transformó en una capa de formato vectorial y se añadió información silvícola y dasométrica relevante para el manejo forestal.

Resultados

Clasificación de la vegetación

La Figura 3 muestra un claro efecto de la resolución espacial de las imágenes sobre la precisión de la clasificación de la cobertura terrestre y el índice kappa; ambos estadísticos de calidad de la clasificación disminuyeron cuando la resolución espacial fue submétrica. A partir de las interacciones definidas en la validación cruzada k -fold, se observó que, en las

defined vegetation/cover classes were obtained with images of spatial resolution from 0.2 to 0.7 m per pixel (Figure 3b). The means comparison analysis showed significant differences ($P < 0.001$) in accuracy and kappa index (Figure 3), which indicates that the spatial resolution of the multispectral images influences the classification of vegetation in forests under forest management.

According to Figure 4, the effect of image spatial resolution on errors of omission and commission varied over the interval evaluated. For images with a spatial resolution of 0.2 to 1.2 m, omission and commission errors in classification were smaller and constant; in contrast, for images with a spatial resolution of 1.3 to 2.5 m, errors were larger and more variable.

imágenes de resolución centimétrica, los resultados de clasificación de la cobertura terrestre se distribuyen en un rango menor; por el contrario, en las imágenes con resoluciones mayores de 1 m, el rango de distribución de la precisión y el índice kappa aumentó.

La precisión de la clasificación de la cobertura terrestre con todas las resoluciones espaciales fue aceptable, ya que estas fueron superiores a los estándares actuales (>80 % – Ahmed et al., 2017; Díaz-Varela et al., 2018; Liu et al., 2020; Xu et al., 2018). La mayor precisión fue de 96 % con imágenes de 0.2 m de resolución espacial y la más baja fue de 82 % con imágenes de 2.5 m (Figura 3a). En cuanto al índice kappa, los valores más altos de concordancia en las clases de vegetación/coberturas definidas se obtuvieron con imágenes de resolución

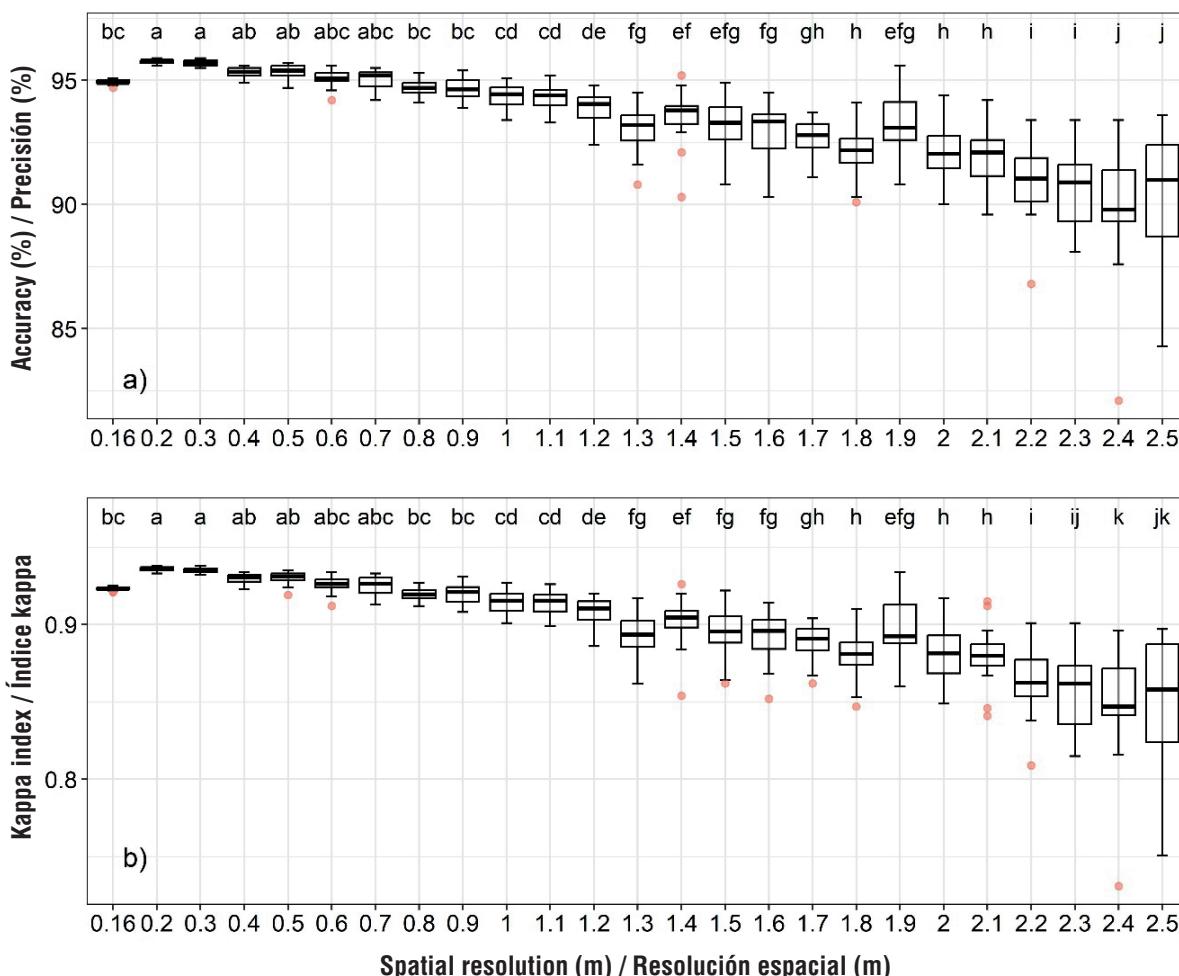


Figure 3. Effect of drone-taken multispectral image spatial resolution on land cover classification: accuracy and kappa index. Different letters indicate significant statistical differences according to the nonparametric Mann-Whitney-Wilcoxon statistical test ($P < 0.05$) in each graph. Red dots indicate outliers.

Figura 3. Efecto de la resolución espacial de imágenes multiespectrales tomadas con drones en la clasificación de la cobertura terrestre: precisión e índice kappa. En cada gráfica, letras diferentes indican diferencias estadísticas significativas de acuerdo con la prueba estadística no paramétrica de Mann-Whitney-Wilcoxon ($P < 0.05$). Los puntos rojos indican valores atípicos.

