

Medición de atributos forestales de especies de coníferas mediante fotogrametría digital con drones

Measurement of forest attributes of coniferous species using digital drone photography

Casimiro Ordóñez-Prado¹ , Adrián Hernández-Ramos² , Enrique Buendía-Rodríguez³ ,
 Bossuet Gastón Cortés-Sánchez⁴ , Adán Nava-Nava⁵ , Juan Carlos Tamarit-Urias^{1*} 

¹Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias, Centro de Investigación Regional Golfo Centro, Campo Experimental San Martinito. Carretera Federal México-Puebla, km 56.5. CP. 74100. San Martinito, Tlahuapan, Puebla, México.

²Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias, Centro de Investigación Regional Noreste, Campo Experimental Saltillo. Carretera Saltillo-Zacatecas, km. 342 + 119. CP. 25315. Hacienda de Buenavista, Saltillo, Coahuila, México.

³Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias, Centro de Investigación Regional Centro, Campo Experimental Valle de México. Carretera Los Reyes-Texcoco, km 13.5. CP. 56250. Coatlinchán, Texcoco, Edo. de México, México.

⁴Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias, Centro de Investigación Regional Centro, Sitio Experimental Tlaxcala. Carretera Federal México-Puebla, km 56.5. CP. 74100. Santa Ana Chiautempan, Tlaxcala, México.

⁵Agropecuaria Santa Genoveva S.A.P.I. de C.V. Carretera Cayal Nohyaxche, km 87, Alfredo V. Bonfil. CP. 24570. San Francisco de Campeche, Campeche, México.

*Autor de correspondencia: tamarit.juan@inifap.gob.mx

Artículo científico

Recibido: 29 de abril 2025

Aceptado: 05 de noviembre 2025

RESUMEN. La nube de puntos fotogramétrica proporciona información para estimar con precisión variables dendrométricas y dasométricas a nivel de árbol individual. El objetivo del presente estudio fue evaluar el potencial de las nubes de puntos geoespaciales, generadas mediante fotogrametría digital de imágenes aéreas capturadas con un dron de bajo costo, para la estimación de variables dendrométricas y dasométricas en rodales de coníferas. Con datos de altura total (At : m), área basal (AB : m^2) y Volumen (Vol : m^3) de 80 árboles de coníferas medidos en campo se ajustaron los modelos de regresión lineal (M1), exponencial (M2), M1 con efectos mixtos (M3), M2 con efectos mixtos (M4), redes neuronales artificiales (RNA-M5) y random forest (RF-M6) para estimar la At , AB y Vol en función de métricas de altura (z), de las coníferas medidas, de la nube de puntos fotogramétrica. La eficiencia de las estimaciones se calculó mediante el mayor coeficiente de determinación (R^2), la raíz del cuadrado medio del error (RCME), el Criterio de Información de Akaike (AIC) y el Sesgo más bajo. La At fue la mejor estimada con las métricas de la nube de puntos de fotogrametría al obtener R^2 entre 0.87 y 0.98, RCME de 1.64 y 0.61; siendo el M2 el mejor. Para la estimación de la AB y Vol el modelo RF-M6 fue el mejor con un R^2 de 0.772 y 0.769 y, RCME de 0.046 y 0.564 respectivamente. La nube de puntos 3D fotogramétrica es una alternativa para estimar variables forestales a nivel de árbol.

Palabras clave: Nube fotogramétrica, métricas, modelos paramétricos, modelos no paramétricos, VANT.

ABSTRACT. The photogrammetric point cloud provides information that allows to estimate dendrometric and dasometric variables at the individual tree level with precision. The objective was to evaluate the potential of the geospatial point cloud generated by photogrammetry of aerial photographs captured by a low-cost drone in the estimation of dendrometric and dasometric variables in conifer species. With data on total height (At : m), basal area (AB : m^2) and volume (Vol : m^3) of 80 conifer trees measured in the field, linear (M1), exponential (M2), M1 with mixed effects (M3), M2 with mixed effects (M4), artificial neural networks (ANN-M5) and random forest (RF-M6) regression models were fitted to estimate At , AB and Vol based on height metrics (z), of the measured conifers, from the photogrammetric point cloud. The efficiency of the estimates was determined using the highest adjusted coefficient of determination (R^2), the lowest root mean square error (RMSE), the Akaike Information Criterion (AIC), and Bias. The At was best estimated using the photogrammetric point cloud metrics, with R^2_{adj} ranging from 0.87 to 0.98, and RMSE of 1.64 and 0.61; M2 being the best. Regarding the estimation of AB and Vol , the RF-M6 model was the best, achieving an R^2 of 0.772 and 0.769, and RMSE of 0.046 and 0.564, respectively. It is concluded that the photogrammetric 3D point cloud is an alternative for estimating forest variables at the tree level.

Keywords: Photogrammetric cloud, metrics, parametric models, no parametric models, UAV.

INTRODUCCIÓN

Los vehículos aéreos no tripulados (VANT) o drones, como comúnmente se les conoce, han tomado relevancia en el sector forestal por su capacidad de recabar información de los atributos del bosque de manera precisa, en tiempo real y de forma asequible (Ivosevic *et al.* 2017). La operatividad de los drones en actividades cotidianas referentes al manejo forestal tiene relación con la disponibilidad, diversidad, costo y seguridad a la hora de volar estos equipos (Panque-Gálvez *et al.* 2014, Ordóñez-Prado *et al.* 2024). El desarrollo tecnológico en los sensores remotos, los cuales son más pequeños y pueden ser transportados por estas plataformas, son capaces de recolectar información sobre las condiciones del bosque con alto grado de detalle, lo que permite un mejor análisis y estudio de los macizos forestales (Kellner *et al.* 2019). Estas dos tecnologías han conducido a la generación de aplicaciones y programas de cómputo que facilitan su incorporación en tareas relacionadas al manejo y conservación de los bosques. En este sentido, hoy en día existe una alta gama de drones, sensores remotos, aplicaciones y softwares, los cuales se puede usar para obtener información diversa de los rodales y así tener más elementos en la planificación de las actividades de manejo forestal sustentable.

