



Scientia Agropecuaria

Web page: <http://revistas.unitru.edu.pe/index.php/scientiaagrop>

Facultad de Ciencias
Agropecuarias

Universidad Nacional de
Trujillo



RESEARCH ARTICLE

Integration of VANT-LiDAR with multispectral imagery for the estimation of carbon stocks in *Prosopis* sp. forest plantations

Integración de VANT-LiDAR con imágenes multiespectrales para la estimación del carbono almacenado en plantaciones forestales de *Prosopis* sp.

Sheyla Y. Chumbimune-Vivanco¹ * ; Hairo León¹ ; Cristina Llanos-Carrillo¹
José Millan-Ramírez¹ Cesar Vilca-Gamarra¹ ; Elvis Vera¹ ; Alex Agurto¹
Juan R. Baselly-Villanueva² ; Camila Cruz-Grimaldo¹

¹ Dirección de Desarrollo Tecnológico Agrario, Instituto Nacional de Innovación Agraria (INIA), Av. La Molina 1981, Lima 15024. Lima, Perú.

² Estación Experimental Agraria San Roque, Instituto Nacional de Innovación Agraria (INIA), Iquitos, Perú.

* Corresponding author: yehv8290@gmail.com (S. Y. Chumbimune-Vivanco).

Received: 19 October 2024. Accepted: 8 April 2025. Published: 5 May 2025.

Abstract

The *Prosopis* sp. individuals known as carob trees are key species in the development of dry forest and recovery of degraded areas in the northern coast of Peru. The evaluation of plantations, calculation of aboveground forest biomass (AFB) and carbon stock represent an important role in forest management and climate change mitigation. This study evaluates monitoring methodologies using multispectral and LiDAR images coupled to a UAV, to validate them and generate models to estimate carbon stocks. Seven species of *Prosopis* sp. were evaluated with the conventional methodology and significant differences were found between species for dasometric characteristics and vegetation indices, as well as in the comparison with the data obtained with LiDAR. Models were selected to determine BAF and the association between the aerial carbon obtained with the models constituted by LiDAR data and vegetation indexes that presented significant correlations ($p < 0.05$), seven models were built for carbon prediction and the model that has as regressor variables the total height and crown area obtained from LiDAR, as well as the indexes Clgreen, GNDVI, RECI, LCI and NDVI ($R^2 = 0.77$) stands out. This confirms that the use of the LiDAR methodology with the vegetation indices allows a more practical estimation of the carbon stored in the plantation.

Keywords: UAV; LiDAR; biomass; carbon stocks; vegetation indices.

Resumen

Los individuos del género *Prosopis* sp. conocidos como algarrobos; son especies claves en el desarrollo del bosque seco y recuperación de áreas degradadas en la Costa norte del Perú. La evaluación de plantaciones, cálculo de la biomasa aérea forestal (BAF) y carbono almacenado representa un papel importante en el manejo forestal y mitigación del cambio climático. Este estudio evalúa metodologías de monitoreo a través del uso de imágenes multiespectrales y LiDAR acopladas a un VANT, con la finalidad de realizar su validación y generar modelos que permitan estimar el carbono almacenado. Se evaluaron siete especies de *Prosopis* sp. con la metodología convencional y se encontraron diferencias significativas entre las especies para las características dasométricas e índices de vegetación, así como en la comparación con los datos obtenidos con el LiDAR. Se seleccionaron modelos para determinar BAF y la asociación entre el carbono aéreo obtenido con los modelos constituidos por datos de LiDAR e índices de vegetación que presentaron correlaciones significativas ($p < 0,05$), se construyeron siete modelos para predicción de carbono y destaca el modelo que tiene como variables regresoras la altura total y área de copa obtenidas del LiDAR, así como los índices Clgreen, GNDVI, RECI, LCI y NDVI ($R^2 = 0,77$). Lo cual confirma que el uso de la metodología LiDAR con los índices de vegetación permite una estimación más práctica del carbono almacenado en la plantación.

Palabras clave: VANT; LiDAR; biomasa; carbono almacenado; índices de vegetación.

DOI: <https://doi.org/10.17268/sci.agropecu.2025.025>

Cite this article:

Chumbimune-Vivanco, S. Y., León, H., Llanos-Carrillo, C. L., Millan-Ramírez, A., Vilca-Gamarra, C., Vera, E., Agurto, A., Baselly-Villanueva, J. R., & Cruz-Grimaldo, C. (2025). Integración de VANT-LiDAR con imágenes multiespectrales para la estimación del carbono almacenado en plantaciones forestales de *Prosopis* sp.. *Scientia Agropecuaria*, 16(3), 333-348.

1. Introducción

Los bosques secos tropicales son uno de los biomas más amenazados (Paladines, 2003) y menos estudiados del mundo (Blackie et al., 2014). Los individuos del género *Prosopis*, conocidos como algarrobos, son especies clave en el equilibrio ecológico del bosque seco. Contribuyen a mejorar la fertilidad y humedad del suelo, regulan el microclima bajo su copa y fortalecen la estabilidad de la llanura fluvial con sus extensos sistemas radiculares (Beresford-Jones & Whaley, 2021). Además, desempeñan un papel importante en la mitigación del cambio climático debido a su capacidad de almacenar CO₂ (Méndez et al., 2012). Sin embargo, el taxón es amenazado por un conjunto de factores como la deforestación, cambio de uso de suelo, de clima, afectaciones a su estructura forestal por incendios forestales, así como pérdida de diversidad lo cual incrementaría la tensión de estos ecosistemas (Calvo-Rodriguez et al., 2021), siendo una acción prioritaria su monitoreo y conservación junto al ecosistema de bosque seco (Vera et al., 2024). Así como, acciones de reforestación para recuperar el equilibrio ecosistémico en las áreas degradadas (Beresford-Jones et al., 2009), para ser utilizada como sistemas silvopastoriles y protección contra la desertificación (Guariguata et al., 2017).

La medición y evaluación de la biomasa aérea forestal (BAF) representa un papel importante en el manejo forestal y en la mitigación del cambio climático por su relación directa con el carbono que almacenan los ecosistemas forestales (Sione et al., 2020; Su et al., 2023). Por lo que es crucial determinar la cantidad de biomasa utilizando parámetros que sean fáciles de medir (Assefa et al., 2023). La BAF puede ser estimada por métodos directos o destructivos, que implican la extracción de los árboles y métodos indirectos, como los modelos alométricos (Carpp et al., 2017). Diversos modelos se han desarrollado para especies tropicales y subtropicales, pero muy pocos para aquellas de zonas semiáridas (Méndez et al., 2012). El diámetro basal (DB), altura total (HT) y área de copa (AC) son las variables más utilizadas para la predicción de biomasa en árboles jóvenes, de tallo múltiple y arbustos; siendo evaluadas mediante métodos convencionales (Zeng et al., 2010; Muturi et al., 2011).

El monitoreo de los bosques y plantaciones es una labor imprescindible para el entendimiento y manejo forestal. No obstante, existen limitaciones en los métodos convencionales de medición, que incluyen un proceso de recolección de datos con inversión de tiempo y costos altos (Al-Jabri et al., 2025). La evaluación y monitoreo de bosques se

han incrementado a lo largo de los años, en la actualidad las técnicas de teledetección cumplen un rol importante para la realización inventarios forestales (Remache-Reinoso et al., 2024) y obtención de información del estado de distintos tipos de cubiertas vegetales (Li et al., 2015; Mohan et al., 2017). El uso de Vehículos Aéreos No Tripulados (VANTS) representan una alternativa de detección económica capaz de generar datos precisos de manera rápida y cubrir extensas áreas (Xu et al., 2025; Matese et al., 2015).

Los sensores pasivos y activos están en aumento en el uso de técnicas de teledetección para estudios y evaluaciones forestales (Colomina et al., 2014), enfocándose principalmente, en los atributos individuales de la estructura forestal, inventarios y monitoreo del vigor forestal (Gallardo-Salazar et al., 2020). La cámara multiespectral es un sensor pasivo capaz de captar varios espectros de la luz y dividirlos en bandas espectrales, generando a partir de ellas índices de vegetación (Candiago et al., 2015), comúnmente utilizados para estudios de vigorosidad o estado de la vegetación (Plaza, 2020; Modica et al., 2020) y en algunos casos para la determinación de BAF mediante métodos de regresión (Baloloy et al., 2018; Tafur et al., 2022).

