

Identificación de defectos de calidad en frutos de aguacate 'Hass' mediante procesamiento de imágenes

Identification of Quality Defects in 'Hass' Avocado Fruits Using Image Processing

Luis Alberto León-Bañuelos^{1*} , René García-Martínez¹ , Gabriela González-Vázquez¹ 

¹Tecnológico Nacional de México / TES Valle de Bravo. Km. 30, Carretera Federal Monumento Valle de Bravo, San Antonio de la Laguna, 51200 Valle de Bravo, Estado de México.

*Autor de correspondencia: luis.lb@vbravo.tecnm.mx

Artículo científico

Recibido: 02 de abril 2024

Aceptado: 31 de diciembre 2024

RESUMEN. México, es el principal productor de aguacate 'Hass' (*Persea americana* Mill.) a nivel mundial. Sin embargo, los pequeños productores suelen presentar problemas de calidad y no cumplen con estándares de la norma NMX-FF-016-2002. Por cual, el objetivo de la investigación fue identificar defectos de calidad en frutos mediante procesamiento de imágenes. Para ello, en septiembre de 2023 se cosecharon frutos en madurez fisiológica en diversos huertos de la región de Valle de Bravo, México. A cada aguacate se le midió el diámetro, longitud y peso. La evaluación de defectos de calidad se realizó por un experto y, simultáneamente, se tomaron fotografías para analizar las imágenes mediante algoritmos de binarización y Canny con la finalidad de identificar daños físicos externos y estimar la longitud, diámetro y peso de cada fruto. Se aplicó una prueba de t para comparar el tamaño del fruto estimado por el algoritmo y datos reales. Como resultado se observaron diferencias significativas ($p < 0.01$) en longitud y diámetro, por lo cual, se aplicó un factor de ajuste para optimizar los resultados del algoritmo. Se obtuvo un modelo de regresión lineal múltiple ($p < 0.01$, $r^2 = 0.91$) que estima el peso en función del diámetro y longitud. El proceso de binarización ayudó a identificar daños por trips, raspaduras y roña. Mientras que con el método de Canny se identificaron daños por trips y roña. En conclusión, el análisis de imágenes fue eficiente para identificar defectos causados por roña, trips y raspaduras, así como la estimación del tamaño de los frutos.

Palabras clave: Análisis de imágenes, visión por computadora, enfermedades en aguacate, agricultura de precisión, inteligencia artificial.

ABSTRACT. Mexico is the main producer of 'Hass' avocado (*Persea Americana* Mill.) worldwide. However, small producers often present quality problems and do not meet the standards of the NMX-FF-016-2002 standard. Therefore, the objective of the research was to identify quality defects in fruits through image processing. To do this, in September 2023, fruits at physiological maturity were harvested in various orchards in the Valle de Bravo region, Mexico. The diameter, length and weight of each avocado were measured. The evaluation of quality defects was carried out by an expert and, simultaneously, photographs were taken to analyze the images using binarization and Canny algorithms to identify external physical damage and estimate the length, diameter and weight of each fruit. A t test was applied to compare the fruit size estimated by the algorithm and real data. As a result, significant differences ($p < 0.01$) were observed in length and diameter, therefore, an adjustment factor was applied to optimize the results of the algorithm. A multiple linear regression model was obtained ($p < 0.01$, $r^2 = 0.91$) that estimates weight as a function of diameter and length. The binarization process helped identify damage from thrips, scrapes, and scab. While with the Canny method, damage from thrips and scab was identified. In conclusion, image analysis was efficient in identifying defects caused by scabs, thrips and scratches, as well as estimating fruit size.

Keywords: Image analysis, computer vision, avocado diseases, precision agriculture, artificial intelligence.

Como citar: León-Bañuelos LA, García-Martínez R, González-Vázquez G (2024) Identificación de defectos de calidad en frutos de aguacate 'Hass' mediante procesamiento de imágenes. Ecosistemas y Recursos Agropecuarios Núm. Esp. IV: e4130. DOI: 10.19136/era.a11nIV.4130.

INTRODUCCIÓN

En 2022, México fue el primer productor mundial de aguacate, seguido de Colombia y Perú (FAOSTAT 2023). Esto explica la importancia económica que tiene este cultivo en el sector agrícola mexicano. A nivel nacional la producción se concentra por orden de importancia en Michoacán, Jalisco, Estado de México, Nayarit y Morelos (SIAP 2023). Estos estados en su conjunto aportan 95% de la producción nacional.

El aguacate es originario del sur de México y de las zonas tropicales y subtropicales de Centroamérica (Sangerman-Jarquín *et al.* 2014). Se reconocen cuatro razas: mexicana, guatemalteca, antillana y costarricense (Pérez-Álvarez *et al.* 2015). La variedad 'Hass' fue seleccionada en la década de 1920 en la granja de Rudolph Hass en La Habra, California (Miller 2020). El fruto se consume en fresco, pero también se procesa para extraer aceite y otros productos, además varios componentes, como la semilla, cáscara y pulpa contienen diferentes compuestos bioactivos de importancia para la salud humana (Salazar-López *et al.* 2020). El aguacate tiene excelentes características nutricionales porque contiene fibra dietética, azúcares totales, K, Na, Mg, vitamina A, C, E, K1, B6, folato, niacina, ácido pantoténico, riboflavina, colina, luteína/zeaxantina, fitoesteroles y ácidos grasos altamente monoinsaturados (Dreher y Davenport 2013).

Las distintas estrategias en el manejo de los huertos ocasionan diferencias en la calidad de los frutos (Nolasco-González y Osuna-García 2017). Por ejemplo, en huertos de Valle de Bravo, México, la productividad, calidad y maduración de frutos de aguacate 'Hass' mostraron diferencias significativas debido a la condición particular del estatus nutrimental de los árboles y la fertilidad del suelo (García-Martínez *et al.* 2021). En la evaluación calidad y comportamiento poscosecha de frutos de aguacate se requiere del análisis de variables como contenido de materia seca, contenido de aceite, color del epicarpio y mesocarpio, diámetro y longitud de fruto, velocidad de respiración, producción de etileno, firmeza y pérdida de peso (Herrera-González *et al.* 2017). La NMX-FF-016-SCFI-2016, que regula la calidad del aguacate fresco para consumo humano con fines de exportación, establece que los defectos superficiales no superen 2 cm² de la superficie del exocarpio, ya sea por roña, trips, granizo y rozaduras y no impacte negativamente en su conservación (SE 2016). Esta situación implica que la clasificación en el empaquetado debe realizarse con rigurosidad para evitar penalizaciones. Por lo tanto, al empaquetar el producto se debe mantener la calidad y las operaciones de recepción, lavado, secado, encerado, empaque y preenfriado se vuelven críticas (Demerutis-Peña 2010).