La información derivada de los sensores remotos montados en drones ha mostrado potencial para la identificación y distribución espacial de la vegetación, vigilancia, seguimiento de incendios forestales, monitoreo de plagas, estimación de variables dendrométricas y generación de inventarios forestales (Nuijten *et al.* 2021, Lee *et al.* 2023). La calidad de estos productos depende en gran medida de las características técnicas del dron y del sensor remoto utilizado; los sensores LiDAR y cámaras multiespectrales permiten obtener información detallada de la vegetación y la estructura vertical, la nube de puntos LiDAR es más completa que la fotogramétrica porque hay retornos, sin embargo, este sensor es más costoso que las cámaras digitales. Una alternativa son los materiales cartográficos derivados de la fotogrametría digital con drones (Herrero-Huerta *et al.* 2016). Esta se fundamenta en la fotogrametría tradicional, que se define como el arte, ciencia y tecnología para obtener medidas fiables de objetos físicos y su entorno, a través de grabación, medida e interpretación de imágenes y patrones de energía electromagnética radiante y otros fenómenos (Brito y Coelho 2017). Las fotografías capturadas con drones se procesan de manera analítica, resultando en orto mosaicos, Modelos Digitales del Terreno (MDT), Modelos Digitales de Superficie (MDS) de alta resolución, así como una nube de puntos tridimensional con información geográfica y de altitud (Buill-Pozuelo *et al.* 2013). De los productos derivados de la fotogrametría con drones, el menos explorado en el área forestal es la nube de puntos. Esta es una representación en 3D de puntos medios tomados de una superficie de la que luego se quiere crear una reconstrucción o modelado en 3D, esto es posible gracias a algoritmos que pueden generar un mallado de triángulos para representar esa superficie previamente capturada (Cordero 2017). Bajo esta premisa, la nube de puntos fotogramétrica puede ofrecer información valiosa como la altura total del arbolado de las áreas forestales, el volumen y la biomasa, la estructura vertical del rodal, entre otras variables de interés forestal.

Generalmente, la medición de los atributos de los bosques se realiza utilizando el método de área, el cual correlaciona información de parcelas medidas en campo con datos de sensores remotos. Al respecto, Vega-Puga *et al.* (2024) encontraron alta correlación entre los MDT y MDS con la biomasa

aérea de un matorral subtropical; pero no encontraron diferencias significativas entre el tamaño de copa medida en campo y medida en el MDS. En este mismo sentido, Colohua-Citláhuatl *et al.* (2024) utilizaron información derivada de la fotogrametría con drones para complementar la información de campo para evaluar y caracterizar rodales de *Pinus hartwegii* Lindl. en el parque Nacional Pico de Orizaba. Otra opción consiste en estimar los atributos directamente a nivel de árbol, obteniendo individualmente las variables dendrométricas y dasométricas de cada ejemplar. En este sentido, Reyes-Zurita *et al.* (2021) aplicaron el modelo paramétrico de tipo exponencial para estimar el diámetro normal (Dn) en función de la altura total (At) y diámetro de copa (Dc) medidos con el MDS. Con base en los antecedentes referidos, el presente estudio tuvo el objetivo de evaluar el potencial de la nube de puntos geoespacial generada por fotogrametría de fotografías aéreas capturadas por un dron de bajo costo en la estimación de variables dendrométricas y dasométricas en especies de coníferas, a nivel de árbol individual.

MATERIALES Y MÉTODOS

Área de estudio

Se tomó como caso de estudio árboles de coníferas de las áreas arboladas del Campo Experimental San Martinito (CESMAR) en Tlahuapan, Pue., México, ubicado entre las coordenadas extremas 19°20'44.50" LN - 98°33'58.88" LO y 19°20'55.44" LN - 98°34'0.28" LO a una altitud de 2 540 m (Figura 1). El arbolado del CESMAR se conforma principalmente por especies de coníferas como *Pinus montezumae* Lamb., *Pinus ayacahuite* Ehrenb. ex Schleidl., *Pinus pseudostrobus* Lindl., *Pinus teocote* Schiede ex Schleidl., *Cupressus lusitanica* Mill. y *Abies religiosa* (Kunth) Schleidl. y Cham. En su mayoría, estos árboles fueron plantados en diferentes años de actividad del CESMAR (40 años), lo que ha dado lugar a una composición forestal muy diversa en especies, diámetros y alturas. El clima de la región es templado subhúmedo con lluvias estivales y una precipitación anual promedio de 900 a 1 100 mm.

Datos de campo

Se seleccionaron 80 árboles de coníferas mediante un muestreo estratificado según categorías de diámetro normal y altura total, privilegiando árboles íntegros, libres de defectos mecánicos y no suprimidos. A estos ejemplares, se les midió la altura total (At, m) con un hipsómetro Haglöf ECII-D y el diámetro normal (Dn, cm) con una forcípula Mantax Blue Marca Haglöf. Cada árbol fue georreferenciado con un GPS Garmin GPSMAP 86i y rectificado con un orto-mosaico de 5 cm de resolución espacial, generado a partir de fotogrametría con drones, y así asegurar que cada árbol medido en campo sea el mismo de la nube de puntos fotogramétrica. También, con un flexómetro se midió la proyección de copa y se obtuvo el radio de copa (RC, m) de cada árbol. Con los datos de campo y aplicando ecuaciones de volumen se estimó el volumen total árbol (Vt, m³), las ecuaciones utilizadas para estas dos variables son las propuestas por Monárrez-González *et al.* (2024). El área basal (AB, m²) por árbol se obtuvo del diámetro normal en la forma convencional.

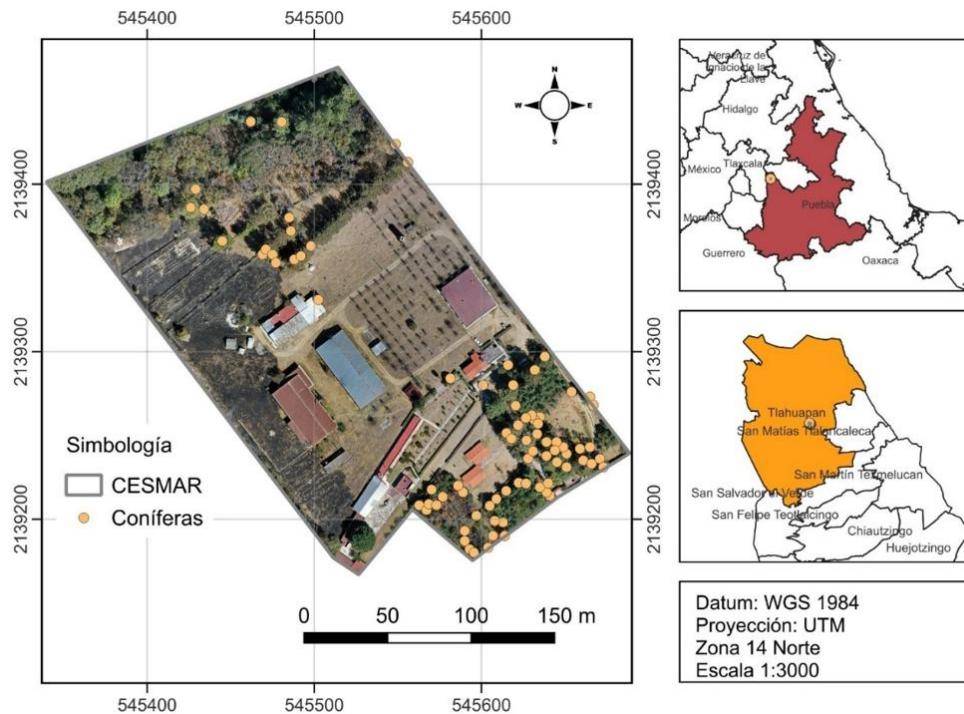


Figura 1. Localización de árboles de coníferas en el Campo Experimental San Martinito, Tlahuapan, Puebla, México.