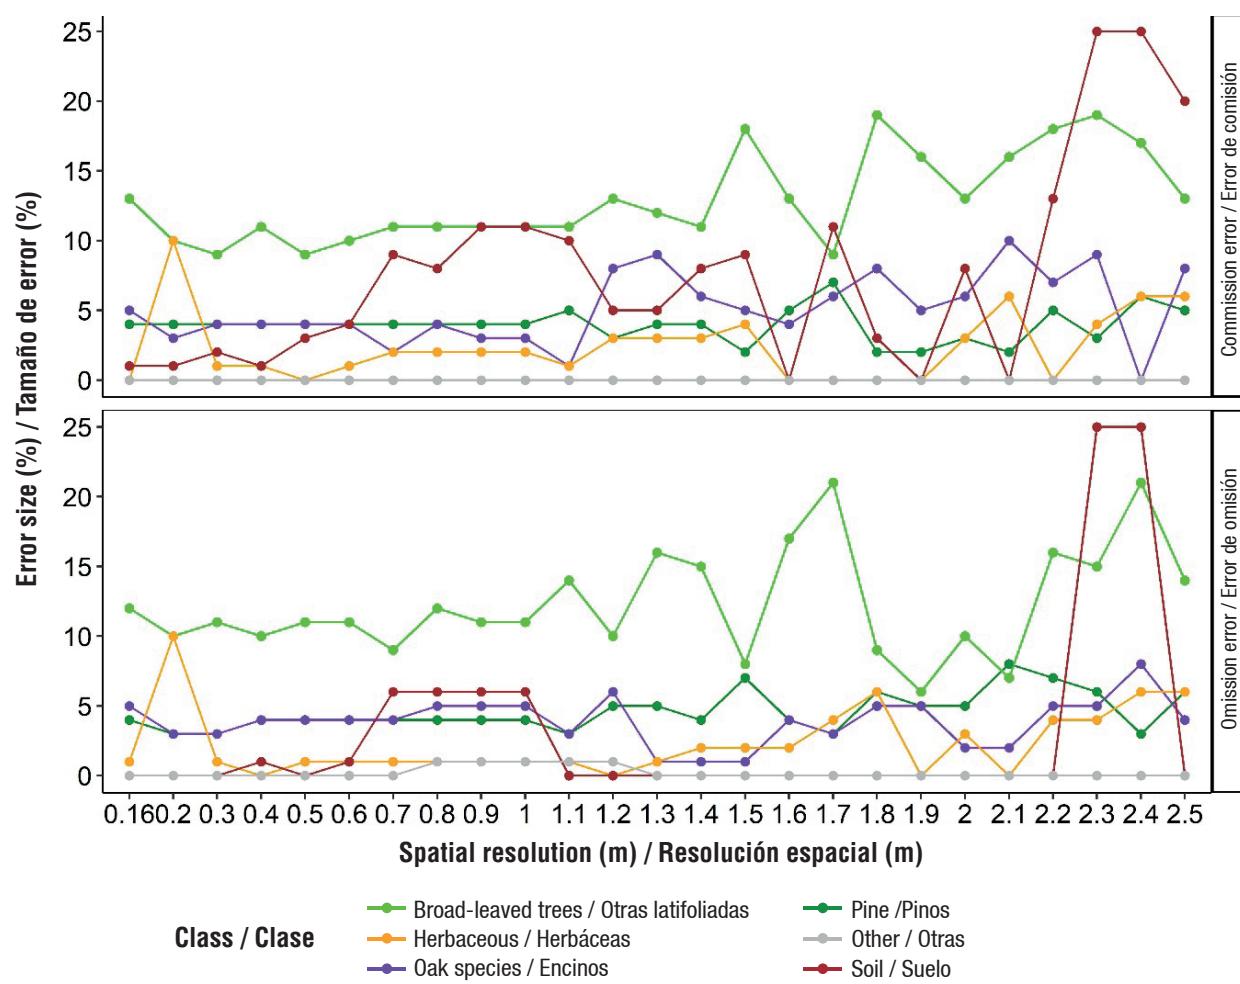


Figure 4. Distribution of omission and commission errors in land cover classification using multispectral images with different spatial resolution, using a fixed-wing drone

Figura 4. Distribución de errores de omisión y comisión en la clasificación de la cobertura terrestre mediante imágenes multiespectrales con diferente resolución espacial, obtenidas con un dron de ala fija.

In general, the accuracy in the classification of vegetation/land cover classes was high, ranging from 77 to 100 %. The lowest values were for oaks and other broad-leaved trees species. The best classified classes were 'bare soil' and 'herbaceous', with the lowest errors of omission and commission (<1 %; Figure 4).

The greatest confusion occurred between the oaks and other broad-leaved cover classes. Some areas were classified as broad-leaved trees, but they belong to oaks. These errors are common within detailed vegetation classifications since some oak's foliage is very similar to that of other broad-leaved tree species.

Land cover classes

Figure 5 shows the fraction of total area estimated by the Random Forest algorithm for each vegetation cover class, in relation to the spatial resolution of the image. Apparently, there seems to be no effect of

espacial de 0.2 a 0.7 m por píxel (Figura 3b). El análisis de comparación de medias mostró diferencias significativas ($P < 0.001$) en la precisión e índice kappa (Figura 3), lo que indica que la resolución espacial de las imágenes multiespectrales influye en la clasificación de la vegetación de los bosques bajo manejo forestal.

De acuerdo con la Figura 4, el efecto de la resolución espacial de la imagen en los errores de omisión y comisión varió a lo largo del intervalo evaluado. Para las imágenes con una resolución espacial de 0.2 a 1.2 m, los errores de omisión y comisión en la clasificación fueron menores y constantes; por el contrario, para las imágenes con una resolución espacial de 1.3 a 2.5 m, los errores fueron mayores y más variables.

En general, la precisión en la clasificación de las clases de vegetación/cobertura del suelo fue alta, entre 77 % y 100 %. Los valores más bajos correspondieron a los encinos y otras especies latifoliadas. Las clases mejor

spatial resolution on the estimated area of each land cover class. Consistently, the greatest estimated land cover was pine, followed by oaks and other broad-leaved trees. However, the pine cover class presented a lower fractional value when images spatial resolutions were centimeters, ranging from 77 % to 85 %. Oaks covered between 1.9 % and 4.0 % of the total analyzed surface, while other broad-leaved trees represented between 7 % to 12 %. Low presence cover classes, such as the herbaceous stratum and bare soil, represented a fraction from 0.7 % to 3 % and from 0.1 to 1 % respectively; these land covers were located mainly in extraction roads and fire breaks. An inconvenience of the high-resolution images taken by drones is the clear presence of shadows. In our analysis, they represented between 3.6 % and 6.6 % of the surface, having their highest values in images with resolution greater than 1.5 m.

The high-resolution images obtained by the Sequoia® sensor allow to detect different and fragmented conditions within the stands, and among stands of different ages. Figure 6 shows the best achieved

clasificadas fueron suelo desnudo y herbáceas con errores de omisión y comisión más bajos (<1 %; Figura 4).

La confusión más alta se produjo entre las clasificaciones de cobertura de encinos y otras latifoliadas, ya que algunas de las zonas clasificadas como otras latifoliadas pertenecen a encinos. Estos errores son habituales en las clasificaciones detalladas de la vegetación, ya que el follaje de algunos encinos es muy similar al de otras especies de latifoliadas.

Clases de cobertura del suelo

La Figura 5 muestra la fracción de superficie total estimada por el algoritmo Random Forest para cada clase de cobertura vegetal, en función de la resolución espacial de la imagen. Aparentemente, la resolución espacial no tiene efecto sobre la superficie estimada de cada clase de cobertura terrestre. De forma consistente, la mayor cobertura del suelo estimada fue la de pinos, seguida de encinos y otras latifoliadas; sin embargo, la clase de cobertura pinos presentó un valor fraccionario inferior cuando la resolución

