



UNIVERSIDAD AUTÓNOMA CHAPINGO

POSGRADO EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL AGUA

CONTEO AUTOMÁTICO DE OLIVOS MEDIANTE MORFOLOGÍA MATEMÁTICA CON IMÁGENES ADQUIRIDAS POR SISTEMA AÉREO TRIPULADO REMOTAMENTE

TESIS DE GRADO

Que como requisito parcial para obtener el grado de:

**MAESTRO EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL
AGUA, ORIENTACIÓN EN MECANIZACIÓN AGRÍCOLA**

Presenta:

RICARDO SARABIA LÓPEZ

Bajo la supervisión de:

DR. GILBERTO DE JESÚS LÓPEZ CANTEÑS



REGISTRACIÓN GENERAL ACADÉMICA
DIRECCIÓN DE SERVICIOS ESCOLARES
SECRETARÍA DE EXÁMENES PROFESIONALES

Chapingo, Estado de México, noviembre de 2019



**CONTEO AUTOMÁTICO DE OLIVOS MEDIANTE MORFOLOGÍA
MATEMÁTICA CON IMÁGENES ADQUIRIDAS POR SISTEMA AÉREO
TRIPULADO REMOTAMENTE**

Tesis realizada por **Ricardo Sarabia López** bajo la dirección del Comité Asesor indicado, aprobado por el mismo y aceptada como requisito parcial para obtener grado de:

**MAESTRO EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL AGUA,
ORIENTACIÓN MECANIZACIÓN AGRÍCOLA**

DIRECTOR: _____


Dr. Gilberto de Jesús López Canteñs

ASESOR: _____


Dr. Eugenio Romantchik Kriuchkova

ASESOR: _____


M.I. Juan Carlos Olguín Rojas

AGRADECIMIENTOS

En este espacio deseo agradecer a las personas e instituciones que han hecho posible mi formación y la realización de este proyecto.

Como primera institución quiero agradecer a la Universidad Autónoma Chapingo, mi alma mater, que me ha brindado apoyo en el transcurso de mis estudios profesionales y de posgrado.

Al programa de Posgrado de Ingeniería Agrícola y Uso Integral del Agua de la Universidad Autónoma Chapingo, por concederme la formación y los medios posibles para mis estudios de Maestría.

Al Consejo Nacional de Ciencia y Tecnología (CONACyT) por el apoyo financiero para el desarrollo de mis estudios de posgrado.

AL Dr. Gilberto de Jesús López Canteñs, por todo su apoyo brindado tanto en lo académico como en lo moral, al igual agradecerle por su motivación y confianza que colocho en mi para el desarrollo del proyecto de investigación.

Al Dr. Eugenio Romantchik Kriuchkova por ser el respaldo de este proyecto y ofrecerme su disponibilidad y por su continuo apoyo durante todo este proceso.

Al M.I. Juan Carlos Olguín Rojas por su colaboración y por conceder las herramientas iniciales para el comienzo de mi aprendizaje en el tema de investigación aquí desarrollado.

A la Universidad de Huelva, España, así como a los investigadores que contribuyeron significativamente al desarrollo de este proyecto en la estancia de investigación realizada en dicha universidad.

Y a todas aquellas personas que me concedieron su tiempo y apoyo durante la realización de mis estudios de Maestría.

DEDICATORIA

A mi madre por su amor infinito, gracias a toda tu entrega por mí. Mujer hermosa y admirable.

DATOS BIBLIOGRÁFICOS

DATOS PERSONALES

Nombre	Ricardo Sarabia López
Fecha de nacimiento	20 de mayo de 1994
Lugar de nacimiento	Santiago Nuyoo, Tlaxiaco, Oaxaca
CURP	SALR940520HOCRPC05
Profesión	Ingeniero Mecánico Agrícola
Cédula profesional	11020069

DESARROLLO ACADÉMICO

Bachillerato:	Centro de bachillerato Tecnológico industrial y de servicio No.2, Tlaxiaco, Oaxaca
Licenciatura:	Universidad Autónoma Chapingo, Texcoco, Estado de México.

CONTENIDO

LISTA DE CUADROS	VIII
LISTA DE FIGURAS	IX
RESUMEN GENERAL.....	XI
GENERAL ABSTRACT	XII
CAPITULO 1 INTRODUCCIÓN GENERAL	13
1.1 INTRODUCCIÓN	13
1.2 OBJETIVO GENERAL	17
1.3 OBJETIVOS PARTICULARES	17
CAPITULO 2 REVISIÓN DE LITERATURA	18
2.1 TECNOLOGÍA DE SENSORES	18
2.1.1 Sensor RGB e infrarrojo cercano	18
2.1.2 Sensor multiespectral	19
2.2 MOSAICO DE IMÁGENES.....	21
2.2.1 Softwares de procesamiento de imágenes	21
2.3 ANÁLISIS DE IMÁGENES	24
2.3.1 Método OBIA	25
2.3.2 Método por Regresión Logística	27
2.3.3 Método por espacios de color en imágenes RGB	27
2.3.4 Método por transformada circular de Hough	28
2.3.5 Método por Machine Learning	30
2.3.6 Método por Redes Neuronales Convolucionales	31
2.3.7 Método por Índices de Vegetación	33
2.4 RESULTADOS DE PARAMETROS DE EVALUACIÓN.....	36
2.5 REFERENCIAS.....	37
CAPITULO 3 ARTÍCULO CIENTÍFICO	42
1. Introducción	43
2. Materiales y métodos.....	44
2.1 Sitio de estudio.....	44

2.2 Aadquisición de imagenes.....	45
2.2.1 Equipamiento de imágenes aéreas.....	45
2.2.2 Planificación de vuelo y rendimiento	46
2.3 Metodología de análisis de imagen para detección de olivos.	46
2.3.1 Preprocesamiento de imágenes.....	46
2.3.2 Modelo Digital de Superficie	47
2.3.3 Algoritmo de análisis de imágenes de detección de árbol	48
2.3.4 Algoritmo de análisis de imágenes de detección de árbol.....	52
2.4 Evaluación del rendimiento de la metodología de análisis de imagen	56
3. Resultados y Discusión.....	57
3.1 Modelo Digital de Superficie	57
3.2 Detección de coronas de olivo.....	58
3.3 Conteo de coronas de olivo.....	59
3.4 Parametros estadísticos de evaluación	60
4. Conclusiones	60
Referencias	61
APÉNDICE A. Diagrama de flujo del análisis de imágenes.....	64
APÉNDICE B. Código de composición de bandas para ortomosaico RENB.....	65
APÉNDICE C. Procedimiento interpolación IDW para generación del DSM.	66
APÉNDICE D. Código de detección y conteo automático de olivos.	67

LISTA DE CUADROS

CAPITULO 2

Cuadro 1. Sensores utilizados en RPAS para adquisición de imágenes	20
Cuadro 2. Trabajos de investigación con procesamientos de imagen en Pix4D24	
Cuadro 3. Registro de resultados de diferentes trabajos científicos en conteo de cultivos.....	36

CAPITULO 3

Tabla 1. Especificaciones de bandas espectrales capturadas por la cámara multispectral MicaSense RedEdge	45
Tabla 2. Número de observaciones en la clasificación False Positive (FP), False Negative (FN) y True Positive (TP). Resultados porcentuales de los tres parámetros de medida para la evaluación.	60

LISTA DE FIGURAS

CAPITULO 2

Figura 1. Vistas parciales de cada fase del procesamiento OBIA (figura tomada de Torres et al., 2015)	26
Figura 2. La imagen Superior es la imagen Original RGB, la imagen inferior es después de aplicar la umbralización con la transformación HSV (figura tomada de Gnädinger & Schmindhalter, 2017).....	28
Figura 3. Esquema de procesamiento en imágenes multiespectrales para la transformación circular de Hough (figura tomada de Koc-San et al., 2018)	30
Figura 4. El modelo puede detectar diferentes colores de cabezas de sorgo: blancas (A) verdes (B) y naranjas (C) (figura tomada de Guo et al., 2018)	31
Figura 5. Esquema del método de dos redes CNN combinadas (Figura tomada de Wu et al., 2019).....	33
Figura 6. Resultados de la evaluación de los IV (Figura tomada Marques et al., 2019)	35

CAPITULO 3

Fig 1. Captura aérea del sitio de estudio. Tenga en cuenta que el área de interés real, esta resaltada en rojo.	45
Fig 2. Configuración de imágenes aéreas.....	46
Fig 3. Representación del DSM calculado como imagen de intensidad. Observe en el área ampliada, en rojo, las diferencias en términos de nivel de gris entre las regiones de píxeles que aparentemente pertenecen a los olivos y las del suelo circundante.	48
Fig 4. (a) Estimación de fondo, IBEDF ; (b) imagen resultante IGS2 , después de extraer (a) de la imagen en escala de grises, IGS1 representativa del DSM.....	50
Fig 5. Resultado de la imagen binarizada, Observe en el área ampliada, en rojo, cómo las plantas potenciales se han segmentado con precisión del fondo.	51
Fig 6. (a) imagen mascara del ROI; (b) imagen resultante del corte IBIN2 con (a)....	52