LiDAR por sus siglas en inglés *Light Detection and Ranging* es un sensor activo y es una alternativa viable para recolección de datos forestales (Tafur et al., 2022). El sensor genera información tridimensional detallada sobre la estructura del bosque y terreno, el cual permite estimar la altura de los árboles, dimensión de copa (Wallace et al., 2014) y realizar una estratificación vertical mejorada de la vegetación y el terreno debido a su mayor penetración en el dosel (Pearse et al., 2018). Estudios con LiDAR han demostrado que permite estimar detección individual de los árboles (Jarahizadeh y Salehi 2025), correctamente variables como la altura de los árboles (Liao et al., 2022; Dalla et al., 2020; Ganz et al., 2019) y a partir de estas características elaborar modelos de predicción de BAF (Islas-Gutierrez et al., 2024).

La mayoría de los estudios de biomasa y stock de carbono en algarrobo se efectuaron mediante métodos destructivos, en donde las variables regresoras fueron evaluadas con métodos convencionales (Carpp et al., 2017; Sione et al., 2020). La presente investigación pretende contribuir con la generación de información para el monitoreo de las plantaciones de *Prosopis* sp. a través del uso de imágenes multiespectrales y LiDAR, con la finalidad de validar estas metodologías y generar modelos que permitan estimar el carbono almacenado de una manera sencilla y eficiente.

2. Metodología

Área de estudio

El área de estudio comprende una plantación de algarrobo, instalada el 9 de octubre de 2021 y ubicada en la Estación Experimental Agraria Vista Florida (EEA VF) del Instituto Nacional de Innovación Agraria, en el distrito de Picsi, Lambayeque, Perú (Figura 1a). La plantación se subdividió en dos unidades experimentales: monitoreo (Figura 1c) y validación (Figura 1b). Geográficamente, se localiza entre los 6° 43' 37,65" S y 79° 47' 25,46" O a una altitud promedio de 30 m.s.n.m. La zona de estudio se caracteriza por presentar una temperatura media anual de 21 °C (máxima de 28 °C y mínima de 22 °C), velocidad de viento que oscilan 32-37 km/h durante el día y ausencia de precipitaciones significativas, típico del ecosistema del bosque seco del norte del Perú. El suelo es franco arcillo arenoso con pH de 9,16 y contenido de materia orgánica de 2,37%.

Evaluación convencional

En la parcela de monitoreo se evaluaron siete especies de algarrobo: *P. alba* var. *alba*, *P. alba* var.

panta, *P. calderensis*, *P. chilensis*, *P. limensis*, *P. mantaroensis*, *P. sp* y *P. purpurea*. Se consideraron todos los individuos de las especies mencionadas, siendo un total de 74, y se realizaron cuatro evaluaciones entre junio y setiembre del 2024, obteniendo un total de 296 mediciones. En la parcela de validación se evaluaron 59 individuos de *Prosopis* sp. Las variables dasométricas evaluadas fueron el diámetro basal (DB) y la altura total (HT) con una cinta diamétrica y un dendrómetro digital Criterion RD 1000 (Laser Technology Inc., Colorado, EE. UU.) respectivamente. Así mismo, se evaluó el área de la copa (AC) que se determinó empleando la fórmula de círculo con los radios, para ello se consideró la medición desde el fuste hasta la proyección de la copa en sentido de los ejes cardinales (N, S, E y O), acorde a la metodología de Bueno et al., (2022) quienes recomiendan medir varios radios en copas asimétricas. Se consideró la fórmula propuesta por Cisneros et al., (2019): $AC = \pi \times rc^2$ Donde AC es el área de la copa (m²) y rc es el radio promedio de la copa (m).



Figura 1. a) Mapa de ubicación del área de estudio. b) Parcela de validación. c) Parcela de monitoreo.

Adquisición y procesamiento de ortofotos multispectrales

Se adquirió información multispectral de la cámara Micasense RedEdge-MX Dual (Micasense Inc., Seattle, EE. UU.) acoplada a un VANT Matrice 300 RTK (DJI, Shenzhen, China). Para mejorar y ajustar la georreferenciación de la nube de puntos y los modelos digitales, se establecieron 6 puntos de control sobre el terreno. Los parámetros de vuelo establecidos fueron: 40 m de altura, 1,9 m/s de velocidad, así como un traslape horizontal y frontal de 75% y 80% respectivamente. El vuelo se realizó bajo condiciones de cielo despejado y soleado en un horario de 11:00 hasta las 13:00 horas, siguiendo la metodología descrita por [Lu et al. \(2020\)](#). Las imágenes se procesaron con el software fotogramétrico Pix4D Mapper V4.3.33 (Pix4D S.A., Prilly, Suiza) obteniéndose el Modelo Digital de Superficie y Modelo Digital del Terreno o DSM y DTM por sus siglas en inglés, respectivamente. El Modelo de altura del dosel (CHM, por sus siglas en inglés) y los índices de vegetación (IV) se calcularon con el programa QGIS 3.22.11. En la [Tabla 1](#) se muestran los índices de vegetación empleados.

Adquisición y procesamiento de data LiDAR

Los datos de la nube de puntos se obtuvieron utilizando el sensor LiDAR modelo ALPHA AIR450 (CHCNAV, Shangai, China) acoplado a un VANT DJI Matrice 300 RTK. El vuelo se realizó a una altura de 30 m, con traslape horizontal y frontal de 75% y

80%, respectivamente ([Figure 2](#)), generando un total de 19 274 785 de puntos por vuelo. Los datos adquiridos fueron preprocesados para generar una densa y optimizada nube de puntos en formato LAS, utilizando el programa CoPre2 Versión 2.7.3 (UPV, Valencia, España), a partir del cual se obtuvo el DSM. Los procesos posteriores para generar el DTM y CHM se realizaron en el programa QGIS Desktop 3.22.11. El CHM se obtuvo del cálculo de la diferencia entre el DSM y el DTM. En la [Figura 3](#) se puede observar el DTM y CHM para ambas unidades experimentales.

Estimación de biomasa y carbono

La biomasa aérea se estimó utilizando modelos alométricos desarrollados para el género *Prosopis*, que tienen como variables regresoras DB y HT, como se muestra en la [Tabla 2](#) ([Duff et al., 1994](#), [Muturi et al., 2011](#) y [Méndez et al., 2012](#)). La selección de los modelos se basaron en el coeficiente de determinación (R^2), una métrica estándar para la evaluación de los modelos de regresión acorde con [Chicco et al. \(2021\)](#). La cantidad de carbono se calculó multiplicando la biomasa estimada y la fracción de carbono predeterminada del IPCC, que es 0,47 ([Walker et al., 2016](#)). Este valor, es consistente con estudios previos realizados en especies del mismo género, donde *Prosopis affinis* y *P. nigra* obtuvieron fracciones de C promedio $0,474 \pm 0,02$ y de $0,481 \pm 0,011$, respectivamente ([Sione et al., 2022](#)).

Tabla 1
Índices de vegetación (IV) empleados

IV	Ecuación	Fuente
Índice de clorofila verde (Clgreen)	$Clgreen = \frac{NIR}{Green} - 1$	Gitelson et al. (2005)
Índice de vegetación de clorofila (CVI)	$CVI = \frac{NIR}{Green} * \frac{Red}{Green}$	Meng et al. (2015)
Índice de vegetación mejorado (EVI)	$EVI = \frac{2.5 (NIR - Red)}{(NIR + 6Red - 7.5Blue + 1)}$	Phadikar & Goswami (2016)
Índice de Vegetación de Diferencia Normalizada Verde (GNDVI)	$GNDVI = \frac{NIR - Green}{NIR + Green}$	Pourazar et al. (2019)
Índice de Clorofila Foliar (LCI)	$LCI = \frac{NIR - Red\ Edge}{NIR + R}$	Eitel et al. (2011)
Índice Modificado de Absorción de Clorofila en la Reflectancia. (MCARI)	$MCARI = \frac{Red\ Edge * Red}{[(Red\ Edge - Red) - 0.2(Red\ Edge - Green)]}$	Jain et al. (2007)
Índice de Diferencia Normalizada del Borde Rojo (NDRE)	$NDRE = \frac{NIR - Red\ Edge}{NIR + Red\ Edge}$	Pourazar et al. (2019)
Índice de Vegetación de Diferenciada Normalizada (NDVI)	$NDVI = \frac{NIR - Red}{NIR + Red}$	Pourazar et al. (2019)
Índice de Diferencia Normalizada de Agua (NDWI)	$NDWI = \frac{Green - NIR}{Green + NIR}$	Meng et al. (2015)
Índice Normalizado de Pigmento de Clorofila (NPCl)	$NPCl = \frac{Red - Blue}{Red + Blue}$	Jain et al. (2007)
Índice de Clorofila del Borde Rojo (RECI)	$RECI = \frac{NIR}{Red} - 1$	Gitelson et al. (2005)
Índice de Vegetación Ajustado al Suelo (SAVI)	$SAVI = \frac{(NIR - Red)(1 + L)}{NIR + Red + L}$	Meng et al. (2015)

Donde: Red, Green, Blue, NIR y Red Edge corresponden a la banda roja, verde, azul, NIR y rojo borde, respectivamente.