Para reducir problemas de identificación de defectos físicos en el fruto se han propuesto sistemas basados en visión por computadora. Los sistemas de visión artificial aplicado a frutos operan a través de las cinco etapas: adquisición de imágenes, preprocesamiento de imágenes, extracción de características, segmentación de imágenes y reconocimiento de imágenes (Xiao *et al.* 2023). En estudios realizados con distintas frutas, las características que mejor las describieron fueron los valores medios de los canales RGB y la longitud del eje mayor y menor (Montoya-Holguin *et al.* 2014). En tomate, se desarrolló un método de detección de frutos maduros que combina el aprendizaje profundo con la detección de contornos de bordes, con ello se logra separar eficientemente los tomates objetivo de los tomates superpuestos para detectar frutas individuales (Hu *et al.* 2019). Estos métodos pueden orientarse a otros frutos, como el aguacate, para mejorar la

eficiencia en la selección, identificación de defectos de calidad y predecir características fisicoquímicas a partir de imágenes digitales. En este sentido, el objetivo de esta investigación fue desarrollar un método para identificar características y defectos físicos en frutos de aguacate 'Hass' mediante el análisis por computadora de imágenes digitales.

MATERIALES Y MÉTODOS

Características del área de estudio

Los frutos de aguacate 'Hass' se cosecharon en el mes de septiembre de 2023, en huertos de la región de Valle de Bravo. En total se obtuvieron 40 frutos de tamaño comercial (140-235 g), que abarcan los diferentes rangos de color y defectos de calidad que se presentan en la zona productora. En la región de estudio, la cosecha se concentra en dos periodos: (1) mayo-julio y (2) septiembre-enero. Siendo la última, la que genera la mayor producción.

Evaluación y clasificación de frutos

A los frutos cosechados, se les midió el diámetro y longitud con un vernier Truper®; y se pesaron en una balanza digital Truper® modelo 102317. Los defectos de calidad se determinaron mediante evaluación visual de los síntomas en el exocarpo; se evaluaron daños por hongos, daños por trips y raspaduras. Con la información obtenida, los aguacates se agruparon de acuerdo con su calibre y grado de clasificación (defectos) de acuerdo con la norma NMX-FF-016-SCFI-2016 (SE 2016).

Obtención de imágenes digitales

La obtención de imágenes digitales de los frutos se realizó con una cámara Logitech® StreamCam, la cual cuenta con una resolución máxima de 1920x1080, una frecuencia de cuadro de hasta 60 fps y un lente f/2.0 con longitud focal 3,7 mm (Logitech 2023).

Proceso identificación de defectos y clasificación de frutos

Las fases que se aplicaron para el procesamiento se iniciaron con la digitalización de imágenes que se procesan mediante algoritmos y librerías del lenguaje Python, las cuales permitieron la definición de las variables del fruto (contornos de la forma, tamaño y peso) y la identificación de defectos para su posterior clasificación.

Adquisición de imágenes de frutos

Para la adquisición de las imágenes se diseñó un módulo de captura, basado en una caja de luz que proporciona una iluminación homogénea del interior, esto tiene como principal objetivo generar fotos de calidad y obtener mayor difusión de la luz (González-Flores 2018). Para la construcción del prototipo del módulo de captura se formó una caja de madera de 27.5 cm de ancho, 40 cm de largo y 30 cm de alto. Para instalar la cámara se realizó un orificio de 5 cm de diámetro en la tapa. En las paredes laterales y la tapa interna se instalaron tiras de luces led (12 V) y se cubrió con tela blanca con la finalidad de difuminar la luz y de generar contraste con fruto. Este tipo de prototipos son efectivos para la obtención de imágenes digitales en ambiente controlado (Carroll 2021).

Se realizaron pruebas de obtención de imágenes digitales hasta que se disminuyó el ruido por sombra y brillo de tal manera que no interfiera en el procesamiento con los algoritmos computacionales. En la Figura 1 se presenta una comparativa de las imágenes obtenidas con el prototipo inicial y final del módulo de captura. El factor de brillo se redujo considerablemente en el resultado final, esto con la finalidad de evitar pérdida de secciones o capturar falsos positivos en los algoritmos empleados a causa del brillo excesivo.