Fig 7.(a) Subimagen de una representación RGB de los ortomosaicos previamente calculados, donde se puede observar un par de árboles con follaje superpuesto; (b) subimagen de la imagen binaria resultante de la segmentación realizada, correspondiente al área representada en (a). Observe cómo los dos olivos comparten el mismo componente conectado en la imagen binaria.....	53
Fig 8. (a) Subimagen de una representación RGB de los ortomosaicos previamente calculados; (b) subimagen de la imagen binaria resultante de la segmentación realizada, correspondiente al área representada en (a); (c) representación en (b) de las elipses (en rojo) calculadas para cada componente conectado en la imagen, con sus correspondientes ejes mayor (en azul) y menor (en verde).	53
Fig 9.Resultado del cálculo de los puntos de ubicación de los árboles individuales....	56
Fig 10. Imagen RGB, donde sus canales, rojo, verde y azul se han alimentado con la información proporcionada, respectivamente, correspondientes a los ortomosaicos azul, borde rojo y NIR.	57
Fig 11. Imágenes para el análisis del DSM, la imagen (a) es el árbol no generado en la imagen (c), esto derivado por la ausencia de información en la nube de puntos observado en la imagen (b).	58
Fig 12. (a) Imagen de copas de árboles con separación entre ellos en (a) se muestran en la imagen binarizada. En la imagen (d) se muestran componentes conexas que contienen dos árboles debido a la frondosidad de los árboles que se muestran en (c).	59
Fig 13. En la imagen se observa los tres casos donde ocurrieron los FP.....	59

RESUMEN GENERAL

CONTEO AUTOMÁTICO DE OLIVOS MEDIANTE MORFOLOGÍA MATEMÁTICA CON IMÁGENES ADQUIRIDAS POR SISTEMA AÉREO TRIPULADO REMOTAMENTE

En el contexto de la agricultura inteligente, el conocimiento preciso sobre la población de plantas presentes en el campo, comprende una información útil, tanto para los agricultores como para los técnicos responsables del fenotipado de cultivo. En este sentido, el uso de Sistemas de Aeronaves Pilotadas a Distancia (RPAS) ha proliferado en los últimos años como respuesta a los métodos tradicionales para el conteo de plantas, que generalmente son laboriosos, requieren mucho tiempo y son propensos a errores humanos. Por lo tanto, se propone una metodología para la detección automatizada y conteo de olivos a partir de imágenes multiespectrales de alta resolución, adquiridas por imágenes aéreas. Posterior a la adquisición de imágenes, las capturas se procesaron para obtener una representación gráfica del campo basada en nube de puntos. Con el fin de aprovechar la información de elevación contenida en ella y eventualmente identificar las plantas, esta nube de puntos 3D fue interpolada determinísticamente y convenientemente transformada mediante morfología matemática. En una etapa final, los olivos que aparecen en la imagen se segmentaron del fondo, lo que permitió su detección. Se puede concluir la viabilidad de esta metodología como una solución para la automatización del conteo de plantas en huertos de olivos, como una forma de mejorar las capacidades de fenotipado en el campo.

Palabras clave: imágenes aéreas, análisis de imagen, imágenes multiespectrales, olivos, fenotipado, población de plantas, RPAS

Tesis de Maestría en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo

Autor: Ricardo Sarabia López

Director de Tesis: Gilberto de Jesús López Canteñs

GENERAL ABSTRACT

AUTOMATED COUNTING OF OLIVE TREES MEANS MATHEMATICAL MORPHOLOGY FROM MULTISPECTRAL IMAGERY BY REMOTELY PILOTED AIRCRAFT SYSTEM

Within the context of smart farming, accurate knowledge about the plant population present on the field comprises useful information, for both farmers and technicians responsible for the crop phenotyping. In this regard, the use of Remote Piloted Aircraft Systems (RPAS) has proliferated in recent years as a response to the traditional methods for plant counting, which are usually laborious, time-demanding and prone to human error. Hence, a methodology for automated detection and counting of olive trees from high resolution multispectral images, acquired by aerial imaging is proposed. After image acquisition, captures were processed to yield a point cloud – based representation of the field. In order to exploit the elevation information contained in it and eventually identify the plants, this 3D point cloud was deterministically interpolated, and conveniently transformed by means of mathematical morphology. In an ultimate stage, the olive-trees appearing in the image were segmented from the ground, enabling their detection. The viability of this methodology, based on the results obtained, can be concluded as a solution to the automation of the plant counting in olive orchards, as a way to improve the in-field phenotyping capabilities.

Keywords: image analysis, multispectral imagery, olive tree, phenotyping, plant population, RPAS

¹Thesis, Universidad Autónoma Chapingo

Author: Ricardo Sarabia López

Advisor: Gilberto de Jesús López Canteñs

CAPITULO 1 INTRODUCCIÓN GENERAL

1.1 INTRODUCCIÓN

Las tendencias demográficas apuntan que para el año 2050 la población mundial será aproximadamente de 10 000 millones de personas, provocando una creciente urbanización de la población. Consecuentemente, la producción agrícola inevitablemente aumentara, para afrontar la demanda de alimentos, limitándose a la disponibilidad y productividad de los recursos de agua y suelo (FAO, 2018). La intensificación agrícola sostenible y el uso eficiente del agua, son claves para evitar la expansión de áreas agrícolas, preservando el suelo y su calidad, y no sobreexplotando los recursos hídricos. La investigación y la aplicación de tecnologías del sector agrícola garantizan el desarrollo de sistemas innovadoras que mantengan el equilibrio entre el rendimiento agrícola y la sostenibilidad. Producir más con menos, será posible a través de estas estrategias (FAO 2018). La forma de abordar esto es mirar a la ciencia y la tecnología (Zarco, Hubbard & Loudjani, 2014), como lo es la implementación de la agricultura de precisión y el estudio del fenotipado de cultivos.

La agricultura de Precisión (AP) es una estrategia de gestión que utiliza tecnología de la información, datos de posicionamiento por satélite, sensores remotos y recolección de datos proximales, para llevar información de múltiples fuentes a las decisiones asociadas con la producción de cultivos (National Research, 1997). Una manera simple de definir es “aplicar el tratamiento correcto en el lugar correcto en el momento adecuado” (Gebbers y Adamchuk, 2010). Los beneficios de la agricultura de precisión son los aumentos en el rendimiento y la rentabilidad de la producción agrícola, de tal manera que optimiza la eficiencia en la producción e incrementa la calidad del producto. A su vez disminuye los impactos ambientales, y mejora las condiciones laborales del agricultor, La AP es respetuosa con el medio ambiente, contribuyendo al objetivo amplio de la sostenibilidad agrícola (Zarco, Hubbard & Loudjani, 2014).

El fenotipado de plantas es una ciencia que vincula las propiedades y características físicas del cuerpo funcional de la planta (Fenotipo) que se va desarrollando durante su ciclo de vida, a partir de la relación del medio ambiente en el que se desarrolla y sus características genéticas, permitiendo comprender el tratamiento ecológico de la planta, rasgos específicos para su monitoreo, el fenotipado es esencial para el mejoramiento cualitativo de los cultivos agrícolas que mejoren su productividad, rendimiento, calidad, y se adecuen a los cambios climáticos actuales y futuros, esto es clave para resolver la creciente demanda de producción global de alimentación prevista para el año 2050 (Sindhuja et al., 2015, Furbank y Mark, 2011, Araus y Cairns, 2014, Fiorani y Schurr 2013).

Las tecnologías tradicionales de teledetección en la agricultura de precisión han sido los satélites y aeronaves, estos se ven limitado frecuentemente por la nubosidad en la atmosfera en el momento de adquisición de imágenes aéreas, así como por la resolución espacial (0.5 a 10 m) y temporal que estas plataformas ofrecen. Para resolver estas dificultades últimamente se le ha prestado especial atención al desarrollo y uso de las Sistemas Aéreos Pilotados Remotamente (RPAS), debido a que tiene menores i) restricciones climáticas, incluso se utilizan en condiciones de nubosidad, ii) menor costo operacional, iii) mayor flexibilidad en la programación de vuelos, iv) una distancia de muestro de tierra (GSD) pequeña, v) una mayor resolución espacial de hasta 1 cm y vi) una mejor resolución que permite realizar el monitoreo de parcelas en periodos específicos del ciclo del cultivo. Las ventajas con respecto a los métodos tradicionales están descritas en diferentes investigaciones (Hunt y Daughtry, 2018, Peña, Torres-Sánchez, de Castro, Kelly, López-Granados, 2013, Tripicchio, Satler, Dabisias, Ruffaldi, Avizzano, 2015, Sindhuja et al., 2015).

Los últimos años las tecnologías de AP reportan un crecimiento exponencial en el desarrollo de RPAS y de los sensores remotos (Erickson y Wibmar, 2015, Erickson y Lowender-DeBoer, 2017). Hunt y Daughtry (2018) Sugieren que los siguientes puntos sobresalientes de la aplicación de los RPAS en la agricultura: exploración de problemas, monitoreo para evitar pérdidas de rendimiento, y

planificación de operaciones del manejo de cultivos. Los avances tecnológicos y ventajas del uso de RPAS expanden las aplicaciones de la teledetección, convirtiéndose en importantes y prometedores herramientas para los investigadores dentro del campo de las ciencias agrícolas (Floreano y Wood, Sindhuja et al., 2015).