Figura 2. a) Plantación de algarrobo y Matrice 300 RTK con LiDAR acoplado. b) Plan de vuelo. c) Reconstrucción de ruta y nube de puntos obtenidos con el LiDAR.




Figura 3. DTMs y CHMs calculados a partir de los datos LiDAR para el área de estudio. a y b: parcela de monitoreo, c y d: parcela de validación.

Tabla 2

Modelos genéricos para estimar la biomasa aérea total de especies del género *Prosopis*.

Autor	Modelo	R ²	Variedad
Salazar et al., 2023	$B = \exp(3,88 + 0,066 * (DB))$	0,79	<i>P. pallida</i>
Sione et al., 2019	$B = \exp(-3,23 + 2,61 * \ln(DB))$	0,97	<i>P. affinis</i>
Sione et al., 2020	$B = \exp(-2,86 + 2,60 * \ln(DB))$	0,98	<i>P. nigrans</i>
Muturi et al., 2012	$B = \exp(0,2933(DB) - 0,03)$	0,92	<i>Prosopis sp.</i>
Padrón y Navarro, 2004	$B = 66,5541 + 0,05796 * (DB)^2 * HT$	0,96	<i>P. pallida</i>

Donde: B es la biomasa aérea (kg); DB: diámetro en la base 0,3 m sobre el nivel del suelo (cm); HT: altura total (m); exp: Exponencial; Ln: logaritmo natural.

Análisis estadístico

Los datos fueron analizados estadísticamente en el software R versión (v. 4.3.3) (R Core Team, 2020, Auckland, Nueva Zelanda). La comparación de las variables dasométricas e IV entre especies se realizó con la prueba no paramétrica de Kruskal-Wallis ($p < 0,05$), debido a que no se cumplió con el supuesto de normalidad (Kolmogorov-Smirnov, $p < 0,05$).

La comparación entre las diferentes metodologías de realizó mediante prueba de Wilcoxon para muestras apareadas ($p < 0,05$); así mismo, se evaluó el error de medición usando la siguiente fórmula:

$$\bar{E} = \frac{Y_i - \bar{Y}_i}{Y_i}$$

Donde, Y_i y $\bar{Y}_i$ son los valores obtenidos con el método convencional y LiDAR, respectivamente.

Adicionalmente, se realizaron regresiones lineales ($p < 0,05$), considerando como variables predictora y predicha a los datos obtenidos mediante el LiDAR y convencional, respectivamente.

Se evaluó la correlación entre el carbono almacenado y las variables dasométricas e IV mediante la prueba Spearman ($p < 0,05$). Finalmente, se generaron modelos para estimar el carbono, se consideró como variables predictora datos LiDAR e índices de vegetación y se usó la técnica de regresión por pasos, de acuerdo con la metodología usada por Cárdenas-Rengifo et al. (2024). La significancia de las regresiones y los parámetros se analizó mediante las pruebas de F y t ($p < 0,05$), y la bondad estadística de se evaluó mediante el coeficiente de determinación (R^2).

3. Resultados y discusión

Evaluación convencional e índices de vegetación

La variación de las características dasométricas entre especies se presenta en la Tabla 3. Existió diferencias altamente significativas en las variables dasométricas ($p < 0,05$), donde *P. alba var. panta* y *P. alba var. alba* son las que presentaron mayor desarrollo con valores promedios de 22,04 y 21,34 cm de diámetro basal (DB), 6,32 y 5,96 m en altura total (HT), 47,15 y 51,42 m² en área de copa respectivamente, siendo estadísticamente superiores respecto a las demás especies. *P. sp* y *P. calderensis*

fueron estadísticamente inferiores a las demás especies con valores de DB de 5,92 y 7,87 cm, HT de 2,44 y 2,58 m y AC de 7,06 y 12,15 m² respectivamente. Estos resultados coinciden con estudios previos que señalan que la especie *P. alba*, incluyendo sus dos variedades *var. alba* y *var. panta* (Fontana et al., 2020), presenta un crecimiento rápido y tiene una fuerte dominancia del eje principal (Castillo, 2022), además de tener copas redondeadas muy extendidas (Cisneros et al., 2019).

En la Tabla 3 se muestran los resultados promedios de los índices de vegetación (IV), se evidencia que existen diferencias altamente significativas entre las especies estudiadas ($p < 0,05$). *P. alba var. panta* y *P. purpurea* presentaron los mayores valores promedios para los índices de CIgreen, EVI, GNDVI, LCI, MCARI, NDRE, NDVI, RECI y SAVI, siendo estadísticamente superiores a los valores obtenidos para *P. alba var. alba*. Por otro lado, *P. purpurea* fue estadísticamente inferior en los valores obtenidos para los índices CVI, NDWI y NPCI.

En la Figura 4 se observan los IV, donde NDVI, SAVI, GNDVI y EVI revelan una clara diferenciación entre la copa y el suelo en el área de estudio. Sin embargo, se presentan algunas áreas de suelo dentro de la copa debido a su escaso desarrollo foliar actual. Los índices NDWI y NPCI presentan valores más bajos para todos los árboles. Estos resultados sugieren que los IV pueden ser una herramienta útil para caracterizar las diferentes especies, incluso cuando las características dasométricas son similares, lo cual coincide con lo descrito por Reis-Pereira et al. (2023). La combinación de valores altos y bajos en los IV, junto con las diferencias observadas entre especies, podría estar relacionada con factores botánicos como el tamaño y pubescencia de los folíolos, como sucede para *P. alba var. alba* (Fontana et al., 2020), así como la posible hibridación interespecífica dentro del género (Castillo, 2022).

Estos hallazgos respaldan la importancia de utilizar los IV para complementar los análisis tradicionales y obtener una caracterización más detallada de las especies.

Comparación de metodologías y data LiDAR

La comparación de los datos convencionales y del CHM, obtenidos a partir del LiDAR, para el cálculo de la altura total (HT) y área de copa (AC) se muestran en la **Tabla 4**. Los resultados obtenidos para la HT muestran diferencias altamente significativas para las especies *P. alba* var. *alba*, *P. alba* var. *panta*, *P. calderensis*, *P. chilensis*, *P. limensis*, y *P. purpurea* ($p < 0,05$); mientras que para *P. mantaroensis* y *P. sp* no se encontraron diferencias significativas. Respecto, a los resultados del AC se observan diferencias significativas para las especies *P. chilensis*, *P. limensis*, *P. mantaroensis* y *P. sp* (**Tabla 4**); en el caso de *P. alba* var. *alba*, *P. alba* var. *panta*, *P. calderensis* y *P. purpurea* no se obtuvieron diferencias significativas. Los valores de HT obtenidos a partir del CHM fueron menores a los del método convencional y presentaron diferencias significativas, esto puede deberse a la heterogeneidad de la altura, propia de cada árbol, que influye en las estimaciones (Taubert et al., 2021). En el caso de AC, la mitad de las especies no presentaron diferencias significativas, esto puede deberse al método de medición de radios que aumenta la precisión para copas asimétricas (Bueno et al., 2022). En base a los resultados obtenidos se determinó el error de medición en ambas metodologías por especie. Se evidencia que los valores de la HT (metodología con LiDAR) fueron menores que los obtenidos por el método convencional; destacando una mayor

subestimación para valores inferiores a 3 m de HT, para *P. calderensis*, *P. chilensis* y *P. sp* (**Figura 5e, 5g y 5m**). La tendencia de subestimación de la HT también fue reportada por Rodríguez-Puerta et al. (2021), especialmente en árboles de menor tamaño. En el caso del AC se evidencia un mayor error en las mediciones con LiDAR en individuos con copas pequeñas (**Figura 5f, 5h, 5l y 5n**). Li et al. (2024) asocia estas tendencias a factores ligados como el tipo de sensor, plataforma o condiciones ambientales en el momento de la recolección de datos.