Datos fotogramétricos

Se tomaron 240 fotografías aéreas con un dron DJI® Mavic 2 pro, equipado con una cámara 4k RGB de 20 megapíxeles y 30 fps, con sensor CMOS de $1/2.3$. El plan de vuelo se realizó en el software Pix4Dcapture® aplicando un vuelo doble (vuelos cruzados) con una sobreposición del 75 % entre fotografías y líneas de vuelo, a una altura promedio de 80 m sobre el terreno y con una velocidad de entre 9 y 10 $m \cdot s^{-1}$. El proceso fotogramétrico (corrección de parámetros básicos de calidad fotográfica, alineación, triangulación y unión de fotografías) se realizó en el programa OpenDroneMap™, con el cual se obtuvo una nube de puntos (*.las) de 50 millones de puntos tridimensionales (XYZ) con una densidad de 457 puntos por m^2 y un modelo digital del terreno (MDT) con una resolución especial de 1 m por píxel.

La nube de puntos fue normalizada utilizando el MDT a través de la librería lidR dentro del entorno R-Studio (Roussel *et al.* 2020); en términos generales, este proceso consiste en quitar la altura del suelo sin vegetación (MDT) a la altura (z) de la nube de puntos, resultando en una nube de puntos que representan la altura de la vegetación arbolada.

Métricas de altura

Una vez normalizada la nube de puntos, se procedió a extraer las métricas de altura (z) para cada árbol medido en campo. Estas métricas describen la tendencia central (*zmean*: altura media); dispersión y distribución (*zstd*: desviación estándar, *zmax*: altura máxima, *zmin*: altura mínima); forma de la distribución (*zskw*: simetría, *zkurt*: curtosis); así como los percentiles de la distribución de la altura (*zq5* a *zq95*, con incrementos de 5, donde el número representa el percentil que corresponde al valor de la variable por debajo del cual se encuentra un porcentaje dado de

observaciones en un grupo). La extracción de métricas y generación de la base de datos se realizó de manera automática con la librería lidR dentro del entorno R-Studio. Para ello, se generó un ciclo de trabajo donde se ingresan las coordenadas X y Y (UTM) y el radio de copa (RC, m) de cada árbol medido en campo; se realizó el recorte de la nube de puntos de cada árbol mediante un círculo de tamaño RC, posteriormente se extrajeron las métricas de altura y se guardaron en una base de datos. En la Figura 2 se muestra un ejemplo de la extracción de métricas de altura de muestra. Para conformar una sola base de datos, se incorporó la información de At, AB y Vol medidos en campo.

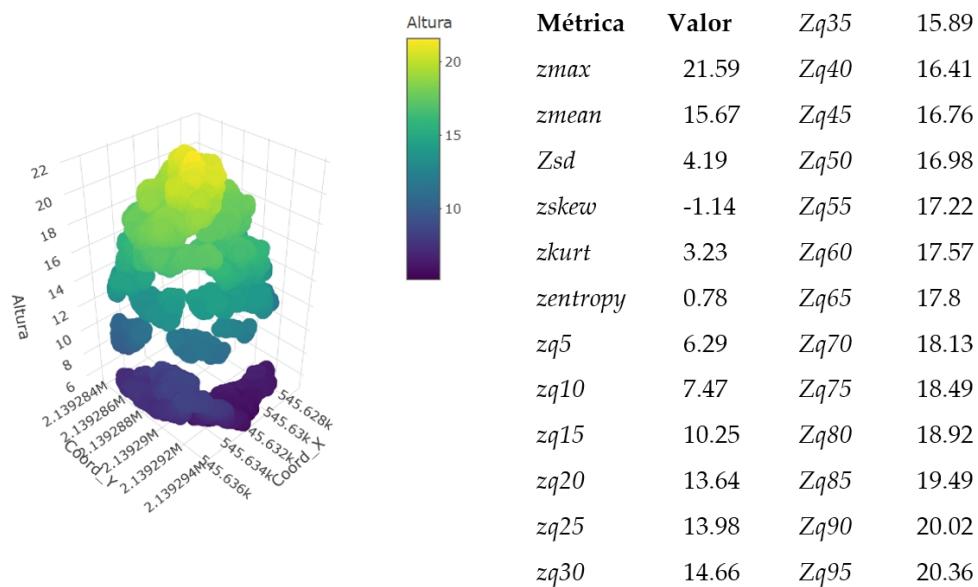


Figura 2. Ejemplo de métricas de altura a nivel de árbol individual, extraídas de una nube de puntos fotogramétrica.

Selección de variables potenciales y modelos candidatos

La selección de variables predictoras potenciales para predecir la At, AB y Vol se realizó mediante regresión Stepwise paso a paso que genera modelos de tipo parámetricos. Esta regresión combina el método hacia adelante y hacia atrás, comienza con un modelo vacío y en cada paso se evalúa la adición de una nueva variable y la eliminación de una variable existente, se elige la acción que resulte en la mayor mejora del modelo, continuando hasta que no sea posible añadir ni eliminar ninguna variable que mejore significativamente el modelo (Miller y Panneerselvan 2022). Las variables en los modelos no paramétricos tal como el modelo Random Forest y Redes Neuronales Artificiales fueron seleccionadas a través del algoritmo Boruta, esta es una herramienta de selección que identifica las variables más relevantes en un conjunto amplio de datos, funciona comparando la importancia de cada característica real con la importancia de sus copias aleatorias, llamadas características de sombra (Picco *et al.* 2025).