El procedimiento de conteo de plantas en los campos agrícolas es crucial para determinar la densidad del cultivo. Normalmente se realiza mediante técnicas de inspección visual y manual, pero esto es un proceso intenso y laborioso consumiendo demasiado tiempo. Además, el trabajo se complica cuando se trata de extensiones grandes de cultivo, obligando a recurrir a técnicas de muestro y posteriormente extrapolar esos datos a toda el área de interés. Debido a la alta probabilidad del error humano, y por el margen de error de las técnicas de inspección y muestro, se obtienen resultados poco precisos e inciertos. Lo mismo sucede con los intentos de caracterizar la estructura de las plantas de forma manual, siendo el principal problema la gran variabilidad en los cultivos. Derivado de estas dificultades existe la necesidad de desarrollar técnicas de conteo y caracterización de cultivos, que sean precisos, eficientes y no destructivos.

La detección y geolocalización individualizada de las plantas mediante el uso de RPAS y análisis de imágenes algoritmos computacionales. Da beneficios al agricultor como lo es un inventario preciso y exacto de su cultivo lo que ayuda a mejorar la planificación de actividades como la aplicación del riego, pesticidas, fertilizantes, etc. de sus campos agrícolas, esto incrementa la rentabilidad del cultivo. Además, el estudio específico de la planta potencializara las investigaciones de fenotipado, aumentando la eficiencia al medir características de los cultivos como la detección de estrés hídrico (Zarco-Tejada, González-Dugo, & Berni, 2012), estimación de índice de área foliar ((Ballesteros, Ortega, Hernández, & Moreno, 2014)), estimación de biomasa (Bendig et al., 2014), detección de vegetación (J. Torres-Sánchez, Peña, de Castro, & López-Granados, 2014), detección de enfermedades (Garcia-Ruiz et al., 2013) y

caracterización del suelo (D'Oleire-Oltmanns, Marzloff, Peter, & Ries, 2012). La revisión tiene el objetivo de proveer información de los distintos trabajos de investigación que han desarrollado procedimientos automáticos de detección y cuantificación de a partir de imágenes aéreas adquiridas por RPAS. Los resultados conseguidos por los investigadores son prometedores, pero el número de trabajos de investigación encontrados siguen siendo insuficientes, para dar resuelto el problema debido a la gran diversidad de cultivos. Sin embargo, en los años 2017, 2018 y 2019 se observa un incremento en el desarrollo de estas investigaciones. En este trabajo se presenta en el segundo de capítulo el estado del arte en el marco del problema planteado en este proyecto de investigación. En el capítulo 3 se presenta artículo científico como resultado del diseño experimental realizado en este trabajo.

1.2 OBJETIVO GENERAL

Desarrollar un procedimiento de conteo automático de árboles de olivo, utilizando imágenes multiespectrales adquiridas mediante un RPAS, mediante el análisis de imagen por morfología matemática.

1.3 OBJETIVOS PARTICULARES

- Planificar vuelos autónomos de RPAS para adquisición imágenes multiespectrales considerando la superposición tanto lateral como al avance.
- Realizar preprocesamientos de imágenes para generar ortomosaicos, nube de puntos y Modelo Digital de Superficie.
- Aplicar la morfología matemática para la segmentación de las coronas de olivo respecto a su entorno.
- Desarrollar algoritmo para el conteo automático de olivos en el área de interés.

CAPITULO 2 REVISIÓN DE LITERATURA

2.1 TECNOLOGÍA DE SENSORES

Las características a considerar al adquirir un sensor son 1.-el tamaño del sensor: 2.-resolución, 3.-distancia focal, 4.-peso y 5.-la longitud de onda espectral, los tres primeros parámetros son necesarios para calcular la distancia de la muestra en el suelo (GSD) en dependencia con la altura de vuelo (Hernandez-Lopez, Felipe-Garcia, Gonzalez-Aguilera, & Arias-Perez, 2013). El cuarto parámetro es utilizado para verificar si la carga útil del RPAS es suficiente para portar el sensor. La longitud de onda espectral de interés en aplicaciones agrícolas suele estar situada entre los 400nm y los 2400nm (Clevers, 1999), abarcando desde el rango de luz visible hasta el rango del infrarrojo térmico.

Las tecnologías de fabricación de los sensores son de tres tipos, se tratan de los CCD (Charge Coupled Device) ología, CMOS (Complementary Metal Oxide) y live MOS (Metal Oxide Semiconductor), los últimos años los avances en el desarrollo en CMOS han superado el rendimiento CCD (Janesick, Elliott, Andrews, & Tower, 2015), debido a su bajo costo, baja potencia, bajo voltaje e integración monolítica que permite la fabricación de cámaras digitales cada vez más pequeñas (Blanc, 2001). Por lo que no es de extrañar que predominen en las investigaciones observadas en esta revisión.

2.1.1 Sensor RGB e infrarrojo cercano

Los sensores que destacan en el equipamiento de los RPAS, son los sensores RGB (Tabla 1) conocidas comúnmente como cámaras digitales, estas capturan imágenes compuestas en el espectro de luz visible Rojo (R), Verde (G) y azul (B). Las ventajas de estos sensores son: precio bajo, sencillos de operar, ligeros y procesamiento de datos simples (Yang et al., 2017). Estos sensores han permitido a los investigadores caracterizar los cultivos de forma visual y morfológica.

En Díaz-Varela et al. 2015; Sankaran et al. 2017; Hall et al. 2018; Marques et al. 2019 modifican el sensor RGB para obtener, información del rango infrarrojo

cercano (NIR), con la finalidad de realizar índices de vegetación donde impliquen el uso de esta banda. Hall et al. 2018 realizó la modificación a una cámara GoPro Hero 4 Silver reemplazando la lente IR CUT Mp-10 de 5.4 mm 1/2.3" por la lente IR MP-10 de 5.4 mm 1/2.3" ambas lentes fabricadas por la compañía GoPro Inc. y (Díaz-Varela et al., 2015) realiza esta modificación removiendo el filtro interno infrarrojo a una cámara Panasonic Lumix DMC-GF1. Otras investigaciones como (Marques et al., 2019; Sankaran et al., 2017) realizaron la modificación en sus cámaras para obtener la banda NIR sin embargo no especifican el método.

2.1.2 Sensor multiespectral

Los investigadores con el fin de estudiar más a fondo de los cultivos, han hecho uso de sensores que le permitan capturar imágenes que obtengan características de observación espectral y reflectancia del cultivo, como es el caso de los sensores multiespectrales. Los sensores multiespectrales son capaces de obtener información dentro del rango espectral visible, así como de rangos espectrales que ya no son visibles por el ojo humano, sin embargo, existen una variedad de softwares que permiten la manipulación de estas imágenes.

A pesar que se registran muchas investigaciones del uso de estos sensores multiespectrales en distintos enfoques de fenotipado de cultivos (Sankaran et al., 2015; Yang et al., 2017), para el caso del estudio en este artículo nos encontramos concretamente con tres investigaciones donde utilizan estos sensores. Es importante mencionar que estos sensores no tienen el mismo número de bandas, ni pueden detectar la misma longitud espectral, haciendo una comparativa, Torres et al. 2015 utiliza un sensor de seis bandas espectrales, que le permite obtener en la banda azul (B) una longitud media de onda espectral de 450nm, 530nm en la banda Verde (G), en la banda roja (R) 670 y 700nm, la banda del borde rojo (RedEdge) 740nm e NIR de 780nm. Mientras que en la investigación de Sankaran et al. 2017 hace uso de un sensor de 4 bandas, que obtienen una longitud espectral en sus bandas G: 530-570nm, R: 640-680nm, RedEdge 730-

Cuadro 1. Sensores utilizados en RPAS para adquisición de imágenes

	SENSORES	MODELO	CULTIVO	REFERENCIAS
1	Sensor RGB	Canon EOS 550D	Palmeras	(Bazi, Malek, Alajlan, & Alhichri, 2014), (Malek, Bazi, Alajlan, AlHichri, & Melgani, 2014)
2	Sensor RGB	Panasonic Lumix G3	Palmera	(Kattenborn, Sperlich, Bataua, & Koch, 2014)
3	Sensor RGB	Panasonic Lumix DMC-GF1 (Modificado para infrarrojo)	Olivos	(Díaz-Varela et al., 2015)
4	Sensor RGB y Sensor Multiespectral	Olympus PEN E-PM1 Tetracam mini-MCA-6	Arboles Agrícolas	(Torres et al., 2015)
5	Sensor RGB	Cámara DJI Phantom 2 Visión Plus	Palmeras	(Miserque Castillo, Laverde Diaz, & Rueda Guzmán, 2016)
6	Sensor RGB	-	Sorgo	(Ribera et al. 2017)
7	Sensor RGB	Canon G12	Maíz	(Gnädinger & Schmidhalter, 2017)
8	Sensor RGB	Sony ILCE-5100L	Trigo	(Jin, Liu, Baret, Hemerlé, & Comar, 2017)
9	Sensor RGB	Canon Powershot ELPH 340 HS (Modificada)	Papa	(Sankaran et al., 2017)
10	Sensor RGB	Nikon Coolpix P7700	Viñedo	(Primicerio et al., 2017)
11	Sensor RGB	-	Sorgo	(Y. Chen et al. 2017)
12	Sensor RGB	Cámara DJI Phantom 2 Vision Plus	Algodón	(R. Chen, Chu, Landivar, Yang, & Maeda, 2018)
13	Sensor RGB	Sony Cyber-shot DSC-RX100M3	Sorgo	(Guo et al., 2018)
14	Sensor RGB	Olympus Pen E-PM1	Olivos	(Jorge Torres-Sánchez, López-Granados, Borra-Serrano, & Peña, 2018)
15	Sensor RGB	Cámara DJI Phantom 3 advanced	Cítricos	(Koc-San, Selim, Aslan, & San, 2018)
16	Sensor RGB	Cámara DJI Phantom 4	Tabaco	(Fan, Lu, Gong, Xie, & Goodman, 2018)
17	Sensor RGB	GoPro Hero 4 (Modificado para Infrarrojo)	Maíz	(Hall et al., 2018)
18	Sensor RGB	Cámara multieespectral	Coco	(Aparna et al., 2018)
19	Sensor Multiespectral	cámara Multiespectral Parrot Sequoia	Cítricos	(Csillik, Cherbini, Johnson, Lyons, & Kelly, 2018)
20	Sensor RGB	Nikon D800 reflex	Colza	(Zhao et al., 2018)
21	Sensores RGB	GoPro Hero 2 y Cámara Rasperry Pi model 2	Platano, coco, mango	(Kestur et al., 2018)
22	Sensor RGB	Cámara DJI Phantom 3 Standart	Cítricos	(Selim, Sonmez, Coslu, & Onur, 2019)
23	Sensor RGB	Cámara Sony QX-100 HD	Arroz	(Wu et al., 2019)
24	Sensor RGB	Cámara DJI Phantom 4	Olivo	(Salamí, Gallardo, Skorobogatov, & Barrado, 2019)
25	Sensor RGB	Cámara DJI Phantom 4 Pro	Papa	(Li et al., 2019)
26	Sensor RGB y Sensor Modificado	Cámara Canon IXUS 12.7 HS Cámara Canon PowerShot ELPH 110 HS (modificado para NIR y RedEdge)	Castaños	(Marques et al., 2019)
27	Sensor Multiespectral	Cámara RedEdge-M, MicaSense	Cítricos	(Ampatzidis & Partel, 2019)