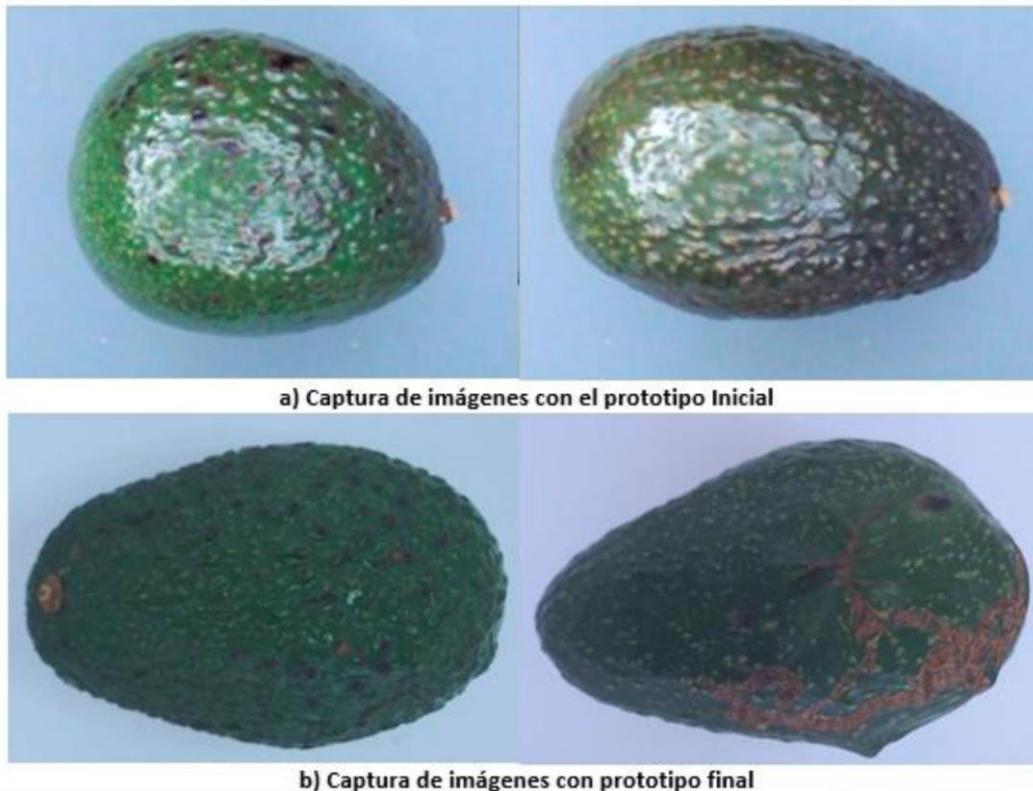


Figura 1. Disminución de brillo y sombra: a) Prototipo inicial y b) Prototipo final.

Preprocesamiento de la imagen

Se tomaron dos imágenes con la finalidad de cubrir la superficie total del fruto. Se utilizó el método de procesamiento de imágenes digitales, permitiendo el análisis de datos mediante software de manera rápida, eficiente y económica (Sindhu *et al.*, 2021).

Algoritmos para identificación de defectos

Se implementaron dos algoritmos utilizando el lenguaje Python (Foundation Python Software, 2023). (1) binarización de las imágenes obtenidas por el módulo de captura (se clasifican los píxeles en blanco y negro, considerando el contraste de los colores). Esta técnica de procesamiento de imágenes es empleada en diferentes aplicaciones como el reconocimiento óptico de caracteres, ya que permite procesar las imágenes, para ser segmentadas o aplicarles un reconocimiento de patrones. (2) Algoritmo de Canny para el análisis de los contornos del fruto a partir de la imagen del fruto con referencia a un aruco de 3 x 3 cm. Es una técnica para la identificación de los bordes en píxeles dentro de una imagen. El contorno de un objeto es de suma importancia a la hora de

identificar defectos en los frutos, tomando en consideración que estos generan relieves y contrastes de tonalidad que permiten diferenciarlos. Con la aplicación de los algoritmos se identificaron los siguientes defectos en la superficie del fruto: 1) crestas o deformaciones asociados a daños por trips, 2) manchas o cambios de color causado por enfermedades fúngicas y 3) manchas o pérdida de exocarpio por daños mecánicos como raspaduras o golpes.

Clasificación por tamaño

Para la clasificación de frutos por tamaño, se utilizaron librerías pertenecientes al Lenguaje de Programación Python (Foundation Python Software 2023): (1) OpenCV, que es una biblioteca de visión artificial desarrollada por la marca de procesadores Intel®, esta permite analizar información por imagen o video. (2) Numpy, es una librería que está especializada en el cálculo numérico y volúmenes de datos. (3) Perspective, permite ubicar la distancia entre la cámara y el objeto, y (4) Countours, permite el cálculo de las curvas que presenta el objeto para no omitir los bordes límites del objeto (OpenCV 2024).

Análisis estadístico

Las pruebas estadísticas se aplicaron para identificar diferencias entre los datos arrojados por el algoritmo y los datos reales medidos en el fruto. Para ello se aplicó una prueba de t para muestras independientes (Sánchez-Turcios 2015). El análisis se ejecutó con el software estadístico R versión 4.3.3 (R Core Team 2020).

RESULTADOS

Características de los frutos

De acuerdo con el calibre establecido en la NMX-FF-016-SCFI-2016, en la muestra de frutos se encontraron desde categoría mediano (140 g) hasta extra (247.2 g) como se muestra en la Tabla 1.

Tabla 1. Características de los frutos de aguacate 'Hass' recolectados en la región de Valle de Bravo.

Estadístico	Díámetro ecuatorial (cm)	Longitud (cm)	Índice de forma	Peso (g)
Media	6.3	9.5	0.66	190.3
Mediana	6.2	9.45	0.67	187.35
Moda	6.1	10.1	--	--
Desviación estándar	0.37	0.73	0.08	28.26
Mínimo	5.8	8.2	0.42	140.00
Máximo	7.3	11.5	0.80	247.20
C.V.	5.95	7.7	11.7	14.9

Binarización de imágenes

A las imágenes se les aplicaron dos filtros. El primero fue de escala de grises que ayudó a resaltar detalles como las crestas, hendiduras y cicatrices en la piel de los frutos. El segundo fue un filtro

de blanco y negro absoluto, con ello se pudieron identificar defectos causados por trips, raspaduras por ramas, daños mecánicos en su transporte y daños por hongos (Figura 2).