Ajuste y validación de los modelos

Para evaluar el potencial de la nube fotogramétrica para la estimación de At, AB y Vol a nivel de árbol individual, se ajustaron seis modelos, cuatro paramétricos: M1, modelo de regresión lineal múltiple (ML); M2, modelo de regresión lineal múltiple con efectos mixtos; M3, modelo exponencial en su forma clásica; M4, modelo exponencial incorporando efectos mixtos; y dos no

paramétricos: M5, redes neuronales artificiales y M6 algoritmo Random Forest. El modelo ML es versátil para evaluar las relaciones entre un destino continuo y los predictores; los predictores pueden ser campos continuos, categóricos o derivados, de modo que las relaciones no lineales también estén soportadas, por lo que, este tipo de modelos son factibles para estimar atributos del bosque con nube de punto tridimensional ya que pueden usar diversas métricas de altura (Abuín 2007). El modelo exponencial describe un crecimiento o decrecimiento donde la tasa de cambio es proporcional a la cantidad actual, en biometría y modelación forestal es utilizado con regularidad para estimar el área basal, biomasa aérea y volumen maderable. Por su parte, los modelos de efectos mixtos incorporan efectos fijos y aleatorios, y normalmente se usa cuando se manejan datos que tiene variabilidad dentro de cada grupo y entre grupos, en la estimación de atributos forestales, son aplicados para manejar la variabilidad que a menudo presentan una estructura jerárquica por ejemplo árboles dentro de parcelas. Por otra parte, la incorporación de un efecto aleatorio mediante un intercepto aleatorio combinado con pendiente fija puede aumentar la eficiencia para estimar la variable dependiente (Pinheiro y Bates 2000, Di-Rienzo *et al.* 2012, Ortiz-Reyes *et al.* 2021). Las redes neuronales artificiales (RNA) son modelos de aprendizaje supervisado inspirados en el funcionamiento del cerebro humano. Las RNA consisten en múltiples capas de neuronas interconectadas que pueden aprender representaciones jerárquicas y no lineales de los datos (Haykin 2009). El algoritmo Random Forest (RF) es un método de regresión basado en árboles de decisión, es un modelo de aprendizaje supervisado que utiliza una estructura de árbol para representar las decisiones y sus posibles consecuencias; RF combina múltiples árboles de decisión, lo que mejora la robustez y el rendimiento del modelo (Breiman 2001). Estos modelos son especialmente adecuados para tareas de regresión y clasificación en problemas de alta dimensionalidad y con datos complejos (Alaminos-Fernández 2023), como las diferentes métricas de altura de los árboles, capturadas por la nube de puntos fotogramétrica.

El análisis estadístico se realizó en el software libre R versión 4.3.3, la eficiencia de cada modelo se determinó mediante los siguientes estadísticos de bondad de ajuste: coeficiente de determinación (R^2) más alto, raíz del cuadrado medio del error (RCME), el sesgo (S) más bajo y el Criterio de Información de Akaike (AIC).

$$\begin{aligned}
 R^2 &= 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \\
 RCME &= \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \\
 S &= \frac{\sum_{i=1}^n (y_i - \hat{y}_i)}{n} \\
 AIC &= 2k + n \ln \left(\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \right)
 \end{aligned}$$

En la Tabla 1 se presentan las estadísticas descriptivas básicas de las variables medidas en campo para la muestra de 80 árboles de coníferas. Estos presentaron una altura total entre 5.50 y 26.80 m distribuida de manera simétrica, con tendencia a una curtosis mesocúrtica. La menor cobertura de

copa tuvo un RC de 2.01 y la mayor fue de 10.15 m, con una asimetría ligeramente cargada a la derecha y una distribución normal. El volumen estimado presentó una media aproximada a 1 m³, con una asimetría cargada a la derecha y con datos concentrados a la media.

Tabla 1. Estadísticas descriptivas básicas de las variables dendrométricas y dasométricas de 80 árboles de coníferas medidos en campo.

Variable	Estadístico						
	Mín.	1 st Qu	Media	3 rd Qu	Máx.	Asimetría	Curtosis
<i>Dn (cm)</i>	12.50	25.2	33.81	40.1	81.40	1.29	1.59
<i>At (m)</i>	5.50	12.7	16.35	20.1	26.80	-0.01	-0.64
<i>RC(m)</i>	1.00	2.010	3.764	5.282	10.150	1.03	0.17
<i>AB (m²)</i>	0.0122	0.0498	0.1048	0.1262	0.5204	2.23	5.28
<i>Vol (m³)</i>	0.0034	0.4245	0.9972	1.0011	5.7972	2.73	7.63

Donde: *Dn* = diámetro normal; *At* = altura total; *RC* = radio de copa; *AB* = área basal; *Vol* = volumen total árbol; Mín = mínimo; Qu = cuantil; Máx = máximo.

En la Figura 3a y 3b se presenta la distribución geoespacial de la nube de puntos fotogramétrica original y la distribución de los datos respectivamente, en la Figura 3c la nube normalizada y en la Figura 3d la información de la altura (z) normalizada. La normalización representa adecuadamente la altura de los objetos del área de estudio, algunos de los árboles presentan alturas superiores a los 20 m, lo cual concuerda con las mediciones de campo; la distribución de los puntos 3D en altura es congruente porque se distribuyen cercanas al nivel del suelo.