740nm e NIR; 770-810 nm. Por ultimo Ampatzidis and Partel 2019 utiliza un sensor de 5 bandas espectrales, las cuales detectan longitudes espectrales en la banda B: 465-485nm, G:550-570nm, R: 663-673nm, RedEdge:712-722 nm e NIR: 820-860nm. Por lo tanto, esas diferencias marcan la adquisición de información de la cual parten los estudios específicos de un cultivo a nivel espectral e identificar las características de la vegetación. Por lo tanto, estas diferencias entre los sensores permiten identificar las características de la vegetación en diferentes rangos del espectro electromagnético, que son de interés en la agricultura.

2.2 MOSAICO DE IMÁGENES

La mayoría de trabajos realizan comúnmente con las imágenes obtenidas por RPAS un pre procesamiento previo, el cual consiste en unir todas las imágenes para obtener una imagen única del sitio de estudio, a esto se le llama mosaico, pero si a esta se le corrigen en las deformaciones creadas por la cámara, altura o velocidad de adquisición de las imágenes y se modifican a una perspectiva ortogonal, se les conoce ortomosaicos. Se encuentran trabajos que se desarrollan solo a partir de imágenes áreas individuales. En los trabajos de investigación cada quien opta por distintas metodologías.

2.2.1 Softwares de procesamiento de imágenes

Existen en la actualidad diversos softwares para crear ortomosaicos a partir de imágenes individuales georreferenciadas, de los softwares que se han utilizado en el marco de esta investigación, se encontraron los siguientes: Autopano, Visual SFM, Agisoft PhotoScan, Pix4D, ArcGis Pro y en otros casos utilizaron softwares de desarrollo propio.

Autopano Kolor Pro/Giga 3.5 (Kolor SARL, Challes-les-Eaux, France) es un software que, si bien no tiene un interfaz dirigido a la fotogrametría con RPAS, y más bien va dirigido a aplicaciones para fotografía, permite realizar mosaicos con imágenes aéreas con drones teniendo la capacidad de detectar por sí mismo imágenes que contienen información entre sí y empalmarlas manera automática, además cuenta con una opción de verificación de la precisión del mosaico,

mediante la observación de pixel por pixel. En Bazi, Malek, Alajlan, & Alhichri, 2014; Malek, Bazi, Alajlan, AlHichri, & Melgani, 2014 utilizan esta herramienta para generar mosaicos con imágenes aéreas sobre cultivo de palmeras, en dos áreas de aproximadamente 1 hectárea cada una. En el trabajo Primicerio et al., 2017 para el procesamiento de imágenes aéreas consistió, en crear un mosaico a partir de 64 imágenes adquiridas sobre un viñedo, esto se realizó con Autopano 3.5 para posterior ser georreferenciadas y ortorectificadas en otro software, estos dos últimos procesos son la limitante de este software en comparación con otros utilizados en el mismo campo de aplicación (fotogrametría con imágenes RPAS).

Visual SFM es una aplicación GUI para la reconstrucción 3D usando structure from motion (SfM), este programa fue desarrollado por Yasutaka Furukawa y Jean Ponce, la GUI es robusta pero muy práctico al momento de reconstrucción 3D de imágenes, El trabajo realizado por Kattenborn, Sperlich, Bataua, & Koch, 2014 usaron Visual SFM para explorar el potencial de la detección de árboles individuales mediante la reconstrucción 3D (nube de puntos), procesando alrededor de 510 imágenes que cubrían un área de 470*200 m donde se encontraba un cultivo de palmera. Cabe señalar que, en la revisión de literatura, fueron escasos los trabajos que usaron los softwares Autopano y Visual SFM.

Agisoft PhotoScan (Agisoft LLC, St. Peterburg, Rusia) es uno de los programas de mayor uso en la fotogrametría con drones en agricultura de precisión, permite generar automáticamente ortomosaicos georreferenciados de alta resolución, nube de puntos densas, modelos poligonales, modelos digitales de superficie y modelos digitales de terreno. Se realizan los productos mediante una secuencia de pasos intuitiva y además ofrece la posibilidad de poder determinar la calidad en cada una de las fases del flujo de trabajo. De manera general los pasos para poder llegar a la construcción del ortomosaico es la siguiente:

1. Alineación de las imágenes, el software busca puntos espaciales coincidentes entre las imágenes

2. Este paso es opcional, si se dispone de puntos de puntos de control terrestre (GCP) tomados en campo con GPS agisoft permite incluirlos para realizar una georreferenciación con mayor precisión en las imágenes.
3. A partir del paso anterior permite crear la nube de puntos densa, y este se observará más realista conforme a la calidad que le asignemos.
4. Mediante la nube de puntos podemos generar cualquiera de los productos mencionados anteriormente.

Torres et al., 2015 y Jorge Torres-Sánchez et al., 2018 utilizaron Agisoft PhotoScan Professional Edition para el proceso de generación de ortomosaicos y DSM utilizando 5 GCP con un dispositivo GPS en las esquinas y en el centro de su sitio de estudio a modo de poder georreferenciar sus imágenes para obtener mayor precisión, esto lo realizaron sobre cultivos de olivo. En un cultivo de trigo Jin et al., 2017 utilizó este mismo software y en el mismo caso utilizó GCP adquiridos mediante el sistema RTK GPS.

Pix4Dmapper (Pix4D, Inc., Lausanne, Suiza) es un software de fotogrametría que ofrece los mismos productos que agisoft, con la diferencia de su desarrollo en el campo de la agricultura, como lo es la generación automática de índices de vegetación, la manipulación de imágenes multiespectrales y térmicas, así como la generación de mapas de reflectancia. Para generar los productos en Pix4D primero se realiza la configuración completa de la calidad y de los resultados que se quieren obtener, y posteriormente se ejecuta el proceso automático. Una configuración general del proceso es la siguiente:

1. Se añaden las imágenes al software, y se realiza la georreferenciación de cada uno de ellas automáticamente, como primera configuración se establece el sistema de coordenadas en que se generaran los productos finales, y se añaden en caso de tenerlos los GCP.
2. Se establece la calidad de los puntos de enlace automático entre imágenes.
3. Se configura la calidad de nube de puntos: baja, óptima y alta.

4. Se establecen los productos a obtener: ortomosaicos, modelo digital de superficie, modelo digital del terreno, curvas de nivel, índices de vegetación, mapas de reflectancia, determinando el formato de importación de cada uno de ellos.
5. Se ejecuta el proceso, por lo que a diferencia de agisoft la forma de trabajar con Pix4D no es mediante pasos secuenciales.

Este software fue el que se encontró en la mayoría de los artículos revisados, destacándose como la herramienta más utilizada en el enfoque de estudio planteado en este trabajo. Los trabajos desarrollados con esta herramienta se muestran en el cuadro 2.

Cuadro 2. Trabajos de investigación con procesamientos de imagen en Pix4D

No. De imágenes	Área de estudio	Productos	Referencia
390 y 255	138 y 82 ha	Ortomosaicos, DSM	(Torres et al., 2015)
-	-	Ortomosaicos	(Miserque Castillo et al., 2016)
180	85x54m	Ortomosaicos	(R. Chen et al., 2018)
48, 56 y 38	-	Ortomosaicos, DSM	(Koc-San et al., 2018)
4574	64.6 ha	Ortomosaicos	(Csillik et al., 2018)
230 y 290	18x50 m	Ortomosaicos	(Zhao et al., 2018)
473	75x150 m	Ortomosaicos	(Jin et al., 2017)
170	438 ha	Ortomosaicos, DSM, DTM	(Marques et al., 2019)
-	14 acres	Ortomosaicos	(Ampatzidis & Partel, 2019)

Se encuentran procesamientos de imágenes, donde los autores de los artículos crean su propio algoritmo como son los casos de Ribera et al., 2017 y Salamí et al., 2019.

