








Fotogrametría con vehículos aéreos no tripulados para la caracterización estructural del cultivo de maíz (*Zea mays* L.) en el trópico húmedo

Photogrammetry with unmanned aerial vehicles for the structural characterization of maize (*Zea mays* L.) in the humid tropic

Sergio Salgado-Velázquez¹ , Fabiola Olvera-Rincón^{2*} , Sabel Barrón-Freyre¹ ,
Dante Sumano-López¹ , Pablo Ulises Hernández-Lara¹ , David Julián Palma-Cancino³ ,
Samuel Córdova-Sánchez⁴ 

¹ Colegio de Postgraduados, Campus Tabasco, km 3.5 periférico Carlos A. Molina s/n, 86500, Cárdenas, Tabasco, México.

² Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias, C.E. Huimanguillo, km 1 carretera Huimanguillo-Cárdenas, 86400, Huimanguillo, Tabasco, México.

³ Colegio de Postgraduados, Campus Campeche, Carretera Haultunchén-Edzná, 24450, Champotón, Campeche, México.

⁴ Universidad Popular de la Chontalpa, Cuerpo Académico de Química Verde y Desarrollo Sustentable, km 2 carretera Cárdenas-Huimanguillo, 86500, Cárdenas, Tabasco, México.

*Autor para correspondencia: olvera.fabiola@colpos.mx

Fecha de recepción:
25 de noviembre de 2025

Fecha de aceptación:
23 de febrero de 2026

Disponible en línea:
5 de mayo de 2026

Este es un artículo en acceso abierto que se distribuye de acuerdo a los términos de la licencia Creative Commons.



**Reconocimiento-
NoComercial-
CompartirIgual 4.0
Internacional
(CC BY-NC-SA 4.0)**

Cómo citar:
Salgado-Velázquez, S., Olvera-Rincón, F., Barrón-Freyre, S., Sumano-López, D., Hernández-Lara, P. U., Palma-Cancino, D. J., & Córdova-Sánchez, S. (2025). Fotogrametría con vehículos aéreos no tripulados para la caracterización estructural del cultivo de maíz (*Zea mays* L.) en el trópico húmedo. *Acta Agrícola y Pecuaria*, 11(núm. esp. 2), e0111041. https://doi.org/10.30973/aap/2025.11.e0111041

RESUMEN

El uso de vehículos aéreos no tripulados se ha consolidado como una herramienta clave para el monitoreo agrícola de alta precisión. En este estudio, se aplicaron técnicas de fotogrametría digital mediante dron para estimar la altura de plantas de maíz (*Zea mays* L.) en condiciones tropicales de Tabasco, México. Las misiones se realizaron a 100 m de altura, con velocidad de 3.5 m s⁻¹ e intervalo de disparo de 2 s, generando un traslape frontal del 95 %. Las imágenes se procesaron con algoritmos Structure from Motion y correlación multivista para generar la nube densa, el modelo digital de superficie, el modelo digital del terreno y el ortomosaico georreferenciado. La altura se obtuvo por diferencia altimétrica, con valores medios de 2.68 m, consistentes con el rango fisiológico del cultivo en el trópico húmedo. Las variaciones espaciales reflejaron heterogeneidad edáfica y manejo agronómico. Valores mayores observados (> 3.5 m) se atribuyeron a artefactos. La validación mostró un R² de 0.96 y un RMSE de 0.205 m, confirmando su precisión.

PALABRAS CLAVE

Fotogrametría, agricultura de precisión, maíz, altura de planta, modelos digitales.

ABSTRACT

The use of unmanned aerial vehicles has become a key tool for high-precision agricultural monitoring. In this study, digital photogrammetry techniques using a drone were applied to estimate plant height in maize (*Zea mays* L.) under tropical conditions in Tabasco, Mexico. Flight missions were conducted at an altitude of 100 m, with a speed of 3.5 m s⁻¹ and a shooting interval of 2 s, achieving 95 % frontal overlap. The images were processed using Structure from Motion and multi-view stereo algorithms to generate the dense point cloud, digital surface model, digital terrain model, and georeferenced orthomosaic. Plant height was obtained by altimetric differencing, with mean values of 2.68 m, consistent with the physiological range of maize in humid tropical environments. Spatial variability reflected soil heterogeneity and agronomic management. Higher values (> 3.5 m) were attributed to artifacts. Validation showed an R² of 0.96 and an RMSE of 0.205 m, confirming its accuracy.

KEYWORDS

Photogrammetry, precision agriculture, maize, plant height, digital models.

INTRODUCCIÓN

El maíz (*Zea mays* L.) es el cultivo más importante de México tanto por su valor económico como por su relevancia sociocultural y alimentaria. México es reconocido como centro de origen y diversificación del maíz, y el grano constituye la base de la dieta nacional, aportando más del 50 % de la ingesta calórica diaria de la población (Servicio de Información Agroalimentaria y Pesquera [SIAP], 2024). A nivel productivo, el maíz ocupa aproximadamente 7 millones de hectáreas anuales, representando cerca del 30 % del valor total de la producción agrícola del país (Food and Agriculture Organization of the United Nations, 2023). En el estado de Tabasco, aunque la superficie cultivada es menor en comparación con los principales estados productores, el cultivo reviste alta importancia estratégica para la seguridad alimentaria regional y forma parte de los programas de autosuficiencia alimentaria y reconversión productiva del trópico húmedo mexicano. Los sistemas de producción de maíz en Tabasco se caracterizan por su diversidad, predominando pequeñas parcelas con manejo tradicional y limitado acceso a tecnologías de monitoreo, lo que genera amplias brechas de productividad (Córdova-Sánchez et al., 2023; SIAP, 2024).

En la última década, la agricultura de precisión se ha convertido en un pilar esencial para optimizar los insumos agrícolas, mejorar la eficiencia en la producción y reducir los impactos ambientales. Esta aproximación se basa en el monitoreo, análisis y gestión de la variabilidad espacial y temporal dentro del campo, de modo que las decisiones agronómicas (por ejemplo, siembra, fertilización y riego) se adapten a las condiciones locales específicas del cultivo (Olvera-Rincón et al., 2024; Salgado-Velázquez et al., 2020).

El uso de la fotogrametría es un método común en teledetección para modelar superficies y atributos del dosel, ya que permite la extracción y separación de las capas del dosel, así como de atributos como altura, densidad y salud, aplicados al monitoreo forestal y de vegetación. La fotogrametría con vehículos aéreos no tripulados (VANT) representa una alternativa precisa y no destructiva frente a las mediciones tradicionales en campo. En esta óptica, el uso de plataformas aéreas no tripuladas (UAV, por sus siglas en inglés) comúnmente conocidos como drones, equipadas con

cámaras ópticas y sensores, ha transformado la capacidad de capturar datos de alta resolución espacial y temporal sobre el desarrollo del cultivo. Estas plataformas permiten generar productos geoespaciales como ortomosaicos, modelos digitales de superficie (MDS), modelos digitales del terreno (MDT) y modelos digitales de elevación (MDE) que facilitan la estimación de variables agronómicas importantes como la altura de la planta, biomasa, cobertura de dosel o índices vegetativos (por ejemplo, el índice de vegetación de diferencia normalizada) (Alemán-Montes et al., 2021). Estudios recientes han demostrado que esta clase de variables derivadas de fotogrametría UAV pueden correlacionarse con mediciones de campo y servir para monitorear el crecimiento del cultivo, estimar rendimiento o detectar anemia nutricional (Dong et al., 2024; Qiao et al., 2022; Salgado-Velázquez et al., 2025; Velusamy et al., 2022). Estas estimaciones se obtienen generalmente al calcular la diferencia entre el MDS, que representa la parte superior del dosel vegetal, y el MDT, que describe la topografía del suelo sin vegetación. La precisión de estos modelos depende del solapamiento frontal y lateral de imágenes, la calidad del procesamiento fotogramétrico, la calibración de la cámara, la presencia de puntos de control terrestre bien distribuidos, tamaño del sensor, velocidad y la altura de vuelo (Dandois et al., 2015).

En particular, para el cultivo de maíz la estimación de la altura de la planta es un indicador estructural relevante, ya que guarda relación con la acumulación de biomasa, la cobertura del dosel, la competencia por luz y, en última instancia, el rendimiento. Por ejemplo, Li et al. (2024) estimaron altura y biomasa aérea de maíz mediante fotogrametría y otros sensores, y observaron que la extracción de altura de planta mediante modelos digitales de superficie presentó un buen ajuste con las mediciones de campo (R^2 de 0.68) en determinados estadios de crecimiento. Otro estudio analizó la comparación de métodos de teledetección para medición de alturas de cultivo y mostró que las variables como ángulo de cámara, uso de RTK-GPS y puntos de control influyen en la precisión (Fujiwara et al., 2022). No obstante, en la región del trópico húmedo mexicano, y específicamente en campos agrícolas del estado de Tabasco, no existen trabajos que apliquen fotogrametría con VANT al maíz para cuantificar directamente la altura de la planta y validarla con mediciones de

campo. En este sentido, el presente estudio constituye el primer trabajo que emplea un vuelo *vant* con cámara RGB de bajo costo para generar MDE, MDS y MDT, junto con un ortomosaico, para estimar la altura de planta de maíz y compararla con mediciones de campo. Los objetivos de este estudio son: generar los productos fotogramétricos (MDE, MDT, MDS y ortomosaico) a partir de un levantamiento *uav* sobre un cultivo de maíz en Huimanguillo, Tabasco, México; extraer y recuperar la variable altura de planta a partir de los modelos digitales; comparar las alturas estimadas con mediciones de campo a fin de evaluar la precisión del método en el contexto de agricultura de precisión en Tabasco, y, finalmente, discutir las implicaciones de este enfoque para el monitoreo estructural del cultivo de maíz y su posible aplicación en sistemas de seguimiento agronómico. Con este enfoque, se espera aportar una herramienta de bajo-coste y alta resolución espacial al monitoreo del cultivo de maíz en el trópico mexicano, contribuyendo al conocimiento científico y a la implementación de agricultura de precisión en la región.