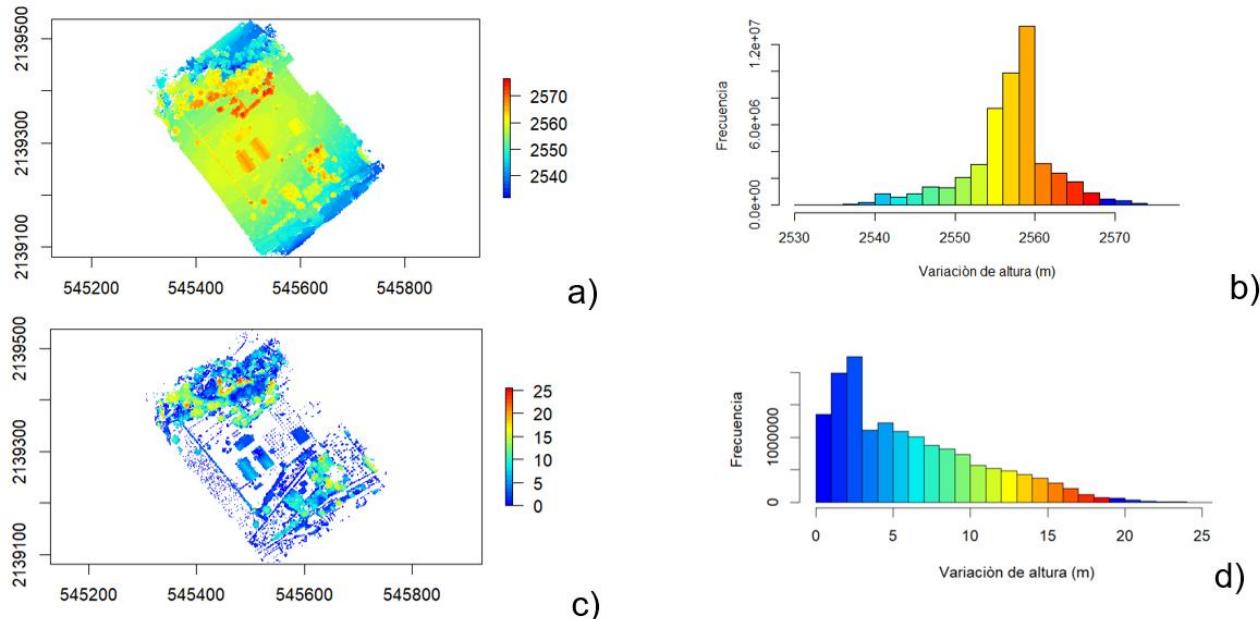


Figura 3. Normalización de la nube de puntos a partir de la sustracción del MDT a la coordenada z; a) nube sin normalizar, b) distribución de la altura sin normalizar, c) nube normalizada y d) distribución de la altura normalizada.

En la Tabla 2 se presentan las estructuras de los modelos para estimar la *At*, *AB* y *Vol* en función de métricas de altura. La regresión Stepwise paso a paso y Bootstrap seleccionaron solo al percentil 95 (*zq95*) como la mejor variable predictora para estimar *At*, *AB* y *Vol*; lo cual genera una estructura

sencilla tanto para la regresión lineal múltiple como el modelo exponencial. Además, evita la autocorrelación con otras métricas. Para el algoritmo de Random Forest y RNA fueron seleccionadas 11 métricas como importantes, entre la omitidas se encuentran las métricas que evalúan la forma de la nube de puntos (asimetría, curtosis y entropía).

Tabla 2. Variables predictoras de los modelos evaluados para la estimación de la altura total, área basal y volumen total árbol de coníferas.

Variable	Modelo	Método de ajuste	Predictores
At	M1	ML	zq95
	M2	MEM-ML	zq95
	M3	Exponencial	zq90
	M4	MEM-Exp	zq90
	M5	RNA	zq95, zq90, zmax, zq65, zq75, zq45, zq60, zq70, zq50, zq85, zq55, zmean
	M6	Random Forest	zq95, zq90, zmax, zq65, zq75, zq45, zq60, zq70, zq50, zq85, zq55, zmean
AB	M1	ML	zq95
	M2	MEM-ML	zq95
	M3	Exponencial	zq95
	M4	MEM-Exp	zq90
	M5	RNA	zq95, zq90, zmax, zq65, zq75, zq45, zq60, zq70, zq50, zq85, zq55, zmean
	M6	Random Forest	zq95, zq90, zmax, zq65, zq75, zq45, zq60, zq70, zq50, zq85, zq55, zmean
Vol	M1	ML	zq95
	M2	MEM-ML	zq95
	M3	Exponencial	zq95
	M4	MEM-Exp	zq90
	M5	RNA	zq95, zq90, zmax, zq65, zq75, zq45, zq60, zq70, zq50, zq85, zq55, zmean
	M6	Random Forest	zq95, zq90, zmax, zq65, zq75, zq45, zq60, zq70, zq50, zq85, zq55, zmean

At = altura total, AB = área basal, Vol = volumen total árbol, ML = modelo de regresión lineal múltiple, MEM-ML = modelo de regresión lineal múltiple con efectos mixtos, MEM-Exp = modelo exponencial con efectos mixtos, RNA = redes neuronales artificiales.

En la Tabla 3 se presentan los estadísticos de bondad de ajuste de los diferentes modelos probados para la estimación de At, AB y Vol. Las métricas de altura de la nube de puntos fotogramétrica mostraron alto potencial para la estimación de la altura total (At) de los árboles. De los modelos paramétricos utilizados, la regresión lineal con efectos mixtos (M2) fue la de mejor desempeño, ya que este modelo explicó más del 98% de la variabilidad de las mediciones en campo; además, la RCME fue la más baja con 60.7 cm. En cuanto a los modelos no paramétricos, Random Forest mostró un desempeño superior con un R^2 de 0.963 y un RCME de 0.871, además de sesgo y AIC bajos. El área basal y volumen maderable se estiman con menor precisión, los modelos paramétricos no tuvieron éxito, ya que los parámetros estimados no fueron significativos ($p>0.05$); aun con la incorporación de efectos mixtos, los estadísticos de bondad de ajuste fueron bajos (M3), tanto para AB como Vol. En contraste, los modelos no paramétricos presentaron un desempeño aceptable; destacando el algoritmo de regresión Random Forest (M6), alcanzando una R^2 de 0.772 y 0.769, y RCME de 0.046 y 0.564 para el área basal y volumen, respectivamente.

Tabla 3. Estadísticos de bondad de los modelos paramétricos y no paramétricos probados para la estimación de la altura total, área basal y volumen maderable.

Variable	Modelo	Tipo de modelo	R ²	RCME	S	AIC
At	M1	Paramétrico	0.869	1.639	0.000	85.006
	M2		0.982	0.607	0.046	83.006
	M3		0.876	1.600	0.000	77.201
	M4	No paramétrico	0.876	1.600	-0.000	79.185
	M5		0.902	1.418	0.000	57.883
	M6		0.963	0.871	0.009	-20.137
AB	M1	Paramétrico	ns	ns	ns	ns
	M2		ns	ns	ns	ns
	M3		0.245	0.084	-0.000	-395.106
	M4	No paramétrico	ns	ns	ns	ns
	M5		0.530	0.066	0.000	-432.929
	M6		0.772	0.046	0.000	-490.917
Vol	M1	Paramétrico	ns	ns	ns	ns
	M2		ns	ns	ns	ns
	M3		0.209	1.044	0.001	8.832
	M4	No paramétrico	ns	ns	ns	ns
	M5		0.443	0.876	-0.000	24.330
	M6		0.769	0.564	0.005	-89.612

At = altura total, AB = área basal, Vol = volumen maderable, R² = coeficiente de determinación, RCME = raíz del cuadrado medio del error, S = sesgo, AIC = criterio de información de Akaike, ns = no significativo.

La Tabla 4 muestra los coeficientes estimados del modelo M2 para estimar la At, porque corresponde al mejor ajuste. La incorporación de un efecto aleatorio, mediante un intercepto aleatorio combinado con pendiente fija, aumentó la eficiencia de estimación de At en un 12% en comparación con la especificación sin efecto aleatorio; todos los coeficientes resultaron altamente significativos ($p < 0.005$). Además, la altura en la nube de puntos definida por zq95 se confirmó como un predictor adecuado para At.