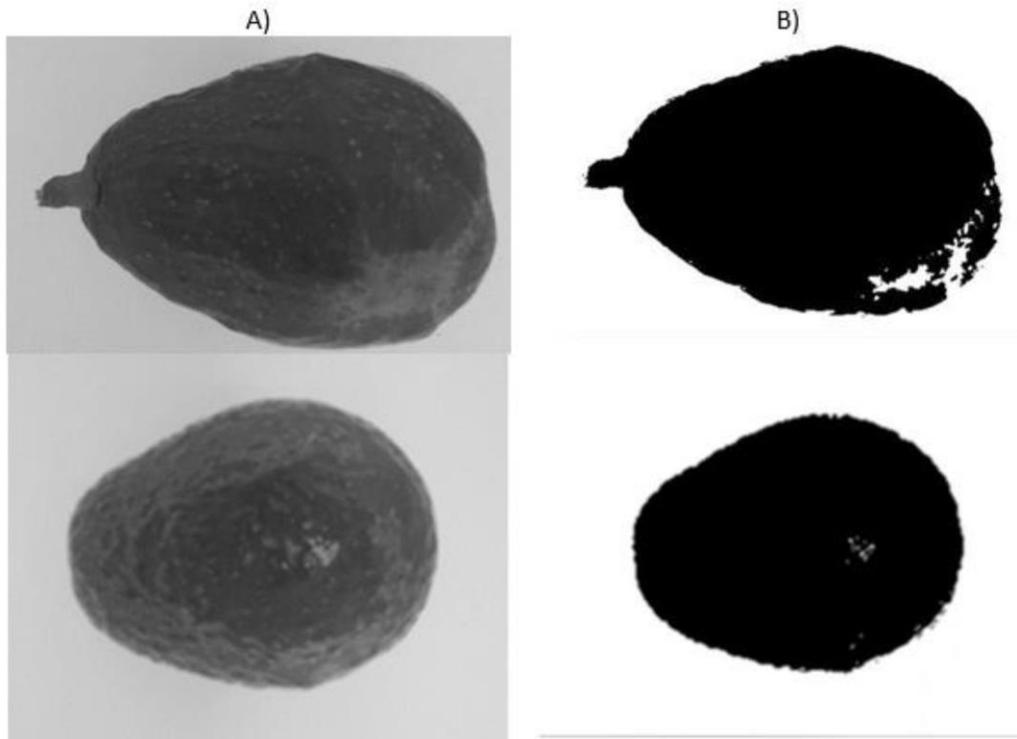


Figura 2. Binarización de las imágenes digitales de los frutos. A) Escala de grises y B) Blanco y negro.

Como se observa en la Figura 2, con la binarización de las imágenes, se lograron apreciar algunos defectos en la piel del aguacate, si bien no identifica la totalidad, es suficiente para clasificarlo con defecto.

Identificación de contornos

El análisis de contorno fue eficiente para identificar daño por trips y daño por roña, esto se puede apreciar en la Figura 3. Donde se observa la capacidad del método de Canny para identificar bordes, en el primer fruto se identifican daños por raspaduras y en la segunda se compara con un fruto sin daños. En ambos frutos se identifica con precisión la forma del fruto. Aplicando los métodos de binarización y Canny a las imágenes, se estimó el diámetro ecuatorial y la longitud del fruto (Figura 4).

Se compararon las medidas digitales con las medidas reales. Sin embargo, se encontraron diferencias significativas tanto en diámetro ecuatorial ($p < 0.01$) como longitud ($p < 0.01$). En la imagen se presentó una sobrestimación de 30% para el diámetro (Figura 5 a) y 23% para la longitud (Figura 5 b).

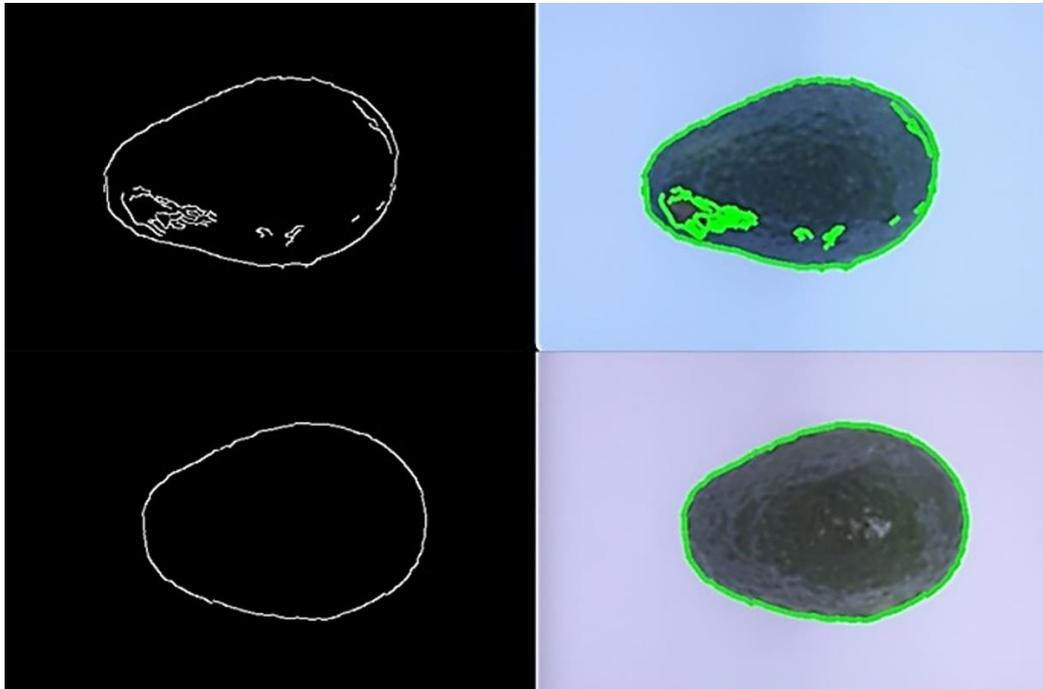


Figura 3. Detección de defectos mediante el análisis de contorno de imágenes.