Por otro lado, *P. alba* var. *alba* y *P. alba* var. *panta* presentaron los menores porcentajes de error (**Figura 5a, 5b, 5c y 5d**), lo que sugiere una mayor consistencia en la estimación de HT y AC entre ambas metodologías. Este comportamiento coincide con lo encontrado por Rodríguez-Puerta et al. (2021), quienes mencionan que el porcentaje de error disminuye a medida que la altura del árbol aumenta y en este estudio ambas variedades presentaron mayor HT. Por otro lado, *P. mantaroensis* tiene mayor porcentaje de error para la HT y AC (**Figura 5i y 5j**), debido a la asimetría de su copa, lo que dificulta su medición. Por lo cual, el desarrollo y estructura del árbol influyen en la precisión de la medición, lo que guarda relación con el estudio de Liao et al., (2022) quienes afirman que los tamaños y formas de las copas de diferentes especies pueden afectar los resultados de la medición.




Figura 4. Índices de vegetación obtenidos en la parcela de monitoreo para especies del género *Prosopis*. a) *P. alba*, b) *P. purpurea*, c) *P. chilensis*, d) *P. limensis*, e) *P. calderensis* f) *P. sp*, g) *P. panta*, h) *P. mantaroensis*.

Tabla 3
Caracterización de las especies del género *Prosopis*. Diámetro basal (DB); altura total (HT), área de copa (AC) e índices de vegetación (IV). Letras diferentes presentan diferencias estadísticas significativas según la prueba de Kruskal-Wallis ($p < 0,05$).

Variables	Especies								p-valor
	<i>P. alba var. alba</i>	<i>P. alba var. panta</i>	<i>P. calderensis</i>	<i>P. chilensis</i>	<i>P. limensis</i>	<i>P. mantaroensis</i>	<i>P. purpurea</i>	<i>P. sp</i>	
Dasométricas									
DB (cm)	21,34±4,91a	22,04±5,22a	7,87±2,32d	10,62±2,88c	13,37±2,36b	12,51±6,38c	10,29±1,87c	5,92±1,72d	<0,0001
H (m)	5,96±0,93a	6,32±1,21a	2,58±0,73e	4,15±1,18c	4,88±0,68b	3,81±1,25cd	3,38±0,8d	2,44±0,39e	<0,0001
AC (m²)	51,42±6,30a	47,15±11, 39a	12,15±8,07de	15,97±6,92cd	18,79±4,23c	28,59±10,85b	16,76±5,61cd	7,06±2,86e	<0,0001
Índices de vegetación									
CIgreen	3,22±0,70bc	4,47±1,29a	2,61±0,88e	2,81±0,79de	2,91±0,45cde	2,89±0,69cde	3,75±0,82ab	3,13±0,79cd	<0,0001
CVI	4,34±0,50ab	4,66±0,71a	3,61±0,46c	2,93±0,49d	2,86±0,32d	4,11±0,53b	3,30±0,69c	3,35±0,39c	<0,0001
EVI	0,35±0,08b	0,45±0,07a	0,32±0,13b	0,41±0,14a	0,42±0,08a	0,33±0,09b	0,48±0,16a	0,42±0,12a	<0,0001
GNDVI	0,61±0,05b	0,67±0,07a	0,55±0,08c	0,57±0,07bc	0,59±0,03bc	0,58±0,07bc	0,64±0,05a	0,60±0,06b	<0,0001
LCI	0,53±0,13bc	0,64±0,16a	0,47±0,15c	0,55±0,16b	0,60±0,13ab	0,49±0,14c	0,64±0,13a	0,58±0,14ab	<0,0001
MCARI	0,16±0,07b	0,24±0,09a	0,16±0,11b	0,30±0,20a	0,28±0,10a	0,14±0,07b	0,40±0,24a	0,25±0,11a	<0,0001
NDRE	0,27±0,04c	0,35±0,06a	0,23±0,06d	0,26±0,06c	0,27±0,04c	0,26±0,05c	0,31±0,06b	0,28±0,06bc	<0,0001
NDVI	0,59±0,09de	0,70±0,10ab	0,53±0,13e	0,63±0,15cd	0,68±0,07abc	0,55±0,12e	0,72±0,11a	0,65±0,12bcd	<0,0001
NDWI	-0,61±0,05b	-0,67±0,07c	-0,55±0,08a	-0,57±0,07ab	-0,59±0,03ab	-0,58±0,07ab	-0,64±0,05c	-0,60±0,06b	<0,0001
NPCI	0,21±0,04a	0,17±0,03bc	0,19±0,04ab	0,19±0,05ab	0,16±0,04c	0,21±0,04a	0,15±0,07c	0,17±0,05c	<0,0001
RECI	3,21±1,10cd	5,69±2,49a	2,75±1,57d	4,46±2,52bc	4,53±1,33ab	2,79±1,07d	6,52±3,23a	4,35±1,93bc	<0,0001
SAVI	0,34±0,07c	0,43±0,07a	0,31±0,11c	0,39±0,12b	0,39±0,06ab	0,32±0,08c	0,45±0,12a	0,39±0,10ab	<0,0001

Tabla 4
Comparación de datos obtenidos de manera convencional y LiDAR para especies del género *Prosopis*

Especies	Altura total (m)			Área de copa (m²)		
	Convencional	LiDAR	p-valor	Convencional	LiDAR	p-valor
<i>P. alba var. alba</i>	5,96	5,49	<0,0001	51,42	53,08	0,391
<i>P. alba var. panta</i>	6,32	5,76	<0,0001	47,15	50,49	0,077
<i>P. calderensis</i>	2,58	2,21	<0,0001	12,15	10,85	0,482
<i>P. chilensis</i>	4,15	3,80	<0,0001	15,97	17,89	0,002
<i>P. limensis</i>	4,88	4,47	<0,0001	18,79	23,09	0,000
<i>P. mantaroensis</i>	3,81	3,84	0,9202	28,59	23,14	0,000
<i>P. purpurea</i>	3,38	3,09	<0,0001	16,76	16,15	0,514
<i>P. sp</i>	2,44	2,38	0,012	7,06	5,78	0,029




Figura 5. Error de medición entre datos convencional vs LIDAR para especies del género *Prosopis*.

Considerando las diferencias significativas encontradas entre las especies, se desarrollaron regresiones lineales entre las medidas convencionales y los datos LiDAR para cada variedad, así como una regresión general para todos los individuos evaluados (Figura 6). Las regresiones lineales de HT fueron estadísticamente significativas para todas las variables ($p < 0,05$), la variabilidad de los datos se explicó en un rango de entre 72% y 91%. La regresión para *P.*

purpurea mostró un ajuste muy bueno ($R^2 = 0,91$); mientras que para las especies *P. alba var. alba*, *P. calderensis*, *P. chilensis* y *P. alba var. panta* se encontró un ajuste bueno ($R^2 = 0,81-0,89$); *P. limensis*, *P. mantaroensis* y *P. sp* obtuvieron ajustes satisfactorios ($R^2 = 0,72 - 0,78$) y la ecuación general para todas las especies obtuvo un coeficiente de 0,89 clasificado como bueno según la escala de valores de Raes et al. (2023).




Figura 6. Regresión lineal entre medidas convencionales y datos LiDAR para especies del género *Prosopis*.
* = $p < 0,05$, ** = $p < 0,01$, *** = $p < 0,001$ y ns = $p > 0,05$

Con respecto a la variable AC, las regresiones lineales fueron estadísticamente significativas para todas las especies ($p < 0,05$) a excepción de *P. purpurea* y *P. sp*, la variabilidad de los datos se explicó en un rango de entre 6% y 76% (Figura 5b). *P. chilensis* obtuvo un ajuste satisfactorio ($R^2 = 0,76$), mientras que las demás especies obtuvieron coeficientes menores. La ecuación general para todas las

especies presentó un R^2 de 0,80, considerado como bueno según la clasificación mencionada. Los análisis de regresión muestran un mayor grado de precisión en los modelos para predecir la altura a partir de los datos LiDAR, así como en estudios similares con otras especies, donde obtuvieron valores de R^2 que van desde satisfactorios como 0,77 para Chung et al. (2019) a muy buenos en rangos

de 0,91 a 0,99 (Liao et al., 2022; Dalla et al, 2020; Ganz et al., 2019). En el caso del área de copa, existe un menor grado de precisión, esto puede deberse a las características irregulares propias de cada variedad y al método de realizar las mediciones con proyecciones fijas, ya que al analizar por especies se observan valores más bajos si se comparan con la ecuación general (Xu et al., 2013).