MATERIALES Y MÉTODOS

Área de estudio

El trabajo se llevó a cabo en el ciclo otoño invierno de 2025 bajo un suelo Fluvisol eútrico cultivado con maíz fertilizado con excretas y lixiviados de estiércol bovino desde hace seis ciclos consecutivos. El suelo tiene un potencial hidrogeno (pH) de 5.8 considerándose adecuado, un contenido de materia orgánica (MO) de 3.2 % considerado como medio y una capacidad de intercambio catiónico (CIC) de 16 mEq/100 g de suelo clasificado como alto. Cabe destacar que el suelo del sitio de estudio corresponde a un fluvisol, tipo de suelo ampliamente registrado en la planicie aluvial de la región de Chontalpa, Tabasco, México. Este tipo de suelo es característico de las zonas bajas inundables y de depósitos aluviales recientes, y es la base de sistemas agrícolas intensivos en los que se establecen cultivos como maíz, caña de azúcar, pastizales inducidos, frutales como cacao y hortalizas como chile habanero (Palma-López et al.,

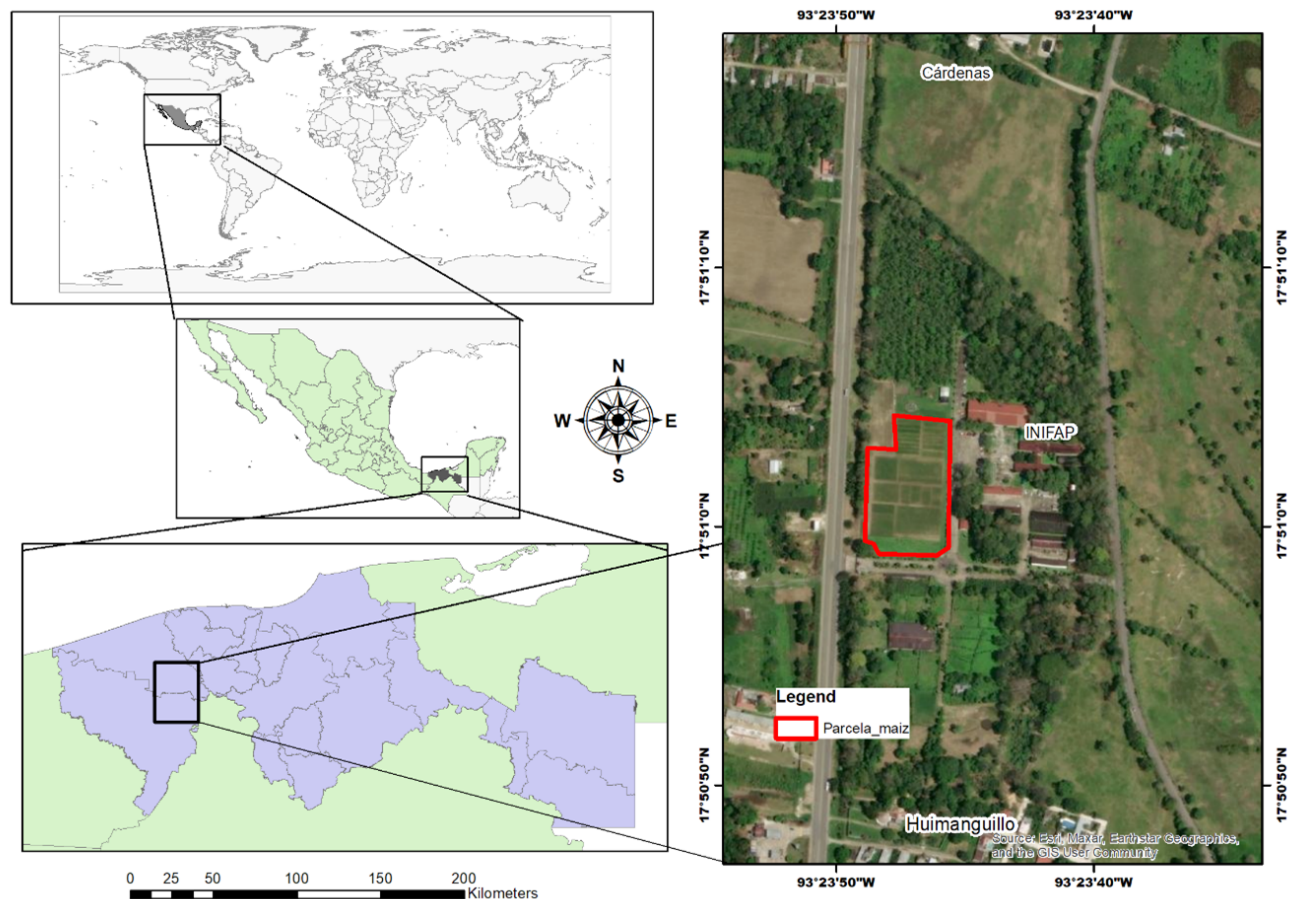


Figura 1. Localización de ensayos de maíz (delimitada en rojo) y el ensayo utilizado (en amarillo) en el Campo Experimental Huimanguillo del INIFAP, Tabasco, México.

2017). El maíz se estableció en el Campo Experimental Huimanguillo del Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias [INIFAP] del municipio de Huimanguillo, Tabasco, México (17°50'27" N, 93°23'28" O, 18 msnm) (Figura 1). La precipitación promedio anual es de 2,356 mm. De febrero a mayo se presenta una temporada de sequía (276 mm) y la temperatura mínima promedio es mayor a 20 °C. El ciclo de cultivo fue de temporal y establecido el 15 de junio de 2025 (Sumano-López et al., 2025).

Manejo agronómico del maíz

La preparación del suelo se realizó de manera mecanizada con tres pasadas de rastra; se utilizó la variedad vs-536 para la siembra del ciclo actual. Cabe destacar que este es el séptimo ciclo consecutivo de cultivo en el que se siembra una variedad mejorada, con el fin de observar el efecto residual del material orgánico mencionado. La siembra se efectuó manualmente el 15 de julio de 2025, en franjas con surcos separados a 80 cm, depositando tres semillas cada 40 cm para dejar dos plantas por golpe y asegurando una densidad de 62,500 plantas ha⁻¹. Las plagas, como el gusano cogollero, se controlaron con dos aplicaciones del insecticida cipermetrina (a los seis y 14 días después de la siembra) y una tercera aplicación de Spinetoram (orteva Agriscience, Indianapolis, Estados Unidos) a los 22 días. El control de malezas se realizó mediante dos deshierbes manuales (a los 12 y 22 días) y un cultivo-aporque mecánico (Barrón-Freyre et al., 2014). La fertilización con lixiviados de maíz se llevó a cabo con una concentración al 50 % diluida en agua. Se reali-

zaron tres aplicaciones a la planta, tanto foliar como al suelo, durante los primeros 40 días después del establecimiento (Sumano-López et al., 2025).

Planificación y parámetros del vuelo fotogramétrico

La adquisición de imágenes aéreas se llevó a cabo mediante un VANT DJI Mini 4 Pro (Figura 2), equipado con una cámara CMOS de 1/1.3" (sensor de 9.65 mm × 4.24 mm) y distancia focal efectiva de 6.72 mm, según los metadatos EXIF de las imágenes obtenidas del dispositivo (DJI, 2023). El tamaño físico de pixel del sensor fue de 2.62 μm (0.00262 mm), parámetro utilizado posteriormente para el cálculo del *ground sampling distance* (GSD), el cual depende además de la altura de vuelo y la distancia focal. Si bien el DJI Mini 4 Pro pertenece a la categoría de drones de consumo y no cuenta con sistema de posicionamiento RTK/PPK integrado ni con una cámara métrica calibrada de fábrica, su empleo resulta adecuado para estudios agronómicos a escala parcelaria cuando se implementa un diseño de vuelo con buen traslape longitudinal y transversal. Es importante señalar que el tamaño reducido del sensor puede limitar el rango dinámico y la estabilidad geométrica en comparación con plataformas profesionales; no obstante, bajo condiciones de vuelo controladas y con un adecuado procesamiento fotogramétrico, es posible obtener modelos digitales con precisión relativa suficiente para la estimación estructural del cultivo. Además, la selección de este equipo se justificó por su accesibilidad, facilidad operativa y menor costo en comparación con plataformas UAV equipadas con sensores métricos o sistemas RTK, lo que lo convierte en



Figura 2. Vehículo aéreo no tripulado (VANT) marca DJI modelo Mini Pro 4 (izquierda) y control DJI RC2 con pantalla integrada y app DJI Fly (derecha).

una alternativa viable para aplicaciones agrícolas en contextos de recursos limitados.

La adquisición de imágenes se realizó mediante un único vuelo el 15 de octubre de 2025 en un horario de 10:00 a 11:00 horas. La misión fue planificada y ejecutada utilizando la aplicación DJI Mini 4 Pro a través de la plataforma DJI Fly, lo que permitió programar y controlar una altura de vuelo de 100 m sobre el nivel del terreno, con una velocidad de avance de 3.5 m·s⁻¹, y un intervalo de disparo de 2 s, programado en modo nadiral (90°). El vuelo se estructuró en ocho líneas paralelas, con un traslape lateral objetivo del 70%.

Cálculo del tamaño de pixel en terreno

El GSD o tamaño de pixel en el terreno se determinó mediante la ecuación fundamental (Wolf et al., 2014):

$$GDS = \frac{H * P}{f}$$

Donde:

H = altura de vuelo (m).

P = tamaño de pixel (mm px⁻¹).

f = distancia focal (mm).

Por tanto, cada pixel del ortomosaico representó 3.9 cm del terreno real, resolución suficiente para análisis estructural de cultivo a nivel de planta individual.

Cálculo de la huella de imagen (*footprint*)

La proyección del campo de visión sobre el terreno se estimó mediante las siguientes expresiones:

$$Sw = \frac{Ws * H}{f}, Sy = \frac{Hs * H}{f}$$

Donde Ws y Hs son el ancho y alto del sensor en milímetros.

Cada imagen cubrió una huella aproximada de 157.1 m × 88.4 m, equivalente a 1.39 ha por fotografía.