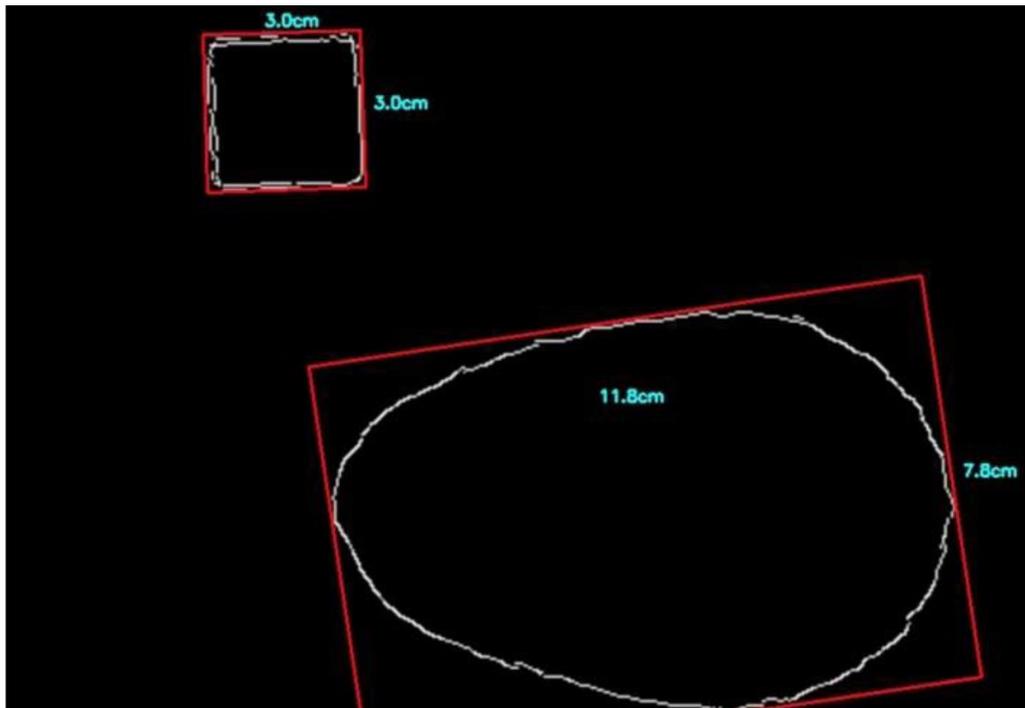


Figura 4. Estimación del diámetro y la longitud del fruto a partir del procesamiento de la imagen.

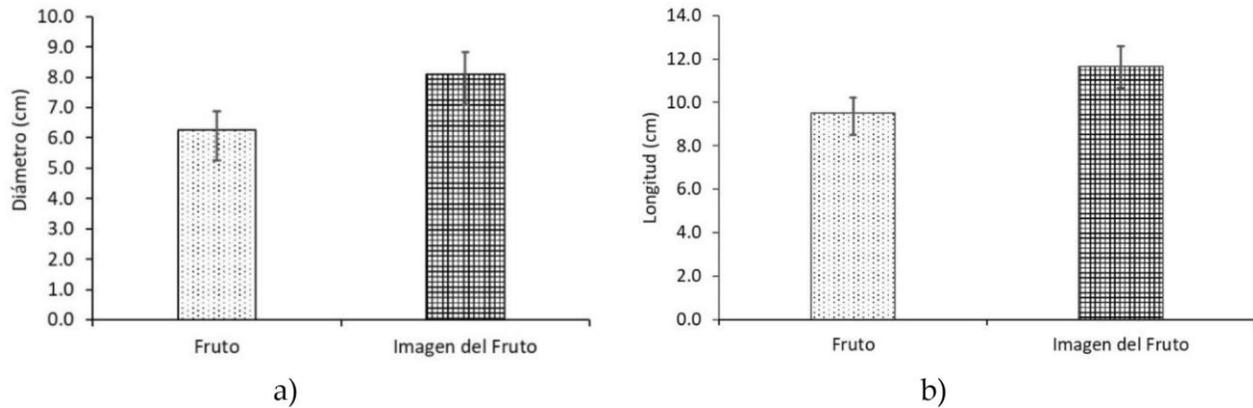


Figura 5. Comparación de las variables de tamaño del fruto y la imagen digital. a) diámetro y b) longitud.

El tamaño estimado a partir de la imagen se ajustó aplicando un factor de corrección que se obtuvo dividiendo el valor real entre el valor obtenido en la imagen. Para el diámetro el factor de corrección promedio fue de 0.79 y para la longitud de 0.82. Después del ajuste no se encontraron diferencias en diámetro ecuatorial ($p > 0.71$) y longitud ($p > 0.78$). En la imagen se presentó una sobrestimación de 0.9% para el diámetro (Figura 6 a) y 0.6% para la longitud (Figura 6 b).

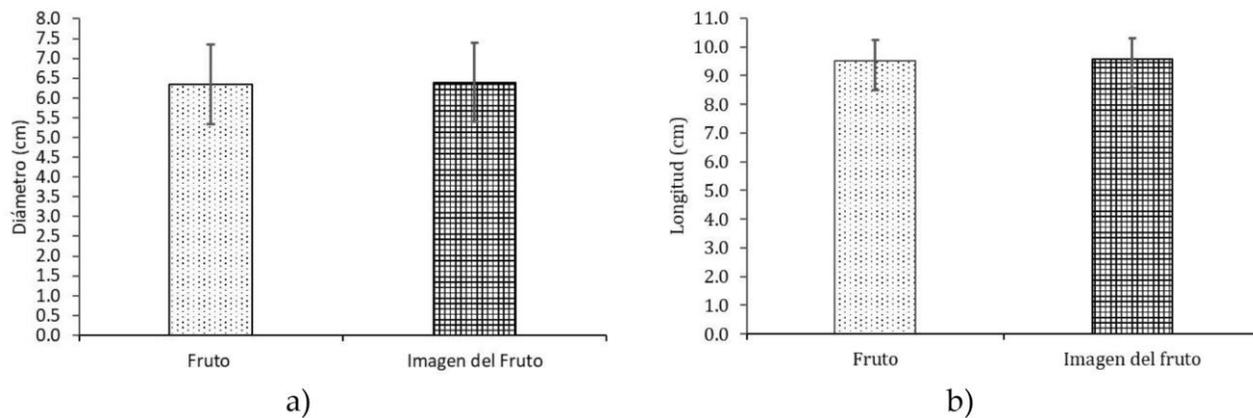


Figura 6. Comparación de los valores ajustados de las variables de tamaño del fruto. a) diámetro y b) longitud.

Estimación del peso del fruto

Los valores de diámetro y longitud calculados por el algoritmo se utilizaron para estimar el peso de los frutos aplicando un modelo de regresión lineal múltiple. El modelo obtenido fue $\text{Peso (g)} = 32.999 * \text{Diámetro (cm)} + 13.369 * \text{Longitud (cm)} - 148.566$, $p < 0.01$, $r^2 = 0.91$. En la Figura 7 se observa la relación del diámetro y longitud con el peso de fruto.