Estimación de carbono

La asociación entre el carbono almacenado estimado mediante los modelos seleccionados y los datos obtenidos de LiDAR e índices de vegetación (IV) se pueden observar en la **Tabla 5**; en ella se muestra que las correlaciones fueron significativas ($p < 0,05$), a excepción del índice NPCI. La mayor asociación se observó entre los datos obtenidos del LiDAR y el modelo de **Padrón & Navarro (2004)**, desarrollado para *P. pallida* en la región norte del Perú.

Con respecto a los IV, las correlaciones más altas se obtuvieron para el modelo de **Padrón & Navarro (2004)**, como se evidencia para EVI, LCI, MCARI, NDVI, RECI y SAVI. Los resultados obtenidos pueden atribuirse a que el modelo de **Padrón & Navarro (2004)** tiene como variables predictoras el DB y la HT, mientras que los otros modelos solo consideran como variable regresora el DB (**Tabla 2**). En esta tabla, los mayores valores se observan para GNDVI, Clgreen y NDRE, índices relacionados a la salud y al contenido de clorofila presente en las plantas (**Brewer et al., 2022**).

La regresión por pasos generó 7 modelos significativos que explicaron la variabilidad de los datos en un rango entre 71% y 77% (**Tabla 6**). Los modelos más simples utilizan solo como variables predictoras las características dasométricas obtenidas con el LiDAR (modelo 1 y 2), mientras que modelos con

mayor capacidad de estimación incluyen IV (modelo 6). El modelo 7 que tiene como variables regresoras la HT y AC del LiDAR, así como los índices Clgreen, GNDVI, RECI, LCI y NDVI estimó mejor la captura de carbono para todas las especies; presentando un R^2 de 0,77. **Zhai et al. (2025)** indican que el NDVI y otros índices de vegetación similares hacen hincapié en el crecimiento de la vegetación; sin embargo, aún se requiere una mayor validación para considerar el coeficiente de variación espectral como un indicador de las características biológicas y fisiológicas de las plantaciones.

Los modelos que integran características dasométricas y datos espectrales tienen mayores coeficientes de determinación, coincidiendo con diferentes estudios donde muestran que la combinación de los IV y las características estructurales como la altura, producen estimaciones más precisas de la biomasa (**Poley & McDermind, 2020; Corti et al., 2022; Zhang et al., 2024**). La importancia de los IV en estos modelos se debe a la relación de las propiedades intrínsecas de las plantas que están ligadas con la acumulación de biomasa, como el verdor y el vigor de las hojas. En estudios similares, con datos de satélite, utilizaron el NDVI y el GNDVI, encontrando un coeficiente de determinación de 0,7 (**Baloloy et al., 2018**), similar al obtenido en esta investigación. Los algarrobos en promedio tienen almacenado ~ 62,43 kg de carbono almacenado (C), mientras que las especies *P. alba* var. *alba* y *P. alba* var. *panta* registraron mayores valores de C (>100 kg), siendo estadísticamente superiores respecto a las demás especies (**Figura 7**). Por otro lado, *P. sp* y *P. calderensis* obtuvieron los menores valores de C. Esto se debe a que el carbono almacenado es directamente proporcional a la biomasa y está relacionada con las características dasométricas.

Tabla 5
Relación del carbono almacenado (kg/árbol) con datos LIDAR e índices de vegetación para especies del género *Prosopis*.

Variable	C (Padrón & Navarro, 2004)	C (Salazar et al., 2023)	C (Sione et al., 2019)	C (Sione et al., 2020)	C (Muturi et al. 2012)
HT-LiDAR	0,927**	0,894**	0,894**	0,894**	0,894**
AC LiDAR	0,911**	0,884**	0,884**	0,884**	0,884**
Clgreen	0,358**	0,363**	0,363**	0,363**	0,363**
CVI	0,331**	0,346**	0,346**	0,346**	0,346**
EVI	0,186**	0,184**	0,184**	0,184**	0,184**
GNDVI	0,361**	0,366**	0,366**	0,366**	0,366**
LCI	0,206**	0,185**	0,185**	0,185**	0,185**
MCARI	0,131*	0,120*	0,120*	0,120*	0,120*
NDRE	0,349**	0,354**	0,354**	0,354**	0,354**
NDVI	0,258**	0,251**	0,251**	0,251**	0,251**
NPCI	-0,072 ^{ns}	-0,076 ^{ns}	-0,076 ^{ns}	-0,076 ^{ns}	-0,076 ^{ns}
RECI	0,249**	0,242**	0,242**	0,242**	0,242**
SAVI	0,201**	0,198**	0,198**	0,198**	0,198**

Tabla 6
Modelos de regresión para estimar el carbono mediante datos LiDAR e índices de vegetación para especies del género *Prosopis*

Modelo		Coeficientes		p-valor	F	R²
		B	Error estándar			
1	(Constante)	13,775	2,222	0,000	0,000	0,71
	AC LiDAR	1,987	,074	0,000		
2	(Constante)	-2,426	4,095	0,554	0,000	0,73
	AC LiDAR	1,460	,134	0,000		
	HT- LiDAR	7,444	1,602	0,000		
3	(Constante)	-12,757	4,928	0,010	0,000	0,74
	AC LiDAR	1,428	,132	0,000		
	HT- LiDAR	6,277	1,603	0,000		
	Clgreen	4,910	1,359	0,000		
4	(Constante)	80,294	21,215	0,000	0,000	0,76
	AC LiDAR	1,431	,127	0,000		
	HT- LiDAR	6,367	1,553	0,000		
	Clgreen	22,342	4,090	0,000		
	GNDVI	-249,271	55,376	0,000		
5	(Constante)	67,743	21,739	0,002	0,000	0,76
	AC LiDAR	1,312	,136	0,000		
	HT- LiDAR	6,904	1,558	0,000		
	Clgreen	26,207	4,387	0,000		
	GNDVI	-230,548	55,550	0,000		
	RECI	-2,390	1,029	0,021		
6	(Constante)	59,864	21,902	0,007	0,000	0,76
	AC LiDAR	1,265	,137	0,000		
	HT- LiDAR	7,223	1,555	0,000		
	Clgreen	26,201	4,359	0,000		
	GNDVI	-196,401	57,385	0,001		
	RECI	-2,382	1,022	0,020		
	LCI	-22,625	10,401	0,030		
7	(Constante)	102,426	28,719	0,000	0,000	0,77
	AC LiDAR	1,321	,139	0,000		
	HT- LiDAR	6,383	1,588	0,000		
	Clgreen	37,488	6,594	0,000		
	GNDVI	-398,935	105,898	0,000		
	RECI	-6,032	1,902	0,002		
	LCI	-26,106	10,441	0,013		
	NDVI	98,638	43,473	0,024		




Figura 7. Comparación de carbono estimado para especies del género *Prosopis*. Letras diferentes presentan diferencias estadísticas significativas según la prueba de Kruskal-Wallis ($p < 0.05$).

En la **Figura 8** se presentan los diagramas de dispersión que comparan las estimaciones de HT, AC y carbono almacenado obtenidas mediante métodos convencionales y a partir de datos LiDAR para la parcela de validación. Los resultados revelan una alta correlación lineal entre ambas metodologías, con coeficientes de correlación (ρ) de 0,94, 0,82 y 0,61 para la HT, carbono almacenado y AC, respectivamente. Estos valores indican una excelente correspondencia entre las estimaciones de HT, una muy buena concordancia para el carbono almacenado y satisfactoria para el AC. La buena correlación obtenida entre el modelo que emplea datos LiDAR e IV para estimar el carbono almacenado, indica que el modelo empleado es fiable para estimar el carbono a partir de sensores remotos al igual que para las variables dasométricas, lo que corrobora hallazgos en investigaciones previas (Vashum & Jayakumar, 2012).