Cálculo del traslape frontal y lateral

El traslape frontal (*front overlap*, O_x) se estimó con:

$$O_x = 1 - \frac{v * \Delta t}{Sh}$$

Donde:

v = velocidad del dron (m·s⁻¹), y Δt = intervalo entre disparos (s).

El traslape frontal efectivo fue de 90 %, valor óptimo para reconstrucciones 3D de alta densidad.

El traslape lateral (*side overlap*, O_y) se calculó según:

$$O_y = 1 - \frac{v * \Delta t}{Sh}$$

Donde:

E es el espaciamiento entre líneas de vuelo.

Dado que el plan de vuelo se configuró con un traslape lateral objetivo del 70 %, el espaciamiento teórico fue:

$$E = Sw - (1 - O_y) = 157.14(1 - 0.70) = 47.14\text{m}$$

Con ocho líneas de vuelo separadas a 47 m, se garantizó cobertura completa del polígono de estudio.

Cálculo de la distancia recorrida y tiempo total de vuelo

El desplazamiento entre disparos se obtiene como:

$$\Delta d = v * \Delta t = 3.5 * 2 = 7\text{m}$$

Considerando la longitud de cada línea (400 m) y ocho pasadas, la distancia total fue de aproximadamente 3.2 km, completados en 5.7 min de vuelo efectivo, dentro del rango de autonomía del DJI Mini 4 Pro (30 min de batería).

El traslape lateral del 70 % (Cuadro 1) utilizado en este estudio es consistente con protocolos estándar de fotogrametría aérea para reconstrucción 3D y generación de ortomosaicos en superficies agrícolas homogéneas (Eskandari et al., 2020). Bajo las condiciones del estudio (vuelo a 100 m, superficie relativamente uniforme y adecuada textura del cultivo), el 70 % proporcionó suficiente coincidencia de puntos homólogos para garantizar una reconstrucción estable y un ortomosaico sin vacíos ni distorsiones como se muestra en las figuras posteriores.

La planificación del vuelo se realizó conforme a las recomendaciones de la American Society for Photogrammetry and Remote Sensing (2024), asegurando redundancia geométrica y solape suficiente para el modelado tridimensional mediante Structure from Motion (SfM). El vuelo se efectuó en condiciones de ilu-

minación constante, evitando proyecciones de sombra sobre el dosel vegetal (Bongomin et al., 2024). Los metadatos de cada imagen fueron posteriormente validados en Agisoft Metashape Professional v2.0, garantizando coherencia radiométrica y precisión posicional submétrica (< 2 cm de error cuadrático medio [RMSE] en puntos de control).

Cuadro 1. Resumen de los parámetros del vuelo fotogramétrico en el campo experimental de Huimanguillo del INIFAP en Tabasco, México.

Parámetro	Valor	Unidad
Altura de vuelo (H)	100	m
Distancia focal (f)	6.72	mm
Resolución imagen	4032 × 2268	px
Tamaño de pixel (p)	0.0026188	mm px ⁻¹
Sensor (ancho × alto)	10.56 × 5.94	mm
GSD	3.9	cm px ⁻¹
Velocidad de vuelo (v)	3.5	m s ⁻¹
Intervalo de disparo (Δt)	2	s
Distancia entre disparos (Δd)	7	m
Traslape frontal (O_x)	92.1	%
Traslape lateral (O_y)	70	%
Espaciado entre líneas	47.1	m
Líneas de vuelo	8	--
Área cubierta por imagen	1.39	ha

Procesamiento fotogramétrico

El procesamiento de las imágenes adquiridas con el dron se llevó a cabo en el *software* Agisoft Metashape Professional, versión 2.0 (Agisoft, 2023), ampliamente utilizado en aplicaciones de fotogrametría digital y agricultura de precisión por su capacidad para generar modelos tridimensionales y ortomosaicos de alta resolución a partir de imágenes superpuestas. El flujo de trabajo fotogramétrico siguió las etapas convencionales de reconstrucción mediante SfM y Multi-View Stereo (MVS), optimizando la precisión geométrica del producto final (Lambertini et al., 2022). Durante la etapa de alineación de imágenes, se aplicó el procedimiento de autocalibración interna de cámara integrado en el algoritmo SfM, el cual estimó automáticamente los parámetros intrínsecos (distancia focal efectiva, coordenadas del punto principal y coeficientes de distorsión radial y tangencial) mediante ajuste por bloques (*bundle adjustment*), corrigiendo las distorsiones

propias de la cámara RGB no métrica del UAV. No se realizó calibración radiométrica absoluta mediante panel de reflectancia, dado que el objetivo del estudio se centró en el análisis estructural y espacial de la superficie agrícola.

Importación y alineación de imágenes

Las imágenes capturadas durante el vuelo fueron importadas al proyecto y alineadas automáticamente mediante el algoritmo SfM, el cual estima la orientación exterior (posición y rotación) de cada toma a partir de puntos homólogos detectados por correlación automática. En esta etapa, se obtuvieron los parámetros de orientación y una nube de puntos dispersa inicial.

Construcción de la nube densa de puntos

Posteriormente, se generó la nube densa utilizando un algoritmo de correlación multivista (MVS) con sensibilidad media, filtrando puntos espurios o inconsistentes. Este paso permitió una reconstrucción tridimensional detallada de la superficie y la vegetación presente en el área de estudio.

Generación de modelos digitales

A partir de la nube densa, se generaron el MDS y MDT, aplicando la clasificación automática de puntos según criterios geométricos y de altura relativa. El MDS conserva los elementos superficiales (cultivos, vegetación, estructuras), mientras que el MDT representa la topografía del terreno desnudo.

Ortorrectificación y mosaico final

Las imágenes fueron ortorrectificadas empleando el MDS como referencia altimétrica, eliminando desplazamientos debidos a la topografía y al ángulo de la cámara. El mosaico final se generó en el sistema de referencia WGS84 / UTM zona 15N, correspondiente a la ubicación geográfica del Campo Experimental Huimanguillo en Tabasco, México.

Antes del procesamiento, las imágenes fueron sometidas a una calibración radiométrica y una corrección geométrica interna, basadas en los parámetros intrínsecos del sensor, con el objetivo de

minimizar las distorsiones ópticas del lente (Olson & Anderson, 2021).

Finalmente, el ortomosaico resultante presentó una precisión planimétrica promedio de $\pm 3-5$ m, validada mediante puntos de control terrestre obtenidos con un receptor GNSS Garmin GPS Etrex 22 (Garmin Ltd., Olathe, Estados Unidos). Este nivel de exactitud permitió la integración confiable de los productos fotogramétricos con información geoespacial y edáfica del área de estudio (Ballesteros et al., 2014; Tsouros et al., 2019).

Estimación de la altura de planta a partir de modelos digitales

La estimación de la altura del cultivo de maíz se realizó a partir de la diferencia entre el MDS y el MDT generados en Agisoft Metashape, y procesados posteriormente en el entorno geoespacial de QGIS (v.3.10.4). Este procedimiento permite derivar la altura de la vegetación (H_p) a partir de información fotogramétrica, con resolución espacial centimétrica, evitando mediciones destructivas en campo (Torres-Sánchez et al., 2015).

La ecuación general empleada fue:

$$H_p = MDS - MDT$$

Donde:

H_p = altura de planta (m).

MDS = modelo digital de superficie (m) que incluye la vegetación.

MDT = modelo digital del terreno (m) que representa la superficie del suelo desnudo.

El cálculo se realizó a partir de la diferencia ráster entre ambos modelos, utilizando la calculadora ráster de QGIS. Los modelos digitales se exportaron previamente en formato GeoTIFF, con resolución espacial de 1 cm/píxel, alineados al mismo sistema de referencia geodésico WGS84 / UTM Zona 15N. Para evitar artefactos en las zonas de borde, se aplicó un enmascaramiento basado en el límite del polígono experimental. Posteriormente, se generaron mapas de altura de planta y estadísticas zonales por subparcela experimental utilizando la herramienta Zonal Statistics de QGIS, obteniendo valores de altura media, mínima y máxima (m) para cada parcela.

Generación del modelo 3D de la altura de planta estimada por fotogrametría

Se utilizó un ráster de alturas derivado de imágenes obtenidas mediante un VANT DJI Mini Pro 4 para representar la estructura vertical del cultivo de maíz. Los datos se procesaron en Python con la librería rasterio para la lectura del ráster, y numpy para la generación de las matrices de coordenadas espaciales (longitudinal y transversal). El modelo 3D se construyó utilizando matplotlib con la función plot_surface, aplicando un colormap "jet" y un sombreado tipo relieve mediante LightSource para resaltar las diferencias de altura. La visualización se ajustó con una cámara inclinada para mejorar la percepción tridimensional, y se añadió una barra de color que indica la altura del cultivo. El resultado se exportó en alta resolución (300 dpi en PNG) para su inclusión en la metodología del estudio (Brandt & Freeman, 2021).

Validación de las estimaciones de altura de planta por fotogrametría

Para validar las estimaciones de altura obtenidas mediante los modelos digitales generados por el VANT, se compararon los valores de altura predichos por los productos fotogramétricos con las mediciones originales realizadas en campo. La relación entre las alturas observadas y las estimadas se evaluó mediante la correspondencia lineal usando una regresión lineal. Además, se calculó el RMSE para cuantificar la desviación promedio entre las alturas estimadas y las observadas. La validación se realizó mediante comparación con mediciones directas de altura de planta tomadas en campo con estadal en 40 puntos distribuidos aleatoriamente por tratamiento y utilizando la media aritmética de cinco observaciones por punto. El ajuste entre las alturas estimadas y observadas se evaluó con un análisis de regresión lineal simple.

$$H_d = a + b * H_c$$

Donde:

H_d = altura estimada por fotogrametría (m).

H_c = altura medida en campo (m).

a = intercepto.

b = pendiente de regresión.