Clasificación de frutos

De acuerdo con el grado de clasificación visual por defectos, 46% de los frutos fueron Clase II, 27% Clase I y 27% Clase Suprema. De acuerdo con el tamaño del fruto, 23% se clasificaron en la categoría B (Extra), 54% en C (Clase I) y 23% en D (Mediano). La comparación en el porcentaje de identificación de defectos se presenta en la Figura 8.

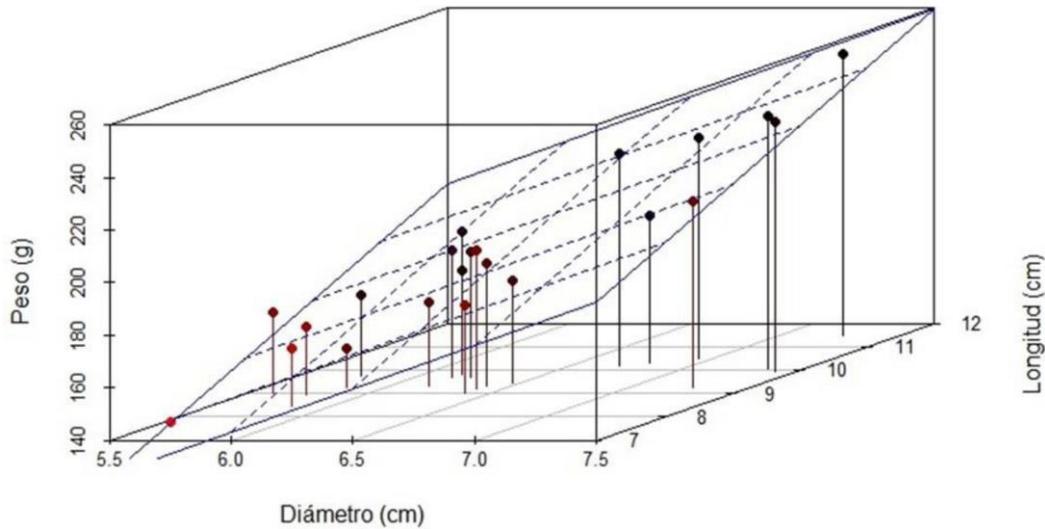


Figura 7. Representación tridimensional de la relación de las variables diámetro y longitud de fruto con el peso.

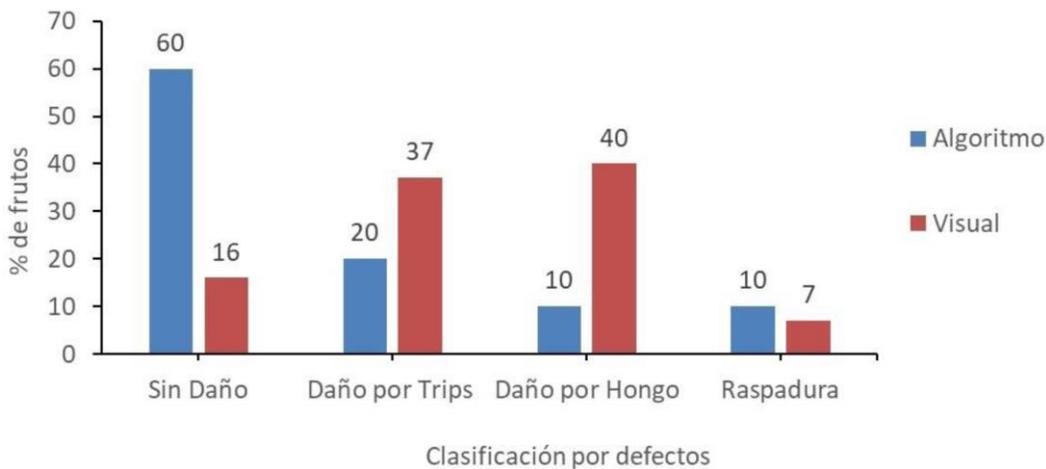


Figura 8. Clasificación de acuerdo con los defectos de los frutos comparando el método del algoritmo y la clasificación visual.

El algoritmo fue eficiente en identificar defectos causados por roña, trips, raspaduras y granizo. Sin embargo, no fue efectivo para varicela, viruela o clavo. Esto se reflejó, principalmente, en el 44% de diferencia entre el algoritmo y clasificación visual en la categoría de frutos sin daños que se presenta en la Figura 8.

DISCUSIÓN

El tamaño de los frutos corresponde con lo reportado por otros autores en la región de estudio. En huertos comerciales de aguacate 'Hass' de Valle de Bravo, México, se reportan frutos con un peso promedio de 167.6 g, diámetro de 6.1 cm, longitud de 8.5 cm y un índice de forma de 0.72 (García-Martínez *et al.* 2021). En plantaciones ubicadas en Guerrero, México, Villalva-Morales *et al.* (2015)

obtuvieron frutos de 150 g en árboles de cinco años. La binarización de las imágenes permitió identificar distintos daños, al clasificar los píxeles entre blanco y negro, los píxeles blancos se asociaron con los defectos del fruto. Esta técnica ayuda a separar las regiones de primer plano y de fondo en una imagen (Sigdel *et al.* 2015). También Herrera-González *et al.* (2017) utilizaron este método en la identificación de frutos de café afectados por broca (*Hypothenemus hampei*) y observaron que los píxeles del área dañada aparecen de color blanco.

El análisis de bordes o contorno permitió identificar problemas causados por trips, roña y raspaduras en la piel de los frutos. La identificación de bordes en el procesamiento de imágenes es importante ya que permite realizar un diagnóstico más acertado en la computadora, esto permite analizar los cambios repentinos en la intensidad de los píxeles, proporcionando información rápida y precisa sobre las áreas relevantes de lo que se está analizando (Niño-Rondón *et al.* 2022). Mientras que Campos-Ferreira y González-Camacho (2021) afirman que las enfermedades como antracnosis, con similitud al color del aguacate en imágenes digitales, generan errores de predicción para la clasificación, sobre todo en frutos con antracnosis en etapas tempranas de la enfermedad. Esto concuerda con los errores de clasificación de este estudio, en daños que tienen semejanza en color con el fruto como los trips, que muestran una protuberancia, pero la tonalidad no muestra un cambio significativo.