2.3 ANÁLISIS DE IMÁGENES

El análisis de imágenes consiste en la extracción de información derivada del procesamiento digital de imágenes, los datos en las imágenes pueden estar representadas en dos dimensiones (Ortomosaicos) o en tres dimensiones (Nube de puntos, DSM). El enfoque estudiado en esta revisión es extraer la información de imágenes aéreas con RPAS en campos agrícolas, que permitan el conteo automático de las plantas, siendo posible gracias al desarrollo de tecnología en

sistemas informáticos y su utilización por los investigadores en las ciencias agrícolas.

Cabe resaltar que en la mayoría de métodos aquí estudiados se dividen en dos procedimientos generales, el primero es la detección del cultivo, el cual consiste en separar en la imagen digital el cultivo del suelo, malezas, sombra, y cualquier atributo en la imagen que no pertenezca al cultivo, después de lo anterior se realiza la cuantificación de plantas presentes en el cultivo.

2.3.1 Método OBIA

El análisis de imágenes basado en objetos (OBIA) esta implementado en el software eCognition Developer (Trimble GeoSpatial, Munich, Alemania) realiza un análisis en imágenes de alta resolución basándose en grupos de píxeles con características similares, que permite estudiar la información espectral pixel a pixel, pero que además el tamaño, textura y forma de los grupos con el entorno que los rodea, he de ahí el análisis por objetos. Jorge Torres-Sánchez et al., 2018; Torres et al., 2015 utilizaron este método para estimar características geométricas de árboles como el área del dosel, la altura del dosel y el volumen de copa, y el número de árboles con información espectral y de alturas en un DSM, en Torres et al., 2015 se describe detalladamente el método realizado. Desarrollo un algoritmo en el software eCognition Developer 9 que consiste en 4 fases consecutivas:

1. La primera parte del método consiste en segmentar los objetos como primer paso una segmentación de resolución múltiple (figura 1(a)) y posteriormente establecen parámetros que varía de 0 a 1 de color, forma, suavidad y compacidad, utilizando información DSM e imágenes multiespectrales (figura 1(b)), esto para conseguir una mejor delimitación de los árboles, consiguiendo una segmentación en la imagen
2. La segunda fase consiste en realizar la clasificación, para esto se usaron índices de vegetación, luego realizaron un método de umbralización para discriminar la vegetación, consiguiendo asilar la vegetación del suelo desnudo (figura 1(c)), y para discriminar suelo con vegetación del cultivo,

utilizaron los datos DSM mediante una diferencia de valores de altura entre la vegetación herbácea y los árboles (figura 1(d)), el suelo desnudo más próximo a cada árbol se utiliza como valores bases para el cálculo de la altura de cada árbol (figura 1(f)).

3. Con lo anterior se consigue tener cada árbol de forma individual, por lo que en la tercera etapa consistió en estimar las características tridimensionales de los árboles, el ancho, longitud y área proyectada de cada árbol y la altura de árbol se calcularon automáticamente, para el volumen se realizó un análisis pixel por pixel que conformaba la copa del árbol esto para lidiar con la forma irregular de las copas.
4. Como último paso entregaron los resultados exportando automáticamente la información generada durante el procedimiento OBIA y en la figura 1(f) se observa el resultado del final del procedimiento del análisis digital de imagen, observándose la vegetación herbácea en tonalidad verde oscuro, los árboles en color verde brillante y el suelo desnudo en color rojo.




Figura 1. Vistas parciales de cada fase del procesamiento OBIA (figura tomada de Torres et al., 2015)

Díaz-Varela et al., 2015 también desarrolla su trabajo entorno a OBIA, para estimar los parámetros de la arquitectura de la copa de árboles y la altura de los mismo.

2.3.2 Método por Regresión Logística

Es un método estadístico de aprendizaje supervisado que es adecuado en análisis de imágenes cuando solo existen dos posibles respuestas, como en el trabajo de Miserque Castillo et al., 2016 realizo la detección de palmeras, donde etiqueta manualmente una muestra considerable de imágenes para indicar si en la imagen se presenta una palmera o no, es decir en positivos y negativos, posteriormente aplico un patrón binario local (LBP) que es un descriptor de texturas en imágenes, el procedimiento asigna valores a cada pixel de acuerdo con la vecindad de 8 pixeles que lo rodeen, una vez preparada estas muestras son utilizadas para entrenar el modelo de regresión logística hasta alcanzar la calificación de 1.0 que significa que es capaz de clasificar las muestras en palmeras y no palmeras. Para realizar el conteo automático de las palmeras utilizo una pirámide gaussiana para poder realizar el conteo de palmeras de distintas dimensiones, estableciendo a partir de que parámetros se considera la existencia de una palmera.

2.3.3 Método por espacios de color en imágenes RGB

Gnädinger & Schmidhalter, 2017 planteo que, para poder detectar el número de plantas en un cultivo de maíz, enfocando el análisis de imágenes RGB se requieren condiciones libres de malezas en el campo al momento de adquirir las imágenes aéreas debido a la similitud del color con el cultivo, esto solo bajo las características del procedimiento realizado en su trabajo.

Primeramente, transformo las imágenes originales realizando un histograma de color que le ayudaron a decidir, corregir y optimizar el brillo y contraste de las imágenes, el cual consistió básicamente explorar los valores de cada banda (Rojo (R), Verde (V) y Azul (B)), teniendo valores de 0 a 255 en una escala de donde cero son es negro y 255 es blanco, evaluando estos valores determina los valores de cada banda para la nueva imagen, teniendo como objetivo una

segmentación donde el color que representa al cultivo resalte sobre el color del suelo. La imagen original modificada se le separa la luminancia de la información de color con un modelo de color HSV el cual es una transformación no lineal del modo RGB, el cual se compone de tres canales tono, saturación y los valores de intensidad de un pixel, y en base a esto se seleccionan los valores que determinen el umbral optimo que permita distinguir el cultivo del fondo. Realizo una eliminación de grupos de pixeles pequeños ya que estos no representan una planta, estos pixeles se establecieron cero y el resto en uno consiguiendo una imagen binaria, y de esta manera las plantas se pudieron contar.




Figura 2. La imagen Superior es la imagen Original RGB, la imagen inferior es después de aplicar la umbralización con la transformación HSV (figura tomada de Gnädinger & Schmindhalter, 2017).

2.3.4 Método por transformada circular de Hough

La transformada de Hough es una técnica de análisis de imágenes digitales, que permite detectar líneas que se puedan parametrizar una figura como pueden ser rectas, círculos, elipses. La aplicación de esta herramienta necesita tener la imagen binarizada para poder detectar los pixeles del contorno de la figura a parametrizar mediante las ecuaciones matemáticas de la figura. Koc-San et al., 2018 utilizó la transformada circular de Hough para el conteo de cítricos, tanto

para imágenes multiespectrales como para modelos digitales de superficie, como datos de entrada realizando así dos procedimientos distintitos para detección y conteo de cítricos.

El análisis para las imágenes DSM consistió en binarizarla mediante una umbralización utilizando los valores medios y de desviación estándar, ya que los pixeles en la imagen son valores de altura, y esto permitió la separación del fondo de las copas de los árboles, realizado el proceso anterior, aplico un algoritmo de detección de bordes canny (desarrollado por John F. Canny en 1986 y que se encuentra implementado en los lenguajes de programación) para delimitar individualmente el borde de la copa de los árboles. Utilizando las imágenes de bordes realizo la transformación de Hough circular para poder representar las copas de las arboles en círculos, consideró las dimensiones de las copas de los árboles y la distancias entre sí en pixeles, y estableció los parámetros de los círculos que mejor se adoptaban a la copa de los árboles, y conseguido esto pudieron ser cuantificarlos.

Para el procedimiento de las imágenes multiespectrales, utilizo la información de la sombra que proyectaban los árboles (figura 3a, 3b), entonces el procedimiento para la obtención de las imágenes con borde, fue para conseguir el borde de las sombras (figura 3c) por lo tanto los bordes son parciales y no incluyen los árboles completos, y para obtenerlos fue el mismo procedimiento que utilizó para las imágenes DSM. La aplicación de la transformada de Hough ofrece la posibilidad de generar los círculos con información parcial del mismo, por lo que los círculos generado en este caso no delimitan al árbol (figura 3d), entonces realizo la determinación de la posición verdadera del árbol, para realizarlo utilizo información de la altura de los árboles, el ángulo de elevación del sol y la información de azimuth para calcular el desplazamiento entre la ubicación del árbol y su sombra (figura 3e), de este modo movió los círculos para que delimiten a los árboles (figura 3f).




Figura 3. Esquema de procesamiento en imágenes multiespectrales para la transformación circular de Hough (figura tomada de Koc-San et al., 2018)

2.3.5 Método por Machine Learning

Machine learning es una rama de la inteligencia artificial donde a través de las ciencias de la computación se encarga de aprender y crear un modelo a partir de un conjunto de datos, y realizar decisiones con mínima intervención humana.

Los árboles de decisión Se representan gráficamente mostrando las probables soluciones a una decisión basándose en las condiciones con las que se interactúan, es de los algoritmos de aprendizaje supervisado que más se han utilizado en machine learning, siendo una solución para resolver tareas de clasificación o regresión.

Una máquina de vectores de soporte (SVM) Se trata de un algoritmo de tipo aprendizaje supervisado el cual se emplea en clasificaciones binarias o de regresión. Los SVM crean un hiperplano óptimo con un arreglo de superficie de decisión, de tal manera que el margen de separación entre clases en los datos se amplíe al máximo.