El grado de ajuste se cuantificó mediante el coeficiente de determinación (R^2) y el RMSE, calculado como:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Hd_i - Hc_i)^2}$$

Todas las métricas se calcularon y visualizaciones se generaron utilizando Python (versión 3.10) con las librerías `numpy`, `scipy.stats` y `matplotlib`. En el gráfico, se incluyó la ecuación de la recta de regresión, el R^2 , el p -value y el RMSE, proporcionando una representación visual clara del desempeño del modelo y de la precisión de las estimaciones derivadas del VANT. Este procedimiento permitió obtener una correlación robusta entre las alturas derivadas de los modelos digitales y las observadas en campo, confirmando la validez del método para la caracterización estructural del cultivo de maíz en condiciones de trópico húmedo.

RESULTADOS Y DISCUSIÓN

Calidad del modelo fotogramétrico

La Figura 3 muestra un acercamiento de los productos fotogramétricos generados a partir de las imágenes del VANT. El proceso de reconstrucción 3D generó una nube

densa (Figura 3a) compuesta por aproximadamente 12.5 millones de puntos, con una densidad promedio de 250 puntos/m². El RMSE de los GCP fue de ± 4.8 cm en planimetría y ± 6.2 cm en altimetría, valores que se encuentran dentro del rango aceptado para levantamientos de baja altura (≤ 120 m) realizados con sensores RGB (Cano et al., 2017). El GSD calculado a una altura de vuelo de 100 m, con una distancia focal de 6.72 mm y tamaño de pixel de 0.002618 mm, fue de 3.9 cm/pixel, lo que permitió obtener ortomosaicos de alta resolución espacial para el análisis estructural del cultivo.

Se generó un modelo 3D texturizado (Figura 3b) que combina la geometría de la nube densa con la información radiométrica de las imágenes originales. Este modelo permitió una visualización realista de la superficie agrícola, facilitando la interpretación de las condiciones del cultivo y la detección de irregularidades topográficas o daños en campo. Durante el procesamiento, el modelo 3D fue dividido en teselas o *tiles* (Figura 3c), unidades espaciales discretas utilizadas para optimizar el manejo computacional de la nube de puntos y los modelos ráster derivados (Kim et al., 2022). Este esquema modular facilitó la comparación entre sectores del campo y la identificación de zonas con diferencias topográficas y de vigor del




Figura 3. Productos fotogramétricos derivados del dron DJI Mini Pro 4: a) nube de puntos, b) modelo 3D, c) modelo de teselas y d) puntos de enlaces (*tie points*) en Agisoft Metashape.

cultivo. Además, las teselas sirvieron para calcular métricas estadísticas locales, como la media, desviación estándar y coeficiente de variación de la altura del cultivo, lo que posibilitó un análisis espacial más detallado y una interpretación agronómica más precisa (Ruwanpathirana et al., 2024).

Mediante el algoritmo *SFM*, se obtuvieron los *tie points* (Figura 3d) que representan las correspondencias homólogas entre imágenes superpuestas. Estos puntos son fundamentales para estimar con precisión la orientación exterior de cada toma y definir la geometría espacial de la escena reconstruida (Ziliani et al., 2018). En total, se identificaron más de 179,569 *tie points* distribuidos homogéneamente a lo largo del área de estudio, garantizando la estabilidad geométrica del bloque fotogramétrico. La densidad y distribución uniforme de estos puntos favoreció la obtención de una nube densa de puntos con alta precisión y detalle topográfico. La correlación multivista aplicada en Agisoft Metashape permitió obtener una nube con una resolución espacial promedio de 1.57 cm/pixel, reflejando microvariaciones en la superficie agrícola y permitiendo un análisis detallado de relieve y estructura de cultivo (Gao et al., 2022).

La calidad de la reconstrucción permitió distinguir claramente las hileras de maíz y su variabilidad espacial, tanto en densidad como en vigor vegetativo. Los resultados obtenidos confirman la eficacia del uso de drones ligeros como el DJI Mini Pro 4 en levantamientos fotogramétricos de alta precisión. La densidad de *tie points*, combinada con el adecuado traslape (90 % frontal y 70 % lateral) y la altura de vuelo de 100 m, garantizó la generación de productos cartográficos con gran fidelidad geométrica (Yu et al., 2022).

Modelos digitales derivados por fotogrametría

El procesamiento en Agisoft Metashape permitió generar una nube densa de puntos cuya resolución media de modelado fue de 1.57 cm·pixel⁻¹, valor correspondiente al tamaño de celda definido durante la interpolación del modelo derivado de la correlación multivista. El ortomosaico se obtuvo mediante la ortorrectificación y mosaico de las imágenes calibradas, utilizando el *MDS* como referencia altimétrica y el sistema de coordenadas WGS84 / UTM zona 15N. El producto final fue exportado con un tamaño de pixel de 1.95 cm·pixel⁻¹; sin embargo, se aclara que la resolución espacial efectiva del sistema

está limitada por el *GSD* geométrico de adquisición (3.9 cm·pixel⁻¹), calculado a partir de la altura de vuelo (100 m) y los parámetros ópticos de la cámara (distancia focal = 6.72 mm; tamaño de pixel = 2.62 μm) del DJI Mini 4 Pro. Por tanto, los valores menores al *GSD* corresponden a procesos de remuestreo interno y no implican un incremento en la resolución geométrica real. La precisión planimétrica del ortomosaico fue verificada mediante puntos de control terrestre georreferenciados con receptor *GNSS* de doble frecuencia, alcanzando un error cuadrático medio (*RMSE*) de ± 5 cm. Este valor se encuentra dentro de los rangos reportados por Agüera-Vega et al. (2017) y Mesas-Carrascosa et al. (2016) para levantamientos *UAV* con cámaras *RGB* no métricas, confirmando la fiabilidad del modelo generado para análisis agronómicos y de precisión espacial.

A partir de la nube densa de puntos obtenida durante el procesamiento fotogramétrico, se generaron los modelos *MDS* y *MDT* que se presentan en la Figura 5. Ambos productos constituyen la base para la caracterización geomorfológica y agronómica del área de estudio, ya que permiten cuantificar variaciones altimétricas, estimar alturas de vegetación y analizar microrrelieves asociados al manejo agrícola.

El *MDS* representa la altitud de todos los elementos de la escena, incluyendo vegetación, infraestructura agrícola, edificaciones y microtopografía superficial. Su generación se realizó a partir de la nube densa de puntos que fue interpolada mediante un método de malla regular con resolución espacial de 2 cm/pixel, garantizando una representación continua de la superficie. Este modelo es particularmente útil en agricultura de precisión, ya que permite identificar irregularidades en el terreno que pueden influir en el drenaje, la acumulación de humedad o el estrés hídrico localizado del cultivo.

Por otro lado, el *MDT* refleja la altitud del terreno desnudo, sin considerar objetos superficiales. Para su obtención, se aplicó una clasificación automática de puntos dentro de Agisoft Metashape Professional (v.2.0) mediante el algoritmo de segmentación adaptativa por densidad y pendiente local. Este procedimiento permitió diferenciar los puntos correspondientes al suelo de aquellos asociados a la vegetación o estructuras. Posteriormente, los puntos clasificados como *ground* fueron interpolados mediante un algoritmo de triangulación irregular (*TIN*) para generar una superficie continua que representara el relieve base de la parcela.