En entornos con iluminación led controlada, la colorimetría con modelo RGB basada en píxeles identifica diferencia de tonalidades y se puede complementar con filtros de color (azul, rojo, amarillo) que beneficien en la distinción de características específicas (León-Bañuelos y González-Vázquez 2019), como la coloración distintiva de la antracnosis en el caso del fruto de aguacate. La diferencia de 30%, entre la clasificación visual y el algoritmo, en la clase de daño por hongo se debe a que en la evaluación visual se incluyeron los frutos que presentaron defectos de roña, varicela, viruela y clavo. Estos síntomas están asociados a enfermedades fúngicas causados principalmente por *Colletotrichum gloeosporioides* en el Estado de México (Tapia-Rodríguez *et al.* 2020) y Nayarit, México (Trinidad-Ángel *et al.* 2017). En la categoría de daños por raspaduras, el algoritmo presentó la mayor eficiencia. Las cortaduras o raspaduras son los daños mecánicos que ocasiona el cosechador y son constantes durante las horas de la cosecha y se presentan en mayor medida en la bolsa de cosecha y en el traslado del camión (Herrera-González *et al.* 2017). La eficiencia del algoritmo en la identificación de daños por trips depende de la severidad del problema. Cuando el daño fue mínimo, el algoritmo no lo detectó. Estos insectos causan cicatrices reduciendo el valor del fruto de aguacate en el mercado y producen malformaciones al provocar alteraciones en la cáscara (Maldonado-Zamora *et al.* 2016). Por otro lado, Portillo-Mendoza y Ponce-Alvino (2022) sugieren la inclusión de sensores y microcontroladores en conjunto con redes neuronales para complementar la identificación de detalles de color en frutos, basados en el modelo RGB. Así mismo León-Bañuelos *et al.* (2023) indican que la implementación de algoritmos de clasificación supervisada beneficia el procesamiento de imágenes digitales RGB para la agrupación de píxeles determinados como objeto de estudio (plagas o enfermedades), para determinar el porcentaje de afectación; lo cual se recomienda implementar en estudios futuros para aumentar la eficiencia de identificación, principalmente en daños por hongos y trips.

CONCLUSIONES

El análisis digital de imágenes permitió identificar los defectos asociados con síntomas de roña, daños por trips y raspaduras. No se identificó de forma correcta los síntomas de varicela, clavo y viruela. Con la aplicación de los algoritmos de binarización y Canny se sobreestimó en 30% el porcentaje de frutos sin daños, por lo cual, la inspección visual por un especialista en manejo agronómico del aguacate es más efectiva. Sin embargo, la automatización de análisis de defectos de calidad en frutos de aguacate es importante porque es un factor clave en el empaqueo del producto, que en la región se realiza manualmente, encareciendo los costos de producción. Es necesario complementar las técnicas de procesamiento de imágenes con algoritmos de Machine Learning, sensores y actuadores para obtener una adecuada clasificación de calidad de los frutos, brindando a los pequeños productores alternativas de selección de bajo costo y que generen mayores ganancias con los empaques que cumplan con las características físicas de la norma oficial.

AGRADECIMIENTOS

Se extiende el agradecimiento al TECNM-TEC Valle de Bravo por las facilidades brindadas para el desarrollo de la presente investigación, así mismo a los productores que apoyaron en la colecta y donación de frutos.

CONFLICTO DE INTERÉS

Los autores declaran que no tienen intereses en competencia.

LITERATURA CITADA

- Campos-Ferreira UE, González-Camacho JM (2021) Clasificador de red neuronal convolucional para identificar enfermedades del fruto de aguacate (*Persea americana* Mill.) a partir de imágenes digitales. *Agrociencia* 55(8): 695-709.
- Carroll H (2021) *Lea este libro si desea tomar buenas fotografías de lugares*. 1era edición. Editorial Blume. Barcelona. 128p.
- Demerutis-Peña C (2010) Requerimientos de calidad y seguridad en la exportación de frutas y verduras tropicales hacia los mercados mundiales. *Revista Iberoamericana de Fisiología Postcosecha* 11(1): 1-7.
- Dreher M, Davenport A (2013) Hass avocado composition and potential health effects. *Critical Reviews in Food Science and Nutrition* 53(7): 738-750. <https://doi.org/10.1080/10408398.2011.556759>.
- FAOSTAT (2023) FAO: Cultivos y productos de ganadería. Organización de las Naciones Unidas para la Alimentación y la Agricultura. <https://www.fao.org/faostat/es/#data/QCL24>. Fecha de consulta: 24 de enero de 2024.