En base en los dos algoritmos anteriores Guo et al., 2018 desarrollo su trabajo para la cuantificación de plantas de sorgo, su trabajo se basó en un método de aprendizaje automático de dos pasos, el primer paso consistió en la detección de las cabezas de sorgo, determino siete clases: suelo, sombra, hojas muertas, hojas, cabezas de sorgo verdes, naranjas y blancas, aplica en sus imágenes diferentes espacios de colores RGB, HSV, L^*a^* para cada una de las clases. Con estas características formo un modelo de segmentación de pixel basado por árbol de decisión con la finalidad de segmentar las cabezas de sorgo de distintos colores, separándolos del resto de clases de manera automática. El segundo

paso consiste en el conteo, para esto extrae 11 características morfológicas de las cabezas de sorgo: área, excentricidad, extensión, perímetro, longitud del eje mayor y menor, área convexa, relleno de área, diámetro equivalente, solidez y redondez, todos en ellos en unidades pixel. Estas características se utilizaron como predictores para entrenar un tipo de clasificador SVM, una vez entrenada el modelo fue capaz de distinguir cabezas de sorgo en diferentes escenarios.




Figura 4. El modelo puede detectar diferentes colores de cabezas de sorgo: blancas (A) verdes (B) y naranjas (C) (figura tomada de Guo et al., 2018)

Otro trabajo de conteo por SVM fue realizado por Jin et al., 2017, para cuantificar plantas de trigo, a diferencia del modelo anterior, estableció 13 características morfológicas para el entrenamiento del modelo. Hall et al., 2018 de la misma manera desarrollo un algoritmo clasificador utilizando SVM con la finalidad de contabilizar la población de plantas en un cultivo de maíz. Estos dos últimos trabajos desarrollaron la detección del cultivo mediante un procedimiento en el espacio de color, en el caso de Hall et al., 2018 añade la información de imágenes infrarrojas cercanas.

2.3.6 Método por Redes Neuronales Convolucionales

La red neuronal convolucional (CNN) es un algoritmo dentro de los denominados Deep Learning que a su vez este es una rama de estudio de Machine Learning, La CNN es aprendizaje supervisado es decir requiere de la

intervención humana para mostrarle sobre lo que debe aprender, y se utiliza en tareas de clasificación directamente a partir imágenes, videos, texto o sonidos. Una forma simple de explicar sus funcionamientos, es que se basa en varias capas ocultas especializadas y con una jerarquía. Si lo vemos desde el sentido de identificación de cultivos, en la primera capa determinaría algún aspecto morfológico simple de la planta que con lleve en la siguiente capa a determinar un aspecto más complejo, atravesando así las capas necesarias de especialización para llegar a la identificación completa de la planta.

En los dos últimos años se encuentran trabajos realizados en el conteo automático de cultivos con algoritmos inteligentes de redes neuronales, tal como el trabajo que desarrollo Csillik et al., 2018 para contabilizar árboles de cítricos, buscando la mejor arquitectura de CNN simple, entreno la red con tres clases: arboles, suelo desnudo y malezas, realizando 4000 muestras por clase, las muestras consistió en encontrar las dimensiones en pixeles, de la imagen muestra de modo que esta coincidiera con el tamaño de los árboles, uso cuatro bandas espectrales (verde, rojo, infrarrojo cercano y borde rojo) como conjunto datos en el entrenamiento. La primera clasificación obtenida por su método tuvo ciertos errores como la confusión con las malezas y cierta dificultad al distinguir los árboles pequeños de los árboles grandes, para solucionar esto planteo un procesamiento en el que incluye información de Índice de Vegetación de Diferencia Normalizada (NDVI).

Wu et al., 2019 aborda un problema con una complejidad el conteo de plántulas de arroz, debido a la densidad del cultivo y a la semejanza con malezas, para esto los autores propusieron una red combinada por dos CNN, la primera se enfoca en la segmentación de las áreas correspondientes a plántulas de arroz y áreas de plántulas que no son arroz en las imágenes RPAS, consiguiendo una imagen resultante binarizada, la segunda red estimo la distribución de las plántulas de arroz en las imágenes y genero un mapa de densidad.




Figura 5. Esquema del método de dos redes CNN combinadas (Figura tomada de Wu et al., 2019)

El objetivo de Ampatzidis & Partel, 2019 fue detectar árboles de cítricos pero a su vez detectar los huecos en el marco de plantación donde potencialmente podría ir un árbol, para esto desarrolla una CNN utilizando YOLOv3 (You Only Look Once) un sistema de detección de objetos de última generación, utilizando imágenes RGB, RNB (Bandas Rojo, infrarrojo y azul) y NDVI, y encontró que la imagen RNB mostraba mejores resultados en la detección de árboles en comparación al RGB.

2.3.7 Método por Índices de Vegetación

Los índices de vegetación (IV) son unas operaciones algebraicas realizadas con imágenes espectrales, las operaciones pueden incluir dos o más bandas espectrales, y se calculan a partir de los valores de reflectancia a distintas longitudes de onda para extraer información relacionada con la vegetación.

Los trabajos desarrollados por Zhao et al., 2018 y Li et al., 2019, estudian los índices de vegetación con bandas espectrales visibles para el conteo en semillas de colza y cultivo de papas respectivamente, haciéndose presente los siguientes IV.

- Exceso de Verde (ExG)
- Exceso Verde menos el Exceso Rojo (ExG-ExR)
- Índice de Diferencia de Rojo (NGRDI)
- Índice de Hoja Verde (GLI)

En ambos trabajos realizan el método de Otsu como algoritmo de umbralización para segmentar el cultivo del suelo, Zhao et al., 2018 obtuvo mejores resultado al utilizar los VI ExG-ExR y GLI sobre los IV ExG y NGRD, indicando un mejor rendimiento de segmentación. Mientras que en el trabajo desarrollado por Li et al., 2019 donde realiza una comparación entre los resultados obtenidos por el IV ExG-ExR y el ExG pero este último combinado con el método Otsu, en base a parámetros estadísticos determinar al método ExG+ Otsu, como el mejor método de segmentación.

Marques et al., 2019 realizo un estudio completo para encontrar los IV más adecuado para su trabajo de detección de castaños, en la que evalúa 6 IV que utilizan bandas en el espectro visible RGB y 11 IV que combinan las bandas RGB con la infrarroja cercano y borde rojo bandas espectrales que no son visibles para el ojo humano. El criterio de selección fue las IV que mostraron mayor potencial de segmentación de la vegetación. Las IV evaluadas fueron las siguientes:

Índices de vegetación que combinaron bandas espectrales en el rango visible y no visible.

- Índice de vegetación de diferencia normalizada azul (BNDVI)
- Índice de vegetación de diferencia (DVI)
- Índice de vegetación mejorado (EVI)
- Exceso de borde rojo (ExRE)
- Índice de vegetación de diferencia verde (GDVI)
- Índice de vegetación de diferencia normalizada verde (GNDVI)
- Índice de vegetación verde ajustada al suelo (GSAVI)
- Índice modificado de vegetación de suelo ajustado (MSAVI)
- Índice de vegetación de diferencia normalizada (NDVI)
- Índice optimizado de vegetación ajustada al suelo (OSAVI)
- Índice de vegetación ajustado al suelo (SAVI)

Índices de vegetación que solo requirieron bandas RGB

- Exceso de verde (ExG)

- Índice de vegetación verde-azul (GBVI)
- Índice de vegetación verde-roja (GRVI)
- Índice de vegetación rojo verde modificado (MGRVI)
- Índice de vegetación rojo verde azul (RGBVI)
- Índice de vegetación Verde (VARlg)




Figura 6. Resultados de la evaluación de los IV (Figura tomada Marques et al., 2019)

La evaluación concluyo que los IV basado en operaciones con la banda infrarroja cercano presentan un mejor rendimiento general, pero a pesar de esto se encontraron IV basados en RGB que presentaron altos rendimientos los cuales fueron el índice de ExG y el RGBVI. Y por otro lado los más destacados con el uso de las bandas Infrarrojas cercanos y borde rojo fueron: GDVI, GNDVI, GSAVI y sobresaliendo sobre todas las anteriores ExRE.

2.4 RESULTADOS DE PARAMETROS DE EVALUACIÓN

Cuadro 3. Registro de resultados de diferentes trabajos científicos en conteo de cultivos.