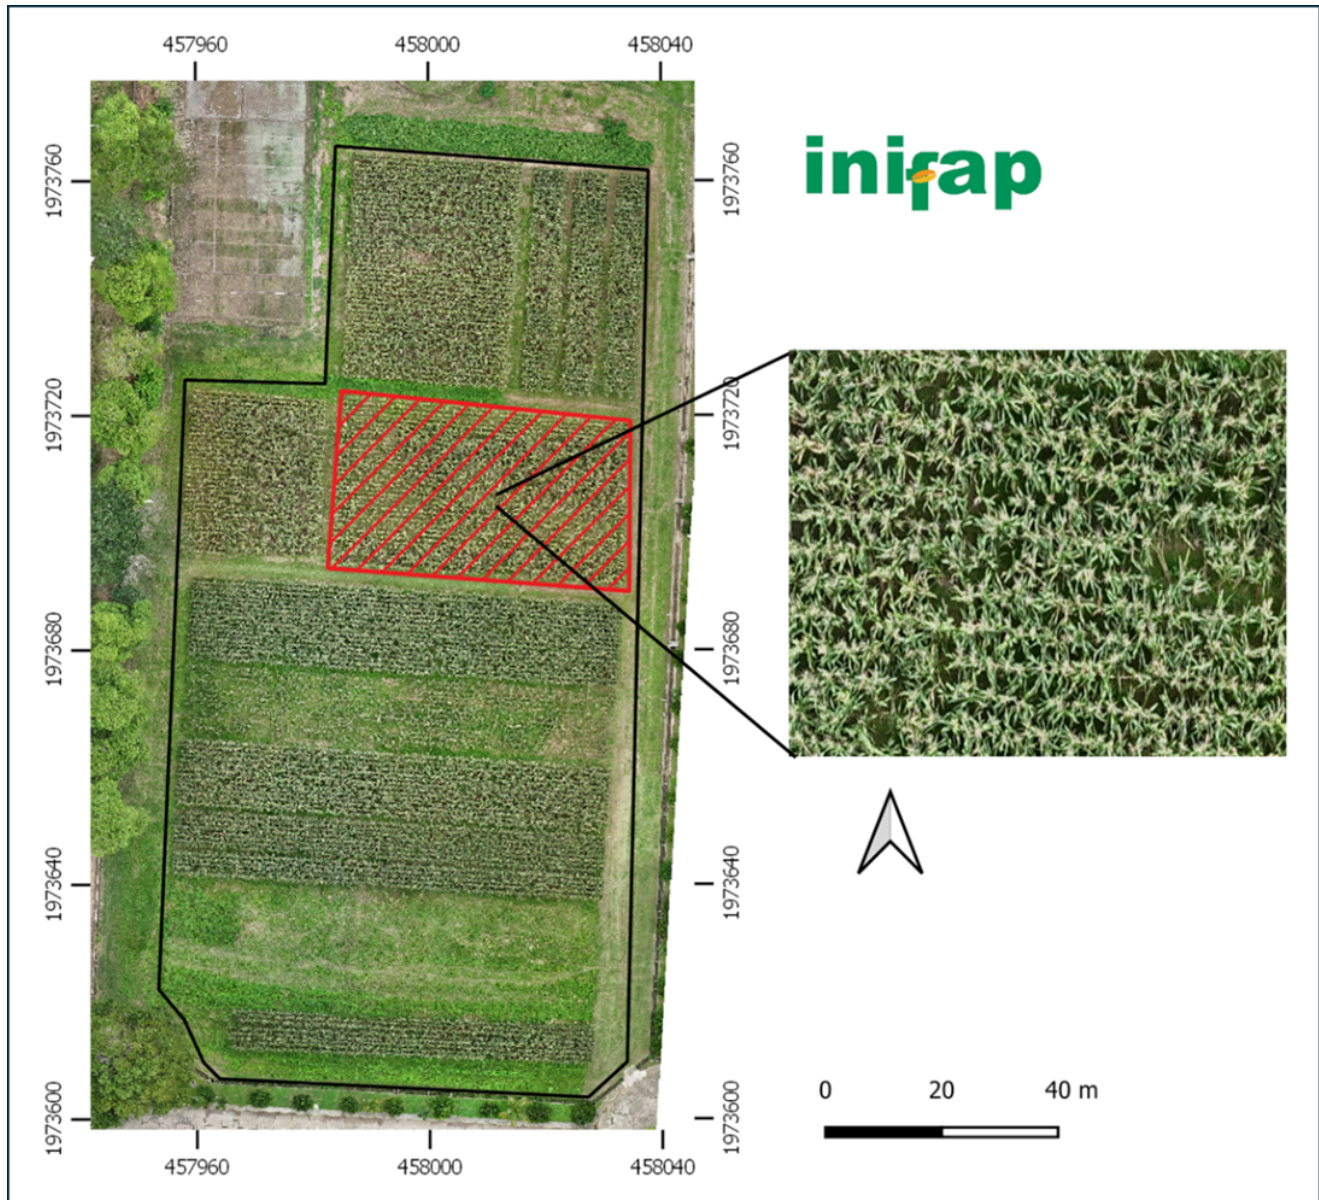


Figura 4. Ortofotomosaico generado a partir de las imágenes capturadas con el dron DJI Mini Pro 4 en el Campo Experimental Huimanguillo del INIFAP en Tabasco, México.

A partir de la nube densa se generaron el MDS y el MDT (Figura 5), aplicando la clasificación automática de puntos basada en criterios geométricos y de altura relativa. No obstante, en cultivos con cobertura densa, como el maíz en etapas avanzadas de desarrollo, la fotogrametría pasiva presenta limitaciones para detectar el suelo bajo el dosel vegetal, a diferencia de tecnologías activas como LiDAR. En estas condiciones, la clasificación automática puede no identificar completamente puntos correspondientes al terreno desnudo, lo que podría introducir errores en el MDT y, en consecuencia, afectar la estimación de la altura del cultivo calculada como la diferencia MDS-MDT. Por ello, se reconoce que la generación de un MDT previo a la

siembra o la disponibilidad de un modelo base de alta precisión del terreno constituye una estrategia metodológica recomendable para reducir la incertidumbre en estudios futuros.

Estimaciones de la altura de planta por medio de fotogrametría

Los modelos digitales generados mediante fotogrametría con VANT demostraron una alta precisión y consistencia espacial en la estimación de la altitud y estructura del cultivo de maíz (Figura 6). La diferencia promedio entre el MDS y el MDT permitió obtener alturas de dosel dentro del rango de 3.2 m reportado

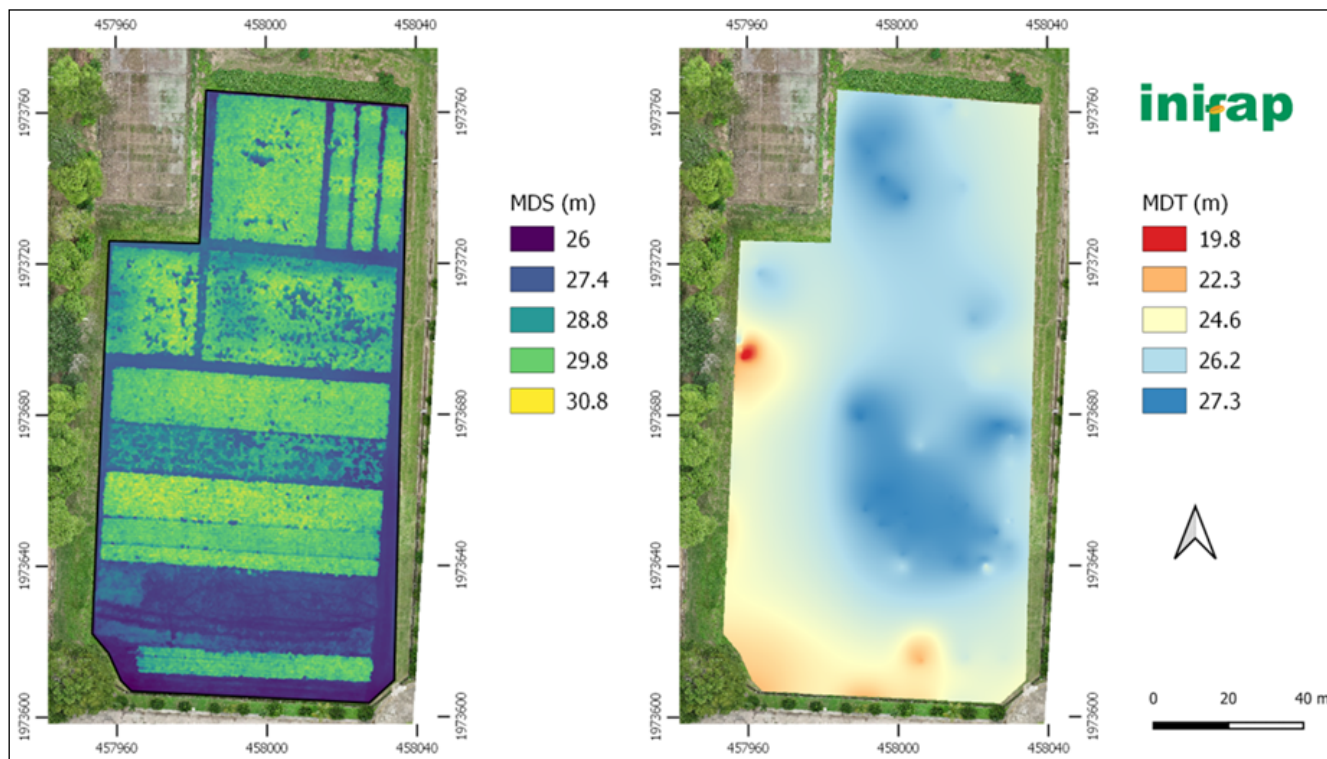


Figura 5. Modelo digital de superficie (MDS) y de terreno (MDT) generados a partir de las imágenes capturadas con el dron DJI Mini Pro 4 en el Campo Experimental Huimanguillo del INIFAP en Tabasco, México.

para híbridos comerciales de *Z. mays* en condiciones de trópico húmedo (Zhang et al., 2021).

Los valores obtenidos evidenciaron una clara variabilidad espacial en la altura del cultivo (Cuadro 2), atribuible a diferencias en el desarrollo vegetativo y en las condiciones locales de humedad y fertilidad del suelo. Se observó una tendencia de mayores alturas hacia el centro, este y sur del lote, lo que sugiere un crecimiento más vigoroso del cultivo en dichas zonas. Esta heterogeneidad refleja la influencia de factores edáficos, la disponibilidad hídrica y el manejo agronómico aplicado (Yang et al., 2023). Las áreas con menor altura se asociaron con posibles condiciones de estrés hídrico o compactación del suelo, mientras que las zonas con mayor desarrollo vegetativo correspondieron a sectores con mejor drenaje y mayor disponibilidad de nutrientes. El uso de los MDS y MDT para estimar la altura de planta permitió identificar patrones espaciales del crecimiento del cultivo con una precisión centimétrica, validando la capacidad de la fotogrametría de baja altura como herramienta eficaz para el monitoreo estructural de los cultivos. La correspondencia observada entre las zonas de mayor altura y las áreas de mayor reflectancia en el ortomosaico respalda la fiabilidad del modelo generado (Malachy et al., 2022).

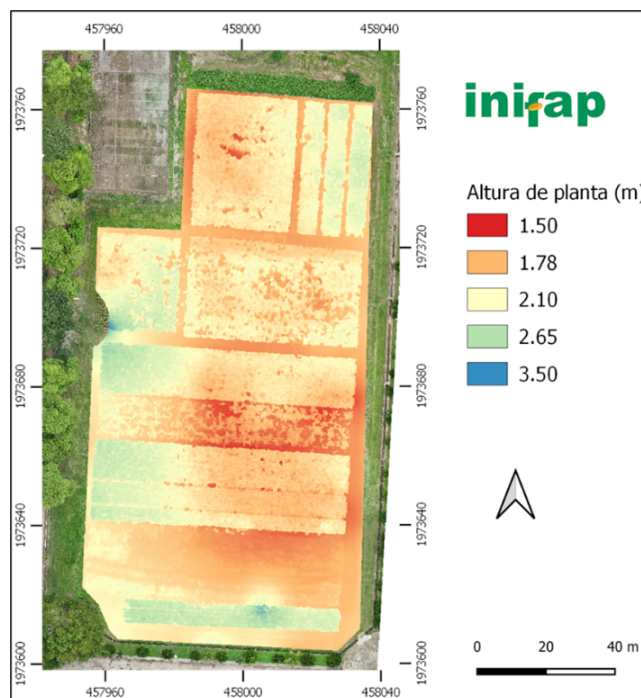


Figura 6. Altura de planta del cultivo de maíz estimados a partir de las imágenes capturadas con el dron DJI Mini Pro 4 en el Campo Experimental Huimanguillo del INIFAP en Tabasco, México.