4. Conclusiones

La presente investigación demuestra la viabilidad y eficacia de emplear imágenes multiespectrales y tecnología LiDAR para evaluar el stock de carbono en plantaciones de algarrobo (*Prosopis* sp.), ofreciendo una alternativa no destructiva a los métodos tradicionales. Al comparar las estimaciones obtenidas mediante LiDAR y métodos convencionales, se observaron correlaciones significativas, especialmente en la estimación del carbono almacenado ($\rho = 0,82$). Estos resultados respaldan la solidez de los modelos desarrollados para estimar el carbono a

partir de datos LiDAR y los índices de vegetación. Entre los diversos modelos evaluados, el modelo que combina los datos LiDAR e índices espectrales demostró ser el más adecuado para estimar el carbono almacenado en los árboles de algarrobo. La validación de los modelos desarrollados, utilizando una parcela independiente, confirmó la fiabilidad de las estimaciones obtenidas para la altura total, área de copa y carbono almacenado. Remarcando el potencial de la tecnología LiDAR para generar modelos de estimación del carbono más accesibles y menos invasivos, facilitando así el monitoreo a gran escala de plantaciones de *Prosopis* sp. y contribuyendo a una mejor gestión forestal. Sin embargo, para una mayor certeza de la eficiencia de estas estimaciones, se hace necesario realizar una validación más exhaustiva mediante la medición de biomasa cuantificada en muestras extraídas.

Agradecimientos

Esta investigación fue financiada por el proyecto "Creación del servicio de agricultura de precisión en los Departamentos de Lambayeque, Huancavelica, Ucayali y San Martín 4 Departamentos" con CUI 2449640 del Ministerio de Desarrollo Agrario y Riego (MIDAGRI) del Gobierno del Perú.

Contribución de los autores

S. Y. Chumbimune-Vivanco: Conceptualización, investigación, metodología, validación, visualización, redacción-borrador original. **H. León:** Investigación, metodología, visualización, redacción-revisión y edición. **C. Llanos-Carrillo:** Curación de datos, investigación, visualización, redacción-revisión y edición. **J. Millan-Ramírez:** Curación de datos e investigación. **C. Vilca-Gamarra:** Visualización e investigación. **E. Vera:** Investigación. **A. Agurto:** Adquisición de fondos. **J. R. Baselly-Villanueva:** Análisis formal, visualización, validación, redacción-revisión y edición. **C. Cruz-Grimaldo:** Investigación, supervisión y redacción-revisión y edición.




Figura 8. Validación de variables dasométricas y carbono para especies del género *Prosopis*.

* = $p < 0,05$, ** = $p < 0,01$, *** = $p < 0,001$

Declaración de conflicto de intereses

Los autores declaran no tener ningún conflicto de interés que pudiera influir en el trabajo presentado en este artículo.

ORCID

S. Y. Chumbimune-Vivanco  <https://orcid.org/0000-0002-2485-0988>
 H. León  <https://orcid.org/0000-0003-2283-7584>
 C. Llanos-Carrill  <https://orcid.org/0009-0004-0613-0049>
 J. Millan-Ramírez  <https://orcid.org/0000-0003-2683-1737>
 C. Vilca-Gamarra  <https://orcid.org/0000-0003-4748-6549>
 E. Vera  <https://orcid.org/0009-0001-7588-7422>
 A. Agurto  <https://orcid.org/0000-0001-8072-3978>
 J. R. Baselly-Villanueva  <https://orcid.org/0000-0001-7795-7925>
 C. Cruz-Grimaldo  <https://orcid.org/0000-0002-0337-3799>

Referencias bibliográficas

- Al-Jabri, K., Al-Mulla, Y., Al-Abri, A., Al-Battashi, F., Al-Sulaimani, M., Tabook, A., Al-Raba'Ni, S., Sulaiman, H., Al-Salmi, N., & Al-Shukailli, T. (2025). Integrating Remote Sensing Techniques and Allometric Models for Sustainable Carbon Sequestration Estimation in *Prosopis cineraria* – Druce Trees. *Sustainability*, 17(1), 123. <https://doi.org/10.3390/su17010123>
- Assefa, D., Mekuriaw, A., Tesfaye, M., Sewnet, H., & Belay, B. (2022). Mapping of *Prosopis juliflora* rate of expansion and developing species-specific allometric equations to estimate its aboveground biomass in the dry land of Ethiopia. *Modeling Earth Systems and Environment*, 9(1), 263–274. <https://doi.org/10.1007/s40808-022-01495-3>
- Baloloy, A. B., Blanco, A. C., Candido, C. G., Argamosa, R. J. L., Dumlalag, J. B. L. C., Dimapilis, L. L. C., & Paringit, E. C. (2018). Estimation of mangrove forest aboveground biomass using multispectral bands, vegetation indices and biophysical variables derived from optical satellite imageries: Rapideye, PlanetScope and Sentinel-2. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV–3(3), 29–36. <https://doi.org/10.5194/isprs-annals-IV-3-29-2018>
- Beresford-Jones, D. G., T. S. A., Whaley, O. Q., & Chepstow-Lusty, A. J. (2009). The Role of *Prosopis* in Ecological and Landscape Change in the Samaca Basin, Lower Ica Valley, South Coast Peru from the Early Horizon to the Late Intermediate Period. *Latin American Antiquity*, 20(2), 303–332. <https://doi.org/10.1017/S1045663500002650>
- Beresford-Jones, D., & Whaley, O. Q. (2021). *Prosopis* in the history of the coast of Peru. En *Elsevier eBooks* (pp. 95–103). <https://doi.org/10.1016/B978-0-12-823320-7.00012-2>
- Blackie, R., Baldauf, C., Gautier, D., Gumbo, D., Kassa, H., Parthasarathy, N., Paumgarten, F., Sola, P., Pulla, S., Waeber, P., & Sunderland, T. (2014). *Tropical dry forests the state of global knowledge and recommendations for future research*.
- Brewer, K., Clulow, A., Sibanda, M., Gokool, S., Naiken, V., & Mabhaudhi, T. (2022). Predicting the Chlorophyll Content of Maize over Phenotyping as a Proxy for Crop Health in Smallholder Farming Systems. *Remote Sensing*, 14(3), 518. <https://doi.org/10.3390/rs14030518>
- Bueno, G. F., Costa, E. A., Finger, C. A. G., Liesenberg, V., & Bispo, P. da C. (2022). Machine Learning: Crown Diameter Predictive Modeling for Open-Grown Trees in the Cerrado Biome, Brazil. *Forests*, 13(8), 1295. <https://doi.org/10.3390/f13081295>
- Candiago, S., Remondino, F., De Giglio, M., Dubbini, M., & Gattelli, M. (2015). Evaluating Multispectral Images and Vegetation Indices for Precision Farming Applications from UAV Images. *Remote Sensing*, 7(4), 4026–4047. <https://doi.org/10.3390/rs70404026>
- Cárdenas-Rengifo, G. P., Baselly-Villanueva, J. R., Chumbimune-Vivanco, S. Y., Macedo-Ramírez, A. T., Salazar, E., Minaya, B., Quintana, S., Cabudivo, A., Palma, S. S. A., Álvarez-Álvarez, P., & Ocaña-Reyes, J. A. (2024). Using acoustic tomography to model wood deterioration in *Cedrelinga cateniformis* Ducke in the Peruvian Amazon. *Forests*, 15(5), 778. <https://doi.org/10.3390/f15050778>
- Carpó, I. A., Sione, S. M. J., Ledesma, S. G., Oszust, J. D., & Rosenberger, L. J. (2017). *Factores de expansión de la biomasa de Prosopis affinis (spreng.), como herramienta para la estimación del carbono almacenado en bosques nativos del espinal (Entre Ríos, Argentina)*.
- Castillo, R. (2022). Actualización del conocimiento de las especies de *Prosopis* (Fabaceae-Mimosoideae) que crecen en Chile. *Revista Chilena de Flora y de Vegetación*, 25(1), 11–55.
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
- Chung, C. H., Wang, C. H., Hsieh, H. C., & Huang, C. Y. (2019). Comparison of forest canopy height profiles in a mountainous region of Taiwan derived from airborne lidar and unmanned aerial vehicle imagery. *GIScience and Remote Sensing*, 56(8), 1289–1304. <https://doi.org/10.1080/15481603.2019.1627044>
- Cisneros, A. B., Moglia, J. G., & Álvarez, J. A. (2019). Morfometría de copa en *Prosopis alba*; Griseb. *Ciencia Florestal*, 29(2), 863–884. <https://doi.org/10.5902/1980509826846>
- Colomina, I., & Molina, P. (2014). Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 92, 79–97. <https://doi.org/10.1016/j.isprsjprs.2014.02.013>
- Corti, M., Cavalli, D., Cabassi, G., Bechini, L., Picca, N., Paolo, D., Marinoni, L., Vigoni, A., Degano, L., & Marino Gallina, P. (2022). Improved estimation of herbaceous crop aboveground biomass using UAV-derived crop height combined with vegetation indices. *Precision Agriculture*, 24(2), 587–606. <https://doi.org/10.1007/s11119-022-09960-w>
- Calvo-Rodríguez, S., Sánchez-Azofeifa, G. A., Durán, S. M., Do Espírito-Santo, M. M., & Ferreira Nunes, Y. R. (2021). Dynamics of Carbon Accumulation in Tropical Dry Forests under Climate Change Extremes. *Forests*, 12(1), 106. <https://doi.org/10.3390/f12010106>
- Dalla Corte, A. P., Rex, F. E., Almeida, D. R. A. de, Sanquetta, C. R., Silva, C. A., Moura, M. M., Wilkinson, B., Zambrano, A. M. A., Cunha Neto, E. M. da, Veras, H. F. P., Moraes, A. de, Klauber, C., Mohan, M., Cardil, A., & Broadbent, E. N. (2020). Measuring Individual Tree Diameter and Height Using GatorEye High-Density UAV-Lidar in an Integrated Crop-Livestock-Forest System. *Remote Sensing*, 12(5), 863. <https://doi.org/10.3390/rs12050863>
- Duff, A. B., Meyer, J. M., Pollock, C., & Felker, P. (1994). Biomass production and diameter growth of nine half-sib families of mesquite (*Prosopis glandulosa* var. *glandulosa*) and a fast growing *Prosopis alba* half-sib family grown in Texas. *Forest Ecology and Management*, 67(1–3), 257–266. [https://doi.org/10.1016/0378-1127\(94\)90020-5](https://doi.org/10.1016/0378-1127(94)90020-5)
- Eitel, J. U. H., Vierling, L. A., Litvak, M. E., Long, D. S., Schulthess, U., Ager, A. A., Krofcheck, D. J., & Stoscheck, L. (2011). Broadband, red-edge information from satellites improves early stress detection in a New Mexico conifer woodland. *Remote Sensing of Environment*, 115(12), 3640–3646. <https://doi.org/10.1016/j.rse.2011.09.002>
- Fontana, M. L. (2020). Distribución, bioecología y provisión de bienes y servicios ecosistémicos de *Prosopis alba* en Argentina. *Revista de La Facultad de Agronomía*, 119(2), 050. <https://doi.org/10.24215/16699513e050>
- 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>
- Ganz, S., Käber, Y., & Adler, P. (2019). Measuring tree height with remote sensing—a comparison of photogrammetric and