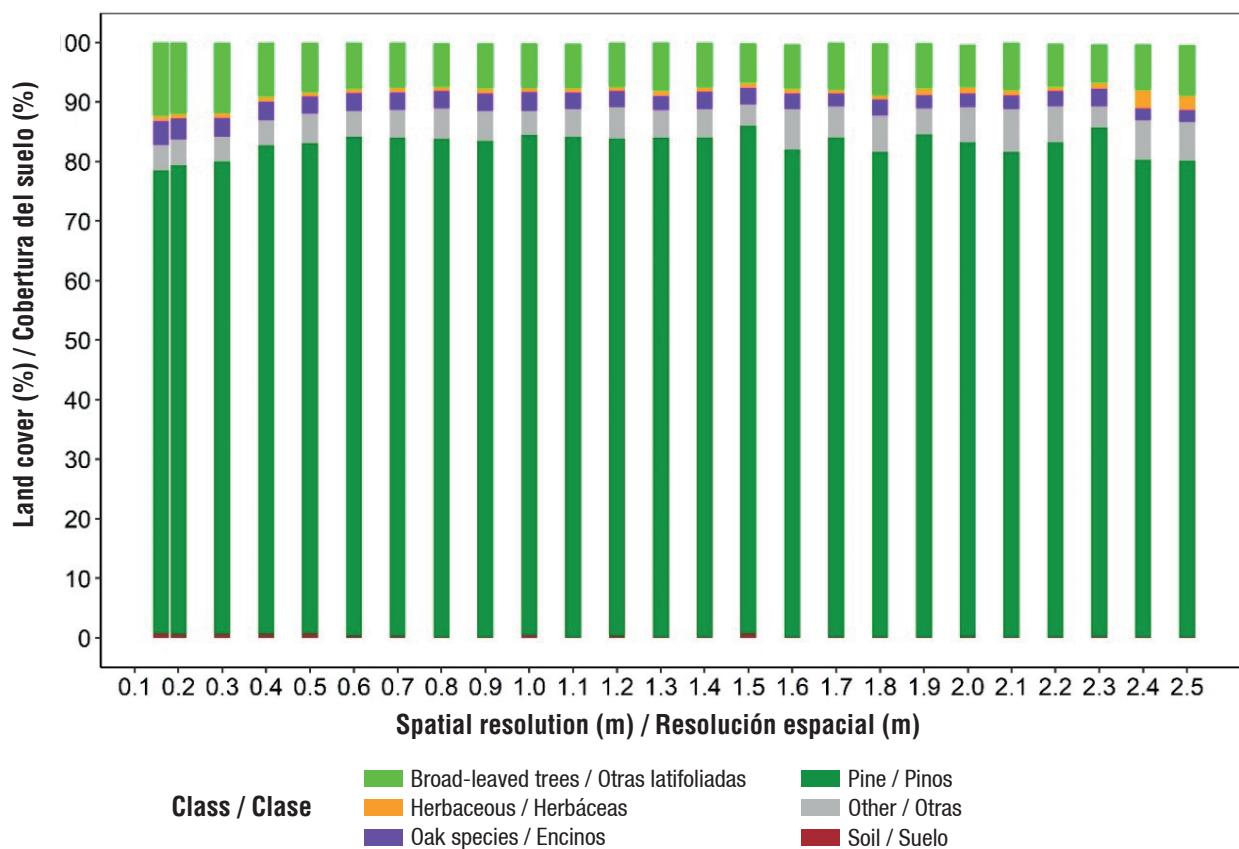


Figure 5. Fraction of total area (%) by land cover class derived from multispectral images of different spatial resolutions. Images obtained by Sequoia® sensor mounted on a fixed-wing drone.

Figura 5. Fracción del área total (%) por clase de cobertura del suelo terrestre derivada de imágenes multiespectrales de diferentes resoluciones espaciales. Imágenes obtenidas por el sensor Sequoia® montado en un dron de ala fija.

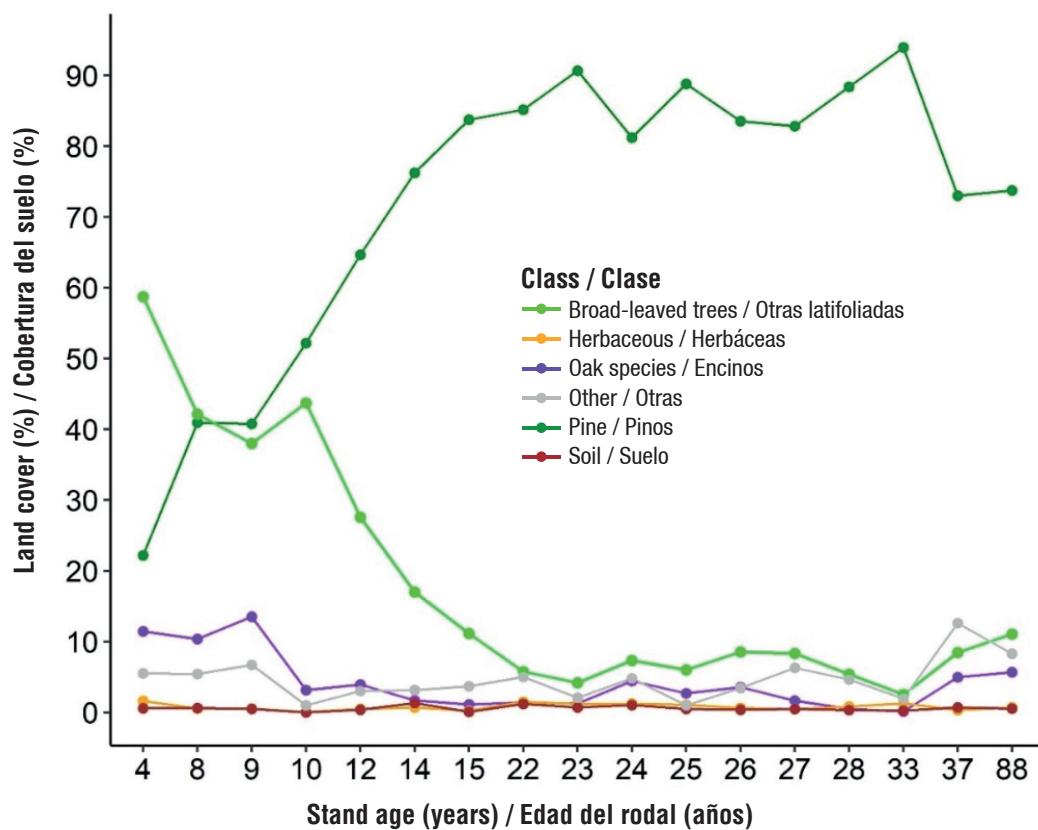


Figure 6. Fractional land cover classes variation as stands mature under a timber management scheme. Drone-taken multispectral images of 0.2 m spatial resolution were used to get land cover estimates.

Figura 6. Variación porcentual de las clases de cobertura del suelo a medida que los rodales maduran bajo un esquema de gestión maderera. Se utilizaron imágenes multiespectrales tomadas con drones de 0.2 m de resolución espacial para obtener estimaciones de la cobertura del suelo.

land cover classification (0.2 m spatial resolution per pixel) in terms of accuracy, kappa index and lowest omission and commission errors. The conditions of areas covered by pine, oak and other hardwoods stand out as depending on the stand age. In young stands, land cover is dominated by oak and other broadleaf species with a high population of pines; however, being young trees, they cover only a small area of the stand. The areas covered by pine trees increase as the stands mature, covering between 85 and 90 % of the stand's area when the trees are more than 20 years old. In contrast, the cover of broadleaf species decreases as the stand matures, mainly due to the application of silvicultural treatments.

Traditional cartography represents stand conditions as a single vegetation class, while high-resolution images differentiate the vegetation composition into different cover types (Figure 7). The images fine spatial resolution played an important role in detecting herbaceous and bare soil covers, as those were not detected when images with a spatial resolution of 2.5 m

espacial de las imágenes fue centimétrica, oscilando entre 77 % y 85 %. Los encinos cubrieron entre 1.9 % y 4.0 % de la superficie total analizada, mientras que otras latifoliadas representaron entre 7 % y 12 %. Las clases de cobertura de baja presencia, como el estrato herbáceo y el suelo desnudo, cubrieron una fracción del 0.7 al 3 % y del 0.1 al 1 %, respectivamente; estas coberturas se localizaron principalmente en caminos de extracción y brechas cortafuego. Un inconveniente de las imágenes de alta resolución tomadas por drones es la clara presencia de sombras; en el análisis, estas representaron entre 3.6 % y 6.6 % de la superficie, teniendo sus valores más altos en las imágenes con resolución mayor de 1.5 m.