Cuadro 2. Estadísticas de la altura de planta estimada por medio de productos fotogramétricos de maíz establecido en el campo experimental Huimanguillo del INIFAP, Tabasco, México.

Variable	Valor min.	Valor máx.	Rango	Media	Mediana	cv
Alt dron	1.5	3.5	2.0	2.68	2.64	10.2
Alt campo	1.86	3.12	1.26	2.65	2.63	12.4

*Alt dron = mediciones estimadas con el dron DJI Mini Pro 4; Alt campo = mediciones realizadas en campo; cv = coeficiente de variación (%).

Los resultados del Cuadro 2 muestran una alta concordancia entre las alturas de planta estimadas a partir de los productos fotogramétricos y las mediciones directas en campo. La altura promedio derivada del dron (2.68 m) fue prácticamente equivalente a la altura promedio observada en campo (2.65 m), lo que evidencia la precisión y confiabilidad del modelo fotogramétrico para la estimación estructural del cultivo. El rango de variación fue ligeramente mayor en las estimaciones del dron (2.0 m) en comparación con las mediciones de campo (1.26 m), lo cual puede atribuirse a la mayor sensibilidad del modelo digital de superficie (MDS) para detectar diferencias locales en la cobertura vegetal, especialmente en bordes o zonas con sombra. El coeficiente de variación (cv) fue bajo en ambos casos, registrando un valor de 10.2 % para las mediciones obtenidas mediante dron y de 12.4 % para las mediciones realizadas en campo, lo cual indica una homogeneidad aceptable en el desarrollo del cultivo. Sin embargo, el cv ligeramente superior en campo refleja la variabilidad natural entre plantas individuales, mientras que las estimaciones fotogramétricas tienden a suavizar esas diferencias al representar promedios espaciales de cada celda del modelo (Belton et al., 2019).

El sesgo observado en las zonas de color rojo puede explicarse por el proceso de emparejamiento de imágenes. Por ejemplo, no todos los puntos modelo del MDS corresponden a la altura de las plantas de maíz; en lugar de coincidir con la parte superior de las plantas, pueden capturarse puntos más bajos, como las hojas más bajas del cultivo. Algunos de estos puntos pueden incluso representar zonas cercanas a la base de las plantas o, en algunos casos, el nivel del suelo (dependiendo de la densidad del cultivo) como se observa en algunas partes de las parcelas de maíz en el MDT (Figura 5) (Belton et al., 2019). Asimismo, las alturas superiores a 3.5 m representadas en azul en la Figura 6 corresponden a sesgos altimétricos derivados de la interferencia de elementos no pertenecientes al cultivo, principalmente copas de árboles situados en el borde oriental del lote. Durante la etapa de recorte del ortomosaico y de la nube densa, parte de la vegetación arbórea quedó incluida dentro

del modelo digital, lo que provocó una sobreestimación local de la altura del cultivo. Este tipo de errores son comunes en zonas de borde cuando el traslape entre imágenes es alto y las texturas del follaje se confunden con la superficie del cultivo. En este caso, la discrepancia observada no refleja la altura real de las plantas de maíz, sino un artefacto geométrico producto del solapamiento de estructuras altas adyacentes que debe corregirse mediante una clasificación más estricta de la nube de puntos o la delimitación previa del área de cultivo antes del procesamiento final (Corti et al., 2023).

Un problema adicional surgió durante el procesamiento de las imágenes: las imágenes del cultivo, en esta etapa, fueron capturadas después de un periodo de condiciones meteorológicas poco favorables. Ráfagas de viento superiores azotaron el cultivo previo a la captura, provocando movimiento en el dosel vegetal y plantas acamadas. Mientras el VANT realizaba una pasada sobre el sitio, tomaba imágenes cada dos segundos, registrando la posición exacta de la parte superior del cultivo de maíz en ese momento. Sin embargo, al realizar la pasada adyacente y capturar la imagen superpuesta de la misma zona, las plantas de maíz se habían inclinado en otra dirección, cambiando así la posición de la planta (Xie et al., 2021).

Modelo 3D de la altura de planta por fotogrametría

En la Figura 7 se visualiza la gráfica en 3D del ráster de las alturas de plantas del cultivo de maíz estimadas por medio de los productos fotogramétricos como los modelos digitales de MDS y MDT. Se tomó una parcela de muestra para generar el gráfico. Ahí se observan las hileras y la variabilidad espacial de las plantas de maíz donde los valores de altura más pequeños se encuentran en los bordes de la parcela y las alturas más uniformes y altas en la parte central de la parcela muestra. Estos resultados respaldan que, al realizar mediciones de variables agronómicas, la parte central de la parcela constituye la región más representativa para la toma adecuada de datos (Li et al., 2024).

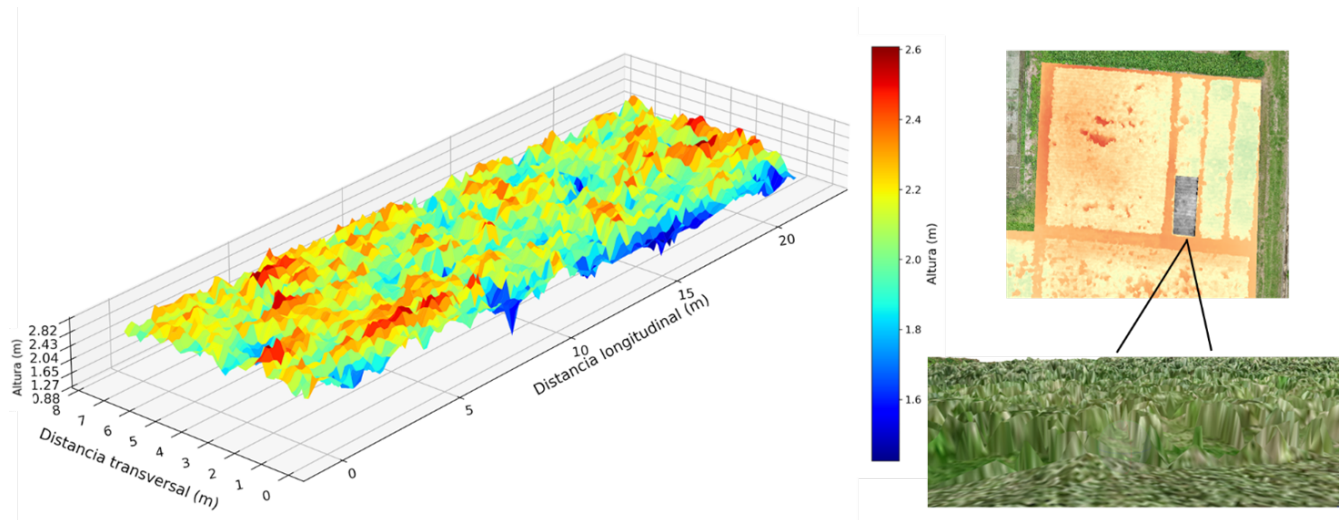


Figura 7. Representación visual en 3D de la altura de planta de maíz estimadas por medio de productos fotogramétricos en el Campo Experimental Huimanguillo del INIFAP en Tabasco, México.

Validación de las estimaciones de altura de planta por fotogrametría

Los resultados de la comparación entre las alturas observadas en campo y las estimadas a partir de los productos fotogramétricos del VANT muestran una excelente concordancia (Figura 8). La regresión lineal entre las alturas observadas y estimadas, con un coeficiente de determinación $R^2 = 0.964$, indicando que el 96.4 % de la variabilidad en las alturas estimadas es explicada por el modelo lineal ajustado. El RMSE de 0.205 m refleja un bajo error promedio entre las alturas predichas y las observadas, confirmando la precisión del modelo. Además, el p -value = 0.0 evidencia que la relación lineal encontrada es altamente significativa estadísticamente. El coeficiente de correlación de Pearson fue $r = 0.982$ ($p < 0.05$), evidenciando una relación lineal positiva muy fuerte y estadísticamente significativa entre ambas variables.

Estos resultados sugieren que los modelos digitales generados por el VANT permiten estimar con alta precisión la altura del cultivo de maíz. La pendiente de la regresión (0.96) sugiere una ligera compresión en la escala de variación de las alturas estimadas respecto a las observadas; sin embargo, la cercanía al valor unitario indica que el modelo reproduce adecuadamente la dinámica estructural del cultivo. No obstante, la alta R^2 y el bajo RMSE respaldan que la metodología fotogramétrica es confiable para estudios agronómicos y para la planificación de manejo del cultivo. Al respecto de la unidad, esto implica que el modelo tiende

a subestimar las alturas más altas del cultivo, lo que podría estar asociado a limitaciones del modelo digital o a la estructura del dosel que no se capturó completamente en el modelo fotogramétrico. Esta tendencia concuerda con hallazgos previos donde la estimación de la altura del cultivo mediante VANT mostró subestimaciones en etapas avanzadas o en cultivos de mayor altura, reportando un RMSE de 0.146 m para maíz usando aprendizaje automático y datos VANT (Ferraz et al., 2024). Asimismo, Oehme et al. (2022) obtuvieron R^2 en el rango 0.44-0.61 y RMSE entre 0.06 m y 0.21 m para maíz usando modelos digitales de MDS y MDT obtenidos por VANT. Además, el estudio de Gao et al. (2022), usando LiDAR y RGB montados en UAV, alcanzó $R^2 > 0.95$ y RMSE en torno a 0.03-0.045 m en etapas de crecimiento temprano, aunque bajo condiciones muy controladas y para plantas individuales. En comparación, este estudio trabaja con parcelas completas del cultivo, lo que representa un escenario más cercano a la aplicación agronómica real. Por lo tanto, la precisión obtenida es notable y sugiere que la metodología es robusta para la estimación de altura del cultivo en contextos de investigación aplicada.