ARTÍCULOS	CULTIVO	MÉTODO	RESULTADOS
(Bazi et al., 2014),	Palmeras	Extreme Learning Machine	Precisión= 94.18 % Sensibilidad 88.04%
(Malek et al., 2014)	Palmeras	Extreme Learning Machine	Precisión= 96.96% Sensibilidad= 95.53%
(Kattenborn et al., 2014)	Palmera	Fotogrametría de Nube de Puntos	Precisión= 86.1%
(Torres et al., 2015)	Olivos	OBIA	Precisión= 95%
(Miserque Castillo et al., 2016)	Palmeras	Modelo de Regresión Logística	Precisión 97.53% Puntuación F1 = 87%
(Ribera et al. 2017)	Sorgo	CNN	Error Porcentual Absoluto Medio (MAPE)= 6.7%
(Gnädinger & Schmidhalter, 2017)	Maíz	Espacios de color	Diferencia Porcentual=≤5%
(Jin et al., 2017)	Trigo	SVM	R ² = 87% RMSE= 34.05 plantas/m ²
(Sankaran et al., 2017)	Papa	SUM-NDVI SUM-BINARY	Coefficiente de Pearson r=0.82
(Primicerio et al., 2017)	Viñedo	SVM	Curva característica de operación del receptor-Área bajo la curva = 0.95%
(Y. Chen et al. 2017)	Sorgo	Multiple Instance Learning	Precisión= 66% Sensibilidad= 64%
(R. Chen et al., 2018)	Algodón	Análisis de imágenes	Precisión= 88.6%
(Guo et al., 2018)	Sorgo	SVM	Coefficiente de determinación= 56%
(Jorge Torres-Sánchez et al., 2018)	Olivos	OBIA	Precisión= 97%
(Koc-San et al., 2018)	Cítricos	Transformación Circular de Hough	Precisión= >80%
(Fan et al., 2018)	Tabaco	CNN	Precisión= 91.12% Sensibilidad= 94.14% Exactitud= 92.87%
(Hall et al., 2018)	Maíz	SVM	Precisión= 94%
(Aparna et al., 2018)	Coco	CNN	Precisión= 90%
(Csillik et al., 2018)	Cítricos	CNN	Puntuación F1= 96.24% Precisión= 94.59% Sensibilidad= 97.94%
(Zhao et al., 2018)	Colza	Análisis de Imagen por IV RGB	R ² = 88.6% Error absoluto medio (RMSE)= 5.11%
(Kestur et al., 2018)	Platano, coco, mango	Extreme Learning Machine	Precisión= 95.99% Sensibilidad= 80.17%
(Selim et al., 2019)	Cítricos	OBIA	Precisión= 82.86%
(Wu et al., 2019)	Arroz	CNN	Precisión= 93.35%
(Salamí et al., 2019)	Olivo	Análisis de imágenes	Precisión= 99.39% Sensibilidad= 98.80% Puntuación F1= 99.09%
(Li et al., 2019)	Papa	SVM	Tasa de clasificación correcta= 96.6% R ² = 96% RMSE=3.63%
(Marques et al., 2019)	Castaños	Análisis de Imagen por IV	Precisión= 97%
(Ampatzidis & Partel, 2019)	Cítricos	Inteligencia Artificial	Precisión= 99.9% Sensibilidad= 99.7%
(Jiang, Chen, Li, Wang, & Yang, 2017)	Papayas	scale-space filtering	Precisión= 95.4% Sensibilidad= 97.3% Puntuación F= 96.3 %

2.5 REFERENCIAS

- Ampatzidis, Y., & Partel, V. (2019). UAV-Based High Throughput Phenotyping in Citrus Utilizing Multispectral Imaging and Artificial Intelligence. *Remote Sensing*, 11(4), 410. <https://doi.org/10.3390/rs11040410>
- Aparna, P., Harshita, M. P., Sounder, H., Nandkishore, K., Vinod, P. V., & Hebbar, R. (2018). CNN based technique for automatic tree counting using very high resolution data. *Proceedings - 2018 International Conference on Design Innovations for 3Cs Compute Communicate Control, ICDI3C 2018*, 127–129. <https://doi.org/10.1109/ICDI3C.2018.00036>
- 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(6), 579–592. <https://doi.org/10.1007/s11119-014-9355-8>
- Bazi, Y., Malek, S., Alajlan, N., & Alhichri, H. (2014). An automatic approach for palm tree counting in UAV images. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 537–540. <https://doi.org/10.1109/IGARSS.2014.6946478>
- Bendig, J., Bolten, A., Bennertz, S., Broscheit, J., Eichfuss, S., & Bareth, G. (2014). Estimating biomass of barley using crop surface models (CSMs) derived from UAV-based RGB imaging. *Remote Sensing*, 6(11), 10395–10412. <https://doi.org/10.3390/rs61110395>
- Blanc, N. (2001). CCD versus CMOS-has CCD imaging come to an end. *Photogrammetric Week*, 131–137. Retrieved from <http://www.ifp.uni-stuttgart.de/publications/phowo01/Blanc.pdf%5Cnhttp://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:CCD+versus+CMOS-has+CCD+imaging+come+to+an+end?#0%5Cnhttp://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:CCD+versus+C>
- Chen, R., Chu, T., Landivar, J. A., Yang, C., & Maeda, M. M. (2018). Monitoring cotton (*Gossypium hirsutum* L.) germination using ultrahigh-resolution UAS images. *Precision Agriculture*, 19(1), 1–17. <https://doi.org/10.1007/s11119-017-9508-7>
- Chen, Y., Ribera, J., Boomsma, C., & Delp, E. (2017). Locating Crop Plant Centers from UAV-Based RGB Imagery. *Proceedings - 2017 IEEE International Conference on Computer Vision Workshops, ICCVW 2017, 2018-Janua*, 2030–2037. <https://doi.org/10.1109/ICCVW.2017.238>
- Clevers, J. G. P. W. (1999). The use of imaging spectrometry for agricultural applications. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54(5–6), 299–304. [https://doi.org/10.1016/S0924-2716\(99\)00033-7](https://doi.org/10.1016/S0924-2716(99)00033-7)
- Csillik, O., Cherbini, J., Johnson, R., Lyons, A., & Kelly, M. (2018). Identification of Citrus Trees from Unmanned Aerial Vehicle Imagery Using Convolutional

- Neural Networks. *Drones*, 2(4), 39. <https://doi.org/10.3390/drones2040039>
- D'Oleire-Oltmanns, S., Marzloff, I., Peter, K. D., & Ries, J. B. (2012). Unmanned aerial vehicle (UAV) for monitoring soil erosion in Morocco. *Remote Sensing*, 4(11), 3390–3416. <https://doi.org/10.3390/rs4113390>
- Díaz-Varela, R. A., de la Rosa, R., León, L., & Zarco-Tejada, P. J. (2015). High-resolution airborne UAV imagery to assess olive tree crown parameters using 3D photo reconstruction: Application in breeding trials. *Remote Sensing*, 7(4), 4213–4232. <https://doi.org/10.3390/rs70404213>
- Fan, Z., Lu, J., Gong, M., Xie, H., & Goodman, E. D. (2018). Automatic Tobacco Plant Detection in UAV Images via Deep Neural Networks. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(3), 876–887. <https://doi.org/10.1109/JSTARS.2018.2793849>
- Garcia-Ruiz, F., Sankaran, S., Maja, J. M., Lee, W. S., Rasmussen, J., & Ehsani, R. (2013). Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. *Computers and Electronics in Agriculture*, 91, 106–115. <https://doi.org/10.1016/j.compag.2012.12.002>
- Gnädinger, F., & Schmidhalter, U. (2017). Digital counts of maize plants by Unmanned Aerial Vehicles (UAVs). *Remote Sensing*, 9(6). <https://doi.org/10.3390/rs9060544>
- Guo, W., Zheng, B., Potgieter, A. B., Diot, J., Watanabe, K., Noshita, K., ... Chapman, S. C. (2018). Aerial Imagery Analysis – Quantifying Appearance and Number of Sorghum Heads for Applications in Breeding and Agronomy. *Frontiers in Plant Science*, 9(October), 1–9. <https://doi.org/10.3389/fpls.2018.01544>
- Hall, O., Dahlin, S., Marstorp, H., Archila Bustos, M., Öborn, I., & Jirström, M. (2018). Classification of Maize in Complex Smallholder Farming Systems Using UAV Imagery. *Drones*, 2(3), 22. <https://doi.org/10.3390/drones2030022>
- Hernandez-Lopez, D., Felipe-Garcia, B., Gonzalez-Aguilera, D., & Arias-Perez, B. (2013). An Automatic Approach to UAV Flight Planning and Control for Photogrammetric Applications. *Photogrammetric Engineering & Remote Sensing*, 79(1), 87–98. <https://doi.org/10.14358/PERS.79.1.87>
- Janesick, J., Elliott, T., Andrews, J., & Tower, J. (2015). Fundamental performance differences of CMOS and CCD imagers: part VI. *Target Diagnostics Physics and Engineering for Inertial Confinement Fusion IV*, 9591, 959102. <https://doi.org/10.1117/12.2189941>
- Jiang, H., Chen, S., Li, D., Wang, C., & Yang, J. (2017). Papaya Tree Detection with UAV Images Using a GPU-Accelerated Scale-Space Filtering Method. *Remote Sensing*, 9(7), 721. <https://doi.org/10.3390/rs9070721>
- Jin, X., Liu, S., Baret, F., Hemerlé, M., & Comar, A. (2017). Estimates of plant