Las imágenes de alta resolución espacial obtenidas por el sensor Sequoia® detectaron condiciones diferentes y fragmentadas dentro de los rodales y entre rodales de edades distintas. La Figura 6 muestra la clasificación de la cobertura terrestre mejor lograda (0.2 m de resolución espacial por píxel) en términos de precisión, índice kappa y errores más bajos de omisión y comisión. Las

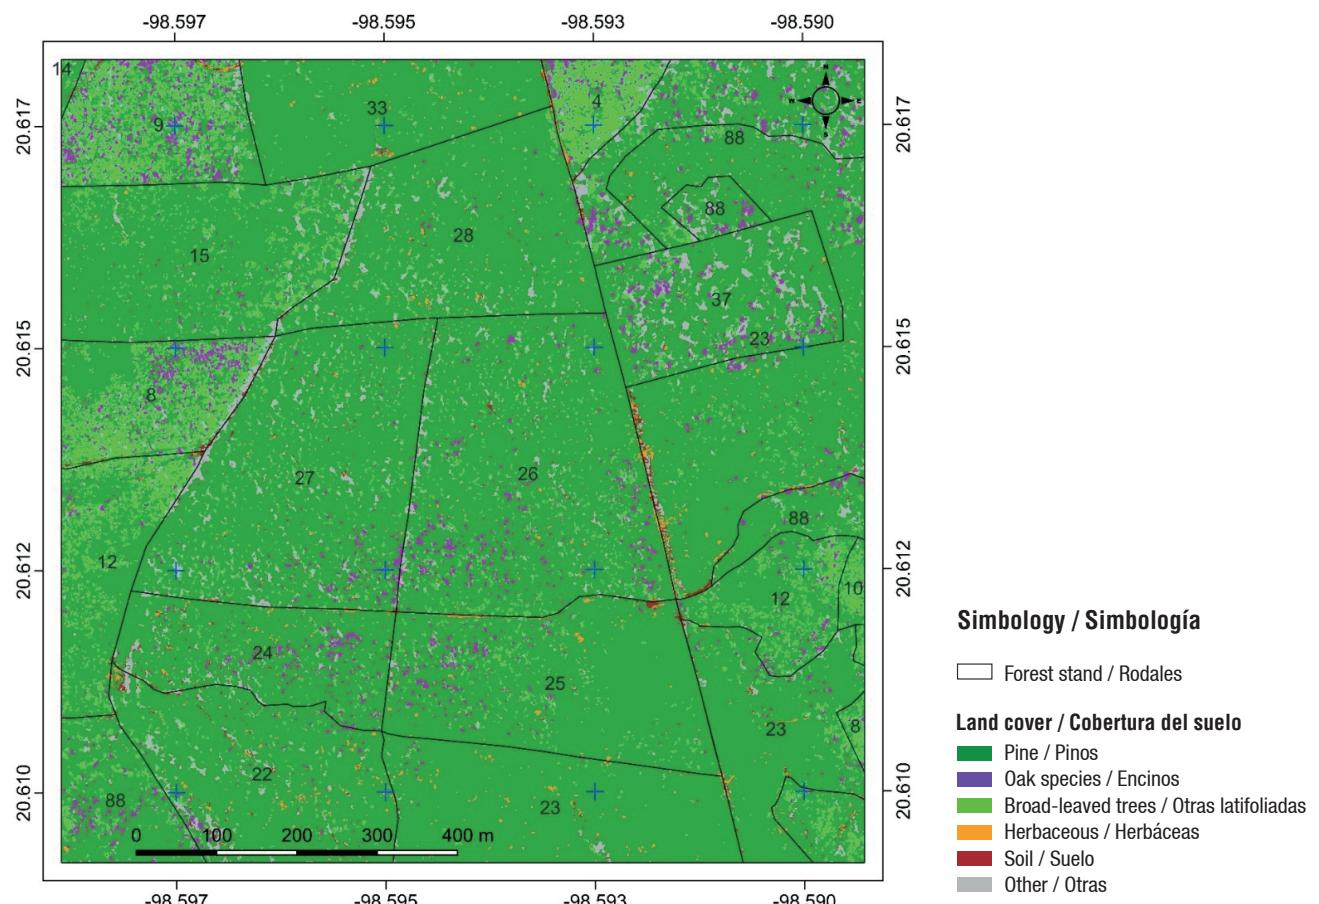


Figure 7. Land cover/vegetation map of a temperate forest under timber forest management (study area) from multispectral images of 0.2 m spatial resolution obtained with a fixed-wing drone. The numerical label represents the age of the stand in years.

Figura 7. Mapa de cobertura del suelo/vegetación de un bosque templado bajo manejo forestal (área de estudio), a partir de imágenes multiespectrales de 0.2 m de resolución espacial obtenidas con un dron de ala fija. La etiqueta numérica representa la edad del rodal en años.

per pixel were used. Furthermore, in young stands the presence of shades (other classes) was lower than in areas with tall trees.

Discussion

Vegetation classification

The fixed-wing drone equipped with the Sequoia® multispectral sensor made it possible to obtain detailed information on forest vegetation. Through the combined use of high spatial resolution images and the Random Forest supervised classification algorithm we were able to identify four cover vegetation classes, bare soil areas and shade areas. The land cover prediction was the expected in a managed forest with a homogenous tree stage in the stands, being able to capture different vegetation types due to the stage of the stand (age). Although the studied

condiciones de las zonas cubiertas por pinos, encinos y otras latifoliadas destacan en función de la edad del rodal. En los rodales jóvenes, la cobertura vegetal está dominada por especies de encinos y otras latifoliadas con una población elevada de pinos; sin embargo, al ser árboles jóvenes, cubren solo una superficie pequeña del rodal. Las zonas cubiertas por pinos aumentan a medida que los rodales maduran, cubriendo entre 85 y 90 % de la superficie del rodal cuando los árboles tienen más de 20 años. Por el contrario, la cobertura de especies latifoliadas disminuye a medida que la masa madura, debido principalmente a la aplicación de tratamientos silvícolas.

La cartografía tradicional representa las condiciones de los rodales como una sola clase de vegetación, mientras que las imágenes de alta resolución diferencian la composición de la vegetación en varios tipos de cobertura (Figura 7). La fina resolución espacial de

area was relatively small (100 ha) compared to the scope of satellite images, the use of a drone allowed us obtaining spatial resolutions at the centimeter level, which provided enough detail to properly zone the forest, this information is basic for forest management planning and operation. In Mexico, 92.4 % of the forest properties that applied for timber harvesting to the government in 2019, have less than 300 ha (Torres-Rojo et al., 2022), which emphasizes the practical potential of using drone-taken high spatial resolution images.

The results obtained clearly show the advantage of using high spatial resolution images (<2.5 m) to map forested areas in contrast to the use of medium spatial resolution images (10 a 30 m). The latter ones are inefficient to detect cover classes with little presence within the forests, such as bare soil and herbaceous plants, generalizing the results by assigning more area to forest class while omitting other covers present.

Our forest cover classification results agree with those reported by Ahmed et al. (2017), who used the Random Forest algorithm and similar images to the ones employed in the present study to classify vegetation in mixed areas (forest and agriculture). These authors obtained an accuracy of 85 % and 93 % for shrubby and herbaceous vegetation, respectively, and 100 % for forests, bare soil, and urban areas, whereas the overall accuracy was 95 %. In another study, Furukawa et al. (2021) used the Support-Vector Machine (SVM) algorithm to classify vegetation, bare soil, and dead matter on Hokkaido, Japan's island, utilizing multispectral and RGB images obtained with an unmanned aerial vehicle. They compared the use of images taken under cloudy conditions and clear skies over a period of four months (April-July), reaching an accuracy of 94.44 % for RGB images under cloudy conditions in the month of April, while the multispectral images reached accuracies of 97.7, 95.5, 96.6 and 98.8 % for each season of the year studied.

On the other hand, Zhao et al. (2020) classified trees, maize, peanuts, and other crops using RGB digital images, with reported global accuracies of 78.19, 73.26 and 76.53 % with Random Forest, SVM, and maximum likelihood algorithms, respectively. They also reported kappa index of 0.72, 0.71 and 0.72, which are lower than the kappa values achieved in this study. Fraser and Congalton (2021) also used drone-taken multispectral images to examine healthy and stressed pine and broad-leaved trees. In their study they established five types of 'forest health' and used RF and SVM algorithms to map the tree conditions; they obtained a general accuracy of 65.4 %, which improved to 71.19 % when they reduced the health classes to only 'healthy', 'stressed' and 'degraded trees'. Clearly, these values are lower than those determined in this study, although their work was more detailed and

las imágenes desempeñó un papel importante en la detección de coberturas herbáceas y de suelo desnudo, ya que estas no se detectaron cuando se utilizaron imágenes con una resolución espacial de 2.5 m por píxel; además, en los rodales jóvenes, la presencia de sombra (otras clases) fue menor que en las zonas con árboles altos.