Las implicaciones prácticas de estos resultados son relevantes: dada la alta correlación y baja desviación, el uso de VANT para estimar la altura del maíz podría reemplazar o complementar mediciones manuales en campo, permitiendo un monitoreo más rápido, menos laborioso y con buena precisión. No obstante, se recomienda calibrar el modelo específicamente para cada localización o variedad, especialmente cuando el cul-

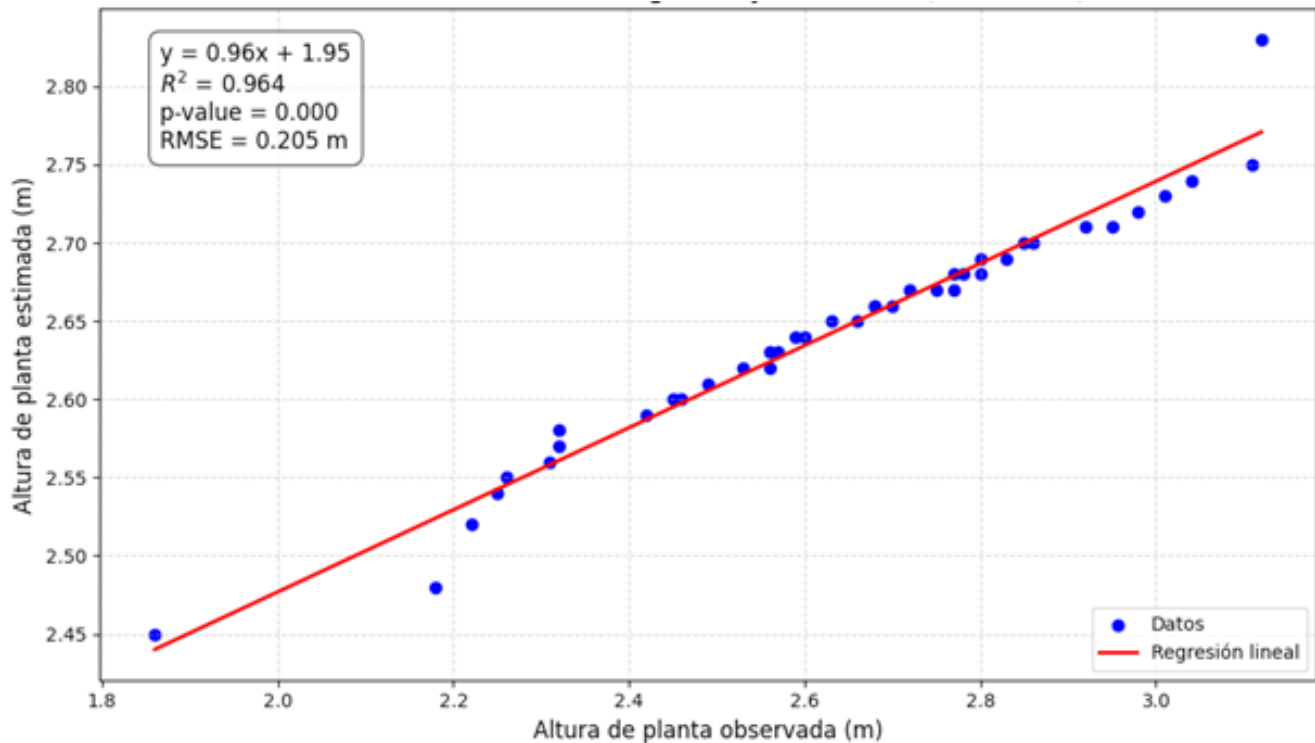


Figura 8. Validación cruzada de las estimadas de la altura de planta de maíz estimadas por medio de productos fotogramétricos y mediciones en tierra en el Campo Experimental Huimanguillo del INIFAP en Tabasco, México.

tivo alcanza alturas elevadas o presenta estructuras densas como plantaciones forestales (Palma-López et al., 2015), para mitigar la subestimación observada.

Por último, la estimación de altura del cultivo mediante vANT fotogramétrico es una herramienta prometedora en agricultura de precisión, siempre que se reconozcan sus limitaciones de pendiente y se realice una validación adecuada frente a mediciones de campo.

CONCLUSIONES

El uso de vehículos aéreos no tripulados (vANT) y técnicas de fotogrametría de baja altura demostró ser una herramienta eficiente y de bajo costo para el monitoreo estructural de cultivos en condiciones tropicales. En comparación con métodos convencionales de medición manual intensiva en campo o con plataformas aerotransportadas tripuladas (por ejemplo, vuelos con aeronaves ligeras o levantamientos LiDAR), esta metodología representa una alternativa operativamente más flexible y potencialmente más económica para evaluaciones a escala parcelaria. Los modelos digitales derivados (MDS y MDT) permitieron estimar la altura de planta con precisión centimétrica cuando se relacionaron con las mediciones de campo (R^2 de 0.96

y RMSE de 0.205 m), evidenciando la capacidad de esta metodología para identificar variaciones espaciales del desarrollo vegetativo relacionadas con factores edáficos, hídricos y de manejo agronómico. Estos resultados evidencian que la metodología es confiable para identificar las variaciones antes descritas, aunque la precisión absoluta está limitada por el instrumento utilizado para la georreferenciación de los puntos de control terrestre.

La generación del ortomosaico de alta resolución, junto con el modelo tridimensional de superficie, facilitó la interpretación visual y cuantitativa del estado del cultivo, aportando información relevante para la toma de decisiones agronómicas, la gestión del riego y la planificación de fertilización localizada. Asimismo, la correspondencia entre los valores de altura estimados y los patrones de reflectancia observados respalda la consistencia geométrica y radiométrica del modelo fotogramétrico, validando la fiabilidad del flujo de trabajo implementado en Agisoft Metashape y su integración con herramientas SIG como QGIS.

Finalmente, los resultados obtenidos confirman que la fotogrametría con drones ligeros, como el DJI Mini Pro 4, constituye una alternativa robusta para el análisis fenotípico y la caracterización espacial del

crecimiento vegetal, con potencial de aplicación en programas de agricultura de precisión y monitoreo de parcelas experimentales del trópico húmedo mexicano.

LITERATURA CITADA

- Agisoft LLC. (2023). *Agisoft Metashape User Manual (Version 2.0)*. Agisoft LLC.
- Agüera-Vega, F., Carvajal-Ramírez, F., & Martínez-Carricondo, P. (2017). Accuracy of digital surface models and orthophotos derived from unmanned aerial vehicle photogrammetry. *Journal of Surveying Engineering*, 143(2), 04016025. [https://doi.org/10.1061/\(ASCE\)SU.1943-5428.0000206](https://doi.org/10.1061/(ASCE)SU.1943-5428.0000206)
- Alemán-Montes, B., Henríquez-Henríquez, C., Ramírez-Rodríguez, T., & Largaespada-Zelaya, K. (2021). Estimación de rendimiento en el cultivo de caña de azúcar (*Saccharum officinarum*) a partir de fotogrametría con vehículos aéreos no tripulados (vANT). *Agronomía Costarricense*, 45(1), 67-80.
- American Society for Photogrammetry and Remote Sensing. (2024). *ASPRS Positional Accuracy Standards for Digital Geospatial Data (Edition 2, Version 2.0)*. ASPRS. <https://publicdocuments.asprs.org/PositionalAccuracyStd-Ed2-V2>
- Ballesteros, R., Ortega, J. F., Hernández, D., & Moreno, M. A. (2014). Applications of georeferenced high-resolution images obtained with unmanned aerial vehicles. Part I: Description of image acquisition and processing. *Precision Agriculture*, 15, 579-592. <https://doi.org/10.1007/s11119-014-9355-8>
- Barrón-Freyre, S., Barrón, A. M., & Palafox, C. A. (2014). Potencial productivo de nueve híbridos de maíz para forraje en condiciones de temporal en la Chontalpa Tabasco. En *xxvi Reunión Científica-Tecnológica Forestal y Agropecuaria Tabasco, III Simposio Internacional en Producción Agroalimentaria Tropical*. Villahermosa, México.
- Belton, D., Helmholz, P., Long, J., & Zerihun, A. (2019). Crop height monitoring using a consumer-grade camera and UAV technology. *ISPRS International Journal of Geoinformation Science*, 87, 249-262. <https://doi.org/10.1007/s41064-019-00087-8>
- Bongomin, O., Lamo, J., Guina, J. M., Okello, C., Ocen, G. G., Obura, M., Alibu, S., Owino, C. A., Akwero, A., & Ojok, S. (2024). UAV image acquisition and processing for high-throughput phenotyping in agricultural research and breeding programs. *The Plant Phenome Journal*, 7(1), e20096. <https://doi.org/10.1002/ppj2.20096>
- Brandt, L. E., & Freeman, W. T. (2021). Toward Automatic Interpretation of 3D Plots. En J. Lladós, D. Lopresti & S. Uchida (Eds.), *Document Analysis and Recognition - ICDAR 2021. Lecture Notes in Computer Science*. Springer. https://doi.org/10.1007/978-3-030-86331-9_3
- Cano, E., Horton, R., Liljegren, C., & Bulanon, D. M. (2017). Comparison of small unmanned aerial vehicles performance using image processing. *Journal of Imaging*, 3(1), 4. <https://doi.org/10.3390/jimaging3010004>
- Córdova-Sánchez, S., Góngora-Cruz, K. G., Hernández-Villegas, M. M., Salgado-Velázquez, S., López-Castañeda, A., & Castañeda-Ceja, R. (2023). Response of different sowing densities on agronomic parameters in the cultivation of *mejen* corn in Tabasco, Mexico. *Agro Productividad*, 16(10), 95-102. <https://doi.org/10.32854/agrop.v16i9.2623>
- Corti, M., Cavalli, D., Cabassi, G., Bechini, L., Pricca, N., Paolo, D., Mariononi, L., Vigoni, A., Degano, L., & Marino Gallina, P. (2023). 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>
- Dandois, J. P., Olano, M., & Ellis, E. C. (2015). Optimal altitude, overlap, and weather conditions for computer vision UAV estimates of forest structure. *Remote Sensing*, 7(10), 13895-13920. <https://doi.org/10.3390/rs71013895>
- DJI. (2023). *DJI Mini 4 Pro. Especificaciones*. <https://www.dji.com/mx/mini-4-pro/specs>
- Dong, H., Dong, J., Sun, S., Bai, T., Zhao, D., Yin, Y., Shen, X., Wang, Y., Zhang, Z., & Wang, Y. (2024). Crop water stress detection based on UAV remote sensing systems. *Agricultural Water Management*, 303, 109059. <https://doi.org/10.1016/j.agwat.2024.109059>
- Eskandari, R., Mahdianpari, M., Mohammadimanesh, F., Salehi, B., Brisco, B., & Homayouni, S. (2020). Meta-analysis of unmanned aerial vehicle (UAV) imagery for agro-environmental monitoring using machine learning and statistical models. *Remote Sensing*, 12(21), 3511. <https://doi.org/10.3390/rs12213511>
- Ferraz, M. A. J., Barboza, T. O. C., Arantes, P. de S., Von Pinho, R. G., & Dos Santos, A. F. (2024). Integrating satellite and UAV technologies for maize plant height estimation using advanced machine learning.