- LiDAR data with different field measurements. *Forests*, 10(8). <https://doi.org/10.3390/f10080694>
- Gitelson, A. A., Viña, A., Ciganda, V., Rundquist, D. C., & Arkebauer, T. J. (2005). Remote estimation of canopy chlorophyll content in crops. *Geophysical Research Letters*, 32(8), 1–4. <https://doi.org/10.1029/2005GL022688>
- Guariguata, M. R., Arce, J., Ammour, T., & Capella J. L. (2017). *Las plantaciones forestales en Perú: Reflexiones, estatus actual y perspectivas a futuro*. Center for International Forestry Research (CIFOR). <https://doi.org/10.17528/cifor/006461>
- Islas-Gutiérrez, F., Cruz-Juárez, E., Buendía-Rodríguez, E., Guerra-De la Cruz, V., Pineda-Ojeda, T., Flores-Ayala, E., Carrillo-Anzures, F., & 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. <https://doi.org/10.35196/rfm.2024.1.70>
- Jain, N., Ray, S. S., Singh, J. P., & Panigrahy, S. (2007). Use of hyperspectral data to assess the effects of different nitrogen applications on a potato crop. *Precision Agriculture*, 8(4–5), 225–239. <https://doi.org/10.1007/s11119-007-9042-0>
- Jarahizadeh, S., & Salehi, B. (2025). Advancing Tree Detection in Forest Environments: A Deep Learning Object Detector Approach with UAV LiDAR Data. *Urban Forestry & Urban Greening*, 128695. <https://doi.org/10.1016/j.ufug.2025.128695>
- Li, T., Lin, J., Wu, W., & Jiang, R. (2024). Effects of Illumination Conditions on Individual Tree Height Extraction Using UAV LiDAR: Pilot Study of a Planted Coniferous Stand. *Forests*, 15(5), 758. <https://doi.org/10.3390/f15050758>
- Li, W., Niu, Z., Liang, X., Li, Z., Huang, N., Gao, S., Wang, C., & Muhammad, S. (2015). Geostatistical modeling using LiDAR-derived prior knowledge with SPOT-6 data to estimate temperate forest canopy cover and above-ground biomass via stratified random sampling. *International Journal of Applied Earth Observation and Geoinformation*, 41, 88–98. <https://doi.org/10.1016/j.jag.2015.04.020>
- Liao, K., Li, Y., Zou, B., Li, D., & Lu, D. (2022). Examining the Role of UAV Lidar Data in Improving Tree Volume Calculation Accuracy. *Remote Sensing*, 14(17), 4410. <https://doi.org/10.3390/rs14174410>
- Liao, L., Cao, L., Xie, Y., Luo, J., & Wang, G. (2022). Phenotypic Traits Extraction and Genetic Characteristics Assessment of Eucalyptus Trials Based on UAV-Borne LiDAR and RGB Images. *Remote Sensing*, 14(3). <https://doi.org/10.3390/rs14030765>
- Lu, H., Fan, T., Ghimire, P., & Deng, L. (2020). Experimental Evaluation and Consistency Comparison of UAV Multispectral Minisensors. *Remote Sensing*, 12(16), 2542. <https://doi.org/10.3390/rs12162542>
- Matese, A., Toscano, P., Di Gennaro, S., Genesio, L., Vaccari, F., Primicerio, J., Belli, C., Zalide, A., Bianconi, R., & Gioli, B. (2015). Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. *Remote Sensing*, 7(3), 2971–2990. <https://doi.org/10.3390/rs70302971>
- Méndez, J., Turlan, O., Rios, J., Nájera, J. (2012). Ecuaciones alométricas para estimar biomasa aérea de *Prosopis laevigata* (Humb. & Bonpl. ex Willd.) M.C. Johnst. *Revista Mexicana de Ciencias Forestales*, 3.
- Meng, J., Xu, J., & You, X. (2015). Optimizing soybean harvest date using HJ-1 satellite imagery. *Precision Agriculture*, 16(2), 164–179. <https://doi.org/10.1007/s11119-014-9368-3>
- Modica, G., Messina, G., De Luca, G., Fiozzo, V., & Praticò, S. (2020). Monitoring the vegetation vigor in heterogeneous citrus and olive orchards. A multiscale object-based approach to extract trees' crowns from UAV multispectral imagery. *Computers And Electronics In Agriculture*, 175, 105500. <https://doi.org/10.1016/j.compag.2020.105500>
- Mohan, M., Silva, C., Klauber, C., Jat, P., Catts, G., Cardil, A., Hudak, A., & Dia, M. (2017). Individual Tree Detection from Unmanned Aerial Vehicle (UAV) Derived Canopy Height Model in an Open Canopy Mixed Conifer Forest. *Forests*, 8(9), 340. <https://doi.org/10.3390/f8090340>
- Muturi, G. M., Kariuki, J. C., Poorter, L., & Mohren, G. M. J. (2011). Allometric equations for estimating biomass in naturally established *Prosopis* stands in Kenya. *Journal of Horticulture and Forestry*, 4(4). <https://doi.org/10.5897/JHF11.066>
- Padrón, E., & Navarro, R. M. (2004). Estimation of above-ground biomass in naturally occurring populations of *Prosopis pallida* (H. & B. ex Willd.) H.B.K. in the north of Peru. *Journal of Arid Environments*, 56(2), 283–292. [https://doi.org/10.1016/S0140-1963\(03\)00055-7](https://doi.org/10.1016/S0140-1963(03)00055-7)
- Paladines, R. (2003). Propuesta de conservación del Bosque seco en el Sur de Ecuador. *Lyonia*, 4(2), 183–186.
- Pearse, G. D., Dash, J. P., Persson, H. J., & Watt, M. S. (2018). Comparison of high-density LiDAR and satellite photogrammetry for forest inventory. *ISPRS Journal of Photogrammetry and Remote Sensing*, 142, 257–267. <https://doi.org/10.1016/j.isprsjprs.2018.06.006>
- Phadikar, S., & Goswami, J. (2016). Vegetation indices based segmentation for automatic classification of brown spot and blast diseases of rice. *2016 3rd International Conference on Recent Advances in Information Technology (RAIT)*, 284–289. <https://doi.org/10.1109/RAIT.2016.7507917>
- Plaza, H. (2020). *Niveles de vigorosidad de plantaciones de Teca (Tectona grandis), mediante índices de vegetación, en cantón Buena Fe, año 2020* [Master's thesis]. Universidad Técnica Estatal de Quevedo.
- Poley, L., & McDermid, G. (2020). A Systematic Review of the Factors Influencing the Estimation of Vegetation Aboveground Biomass Using Unmanned Aerial Systems. *Remote Sensing*, 12(7), 1052. <https://doi.org/10.3390/rs12071052>
- Pourazar, H., Samadzadegan, F., & Dadras Javan, F. (2019). Aerial multispectral imagery for plant disease detection: radiometric calibration necessity assessment. *European Journal of Remote Sensing*, 52(sup3), 17–31. <https://doi.org/10.1080/22797254.2019.1642143>
- R Core Team. (2020). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing. <https://www.R-project.org/>
- Raes, D., Fereres, E., García Vila, M., Curnel, Y., Knoden, D., Çelik, S. K., Ucar, Y., Türk, M., & Wellens, J. (2023). Simulation of alfalfa yield with AquaCrop. *Agricultural Water Management*, 284, 108341. <https://doi.org/10.1016/j.agwat.2023.108341>
- Remache-Reinoso, F. M., Horna-Durán, S. D., Lara-Vásquez, N. X., Cushquicullma-Colcha, D. F., & Muñoz-Jácome, E. A. (2024). Estimación de alturas de pinus radiata d. Don en san juan, chimborazo, usando vehículos aéreos no tripulados. *Perfiles*, 1(32), 6–14. <https://doi.org/10.47187/perf.v1i32.276>
- Reis-Pereira, M., Verrelst, J., Tosin, R., Rivera Caicedo, J. P., Tavares, F., Neves dos Santos, F., & Cunha, M. (2024). Plant Disease Diagnosis Based on Hyperspectral Sensing: Comparative Analysis of Parametric Spectral Vegetation Indices and Nonparametric Gaussian Process Classification Approaches. *Agronomy*, 14(3), 493. <https://doi.org/10.3390/agronomy14030493>
- Rodríguez-Puerta, F., Gómez-García, E., Martín-García, S., Pérez-Rodríguez, F., & Prada, E. (2021). UAV-Based LiDAR Scanning for Individual Tree Detection and Height Measurement in Young Forest Permanent Trials. *Remote Sensing*, 14(1), 170. <https://doi.org/10.3390/rs14010170>
- Salazar, P., Navarro-Cerrillo, R. M., Palacios Mc Cubbin, E., Cruz, G., & Lopez, M. (2023). Biomass estimation models for four priority *Prosopis* species: Tools required for forestry management in overexploited arid ecosystems. *Journal of Arid Environments*, 209, 104904. <https://doi.org/10.1016/j.jaridenv.2022.104904>
- Sione, S., Ledesma, S., Rosenberger, L., Oszust, J., Andrade-Castañeda, H., Maciel, G., Wilson, M., & Sasal, M. (2020). Allometric equations of aerial biomass for *Prosopis nigra*

