

# Capítulo 16

---

## Cuantificación de plantas mediante el uso de imágenes aéreas e inteligencia artificial

*Samuel Uriel Samaniego Gamez*<sup>91</sup>

*Moisés Gilberto Yáñez Juárez*<sup>92</sup>

*Fidel Núñez Ramírez*<sup>93</sup>

*María Alejandra Payán Arzapalo*<sup>94</sup>

*Raúl Enrique Valle Gough*<sup>95</sup>

*Blancka Y. Samaniego Gamez*<sup>96</sup>

DOI: <https://doi.org/10.61728/AE26000343>



---

<sup>91</sup> Estudiante del programa de Doctorado en Ciencias Agropecuarias de la Universidad Autónoma de Sinaloa, Facultad de Agronomía, Campus Culiacán. Carretera Culiacán-El Dorado km. 17.5 Culiacán, Sinaloa, México. C. P. 80000.

<sup>92</sup> Universidad Autónoma de Sinaloa, Facultad de Agronomía, Campus Culiacán. Carretera Culiacán-El Dorado km. 17.5 Culiacán, Sinaloa, México. C. P. 80000.

<sup>93</sup> Universidad Autónoma de Baja California, Instituto de Ciencias Agrícolas. Carretera a Delta s/n, ejido Nuevo León, Mexicali, Baja California, México. C. P. 21705, [fidel.nunez@uabc.edu.mx](mailto:fidel.nunez@uabc.edu.mx).

<sup>94</sup> Universidad Autónoma de Sinaloa, Facultad de Agronomía, Campus Culiacán. Carretera Culiacán-El Dorado km. 17.5 Culiacán, Sinaloa, México. C. P. 80000.

<sup>95</sup> Universidad Autónoma de Baja California, Instituto de Ciencias Agrícolas. Carretera a Delta s/n, ejido Nuevo León, Mexicali, Baja California, México. C. P. 21705.

<sup>96</sup> Universidad Autónoma de Baja California, Instituto de Ciencias Agrícolas. Carretera a Delta s/n, ejido Nuevo León, Mexicali, Baja California, México. C. P. 21705.

## Resumen

A nivel mundial, la creciente demanda de productos agropecuarios responde a las necesidades alimentarias y nutricionales de una población cada vez mayor. En este contexto, mantener inventarios actualizados del número de plantas en los sistemas de producción agrícola es una práctica habitual que coadyuva a la mejor toma de decisiones. La cuantificación de plantas mediante imágenes aéreas e inteligencia artificial se ha convertido en una herramienta que permite el seguimiento exhaustivo de las plantaciones. Es por ello que el objetivo de la presente investigación fue evaluar la confiabilidad de la cuantificación de plantas mediante el uso de imágenes aéreas e inteligencia artificial, a través de un estudio de caso enfocado en la detección multitemporal de plantas cultivadas de brócoli (*Brassica oleracea* L. var. *italica*). La detección de plantas se evaluó bajo un diseño de bloques completamente al azar con cinco tratamientos y cuatro repeticiones. Los tratamientos consistieron en camas de cultivo sin acolchado (suelo desnudo) y con acolchado plástico de color gris, transparente, blanco y negro. Se realizaron misiones de vuelo para la detección de plantas en ortomosaicos a los 12, 20, 32 y 47 días después del trasplante (DDT). En las cuatro fechas de monitoreo se obtuvo relación positiva entre el conteo manual y la detección automatizada, presentando el máximo valor de coeficiente de determinación ( $R^2=0.978$ ) en la detección realizada a los 32 DDT. La detección en suelo desnudo presentó la mejor precisión de estimación ( $P_s=1.02$ ), indicando interferencia causada por los acolchados plásticos durante el proceso de detección de plantas. Se concluye que el momento y color del acolchado del suelo influyen en la confiabilidad de la detección automatizada de plantas a partir de fotografías aéreas.