Tabla 4. Parámetros fijos y aleatorios del modelo M2 seleccionado para estimar la altura total de coníferas en función de métricas de altura en la nube de puntos fotogramétrica.

Modelo	Parámetro	Valor	Error estándar	Valor t	Pr > t
MEM-ML	Intercepto fijo (β_0)	2.903	0.595	4.880	<0.0001
	Pendiente fija métrica zq95 (β_1)	1.140	0.050	22.911	<0.0001
	Varianza del intercepto aleatorio (σ^2)	1.468			
	Varianza residual (σ^2)	7.512×10 ⁻⁹			

MEM-ML = modelo lineal con efecto mixto.

En las Figuras 4a, b y c, se presenta el análisis gráfico del comportamiento de los residuales estandarizados vs. predichos para los modelos seleccionados para estimar la At, AB y Vol (M2, M6, y M6 respectivamente). En la Figura 4 d, e y f se presenta una comparación de valores observados

vs. valores estimados mediante los modelos seleccionados. Se observa una alta correlación (r) entre los valores estimados y los observados para la At ($r = 0.98$), y una r considerable para el AB ($r = 0.85$) y el Vol ($r = 0.83$).

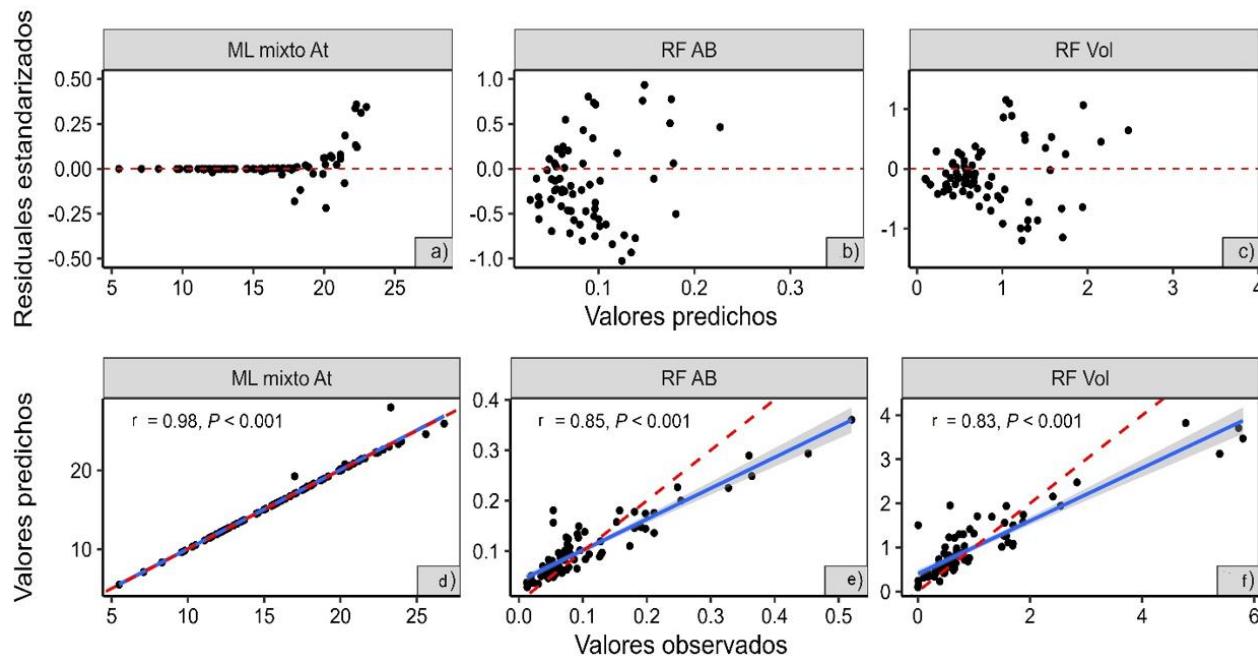


Figura 4. En a), b) y c) se presenta la distribución de los residuales estandarizados vs. valores predichos de los modelos seleccionados. En d), e) y f) la relación de los valores observados vs. valores predichos de los modelos seleccionados; modelo lineal mixto, random forest para la estimación de altura total, área basal y volumen maderable, respectivamente.

DISCUSIÓN

Los resultados obtenidos muestran el potencial de la nube fotogramétrica para la estimación de variables forestales a nivel de árbol individual. En particular, la altura total (At) se estimó con gran exactitud a partir de las métricas derivadas de la nube de puntos, alcanzando coeficientes de determinación ajustada (R^2) entre 0.87 y 0.98 y RCME entre 0.61 y 1.64 m. Por su parte, tanto el área basal (AB) como el volumen (Vol) mostraron un mejor desempeño cuando se aplicó el algoritmo Random Forest (RF-M6), con R^2 de 0.772 y RCME de 0.046, 0.769 y 0.564, respectivamente. Tanto los modelos paramétricos y no paramétricos evaluados mostraron alta eficiencia para la estimación de variables forestales a nivel de árbol; sobresaliendo en el caso de la At la regresión lineal con efectos mixtos, además, de utilizar una sola métrica como variable predictora.

El análisis efectuado muestra evidencia de altos niveles de ajuste, especialmente en las variables área basal y volumen, donde los modelos no paramétricos (particularmente el M6) alcanzaron valores de R^2 superiores al 0.96 y errores de predicción bajos (RCME < 1). Estos hallazgos coinciden con investigaciones previas como las de Puliti *et al.* (2015) y Wallace *et al.* (2016), quienes demostraron que las nubes de puntos generadas por UAVs pueden proporcionar estimaciones precisas de variables estructurales forestales comparables a las obtenidas mediante LiDAR aéreo

convencional. Asimismo, en comparación con estudios como los de Briechle *et al.* (2020), donde el uso de drones de bajo costo presentaba limitaciones en la captura de detalles finos, el presente estudio confirma que, al menos para coníferas y en condiciones de vuelo controladas, la fotogrametría aérea digital ofrece una alternativa viable y precisa para aplicaciones forestales, reduciendo costos y sin comprometer significativamente la calidad de las estimaciones.