Discusión

Clasificación de vegetación

El dron de ala fija equipado con el sensor multiespectral Sequoia® generó información detallada sobre la vegetación forestal. Mediante el uso combinado de imágenes de alta resolución espacial y el algoritmo de clasificación supervisada Random Forest se identificaron cuatro clases de vegetación, áreas de suelo desnudo y de sombras. La predicción de la cobertura del suelo estuvo acorde con lo esperado en un bosque gestionado con arbolado de edad uniforme dentro de los rodales y se captaron las diferencias de vegetación debidas a la etapa de desarrollo del rodal (edad). Aunque el área estudiada fue relativamente pequeña (100 ha) en comparación con el alcance de las imágenes de satélite, las resoluciones espaciales a nivel centimétrico obtenidas con el dron proporcionaron detalle suficiente para la zonificación adecuada del bosque, información base para la planificación y operación del manejo forestal. En México, 92.4 % de los predios forestales que solicitaron autorización al gobierno para aprovechamiento forestal maderable en 2019 tuvieron superficie menor de 300 ha (Torres-Rojo et al., 2022), lo que enfatiza el potencial práctico del uso de imágenes de alta resolución espacial tomadas con dron.

Los resultados muestran claramente la ventaja del uso de imágenes de alta resolución espacial (<2.5 m) para cartografiar zonas boscosas en contraste con el uso de imágenes de resolución espacial media (10 a 30 m). Estas últimas son ineficaces para la detección de clases de cobertura con poca presencia, como suelo desnudo y plantas herbáceas, generalizando los resultados al asignar más superficie a la clase bosque mientras se omiten otras coberturas presentes.

La precisión de la clasificación de la cobertura forestal coincide con la señalada por Ahmed et al. (2017), quienes también emplearon el algoritmo Random Forest e imágenes similares a las del presente estudio para clasificar la vegetación en zonas mixtas (bosque y agricultura). Estos autores obtuvieron una precisión del 85 % y 93 % para la vegetación arbustiva y herbácea, respectivamente, y del 100 % para los bosques, el suelo desnudo y las zonas urbanas, mientras que la precisión global fue de 95 %. En otro estudio, Furukawa et al. (2021) utilizaron el algoritmo Support-Vector Machine (SVM) para clasificar la vegetación, el suelo

with a different purpose. Regarding the same topic of cover classification, Díaz-Varela et al. (2018) classified land cover in the Sierra del Gistral, north of Galicia, Spain using convolutional neural networks (CNN). The authors reported accuracies of 88.57, 87.30 and 87.50 % for shrub, herbaceous, swampy classes, respectively. The foregoing suggests that machine learning (RF, SVM) and deep learning (CNN) classification algorithms are capable of classifying vegetation in detail, using images derived from the photogrammetric process with drones as input.

The type of vegetation analyzed can explain accuracy differences between formerly cited studies and the present study. The spectral responses in areas with contrasting land cover such as forest, agriculture, water bodies and urban areas tend to be more clearly differentiated. Therefore, a more precise vegetation classification can be achieved (Chuvieco, 2020). Opposite to this, when the vegetation classification is more detailed and the aim is to map tree species or highly dense canopies, the classification may present difficulties and the accuracy may decrease (Baena et al., 2017). Besides, the type of information used needs to be consider classify vegetation, since multispectral images provide data about the reflectance of vegetation, while digital RGB images only produce true color information.

Image Spatial Resolution

The level of detail obtained by drone-taken images is not achieved with satellite images such as Landsat or Sentinel (Aliaga et al., 2016); therefore, an advantageous effect can be argued for drone images on land cover classification accuracy. However, how high an image spatial resolution should be? based on the comparison of means procedure carried out, the results indicate that images with a spatial resolution from 0.2 to 0.7 m provide high accuracy and kappa index without significant differences. Therefore, to optimize the classification time, images with a spatial resolution of 0.7 m per pixel can be used without losing accuracy and quality in land cover classification analysis.

Against to common believes, the use of extremely high image spatial resolutions can lead to problems when classifying vegetation, since it can detect information in small spaces such as those between the foliage of trees, and hence cause uncertainty in the classification process. In addition, furthermore, the higher the resolution, the greater the amount of data to process, and therefore, handling requires more analysis time and computers with high storage and processing capacity, which are typically more expensive than common ones. In this regard, Liu et al. (2020) analyzed the importance of spatial resolution for vegetation classification in highly fragmented areas of Xingbin district, Guangxi, China, and concluded that greater

desnudo y la materia muerta en la isla de Hokkaido, Japón, utilizando imágenes multiespectrales y RGB obtenidas con un vehículo aéreo no tripulado. Dichos autores compararon el uso de imágenes tomadas en condiciones de nubosidad y de cielo despejado durante cuatro meses (abril-julio) y lograron una precisión del 94.44 % para las imágenes RGB en condiciones de nubosidad en el mes de abril, mientras que con las imágenes multiespectrales obtuvieron 97.7, 95.5, 96.6 y 98.8 % para cada mes del periodo de estudio.

Por otra parte, Zhao et al. (2020) clasificaron árboles, maíz, cacahuate y otros cultivos utilizando imágenes digitales RGB y lograron precisiones globales de 78.19, 73.26 y 76.53 % con los algoritmos Random Forest, SVM y máxima verosimilitud, respectivamente; asimismo, informaron índices kappa de 0.72, 0.71 y 0.72 que son inferiores a los del presente estudio. Fraser y Congalton (2021) también utilizaron imágenes multiespectrales tomadas con drones para examinar pinos y árboles caducifolios saludables y estresados, establecieron cinco tipos de ‘salud forestal’ y utilizaron los algoritmos Random Forest y SVM para el mapeo de las condiciones de los árboles. Dichos autores obtuvieron una precisión general del 65.4 %, que mejoró al 71.19 % cuando redujeron las clases de salud a solo ‘árboles sanos’, ‘estresados’ y ‘degradados’. Evidentemente, estos valores son inferiores a los determinados en el presente trabajo, aunque su estudio fue más detallado y con otra finalidad. En el mismo tópico de clasificación de vegetación, Díaz-Varela et al. (2018) clasificaron la cobertura del suelo en la Sierra del Gistral, al norte de Galicia, España, utilizando redes neuronales convolucionales (CNN). Los autores reportaron precisiones de 88.57, 87.30 y 87.50 % para las clases arbustiva, herbácea y pantanosa, respectivamente. Lo anterior sugiere que los algoritmos de clasificación de aprendizaje automático (Random Forest y SVM) y profundo (CNN) son capaces de clasificar la vegetación en detalle, utilizando como entrada imágenes derivadas del proceso fotogramétrico con drones.

El tipo de vegetación analizada puede explicar las diferencias de precisión entre los estudios citados y el presente trabajo. Las respuestas espetrales en zonas con coberturas genéricas de suelo como bosques, agricultura, cuerpos de agua y zonas urbanas tienden a diferenciarse con mayor claridad; por lo tanto, se puede conseguir una clasificación más precisa de la vegetación (Chuvieco, 2020). En contraste, cuando la clasificación de la vegetación es más detallada y se pretende cartografiar especies arbóreas o doseles muy densos es probable que la clasificación se dificulte y la precisión disminuya (Baena et al., 2017). Además, el tipo de información utilizada también es un factor para considerar en la clasificación de vegetación, ya que las imágenes multiespectrales proporcionan datos sobre la reflectancia de la vegetación, mientras que las imágenes digitales RGB solo producen información de color verdadero.

accuracy is not always achieved at the original image resolution (0.025 m), but at intermediate spatial resolutions (0.5 m).