## Introducción

A nivel mundial, la creciente demanda de productos agropecuarios responde a las necesidades alimentarias y nutricionales de una población cada vez mayor (Ahmad et al., 2024). En este contexto, mantener inventarios actualizados del número de plantas en los sistemas de producción agrícola es una práctica habitual que coadyuva a la mejor toma de decisiones y al uso eficiente de recursos, lo que permite avanzar hacia la sostenibilidad (Chamara et al., 2023; Farjon et al., 2023). La teledetección emplea diversas fuentes de información que, al ser analizadas y procesadas mediante sistemas de información geográfica e inteligencia artificial, se han consolidado como herramientas en la gestión agrícola (Khanal et al., 2020), ya que permiten visualizar los procesos de crecimiento y desarrollo de los cultivos, así como la cuantificación del número de plantas (Gupta et al., 2024; Pathak et al., 2022).

La cuantificación de plantas mediante imágenes aéreas e inteligencia artificial se ha convertido en una herramienta que permite el seguimiento exhaustivo de las plantaciones (Lu et al., 2023). Esto brinda la posibilidad de intervenir de forma oportuna para evitar problemas potenciales en la productividad (Khanal et al., 2020). Sin embargo, existen diferentes factores del sistema de producción agrícola que pueden disminuir la precisión de la detección de plantas en imágenes aéreas. Destacando la presencia de malezas, el porcentaje de cobertura foliar e interferencias por la utilización de diferentes acolchados del suelo (Maurya et al., 2024). Es por ello que el objetivo de la presente investigación fue evaluar la confiabilidad de la cuantificación de plantas mediante el uso de imágenes aéreas e inteligencia artificial, a través de un estudio de caso enfocado en la detección multitemporal de plantas cultivadas de brócoli (*Brassica oleracea* L. var. *Italica*).

## Materiales y métodos

El presente estudio se realizó en el campo experimental del Instituto de Ciencias Agrícolas de la Universidad Autónoma de Baja California (ICA-UABC), ubicado en las coordenadas 32.405105° de latitud norte

y  $-115.200136^\circ$  de longitud oeste. La plantación cultivada fue brócoli, híbrido Rijk Zwaan [Tahoe RZ F1 (25-962)]. La detección de plantas se evaluó bajo un diseño de bloques completamente al azar con cinco tratamientos y cuatro repeticiones. Los tratamientos consistieron en camas de cultivo sin acolchado (suelo desnudo) y con acolchado plástico de color gris, transparente, blanco y negro, lo que dio como resultado un total de 20 unidades experimentales. Cada una con superficie de  $21 \text{ m}^2$ , orientadas de norte a sur, con 6.0 m de longitud, 3.5 m de separación y 0.2 m de altura. Las plantas fueron trasplantadas en sistema triangular tresbolillo, con 0.4 m de separación entre plantas y 0.5 m entre hileras.

Las plantas fueron contabilizadas de forma exhaustiva, marcando cada una de forma manual en el ortomosaico de referencia utilizando el software QGIS v. 3.22.10 (QGIS, 2023). Esto mediante un vector de punto perteneciente a un archivo tipo shape. Así mismo, se realizaron cuatro misiones de vuelo, para obtener ortomosaicos de la plantación a los 12, 20, 32 y 47 días después del trasplante. Para ello se utilizó un RPAS Phantom 4 multispectral [© DJI] (DJI, 2019). El procesamiento de las imágenes aéreas para obtener los ortomosaicos se realizó con el software bajo licencia académica PIX4DFields (Pix4D, 2024). Los ortomosaicos generados tuvieron una distancia de muestreo terrestre de 0.04 m y fueron corregidos geográficamente con siete puntos de control terrestre de alta precisión (GPS-RTK) (SOUTH, 2024).