Si bien, la nube de puntos fotogramétrica ha sido poco utilizada para estimar variables forestales a nivel de árbol individual, estudios como el realizado por Ota *et al.* (2017), en el cual evalúan la capacidad de la nube de puntos fotogramétrica para estimar propiedades biofísicas forestales en bosques de coníferas; estimaron el volumen maderable, a nivel de parcela, mediante la métrica de altura $zq90$ con una $R^2 = 0.71$, y la At con un $R^2 = 0.93$, valores ligeramente inferiores a los obtenidos en el presente estudio. Por su parte, Filippelli *et al.* (2019) evaluaron las nubes de puntos 3D LiDAR y fotogramétrica para estimar la At y AB de coníferas, para la estimación de At determinaron que solo es necesario la métrica de altura máxima ($zmax$) con un R^2_{adj} de 0.81 y 0.88, mientras que para el AB con R^2_{adj} de 0.65 y 0.67, utilizando la altura media ($zmean$) de la información fotogramétrica, el porcentaje de primeros retornos por encima de la altura y el porcentaje de puntos por encima del límite de altura, de LiDAR, respectivamente; los valores en los estadísticos de bondad que reportan son ligeramente inferiores a los determinados en el presente estudio. Por su parte, Bohlin *et al.* (2012) estimaron la At, AB y Vol mediante nube de puntos 3D de fotogrametría, para ello aplicaron el algoritmo no paramétrico k-MSN y el programa fusion®; reportan que la RCME fue de 1.32 para At, valor superior al reportado en el presente estudio.

A nivel nacional, se han realizado algunos esfuerzos para usar la fotogrametría en la estimación de los atributos forestales. Al respecto, Quiñones-Barraza *et al.* (2023) estimaron el volumen maderable de coníferas utilizando la altura del arbolado medida a partir del modelo digital de elevación y de superficie, sus resultados fueron menores a los del presente trabajo con R^2 de 0.57. Mientras que Ortiz-Reyes *et al.* (2022) aplicaron el modelo lineal mixto para estimar el AB y Vol en bosques de coníferas con datos LiDAR, al incorporar los efectos aleatorios obtuvieron una mejora en la estimación de estas variables, alcanzando una R^2 marginal de 0.92 y 0.85 para AB y Vol, respectivamente. Con este mismo tipo de información, Islas-Gutiérrez *et al.* (2023) probaron diferentes modelos para estimar la biomasa aérea de árboles individuales de *Pinus hartwegii*, alcanzando una R^2_{adj} de 0.81, utilizaron el diámetro de copa LiDAR, la altura total LiDAR y la combinación de estas. Si bien, los puntos tridimensionales (XYZ) que se generan del proceso fotogramétrico no cuenta con retornos como la nube puntos generada por un sensor LiDAR (laser), lo que aparentemente podría ser una desventaja, en este estudio se ha determinado que la nube de puntos obtenida con cámara 4k RGB procesada mediante fotogrametría digital, representa de manera adecuada la copa de los árboles y el suelo.

A pesar de que la nube de puntos fotogramétrica presenta ciertas limitaciones frente a las obtenidas por LiDAR 3D al carecer de información de retornos múltiples y capturar únicamente la superficie exterior de la vegetación, ha demostrado un notable potencial para la estimación de variables forestales, en especial la altura total (At), con alta precisión. Además, la fotogrametría digital resulta sensiblemente más económica que el LiDAR, permitiendo, mediante el uso de drones de bajo costo, cubrir rápidamente grandes extensiones de bosque. Por lo tanto, esta técnica se perfila como una alternativa de uso práctico frente a la medición manual en campo o las relaciones altura-

diámetro, al optimizar tiempos, reducir costos de campo y mantener un alto nivel de exactitud en los inventarios forestales.

CONCLUSIONES

La nube de puntos 3D generada mediante fotogrametría digital con el apoyo de un dron de bajo costo es viable para la estimación de variables dendrométricas y dasométricas a nivel de árbol individual en rodales de coníferas. Los hallazgos de este análisis son consistentes con investigaciones previas que han resaltado la eficacia de la fotogrametría aérea como alternativa al LiDAR, particularmente en ambientes forestales complejos; además, resaltan el potencial de la fotogrametría VANT para optimizar inventarios forestales, por lo que puede contribuir a apoyar el proceso de toma de decisiones silvícolas con datos precisos a escala de árbol individual. Este trabajo confirma que los drones de bajo costo, junto con técnicas accesibles de procesamiento de imágenes, representan una herramienta viable, económica y precisa para el monitoreo forestal en proyectos de manejo sostenible y conservación de ecosistemas de coníferas.

CONFLICTO DE INTERÉS

Los autores declaran no tener conflicto de intereses.

LITERATURA CITADA

Abuín JR (2007) Regresión lineal múltiple. IdEyGdM-Ld Estadística, Editor. Madrid, España. 32p.

Alaminos-Fernández AF (2023) Árboles de decisión en R con random forest. Universidad de Alicante. Obets Ciencia Abierta. Alicante, España. 123p.

Bohlin J, Wallerman J, Olsson H, Fransson JES (2012) Species-specific forest variable estimation using non-parametric modeling of multi-spectral photogrammetric point cloud data. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 39: 387-391. <https://doi.org/10.5194/isprsarchives-XXXIX-B8-387-2012>

Breiman L (2001) Random forests. Machine learning 45(1): 5-32. <https://doi.org/10.1023/A:1010933404324>

Briechle M, Heinzel J, Koch B (2020) UAV-based photogrammetric point clouds for forest structure modeling in steep terrain: A case study from the Bavarian Forest National Park. Remote Sensing 12(9): 1444. <https://doi.org/10.3390/rs12091444>

Brito J, Coelho L (2007) Fotogrametría digital. CEP 22290. 1ra ed. Río de Janeiro, Brasil. 270p.

Buill-Pozuelo F, Núñez-Andrés MA, Lantada N, Prades-Valls A (2016) Fotogrametría y videogrametría desde UAV para la captura de geoinformación en estudios geológicos. In: Topografía cartográfica 35(174): 47-53.

Colohua-Citláhuia B, Gómez-Guerrero A, Correa-Díaz A, Vargas-Hernández JJ (2024) Estructura y caracterización de rodales de *Pinus hartwegii* Lindl. en el Parque Nacional Pico de Orizaba. Revista Mexicana de Ciencias Forestales 15(83): 28-54. <https://doi.org/10.29298/rmcf.v15i83.1433>

Cordero MH (2017) El uso de fotogrametría de bajo coste en la creación de nubes de puntos aplicada a la arqueología comercial-the use of lowcost photogrammetry in the creation of point clouds applied to commercial archeology. Revista Otarq 1: 311-324.

Di-Rienzo JA, Macchiavelli R, Casanoves F (2012) Modelos lineales mixtos. Aplicaciones en InfoStat. Grupo InfoStat, FCA, Universidad Nacional de Córdoba. Argentina. 248p.

Filippelli SK, Lefsky MA, Rocca ME (2019) Comparison and integration of lidar and photogrammetric point clouds for mapping pre-fire forest structure. *Remote Sensing of Environment* 224: 154-166. <https://doi.org/10.1016/j.rse.2019.01.029>

Haykin S (2009) Neural networks and learning machines. 3rd ed. Pearson Education. New Jersey, USA. 938p.