- AgriEngineering*, 6(1), 20-33. <https://doi.org/10.3390/agriengineering6010002>
- Food and Agriculture Organization of the United Nations. (2023). *FAOSTAT Statistical Database*. FAO. <https://www.fao.org/faostat/>
- Fujiwara, R., Kikawada, T., Sato, H., & Akiyama, Y. (2022). Comparison of remote sensing methods for plant heights in agricultural fields using unmanned aerial vehicle-based structure from motion. *Frontiers in Plant Science*, 13, 886804. <https://doi.org/10.3389/fpls.2022.886804>
- Gao, M., Yang, F., Wei, H., & Liu, X. (2022). Individual maize location and height estimation in field from UAV-Borne LiDAR and RGB images. *Remote Sensing*, 14(10), 2292. <https://doi.org/10.3390/rs14102292>
- Kim, T., Park, J., Lee, C., Yun, Y., Jung, J., & Han, Y. (2022). Multi-temporal orthophoto and digital surface model registration produced from UAV imagery over an agricultural field. *Geocarto International*, 37(27), 18767-18790. <https://doi.org/10.1080/10106049.2022.2143913>
- Lambertini, A., Mandanici, E., Tini, M. A., & Vittuari, L. (2022). Technical challenges for multi-temporal and multi-sensor image processing surveyed by UAV for mapping and monitoring in precision agriculture. *Remote Sensing*, 14(19), 4954. <https://doi.org/10.3390/rs14194954>
- Li, Y., Li, C., Cheng, Q., Duan, F., Zhai, W., Li, Z., Mao, B., Ding, F., Kuang, X., & Chen, Z. (2024). Estimating maize crop height and aboveground biomass using multi-source unmanned aerial vehicle remote sensing and optimal-optimized ensemble learning algorithms. *Remote Sensing*, 16(17), 3176. <https://doi.org/10.3390/rs16173176>
- Malachy, N., Zadach, I., & Rozenstein, O. (2022). Comparing methods to extract crop height and estimate crop coefficient from UAV imagery using structure from motion. *Remote Sensing*, 14(4), 810. <https://doi.org/10.3390/rs14040810>
- Mesas-Carrascosa, F.-J., Notario García, M. D., Meroño de Larriva, J. E., & García-Ferrer, A. (2016). An analysis of the influence of flight parameters in the generation of unmanned aerial vehicle (UAV) orthomosaics to survey archaeological areas. *Sensors*, 16(11), 1838. <https://doi.org/10.3390/s16111838>
- Oehme, L. H., Reineke, A.-J., Weiß, T. M., Würschum, T., He, X., & Müller, J. (2022). Remote sensing of maize plant height at different growth stages using UAV-based digital surface models (DSM). *Agronomy*, 12(4), 958. <https://doi.org/10.3390/agronomy12040958>
- Olson, D., & Anderson, J. (2021). Review on unmanned aerial vehicles, remote sensors, imagery processing, and their applications in agriculture. *Agronomy Journal*, 113(2), 971-992. <https://doi.org/10.1002/agj2.20595>
- Olvera-Rincón, F., Salgado-Velázquez, S., Córdova-Sánchez, S., Palma-López, D. J., López-Castañeda, A., & Castañeda-Ceja, R. (2024). Defoliación del cultivo de caña de azúcar (*Saccharum officinarum*) en la Chontalpa, Tabasco, México. *Agronomía Mesoamericana*, 35, 53608. <http://doi.org/10.15517/am.2024.53608>
- Palma-López, D. J., Salgado-García, S., Martínez Sebastian, G., Zavala-Cruz, J., & Lagunes-Espinoza, L. Del C. (2015). Cambios en las propiedades del suelo en plantaciones de eucalipto de Tabasco, México. *Ecosistemas y Recursos Agropecuarios*, 2(5), 163-172. <https://doi.org/10.19136/era.a2n5.767>
- Palma-López, D. J., Jiménez Ramírez, R., Zavala-Cruz, J., Bautista-Zúñiga, F., Gavi Reyes, F., & Palma-Cancino, D. Y. (2017). Actualización de la clasificación de suelos de Tabasco, México. *Agro Productividad*, 10(12), 29-35.
- Qiao, L., Tang, W., Gao, D., Zhao, R., An, L., Li, M., Sun, H., & Song, D. (2022). UAV-based chlorophyll content estimation by evaluating vegetation index responses under different crop coverages. *Computers and Electronics in Agriculture*, 196, 106775. <https://doi.org/10.1016/j.compag.2022.106775>
- Ruwanpathirana, P. P., Sakai, K., Jayasinghe, G. Y., Nakandakari, T., Yuge, K., Wijekoon, W. M. C. J., Priyankara, A. C. P., Samaraweera, M. D. S., & Madushanka, P. L. A. (2024). Evaluation of sugarcane crop growth monitoring using vegetation indices derived from RGB-based UAV images and machine learning models. *Agronomy*, 14(9), 2059. <https://doi.org/10.3390/agronomy14092059>
- Salgado-Velázquez, S., Salgado-García, S., Rincón-Ramírez, J. A., Rodrigues Jr, F. A., Palma-López, D. J., Córdova-Sánchez, S., & López-Castañeda, A. (2020). Spatial variability of soil physicochemical properties in agricultural fields cultivated with sugarcane (*Saccharum officinarum* L.) in Southeastern Mexico. *Sugar Tech*, 22, 65-75. <https://doi.org/10.1007/s12355-019-00742-9>
- Salgado-Velázquez, S., Becerril-Hernández, H., Rincón-Ramírez, J. A., Aceves-Navarro, L., & Córdova-Sánchez, S. 2025. Remote sensing and machine learning techniques used to predict sugarcane (*Saccharum* spp.)

- yield. *Agro Productividad*, 18(9), 229-237. <https://doi.org/10.32854/dp4qtd40>
- Servicio de Información Agroalimentaria y Pesquera. (2024). *Anuario estadístico de la producción agrícola*. SIAP. https://nube.agricultura.gob.mx/cierre_agricola/
- Sumano-López, D., Barrón-Freyre, S., Ramírez-Guillermo, M. A., Palma-Cancino, D. J., Salgado-Velázquez, S., & Rodríguez-Cuevas, M. (2025). Performance of corn (*Zea mays* L.) with application of poultry manure and leachates as organic fertilizer. *Agro Productividad*, 18(2), 135-148. <https://doi.org/10.32854/agrop.v18i2.3251>
- Torres-Sánchez, J., López-Granados, F., Serrano, N., Arquero, O., & Peña, J. M. (2015). High-throughput 3-D monitoring of agricultural-tree plantations with unmanned aerial vehicle (UAV) technology. *PloS ONE*, 10(6), e0130479. <https://doi.org/10.1371/journal.pone.0130479>
- Tsouros, D. C., Triantafyllou, A., Bibi, S., & Sarigannidis, P. G. (2019). Data acquisition and analysis methods in UAV-based applications for precision agriculture. En *2019 15th International Conference on Distributed Computing in Sensor Systems*. Santorini, Grecia. <https://doi.org/10.1109/DCOSS.2019.00080>
- Velusamy, P., Rajendran, S., Mahendran, R. K., Naseer, S., Shafiq, M., & Choi, J.-G. (2022). Unmanned aerial vehicles (UAV) in precision agriculture: Applications and challenges. *Energies*, 15(1), 217. <https://doi.org/10.3390/en15010217>
- Xie, T., Li, J., Yang, C., Jiang, Z., Chen, Y., Guo, L., & Zhang, J. (2021). Crop height estimation based on UAV images: Methods, errors, and strategies. *Computers and Electronics in Agriculture*, 185, 106155. <https://doi.org/10.1016/j.compag.2021.106155>
- Yang, Z., Cao, Y., Shi, Y., Qin, F., Jiang, C., & Yang, S. (2023). Genetic and molecular exploration of maize environmental stress resilience: Toward sustainable agriculture. *Molecular Plant*, 16(10), 1496-1517. <https://doi.org/10.1016/j.molp.2023.07.005>
- Yu, X., Yin, D., Nie, C., Ming, B., Xu, H., Liu, Y., Bai, Y., Shao, M., Cheng, M., Liu, Y., Liu, S., Wang, Z., Wang, S., Shi, L., & Jin, X. (2022). Maize tassel area dynamic monitoring based on near-ground and UAV RGB images by u-Net model. *Computers and Electronics in Agriculture*, 203, 107477. <https://doi.org/10.1016/j.compag.2022.107477>
- Zhang, Y., Xia, C., Zhang, X., Cheng, X., Feng, G., Wang, Y., & Gao, Q. (2021). Estimating the maize biomass by crop height and narrowband vegetation indices derived from UAV-based hyperspectral images. *Ecological Indicators*, 129, 107985. <https://doi.org/10.1016/j.ecolind.2021.107985>
- Ziliani, M. G., Parkes, S. D., Hoteit, I., & McCabe, M. F. (2018). Intra-season crop height variability at commercial farm scales using a fixed-wing UAV. *Remote Sensing*, 10(12), 2007. <https://doi.org/10.3390/rs10122007>
- Wolf, P. R., Dewitt, B. A., & Wilkinson, B. E. (2014). *Elements of Photogrammetry with Applications in GIS*. McGraw-Hill.