- Foundation Python Software (2023) Python Docs. <https://www.python.org/doc/>. Fecha de consulta: 01 de marzo de 2024.
- García-Martínez R, Cortés-Flores JI, López-Jiménez A, Etchevers-Barra JD, Carrillo-Salazar JA, Saucedo-Veloz C (2021) Rendimiento, calidad y comportamiento poscosecha de frutos de aguacate 'Hass' de huertos con diferente fertilización. *Revista Mexicana de Ciencias Agrícolas* 12(2): 205-218.
- González-Flores L (2018) La fotografía ha muerto, ¡viva la fotografía! *Textos sobre teoría fotográfica. Foto Cinema* 21: 491-496.
- Herrera-González J, Salazar-García S, Martínez-Flores H, Ruiz-García J (2017) Indicadores preliminares de madurez fisiológica y comportamiento poscosecha del fruto de aguacate Méndez. *Revista Fitotecnia Mexicana* 40(1): 55-63.
- Hu C, Liu X, Pan Z, Li P (2019) Automatic detection of single ripe tomato on plant combining faster R-CNN and intuitionistic fuzzy set. *IEEE Access* 7: 154683-154696.
- León-Bañuelos LA, González-Vázquez G (2019) Comparación de colorimetría del *Arceuthobium globosum* en imágenes de UAV y con iluminación LED. *Coloquio de Investigación Multidisciplinaria* 7(1): 529-536. <https://doi.org/10.5281/zenodo.4312240>.
- León-Bañuelos LA, Endara-Agramont AR, Nava-Bernal EG, Gómez-Demetrio W (2023) Use of unmanned aerial vehicles for the diagnosis of parasitic plant infestation at the crown level in *Pinus hartwegii*. *iForest-Biogeosciences and Forestry* 16(5): 282-289. <https://doi.org/10.3832/ifer4002-016>.
- Logitech (2023) Logitech. www.logitech.com/. Fecha de consulta: 13 de febrero de 2024.
- Maldonado-Zamora FI, Ramírez-Dávila JF, Rubí-Arriaga M, Antonio-Némiga X, Lara-Díaz V. (2016) Distribución espacial de trips en aguacate en Coatepec Harinas, Estado de México. *Revista Mexicana de Ciencias Agrícolas*, 7(4): 845-856. <https://doi.org/10.29312/remexca.v7i4.259>.
- Miller J (2020) *Avocado: A global history*. Editorial Reaktion Books. España. 136p.
- Montoya-Holguin C, Cortés-Osorio JA, Chaves-Osorio A (2014) Sistema automático de reconocimiento de frutas basado en visión por computador. *Ingeniare* 22(4): 504-516. <http://dx.doi.org/10.4067/S0718-33052014000400006>
- Niño-Rondón CV, Castellano-Carvajal DA, Castro-Casadiago Sergio A, Medina-Delgado B, Guevara-Ibarra D (2022) An approach to edge detection in medical imaging through histogram analysis and morphological gradient. *Ingeniería y Competitividad* 24(2): 1-18. <https://doi.org/10.25100/iyc.v24i2.11352>
- Nolasco-González Y, Osuna-García J (2017) Calidad poscosecha de mango 'Kent' con fertilización normal y alta. *Revista Mexicana de Ciencia Agrícolas* 19: 4009-4022. <https://doi.org/10.29312/remexca.v0i19.669>.
- OpenCV (2024) Introduction to OpenCV. https://docs.opencv.org/4.x/da/df6/tutorial_py_table_of_contents_setup.html. Fecha de consulta: 08 de febrero de 2024.
- Pérez-Álvarez S, Ávila Quezada G, Coto Arbelo O (2015) El aguacatero (*Persea americana* Mill). *Cultivos Tropicales* 36(2): 111-123.

- Portillo-Mendoza PM, Ponce-Alvino JP (2022) Clasificación óptima de los frutos de café por su madurez mediante algoritmo de control. *Alfa Revista de Investigación en Ciencias Agronómicas y Veterinaria* 6(18): 441-452.
- R Core Team (2020) The R Project for Statistical Computing. R Foundation for Statistical computing, Vienna, Austria. <https://www.r-project.org/>. Fecha de consulta: 19 de enero de 2024.
- Salazar-López NJ, Domínguez-Avila JA, Yahia EM, Belmonte-Herrera BH, Wall-Medrano A, Montalvo-González E, González-Aguilar GA (2020) Avocado fruit and by-products as potential sources of bioactive compounds. *Food Research International* 138: 109774. <https://doi.org/10.1016/j.foodres.2020.109774>.
- Sánchez-Turcios RA (2015) T-Student. Usos y abusos. *Revista Mexicana de Cardiología* 26(1): 56-61.
- Sangerman-Jarquín DM, Larqué-Saavedra BS, Omaña-Silvestre JM, Shwenstesius-de-Rinderman R, Navarro-Bravo A (2014) Tipología del productor de aguacate en el Estado de México. *Revista Mexicana de Ciencias Agrícolas* 5(6): 1081-1095. <https://www.redalyc.org/pdf/2631/263131532014.pdf>
- SE (2016) Productos alimenticios no industrializados para uso humano-fruta fresca-Aguacate (*Persea americana* Mill.). Secretaría de Economía. Diario Oficial de la Federación. https://dof.gob.mx/nota_detalle.php?codigo=5445368&fecha=21/07/2016#gsc.tab=0. Fecha de consulta: 20 de febrero de 2024
- SIAP (2023) Anuario estadístico de la producción agrícola. <https://nube.siap.gob.mx/cierreagricola/>. Fecha de consulta: 18 de marzo de 2024
- Sigdel M, Sigdel MS, Dinç İ, Dinç S, Pusey ML, Aygün RS (2015) Automatic classification of protein crystal images. *Emerging Trends in Image Processing, Computer Vision and Pattern Recognition*. Morgan Kaufmann. pp. 421-432.
- Sindhu C, Sasmitha S, Tamilmani P, Udaysriram C, Gowri, VV (2021) Rice grain type and grading of rice grains using image processing. *International Journal of Research in Engineering, Science and Management* 4(7): 332-334.
- Tapia-Rodríguez A, Ramírez-Dávila JF, Salgado-Siclán ML., Castañeda-Vildózola Á, Maldonado-Zamora FI, Lara-Díaz AV (2020) Distribución espacial de antracnosis (*Colletotrichum gloeosporioides* Penz) en aguacate en el Estado de México, México. *Revista Argentina de Microbiología* 52(1): 72-81.
- Trinidad-Ángel E, Ascencio-Valle FD, Ulloa JA, Ramírez-Ramírez JC, Ragazzp-Sánchez JA, Calderón-Santoyo M, Bautista-Rosales PU (2017) Identificación y caracterización de *Colletotrichum* spp. causante de antracnosis en aguacate de Nayarit, México. *Revista Mexicana de Ciencias Agrícolas* 19: 3953-3964. <https://doi.org/10.29312/remexca.v0i19.664>
- Villalva-Morales A, Damián-Nava A, González-Hernández VA, Talavera-Mendoza O, Hernández-Castro E, Palemón-Alberto F, Díaz-Villaseñor G, Sotelo-Nava H (2015) Nutrición química y orgánica en aguacate Hass en Filo de Caballos, Guerrero, México. *Revista Mexicana de Ciencias Agrícolas* 6(11spe): 2169-2176. <https://dx.doi.org/10.29312/remexca.v0i11.794>
- Xiao F, Haibin R, Xu Y, Zhang RQ (2023) Detección y reconocimiento de frutas basado en aprendizaje profundo para la cosecha automática: descripción general y revisión. *Agronomy* 13(6): 1625. <https://doi.org/10.3390/agronomy13061625>