Implications of forest cover classification in forest management

Drone-taken high spatial resolution images can result advantageous as a mean to classify the different vegetation conditions present in a forest property, mainly when timber production is an important management goal, i.e., this technology could be used to detect temporal changes in vegetation (van Lersel et al., 2018). For example, our results showed that stands older than 20 years have a more homogeneous canopy cover, dominated by pine species, which is relevant to know for planning and timber production projection. This result is logic for a forest with intensive silvicultural intervention, whose objective is to convert the irregular forest structure to regular at the end of the rotation (Hernández-Díaz et al., 2016). Small gaps in the canopy continuum were also detected in the stands, some covered by herbaceous vegetation, while others produced insufficient reflectance information to generate a classification (shades). These gaps can be explained by thinning, a silvicultural activity that promotes the diameter growth of residual trees or due to natural phenomena such as the death of trees due to competition or pests and diseases (Pérez-López et al., 2020; Ramírez-Santiago et al., 2019).

In young stands (<15 years old), the vegetation classification showed a high cover of oaks and other broadleaves, which agrees with the normal ecological succession process of managed temperate forests. The first woody species to grow after a regeneration cut are the broadleaf species such as *Quercus* sp., *Prunus*, *Alnus*, *Clethra*, *Cleyera*, *Cornus*, *Turpinia*, and *Vaccinium*. In the seedling and sapling stages, the canopies of broadleaf trees tend to be larger than the canopies of the genus *Pinus* tree, and therefore they cover a larger area. Moreover, the regeneration of these broad-leaved genera is by shoots that emerge from the stumps, which grow faster during the first years after the regeneration cut (Alanís-Rodríguez et al., 2011). However, silvicultural activities such as clearing and thinning reduce the presence of broadleaves and promote the establishment and growth of pines, this behavior (Figure 6).

Conclusions

Images taken with drones are viable for planning and monitoring timber management on small properties of temperate forests (<500 ha). Multispectral images from a fixed-wing drone allowed for the classification of vegetation cover with adequate accuracy, delineating the spatial distribution of pines, oaks, and other broadleaf

Resolución espacial de las imágenes

El nivel de detalle obtenido en las imágenes tomadas con drones no se alcanza con imágenes de satélite como Landsat o Sentinel (Aliaga et al., 2016); por lo tanto, se puede argumentar un efecto ventajoso de las imágenes con drones sobre la precisión de la clasificación de la cobertura terrestre; sin embargo, ¿qué tan alta debe ser la resolución espacial de una imagen? Con base en el procedimiento de comparación de medias, las imágenes con una resolución espacial de 0.2 a 0.7 m proporcionan una alta precisión e índice kappa sin diferencias significativas. Por lo tanto, para optimizar el tiempo de clasificación, se pueden utilizar imágenes con una resolución espacial de 0.7 m por píxel sin perder precisión y calidad en el análisis de clasificación de la cobertura terrestre.

Contrariamente a la creencia común, el uso de resoluciones espaciales de imagen extremadamente altas puede generar problemas, ya que puede detectar información en espacios pequeños, como los que hay entre el follaje de los árboles, y, por tanto, provocar incertidumbre en el proceso de clasificación de la vegetación. Además, cuanto mayor es la resolución, mayor es la cantidad de datos por procesar y, por tanto, el manejo requiere más tiempo de análisis y computadoras con gran capacidad de almacenamiento y procesamiento que normalmente son más caras que las comunes. En este sentido, Liu et al. (2020) analizaron la importancia de la resolución espacial para la clasificación de la vegetación en zonas muy fragmentadas del distrito de Xingbin, Guangxi, China, y concluyeron que la mayor precisión no siempre se da en la resolución original de las imágenes (0.025 m), sino en resoluciones espaciales intermedias (0.5 m).

Implicaciones de la clasificación de la cobertura forestal en el manejo forestal

Las imágenes con alta resolución espacial tomadas con drones pueden resultar ventajosas para la clasificación de las condiciones de vegetación presentes en una propiedad forestal, sobre todo cuando la producción de madera es el objetivo principal; es decir, esta tecnología podría ser útil para la detección de cambios temporales en la vegetación (van Lersel et al., 2018). Por ejemplo, los resultados del presente estudio mostraron que los rodales de más de 20 años tienen una cobertura de copas más homogénea, dominada por especies de pino, lo cual es relevante conocer para la planificación y proyección de la producción maderera. Este resultado es lógico para un bosque con intervención silvícola intensiva, cuyo objetivo es convertir la estructura irregular en regular al final del turno (Hernández-Díaz et al., 2016). También se detectaron pequeños claros en el continuo del dosel, algunos cubiertos por vegetación herbácea, mientras que otros produjeron

trees accurately. Additionally, this technology detected changes in vegetation due to stand development stages, making it an effective tool for studying forest dynamics under management. The vegetation cover of managed temperate forests can be satisfactorily classified using images with spatial resolutions of 0.20 to 0.70 m per pixel. Within this range, higher resolutions (0.20 m) do not necessarily increase accuracy but do increase the volume of data to be processed; in contrast, lower spatial resolution (0.7 m) reduces acquisition time and cost, as well as processing time.

Acknowledgments

The authors would like to thank the Consejo Nacional de Humanidades, Ciencia y Tecnología (CONAHCYT) for their support in conducting this research and for partial funding through the project “El papel de los bosques bajo gestión forestal comunitaria en la mitigación del cambio climático” (PN 2017-6231). The study was also partially funded by the Sustainable Landscapes Program of the United States Agency for International Development (USAID), through the International Programs Office of the United States Department of Agriculture (USDA), project “Reducing Greenhouse Gas Emissions and Improving Forest Management in Mexico” (agreement number 12-IJ-11242306-033).

End of English version

References / Referencias

- Abraira, V. (2001). El índice kappa. SEMERGEN, 27(5), 247 – 249. [https://doi.org/10.1016/S1138-3593\(01\)73955-X](https://doi.org/10.1016/S1138-3593(01)73955-X)
- Ahmed, O. S., Shemrock, A., Chabot, D., Dillon, C., Williams, G., Wasson, R., & Franklin, S. E. (2017). Hierarchical land cover and vegetation classification using multispectral data acquired from an unmanned aerial vehicle. *International Journal of Remote Sensing*, 38(8-10), 2037 – 2052. <https://doi.org/10.1080/01431161.2017.1294781>
- Alanís-Rodríguez, E., Jiménez-Pérez, J., Valdecantos-Dema, A., Pando-Moreno, M., Aguirre-Calderón, O., & Treviño-Garza, E. J. (2011). Caracterización de regeneración leñosa post-incendio de un ecosistema templado del parque ecológico Chipinque, México. *Revista Chapingo Serie Ciencias Forestales y del Ambiente*, 17(1), 31 – 39. <https://doi.org/10.5154/r.rchscfa.2010.05.032>
- Aliaga, V. S., Ferrelli, F., Bohn, V. Y., & Piccolo, M. C. (2016). Utilización de imágenes satelitales para comprender la dinámica lagunar en la Región Pampeana. *Revista de Teledetección*, 46, 1 – 14. <https://doi.org/10.4995/raet.2016.5196>
- Al-Kaff, A., Madridano, Á., Campos, S., García, F., Martín, D., & de la Escalera, A. (2020). Emergency support unmanned aerial vehicle for forest fire surveillance. *Electronics*, 9(260), 1 – 14. <https://doi.org/10.3390/electronics9020260>
- Baena, S., Moat, J., Whaley, O., & Boyd, D. S. (2017). Identifying species from the air: UAVs and the very high resolution challenge for

información de reflectancia insuficiente para generar una clasificación (sombra). Estos pueden explicarse por el aclareo, una actividad silvícola que promueve el crecimiento diamétrico de los árboles residuales o bien por fenómenos naturales como la muerte de árboles por competencia o plagas y enfermedades (Pérez-López et al., 2020; Ramírez-Santiago et al., 2019).