La detección mediante inteligencia artificial se realizó en la plataforma agrícola Agremo (Agremo, 2024). Por medio del algoritmo “row plant algorithm”, que se encuentra en la herramienta “conjunto logrado”, la cual generó un archivo vectorial de puntos correspondientes a las plantas estimadas en cada ortomosaico (Agremo, s. f. Finalmente, la cantidad estimada de plantas detectadas en cada misión fue contrastada con el conteo manual exhaustivo de referencia. Para lo cual se utilizaron el coeficiente de determinación obtenido por regresión lineal ( $R^2$ ) y la precisión en la estimación ( $P_s$ ) (Ecuación 1). Posteriormente, se evaluaron diferencias entre tratamientos mediante ANOVA de una vía con prueba post-hoc de Tukey ( $\alpha = .05$ ) (García et al., 2020; Li et al., 2023; Lu et al., 2023).

$Es = (\text{Plantas estimadas} - \text{Plantas contadas}) / (\text{Plantas contadas})$  Ecuación 1

## Resultados y discusión

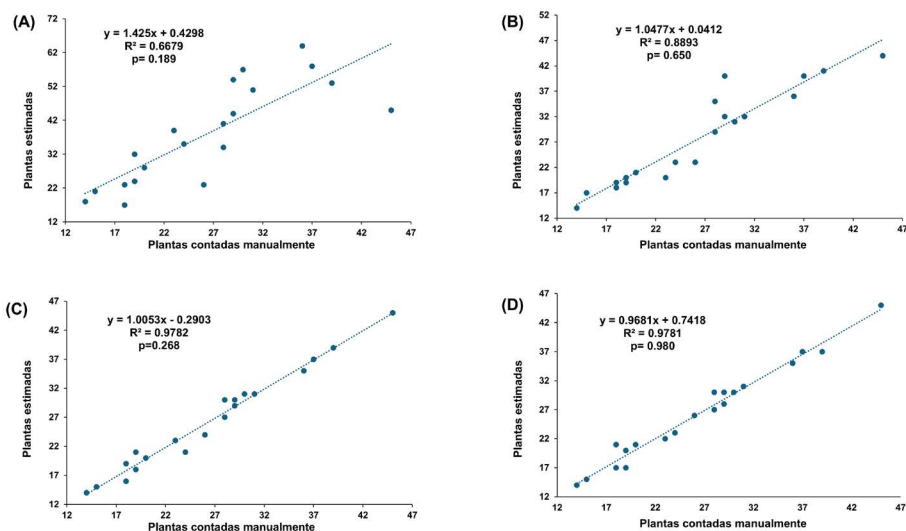
En las cuatro fechas de monitoreo se observó una relación positiva entre el conteo manual y la detección automatizada (Figura 1). Sin embargo, dicha relación no fue homogénea a lo largo del ciclo de cultivo. En la primera evaluación se registró mayor dispersión de los datos y una tendencia a la sobreestimación del número de plantas. En las evaluaciones posteriores, el coeficiente de determinación se incrementó, alcanzando su máximo valor a los 32 DDT. Estos resultados concuerdan con lo reportado por Lee et al. (2023), quienes señalan que la detección individual de plantas en etapas tempranas se ve limitada por su reducida cobertura foliar.

### Figura 1

Regresión lineal de las distintas misiones de vuelo en cultivo de brócoli: Misión 1 (DDT=12) (A); Misión 2 (DDT=20) (B); Misión 3 (DDT=32) (C); Misión 4 (DDT=47) (D).

DDT= Días después del trasplante

Fuente: elaboración propia.



Fuente: elaboración propia.