- (Griseb.) Hieron." Algarrobo negro"(Fabaceae) in forests of Entre Ríos (Argentina). *Rev. Facultad de Agronomía UBA*, 40(1), 63–76.
- Sione, S. M. J., Andrade-Castañeda, H. J., Ledesma, S. G., Rosenberger, L. J., Oszust, J. D., & Wilson, M. G. (2019). Aerial biomass allometric models for *Prosopis affinis* Spreng. in native Espinal forests of Argentina. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 23(6), 467–473. <https://doi.org/10.1590/1807-1929/agriambi.v23n6p467-473>
- Su, R., Du, W., Ying, H., Shan, Y., & Liu, Y. (2023). Estimation of Aboveground Carbon Stocks in Forests Based on LiDAR and Multispectral Images: A Case Study of Duraer Coniferous Forests. *Forests*, 14(5), 992. <https://doi.org/10.3390/f14050992>
- Tafur, E., Veneros, J., García, L., Gamarra, Ó., Farje, J., & Santistevan, M. (2022). Técnicas no destructivas para la estimación de la biomasa forestal aérea. *Idesia (Arica)*, 40(3), 7–17. <https://doi.org/10.4067/S0718-34292022000300007>
- Taubert, F., Fischer, R., Knapp, N., & Huth, A. (2021). Deriving Tree Size Distributions of Tropical Forests from Lidar. *Remote Sensing*, 13(1), 131. <https://doi.org/10.3390/rs13010131>
- Vashum, K., & Jayakumar, S. (2012). Methods to Estimate Above-Ground Biomass and Carbon Stock in Natural Forests - A Review. *Journal of Ecosystem & Ecography*, 2(4). <https://doi.org/10.4172/2157-7625.1000116>
- Vera, E., Cruz, C., Barboza, E., Salazar, W., Canta, J., Salazar, E., Vásquez, H. V. & Arbizu, C. I. (2024). Change of vegetation cover and land use of the Pómac forest historical sanctuary in northern Peru. *International Journal of Environmental Science and Technology*, 1-12. <https://doi.org/10.1007/s13762-024-05597-6>
- Walker, S. M., Murray, L., & Tepe, T. (2016). Allometric Equation Evaluation Guidance Document. Winrock International, USA.
- Wallace, L., Watson, C., & Lucieer, A. (2014). Detecting pruning of individual stems using Airborne Laser Scanning data captured from an Unmanned Aerial Vehicle. *International Journal of Applied Earth Observation and Geoinformation*, 30(1), 76–85. <https://doi.org/10.1016/j.jag.2014.01.010>
- Xu, W., Cheng, Y., Luo, M., Mai, X., Wang, W., Zhang, W., & Wang, Y. (2025). Progress and Limitations in Forest Carbon Stock Estimation Using Remote Sensing Technologies: A Comprehensive Review. *Forests*, 16(3), 449. <https://doi.org/10.3390/f16030449>
- Xu, W., Su, Z., Feng, Z., Xu, H., Jiao, Y., & Yan, F. (2013). Comparison of conventional measurement and LiDAR-based measurement for crown structures. *Computers and Electronics in Agriculture*, 98, 242–251. <https://doi.org/10.1016/j.compag.2013.08.015>
- Zhai, Y., Wang, L., Yao, Y., Jia, J., Li, R., Ren, Z., He, X., Ye, Z., Zhang, X., Chen, Y., & Xu, Y. (2024). Spatially continuous estimation of urban forest aboveground biomass with UAV-LiDAR and multispectral scanning: An allometric model of forest structural diversity. *Agricultural And Forest Meteorology*, 360, 110301. <https://doi.org/10.1016/j.agrformet.2024.110301>
- Zhang, L., Zhao, Y., Chen, C., Li, X., Mao, F., Lv, L., Yu, J., Song, M., Huang, L., Chen, J., Zheng, Z., & Du, H. (2024). UAV-LiDAR Integration with Sentinel-2 Enhances Precision in AGB Estimation for Bamboo Forests. *Remote Sensing*, 16(4), 705. <https://doi.org/10.3390/rs16040705>
- Zeng, H.-Q., Liu, Q.-J., Feng, Z.-W., & Ma, Z.-Q. (2010). Biomass equations for four shrub species in subtropical China. *Journal of Forest Research*, 15(2), 83–90. <https://doi.org/10.1007/s10310-009-0150-8>