En los rodales jóvenes (<15 años), la clasificación de la vegetación mostró una cobertura elevada de encinos y otras especies de latifoliadas, lo que concuerda con el proceso normal de sucesión ecológica de los bosques templados gestionados. Las primeras especies leñosas que crecen tras una corta de regeneración son las latifoliadas como *Quercus* sp., *Prunus*, *Alnus*, *Clethra*, *Cleyera*, *Cornus*, *Turpinia* y *Vaccinium*. En las etapas de plántula y brizal, las copas de las latifoliadas tienden a ser más grandes que las copas de los árboles *Pinus* y, por lo tanto, cubren un área mayor. Además, la regeneración de estos géneros es mediante brotes que emergen de los tocónes, por lo que crecen más rápido durante los primeros años posteriores a la corta de regeneración (Alanís-Rodríguez et al., 2011). No obstante, las actividades silvícolas como limpias y aclareos reducen la presencia de latifoliadas y promueven el establecimiento y crecimiento de pinos (Figura 6).

Conclusiones

Las imágenes tomadas con drones son viables para la planificación y seguimiento de la gestión maderera en propiedades pequeñas de bosques templados (<500 ha). Las imágenes multiespectrales de un dron de ala fija permitieron la clasificación de cobertura vegetal con la precisión adecuada, señalando la distribución espacial de pinos, encinos y otros árboles latifoliados con exactitud. Además, esta tecnología detectó cambios en la vegetación a causa de las etapas de desarrollo de los rodales, por lo que puede ser una herramienta eficaz para estudiar la dinámica de los bosques bajo manejo. La cobertura vegetal de los bosques templados bajo manejo puede clasificarse satisfactoriamente utilizando imágenes con resolución espacial de 0.20 a 0.70 m por píxel. En dicho rango, las resoluciones más altas (0.20 m) no aumentan necesariamente la precisión, pero sí el volumen de datos por procesar; en contraste, una menor resolución espacial (0.7 m) reduce el tiempo y costo de adquisición, así como el tiempo de procesamiento.

Agradecimientos

Los autores agradecen al Consejo Nacional de Humanidades, Ciencia y Tecnología (CONAHCYT) por el apoyo para hacer esta investigación y por el financiamiento parcial a través del proyecto “El papel de los bosques bajo gestión forestal comunitaria en la mitigación del cambio climático” (PN 2017-6231). El

- plant conservation. *PLoS ONE*, 12(11), e0188714. <https://doi.org/10.1371/journal.pone.0188714>
- Banu, T. P., Borlea, G. F., & Banu, C. (2016). The use of drones in forestry. *Journal of Environmental Science and Engineering B*, 5, 557 – 562. <https://doi.org/10.17265/2162-5263/2016.11.007>
- Bhatnagar, S., Gill, L., & Ghosh, B. (2020). Drone image segmentation using machine and deep learning for mapping raised bog vegetation communities. *Remote Sensing*, 12(16), 2602. <https://doi.org/10.3390/rs12162602>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Cárdenas-Tristán, A., Treviño-Garza, E. J., Aguirre-Calderón, O. A., Jiménez-Pérez, J., González-Tagle, M. A., & Antonio Némiga, X. (2013). Uso de tecnologías espaciales para evaluar la calidad de muestras vectoriales de la producción de cartografía. *Investigaciones Geográficas*, (80), 111 – 128. <https://doi.org/10.14350/rg.36649>
- Chávez-Aguilar, G., Pérez-Suárez, M., Gayoso-Barragán, O., Á López-López, M., & Ángeles-Pérez, G. (2023). Forest management accelerates aboveground biomass accumulation in a temperate forest of Central Mexico. *Revista Chapingo Serie Ciencias Forestales*, 29(1), 16 – 33. <https://doi.org/10.5154/rchscfa.2022.03.014>
- Chuvieco, E. (2020). *Fundamentals of satellite remote sensing: An environmental approach* (3rd. ed.). CRC Press.
- Coelho-Eugenio, F., Badin, T. L., Fernandes, P., Mallmann, C. L., Schons, C., Schuh, M. S., Soares Pereira, R., Aparecida fantinel, R., & Pereira da Silva, S. D. (2021). Remotely Piloted Aircraft Systems (RPAS) and machine learning: A review in the context of forest science. *International Journal of Remote Sensing*, 42(21), 8207 – 8235. <https://doi.org/10.1080/01431161.2021.1975845>
- Congalton, R. G., & Green, K. (2008). *Assessing the accuracy of remotely sensed data: Principles and practices* (2nd ed.). CRC Press. <https://doi.org/10.1201/9781420055139>
- Díaz-Varela, R. A., Calvo Iglesias, S., Cillero Castro, C., & Díaz Varela, E. R. (2018). Sub-metric analysis of vegetation structure in bog-heathland mosaics using very high resolution rpas imagery. *Ecological Indicators*, 89, 861 – 873. <https://doi.org/10.1016/j.ecolind.2017.11.068>
- Fernández-Lozano, J., & Gutiérrez-Alonso, G. (2016). Aplicaciones geológicas de los drones. *Revista de la Sociedad Geológica de España*, 29(1), 89 – 105. https://www.researchgate.net/publication/303696594_Aplicaciones_Geologicas_de_los_Drones_-_Geological_Applications_of_UAVs
- Franzini, M., Ronchetti, G., Sona, G., & Casella, V. (2019). Geometric and radiometric consistency of parrot sequoia multispectral imagery for precision agriculture applications. *Applied Sciences*, 9(24), 1 – 24. <https://doi.org/10.3390/app9245314>
- Fraser, B. T., & Congalton, R. G. (2021). Estimating primary forest attributes and rare community characteristics using unmanned aerial systems (UAS): An enrichment of conventional forest inventories. *Remote Sensing*, 13(15), 1 – 22. <https://doi.org/10.3390/rs13152971>
- Furukawa, F., Laneng, L. A., Ando, H., Yoshimura, N., Kaneko, M., & Morimoto, J. (2021). Comparison of RGB and multispectral unmanned aerial vehicle for monitoring vegetation coverage estudio también fue financiado parcialmente por el Programa de Paisajes Sostenibles de la Agencia para el Desarrollo Internacional de los Estados Unidos de América, a través de la Oficina de Programas Internacionales del Servicio Forestal de la USDA (United States Department of Agriculture), proyecto “Reducing Greenhouse Gas Emissions and Improving Forest Management in Mexico (acuerdo núm. 12-IJ-11242306-033).
- Gallardo-Salazar, J. L., Pompa-García, M., Aguirre-Salado, C. A., López-Serrano, P. M., & Meléndez-Soto, A. (2020). Drones: Tecnología con futuro promisorio en la gestión forestal. *Revista Mexicana de Ciencias Forestales*, 11(61). <https://doi.org/10.29298/rmcf.v11i61.794>
- García-Martínez, H., Flores-Magdaleno, H., Ascencio-Hernández, R., Khalil-Gardezi, A., Tijerina-Chávez, L., Mancilla-Villa, O. R., & Vázquez-Peña, M. A. (2020). Corn grain yield estimation from vegetation indices, canopy cover, plant density, and a neural network using multispectral and RGB Images acquired with unmanned aerial vehicles. *Agriculture*, 10(277), 1 – 24. <https://doi.org/10.3390/agriculture10070277>
- Guevara-Bonilla, M., Meza-Leandro, A. S., Esquivel-Segura, E. A., Arias-Aguilar, D., Tapia-Arenas, A., & Masís Meléndez, F. (2020). Uso de vehículos aéreos no tripulados (VANTS) para el monitoreo y manejo de los recursos naturales: Una síntesis. *Revista Tecnología en Marcha*, 33(4), 77–88. <https://doi.org/10.18845/tm.v33i4.4528>
- Hamilton, G., Corcoran, E., Denman, S., Hennekam, M. E., & Koh, L. P. (2020). When you can't see the koalas for the trees: Using drones and machine learning in complex environments. *Biological Conservation*, 247, 108598. <https://doi.org/10.1016/j.biocon.2020.108598>
- Hernández-Díaz, J. C., Corral-Rivas, J. J., Quiñones-Chávez, A., Bacon-Sobbe, J. R., & Vargas-Larreta, B. (2016). Evaluación del manejo forestal regular e irregular en bosques de la Sierra Madre Occidental. *Madera y Bosques*, 14(3), 25 – 41. <https://doi.org/10.21829/myb.2008.1431205>
- Ivosevic, B., Han, Y.-G., Cho, Y., & Kwon, O. (2015). The use of conservation drones in ecology and wildlife research. *Journal of Ecology and Environment*, 38(1), 113 – 118. <https://doi.org/10.5141/ecoenv.2015.012>
- Jiang, Y., Zhang, L., Yan, M., Qi, J., Fu, T., Fan, S., & Chen, B. (2021). High-resolution mangrove forests classification with machine learning using worldview and UAV hyperspectral data. *Remote Sensing*, 13(8), 1529. <https://doi.org/10.3390/rs13081529>
- Kedia, A. C., Kapos, B., Liao, S., Draper, J., Eddinger, J., Updike, C., & Frazier, A. E. (2021). An integrated spectral-structural workflow for invasive vegetation mapping in an arid region using drones. *Drones*, 5(1), 19. <https://doi.org/10.3390/drones5010019>