En el ANOVA realizado para cada tratamiento, se identificó que la Ps no fue uniforme a lo largo del tiempo para cada tipo de acolchado plástico utilizado (Cuadro 1). En suelo desnudo y en el acolchado con plástico

gris, la precisión no presentó diferencias significativas entre las fechas de evaluación. En contraste, los acolchados de plástico transparente, blanco y negro sí presentaron diferencias significativas, ya que durante la primera evaluación registraron valores de precisión bajos o lejanos de la unidad. Sin embargo, a partir de la segunda fecha de monitoreo se observó incremento en la precisión, con ligeras subestimaciones en los tratamientos con plástico transparente y negro. Este comportamiento puede atribuirse al incremento de la cobertura foliar, que favorece la detección de plantas al aumentar la superficie expuesta al sensor (García et al., 2020). Asimismo, Li et al. (2024) señalan que la alta reflectancia de los acolchados plásticos blancos puede reducir la precisión en la identificación de plantas, debido a que los valores de reflectancia de la vegetación son menores en comparación con superficies blancas.

### **Cuadro 1**

*ANOVA de un factor por cada tratamiento a través del tiempo.*

<b>Tratamiento</b>	<b>Ps DDT=12</b>	<b>Ps DDT=20</b>	<b>Ps DDT=32</b>	<b>Ps DDT=47</b>
Suelo desnudo	1.13	0.98	0.98	0.99
Plástico gris	1.41	1.06	1.04	1.01
Plástico transparente	1.51 <sup>A</sup>	1.10 <sup>B</sup>	0.98 <sup>B</sup>	1.01 <sup>B</sup>
Plástico blanco	1.58 <sup>A</sup>	1.06 <sup>B</sup>	1.01 <sup>B</sup>	1.00 <sup>B</sup>
Plástico negro	1.52 <sup>A</sup>	1.00 <sup>B</sup>	0.97 <sup>B</sup>	0.97 <sup>B</sup>

Letras distintas entre filas indican diferencias significativas de precisión en la estimación (Ps) realizada a los diferentes días después del trasplante (DDT) para cada acolchado plástico del suelo. (Ps=1.0 → mejor Ps), ( $\alpha=.05$ ). (factor: DDT, post-hoc Tukey  $\geq 0.05$ ). Fuente: Elaboración propia.

## **Conclusiones**

El uso de imágenes aéreas e inteligencia artificial permitió cuantificar de forma confiable las plantas de brócoli, mediante la utilización de ortomosaicos obtenidos a partir de los 20 DDT, presentando la mayor Ps a los 32 DDT. La detección en suelo desnudo presentó la mejor Ps, indicando interferencia causada por los acolchados plásticos durante el proceso de detección de plantas. De los acolchados plásticos, el color

negro presentó la mejor Ps; en contraste, el acolchado color blanco tuvo mayores niveles de error en la estimación. Se concluye que el momento y color del acolchado del suelo influyen en la confiabilidad de la detección automatizada de plantas a partir de fotografías aéreas.

## Agradecimiento

Se agradece infinitamente el apoyo a AGREMO por el apoyo recibido para la realización del presente documento (Agremo Ltd., Djordja Stanojevica 14, 11070 Belgrade, Serbia) (<https://www.agremo.com/usecases/>).

## Referencias

- Agremo. (2024). *Agremo Analyses - Plant Count & Health Monitoring*. <https://www.agremo.com/documentation/agremo-analyses/>
- Agremo. (s. f.). *Agremo Analyses - Plant Count & Health Monitoring*. <https://www.agremo.com/documentation/agremo-analyses/>
- Ahmad, A., Liew, A. X. W., Venturini, F., Kalogeras, A., Candiani, A., Di Benedetto, G., Ajibola, S., Cartujo, P., Romero, P., Lykoudi, A., De Grandis, M. M., Xouris, C., Lo Bianco, R., Doddy, I., Elegbede, I., D'Urso Labate, G. F., García del Moral, L. F., & Martos, V. (2024). AI can empower agriculture for global food security: challenges and prospects in developing nations. *Frontiers in Artificial Intelligence*, (7). <https://doi.org/10.3389/frai.2024.1328530>
- Chamara, N., Bai, G., & Ge, Y. (2023). AICropCAM: Deploying classification, segmentation, detection, and counting deep-learning models for crop monitoring on the edge. *Computers and Electronics in Agriculture*, 215. <https://doi.org/10.1016/j.compag.2023.108420>
- DJI. (2019). P4 Multispectral. <https://www.dji.com/mx/p4-multispectral>
- Farjon, G., Huijun, L., & Edan, Y. (2023). Deep-learning-based counting methods, datasets, and applications in agriculture: a review. *Precision Agriculture*, 24(5), 1683-1711. <https://doi.org/10.1007/s11119-023-10034-8>
- García, H., Flores, H., Khalil, A., Ascencio, R., Tijerina, L., Vázquez, M., & Mancilla, O. (2020). Estimación de la fracción de cobertura de la vegetación en maíz (*Zea mays*) mediante imágenes digitales