Herrero-Huerta M, Gonzalez-Aguilera D, Yang Y (2023) Structural component phenotypic traits from individual maize skeletonization by UAS-based structure-from-motion photogrammetry. *Drones* 7(2): 108. <https://doi.org/10.3390/drones7020108>

Islas-Gutiérrez F, Cruz-Juárez E, Buendía-Rodríguez E, Guerra-De la Cruz V, Pineda-Ojeda T, Flores-Ayala E, Acosta-Mireles M (2024) Ecuación alométrica para estimar biomasa aérea de árboles de *Pinus hartwegii* Lindl. A partir de datos lidar. *Revista Fitotecnia Mexicana* 47(1): 70-79. <https://doi.org/10.35196/rfm.2024.1.70>

Ivosevic B, Han YG, Kwon O (2017) Calculating coniferous tree coverage using unmanned aerial vehicle photogrammetry. *Journal of Ecology and Environment* 41: 1-8. <https://doi.org/10.1186/s41610-017-0029-0>

Kellner JR, Armston J, Birrer M, Cushman KC, Duncanson L, Eck C, Zgraggen P (2019) New opportunities for forest remote sensing through ultra-high-density drone lidar. *Surveys in Geophysics* 40: 959-977. <https://doi.org/10.1007/s10712-019-09527-1>

Lee CKF, Song G, Muller-Landau HC, Wu S, Wright SJ, Cushman KC, Wu J (2023) Cost-effective and accurate monitoring of flowering across multiple tropical tree species over two years with a time series of high-resolution drone imagery and deep learning. *ISPRS Journal of Photogrammetry and Remote Sensing* 201: 92-103. <https://doi.org/10.1016/j.isprsjprs.2023.05.022>

Miller A, Panneerselvam J (2022) Una revisión de las técnicas de regresión y clasificación para el análisis de variantes comunes y raras y factores genético-ambientales. *Neurocomputing* 489: 466-485. <https://doi.org/10.1016/j.neucom.2021.08.150>

Monárrez-González JC, Márquez-Linares MA, López Hernández JA, Pérez Verdín G, Quiñonez Barraza G, García Cuevas X (2024) Ecuaciones de volumen fustal-total y ahusamiento para especies maderables del ecosistema templado en Puebla, México. *Revista Mexicana de Ciencias Forestales* 15(84): 4-28. <https://doi.org/10.29298/rmcf.v15i84.1440>

Nuijten RJ, Coops NC, Watson C, Theberge D (2021) Monitoring the structure of regenerating vegetation using drone-based digital aerial photogrammetry. *Remote Sensing* 13(10): 1942. <https://doi.org/10.3390/rs13101942>

Ordóñez-Prado C, Valdez-Lazalde JR, Flores-Magdaleno H, Ángeles-Pérez G, de los Santos-Posadas HM, Buendía-Rodríguez E (2024) Implicaciones operativas de la resolución espacial de imágenes de drones en el mapeo de la vegetación para el manejo forestal. *Revista Chapingo Serie Ciencias Forestales y del Ambiente* 30(2): 1-18. <https://doi.org/10.5154/r.rchscfa.2023.06.040>

Ortiz-Reyes AD, Velasco-Bautista E, Correa-Díaz A, Ángeles-Pérez G (2021) Predicción de variables dasométricas mediante modelos lineales mixtos y datos de LiDAR aerotransportado. *e-CUCBA* 17(9): 88-95. <https://doi.org/10.32870/ecucba.vi17.213>

Ota T, Ogawa M, Mizoue N, Fukumoto K, Yoshida S (2017) Forest structure estimation from a UAV-based photogrammetric point cloud in managed temperate coniferous forests. *Forests* 8(9): 343. <https://doi.org/10.3390/f8090343>

Paneque-Gálvez J, McCall MK, Napoletano BM, Wich SA, Koh LP (2014) Small drones for community-based forest monitoring: An assessment of their feasibility and potential in tropical areas. *Forests* 5(6): 1481-1507. <https://doi.org/10.3390/f5061481>

Picco ML, Ruiz MS, Maldonado JR (2025) Selección de bandas para la visualización y clasificación de imágenes hiperespectrales. *Revista de Teledetección* 66: e22291. <https://doi.org/10.4995/raet.2025.22291>

Pinheiro JC, Bates DM (2000) Mixed-effects models in S and S-PLUS. Springer-Verlag, New York, USA. 528p. <https://doi.org/10.1007/b98882>

Puliti S, Ørka HO, Gobakken T, Næsset E (2015) Inventory of small forest areas using an unmanned aerial system. *Remote Sensing* 7(8): 9632-9654. <https://doi.org/10.3390/rs70809632>

Quiñonez-Barraza G, Pompa-García M, Vivar-Vivar ED, Gallardo-Salazar JL, Hernández FJ, Rodríguez-Flores FD, Hernández-Díaz JC (2023) Modeling biometrie attributes from tree height using unmanned aerial vehicles (UAV) in natural forest stands. *Ingeniería e Investigación* 43(2): e98945. <https://doi.org/10.15446/ing.investig.98945>

R Core Team. (2024). R: A language and environment for statistical computing. R Foundation for Statistical Computing. <https://www.R-project.org/>

Reyes-Zurita N, Rodríguez-Ortiz G, Enríquez-del Valle JR, Jiménez-Colmenares CL, Rincón-Ramírez JA (2022) Estimación de variables dasométricas en rodales bajo manejo forestal con vehículos aéreos no tripulados. *Investigación y Desarrollo* 13(1): 22-31. <https://doi.org/10.29166/revfig.v13i1.3299>

Roussel JR, Auty D, Coops NC, Tompalski P, Goodbody TR, Meador AS, Achim A (2020) lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sensing of Environment* 251: 112061. <https://doi.org/10.1016/j.rse.2020.112061>

Vega-Puga MG, Romo-León JR, Castellanos AE, Castillo-Gámez RA, Garatuza-Payán J (2024) Use of unmanned aerial vehicles for estimating carbon storage in subtropical shrubland aboveground biomass. *Revista Chapingo Serie Ciencias Forestales y del Ambiente* 30(2): 1-18. <https://doi.org/10.5154/r.rchscfa.2023.06.043>

Wallace L, Luceir A, Malenovský Z, Turner D, Vopěnka P (2016) Assessment of forest structure using two UAV techniques: A comparison of airborne laser scanning and structure from motion (SfM) point clouds. *Forest Ecology and Management* 361: 1-9. <https://doi.org/10.1016/j.foreco.2015.11.021>