Fin de la versión en español

- Khan, M. S. I., Ohlemüller, R., Maloney, R. F., & Seddon, P. J. (2021). Monitoring dynamic braided river habitats: Applicability and efficacy of aerial photogrammetry from manned aircraft versus unmanned aerial systems. *Drones*, 5(2), 39. <https://doi.org/10.3390/drones5020039>
- Liu, M., Yu, T., Gu, X., Sun, Z., Yang, J., Zhang, Z., Mi, X., Cao, W., & Li, J. (2020). The impact of spatial resolution on the classification of vegetation types in highly fragmented planting areas based on unmanned aerial vehicle hyperspectral images. *Remote Sensing*, 12(146), 1 – 25. <https://doi.org/10.3390/rs12010146>
- Mellor, A., Haywood, A., Stone, C., & Jones, S. (2013). The performance of random forests in an operational setting for large area sclerophyll forest classification. *Remote Sensing*, 5(6), 2838 – 2856. <https://doi.org/10.3390/rs5062838>
- Medina-Merino, R. F., & Ñique-Chacón, C. I. (2017). Bosques aleatorios como extensión de los árboles de clasificación con los programas R y Python. *Interfases*, 10(010), 165. <https://doi.org/10.26439/interfases2017.n10.1775>
- Ortiz-Reyes, A. D., Valdez-Lazalde, J. R., De los Santos-Posadas, H. M., Ángeles-Pérez, G., Paz-Pellat, F., & Martínez-Trinidad, T. (2015). Inventory and cartography of forest variables derived from LiDAR data: Comparison of methods. *Madera y Bosques*, 21(3), 111 – 128. [https://www.scielo.org.mx/pdf\(mb/v21n3/v21n3a8.pdf](https://www.scielo.org.mx/pdf(mb/v21n3/v21n3a8.pdf)
- Paneque-Gálvez, J., McCall, M., Napoletano, B., Wich, S., & Koh, L. (2014). Small drones for community-based forest monitoring: An assessment of their feasibility and potential in tropical areas. *Forests*, 5, 1481 – 1507. <https://doi.org/10.3390/f5061481>
- Pérez-López, R. I., González-Espinosa, M., Ramírez-Marcial, N., & Toledo-Aceves, T. (2020). Efectos del “Método de Desarrollo Silvícola” sobre la diversidad arbórea en bosques húmedos de montaña del norte de Chiapas, México. *Revista Mexicana de Biodiversidad*, 91(e913326), 1 – 13. <https://doi.org/10.22201/ib.20078706e.2020.91.3326>
- Pix4D, S. A. (2017). *Pix4Dmapper 4.1 user manual*. Pix4D S.A. <https://support.pix4d.com/hc/en-us/articles/204272989-Offline-Getting-Started-and-Manual-pdf>
- Quantum GIS Development Team. (2021). *QGIS Geographic Information System (v. 3.10.14-A)*. República Checa: Open Source Geospatial Foundation Project. <http://www.qgis.org>
- R Development Core Team. (2021). *R: A language and environment for statistical computing*. Vienna, Austria: R Foundation for Statistical Computing. <https://www.R-project.org/>
- Ramírez-Santiago, R., Ángeles-Pérez, G., Hernández-de La Rosa, P., Cetina-Alcalá, V. M., Plascencia-Escalante, O., & Clark-Tapia, R. (2019). Efectos del aprovechamiento forestal en la estructura, diversidad y dinámica de rodales mixtos en la Sierra Juárez de Oaxaca, México. *Madera y Bosques*, 25(3), 1 – 12. <https://doi.org/10.21829/myb.2019.2531818>
- Sánchez-Medor, A. J., Waring, K. M., & Kalies, E. L. (2015). Implications of diameter caps on multiple forest resource responses in the context of the four forests restoration initiative: Results from the forest vegetation simulator. *Journal of Forestry*, 113(2), 219 – 230. <https://doi.org/10.5849/jof.14-021>
- Sánchez-Muñoz, J. M. (2016). Análisis de calidad cartográfica mediante el estudio de la matriz de confusión. *Pensamiento Matemático*, 6(2), 9 – 26. <https://dialnet.unirioja.es/servlet/articulo?codigo=5998855>
- SenseFly, S. A. (2018). *eMotion, a Parrot Company*. www.sensefly.com.
- Tang, L., & Shao, G. (2015). Drone remote sensing for forestry research and practices. *Journal of Forestry Research*, 26(4), 791 – 797. <https://doi.org/10.1007/s11676-015-0088-y>
- Torres-Rojas, G. T.-R., Romero-Sánchez, M. E., Velasco-Bautista, E., & González-Hernández, A. (2017). Estimación de parámetros forestales en bosques de coníferas con técnicas de percepción remota. *Revista Mexicana de Ciencias Forestales*, 7(36), 7 – 24. <https://doi.org/10.29298/rmcf.v7i36.56>
- Torres-Rojo, J. M., Carrillo Anzures, F., Acosta Mireles, M., Flores Ayala, E., & Sangerman-Jarquín, D. M. (2022). Características de los productores forestales particulares de México. *Revista Mexicana de Ciencias Agrícolas*, 13(5), 841 – 852. <https://doi.org/10.29312/remexca.v13i5.3228>
- van Lersel, W., Straatsma, M., Addink, E., & Middelkoop, H. (2018). Monitoring height and greenness of non-woody floodplain vegetation with UAV time series. *ISPRS Journal of Photogrammetry and Remote Sensing*, 141, 112 – 123. <https://doi.org/10.1016/j.isprsjprs.2018.04.011>
- Veneros, J., García, L., Morales, E., Gómez, V., Torres, M., & López-Morales, F. (2020). Aplicación de sensores remotos para el análisis de cobertura vegetal y cuerpos de agua. *Idesia (Arica)*, 38(4), 99 – 107. <https://doi.org/10.4067/S0718-34292020000400099>
- Xu, C. X., Lim, J. H., Jin, X. M., & Yun, H. C. (2018). Land cover mapping and availability evaluation based on drone images with multi-spectral camera. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, 36(6), 589 – 599. <https://doi.org/10.7848/ksgpc.2018.36.6.589>
- 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. *Photogrammetric Engineering & Remote Sensing*, 72(7), 799 – 811. <https://doi.org/10.14358/PERS.72.7.799>
- Zhao, F., Wu, X., & Wang, S. (2020). Object-oriented vegetation classification method based on UAV and satellite image fusion. *Procedia Computer Science*, 174, 609 – 615. <https://doi.org/10.1016/j.procs.2020.06.132>
- Zhong, Y., He, J., & Chalise, P. (2020). Nested and repeated cross validation for classification model with high-dimensional data. *Revista Colombiana de Estadística*, 43(1), 103 – 125. <https://doi.org/10.15446/rce.v43n1.80000>