- tomadas por un vehículo aéreo no tripulado (UAV). *Revista Fitotecnia Mexicana*, 43(4), 399-409. <https://doi.org/10.35196/rfm.2020.4.399>
- Gupta, A., Ruan, J., & Jaiswal, S. (2024). The potential of geographic information systems as a tool to achieve sustainable development goals. In *sustainable development and geospatial technology: Foundations and innovations*. [https://doi.org/10.1007/978-3-031-65683-5\\_10](https://doi.org/10.1007/978-3-031-65683-5_10)
- Khanal, S., Kushal, K., Fulton, J. P., Shearer, S., & Ozkan, E. (2020). Remote sensing in agriculture-accomplishments, limitations, and opportunities. *Remote Sensing*, 12. <https://doi.org/10.3390/rs12223783>
- Lee, C. J., Yang, M. Der, Tseng, H. H., Hsu, Y. C., Sung, Y., & Chen, W. L. (2023). Single-plant broccoli growth monitoring using deep learning with UAV imagery. *Computers and Electronics in Agriculture*, 207. <https://doi.org/10.1016/j.compag.2023.107739>
- Li, J., Li, Y., Qiao, J., Li, L., Wang, X., Yao, J., & Liao, G. (2023). Automatic counting of rapeseed inflorescences using deep learning method and UAV RGB imagery. *Frontiers in Plant Science*, 14. <https://doi.org/10.3389/fpls.2023.1101143>
- Li, T., Wang, H., Song, J., Cui, J., Wang, W., Li, W., Jiang, M., Shi, X., Wang, J., Zhang, L., & Lu, X. (2024). Improving the accuracy of cotton seedling emergence rate estimation by fusing UAV-based multispectral vegetation indices. *Frontiers in Plant Science*, 15. <https://doi.org/10.3389/fpls.2024.1333089>
- Lu, D., Ye, J., Wang, Y., & Yu, Z. (2023). Plant detection and counting: enhancing precision agriculture in UAV and general scenes. *IEEE Access*, 11, 116196–116205. <https://doi.org/10.1109/access.2023.3325747>
- Maurya, D. K., Maurya, S. K., Kumar, M., Chaubey, C., Gupta, D., Patel, K. K., Mehta, A. K., & Yadav, R. (2024). A review on precision agriculture: An evolution and prospect for the future. *International Journal of Plant & Soil Science*, 36(5), 363–374. <https://doi.org/10.9734/ijpss/2024/v36i54534>
- Pathak, H., Igathinathane, C., Zhang, Z., Archer, D., & Hendrickson, J. (2022). A review of unmanned aerial vehicle-based methods for plant stand count evaluation in row crops. *Computers and Electronics in Agriculture* (Vol. 198). Elsevier. <https://doi.org/10.1016/j.compag.2022.107064>

Pix4D. (2024). PIX4Dfields. <https://www.pix4d.com/es/producto/pix-4dfields/>

Qgis. (2023). QGIS. <https://download.qgis.org/downloads/>

SOUTH. (2024). *Galaxy G7*. Guangzhou SOUTH Surveying & Mapping Technology Co., Ltd. [https://www.southinstrument.com/product/details/pro\\_tid/3/id/210.html](https://www.southinstrument.com/product/details/pro_tid/3/id/210.html)