- density of wheat crops at emergence from very low altitude UAV imagery. *Remote Sensing of Environment*, 198, 105–114. <https://doi.org/10.1016/j.rse.2017.06.007>
- Kattenborn, T., Sperlich, M., Bataua, K., & Koch, B. (2014). Automatic single palm tree detection in plantations using UAV-based photogrammetric point clouds. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 40(3), 139–144. <https://doi.org/10.5194/isprsarchives-XL-3-139-2014>
- Kestur, R., Angural, A., Bashir, B., Omkar, S. N., Anand, G., & Meenavathi, M. B. (2018). Tree Crown Detection, Delineation and Counting in UAV Remote Sensed Images: A Neural Network Based Spectral–Spatial Method. *Journal of the Indian Society of Remote Sensing*, 46(6), 991–1004. <https://doi.org/10.1007/s12524-018-0756-4>
- Koc-San, D., Selim, S., Aslan, N., & San, B. T. (2018). Automatic citrus tree extraction from UAV images and digital surface models using circular Hough transform. *Computers and Electronics in Agriculture*, 150(May), 289–301. <https://doi.org/10.1016/j.compag.2018.05.001>
- Li, B., Xu, X., Han, J., Zhang, L., Bian, C., Jin, L., & Liu, J. (2019). The estimation of crop emergence in potatoes by UAV RGB imagery. *Plant Methods*, 15(1), 1–13. <https://doi.org/10.1186/s13007-019-0399-7>
- Malek, S., Bazi, Y., Alajlan, N., AlHichri, H., & Melgani, F. (2014). Efficient framework for palm tree detection in UAV images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(12), 4692–4703. <https://doi.org/10.1109/JSTARS.2014.2331425>
- Marques, P., Pádua, L., Adão, T., Hruška, J., Peres, E., Sousa, A., & Sousa, J. J. (2019). UAV-Based Automatic Detection and Monitoring of Chestnut Trees. *Remote Sensing*, 11(7), 855. <https://doi.org/10.3390/rs11070855>
- Miserque Castillo, J. Z., Laverde Diaz, R., & Rueda Guzmán, C. L. (2016). Development of an aerial counting system in oil palm plantations. *IOP Conference Series: Materials Science and Engineering*, 138(1). <https://doi.org/10.1088/1757-899X/138/1/012007>
- Primicerio, J., Caruso, G., Comba, L., Crisci, A., Gay, P., Guidoni, S., ... Vaccari, F. P. (2017). Individual plant definition and missing plant characterization in vineyards from high-resolution UAV imagery. *European Journal of Remote Sensing*, 50(1), 179–186. <https://doi.org/10.1080/22797254.2017.1308234>
- Ribera, J., Chen, Y., Boomsma, C., & Delp, E. J. (2017). Counting plants using deep learning. *2017 IEEE Global Conference on Signal and Information Processing, GlobalSIP 2017 - Proceedings, 2018-Janua*, 1344–1348. <https://doi.org/10.1109/GlobalSIP.2017.8309180>
- Salamí, E., Gallardo, A., Skorobogatov, G., & Barrado, C. (2019). On-the-fly olive tree counting using a UAS and cloud services. *Remote Sensing*, 11(3).

<https://doi.org/10.3390/rs11030316>

- Sankaran, S., Khot, L. R., Espinoza, C. Z., Jarolmasjed, S., Sathuvalli, V. R., Vandemark, G. J., ... Pavek, M. J. (2015). Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review. *European Journal of Agronomy*, 70, 112–123. <https://doi.org/10.1016/j.eja.2015.07.004>
- Sankaran, S., Quirós, J. J., Knowles, N. R., & Knowles, L. O. (2017). High-Resolution Aerial Imaging Based Estimation of Crop Emergence in Potatoes. *American Journal of Potato Research*, 94(6), 658–663. <https://doi.org/10.1007/s12230-017-9604-2>
- Selim, S., Sonmez, N. K., Coslu, M., & Onur, I. (2019). Semi-automatic Tree Detection from Images of Unmanned Aerial Vehicle Using Object-Based Image Analysis Method. *Journal of the Indian Society of Remote Sensing*, 47(2), 193–200. <https://doi.org/10.1007/s12524-018-0900-1>
- Torres-Sánchez, J., Peña, J. M., de Castro, A. I., & López-Granados, F. (2014). Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture*, 103, 104–113. <https://doi.org/10.1016/j.compag.2014.02.009>
- Torres-Sánchez, Jorge, López-Granados, F., Borra-Serrano, I., & Peña, J. M. (2018). Assessing UAV-collected image overlap influence on computation time and digital surface model accuracy in olive orchards. *Precision Agriculture*, 1–19. <https://doi.org/10.1007/s11119-017-9502-0>
- Torres, 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), 1–20. <https://doi.org/10.1371/journal.pone.0130479>
- Wu, J., Yang, G., Yang, X., Xu, B., Han, L., & Zhu, Y. (2019). Automatic Counting of in situ Rice Seedlings from UAV Images Based on a Deep Fully Convolutional Neural Network. *Remote Sensing*, 11(6), 691. <https://doi.org/10.3390/rs11060691>
- Yang, G., Liu, J., Zhao, C., Li, Z., Huang, Y., Yu, H., ... Yang, H. (2017). Unmanned Aerial Vehicle Remote Sensing for Field-Based Crop Phenotyping: Current Status and Perspectives. *Frontiers in Plant Science*, 8(June). <https://doi.org/10.3389/fpls.2017.01111>
- Zarco-Tejada, P. J., González-Dugo, V., & Berni, J. A. J. (2012). Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. *Remote Sensing of Environment*, 117, 322–337. <https://doi.org/10.1016/j.rse.2011.10.007>
- Zhao, B., Zhang, J., Yang, C., Zhou, G., Ding, Y., Shi, Y., ... Liao, Q. (2018). Rapeseed Seedling Stand Counting and Seeding Performance Evaluation at Two Early Growth Stages Based on Unmanned Aerial Vehicle Imagery.

Frontiers in Plant Science, 9(September), 1–17.
<https://doi.org/10.3389/fpls.2018.01362>

CAPITULO 3 ARTÍCULO CIENTÍFICO

DETECCIÓN Y CONTEO AUTOMÁTICO DE OLIVOS A PARTIR DE IMÁGENES AÉREAS MULTIESPECTRALES MEDIANTE ANÁLISIS DE IMÁGENES

AUTOMATED DETECTION AND COUNTING OF OLIVE TREES FROM MULTISPECTRAL AERIAL IMAGERY BY MEANS OF IMAGE ANALYSIS

Ricardo **Sarabia López**¹ y Gilberto de Jesús **López Canteñs**²

RESUMEN

En el contexto de la agricultura inteligente, el conocimiento preciso sobre la población de plantas presentes en el campo, comprende una información útil, tanto para los agricultores como para los técnicos responsables del fenotipado de cultivo. En este sentido, el uso de Sistemas de Aeronaves Pilotadas a Distancia (RPAS) ha proliferado en los últimos años como respuesta a los métodos tradicionales para el conteo de plantas, que generalmente son laboriosos, requieren mucho tiempo y son propensos a errores humanos. Por lo tanto, se propone una metodología para la detección automatizada y conteo de olivos a partir de imágenes multiespectrales de alta resolución, adquiridas por imágenes aéreas. Posterior a la adquisición de imágenes, las capturas se procesaron para obtener una representación gráfica del campo basada en nube de puntos. Con el fin de aprovechar la información de elevación contenida en ella y eventualmente identificar las plantas, esta nube de puntos 3D fue interpolada determinísticamente y convenientemente transformada mediante morfología matemática. En una etapa final, los olivos que aparecen en la imagen se segmentaron del fondo, lo que permitió su detección. Con una población de 3918 olivos en el sitio de estudio, la metodología propuesta logró una precisión del 99,92%, una sensibilidad del 99,67% y un puntaje F del 99,75%, identificando correctamente 3906 plantas. Atendiendo a los resultados obtenidos, se puede concluir la viabilidad de esta metodología como una solución para la automatización del conteo de plantas en huertos de olivos, como una forma de mejorar las capacidades de fenotipado en el campo

Palabras clave: imágenes aéreas, análisis de imagen, imágenes multiespectrales, olivos, fenotipado, población de plantas, RPAS

¹ Autor

² Director de tesis

ABSTRACT

Within the context of smart farming, accurate knowledge about the plant population present on the field comprises a useful information, for both farmers and technicians responsible for the crop phenotyping. In this regard, the use of Remotely Piloted Aircraft Systems (RPAS) has proliferated in recent years as a response to traditional methods for plant counting, which usually are laborious, time-demanding and prone to human error. Hence, it is proposed a methodology for automated detection and counting of olive trees from high resolution multispectral images, acquired by aerial imaging. After image acquisition, captures were processed to yield a point cloud -based representation of the field plot. In order to exploit the elevation information contained in it and eventually identify the plants, this 3D point cloud was deterministically interpolated, and conveniently transformed by means of mathematical morphology. In an ultimate stage, the olive-trees appearing in the image were segmented from the ground, enabling their detection. With a population 3918 olive-trees in the study site, the proposed methodology achieved a precision of 99.92%, a sensibility of 99.67%, and a F-score of 99.75%, correctly identifying 3906 plants. Attending to the results obtained, it can be concluded the viability of this methodology as a solution to the automation of the plant counting in olive orchards, as a way to improve the in-field phenotyping capabilities.

Keywords: aerial imagery; image analysis; multispectral imagery; olive tree; phenotyping; plant population; RPAS

¹ Author

² Advisor

1. Introducción

Actualmente, la demanda mundial de alimentos conlleva uno de los problemas más desafiantes abordados por la sociedad. De hecho, como consecuencia de las expectativas de crecimiento de la población, se estima que la demanda de producción de cultivos aumentará en el orden del 100% en 2050, en comparación con los informes de 2005 [1]. Este escenario obliga a desarrollar sistemas agrícolas y alimentarios, propensos a satisfacer de manera proactiva dicha demanda al mismo tiempo que sean capaces de minimizar el impacto ambiental. En este sentido, el fenotipado de cultivos constituye una herramienta crucial para lograr este equilibrio.

De hecho, el conocimiento profundo sobre los senderos de cultivos observables y la forma en que el genotipo de las plantas se expresa en relación con los factores ambientales comprende una información relevante y valiosa para los agricultores [2]. Dentro de este contexto, el conteo individual de plantas involucra un factor clave, no solo con respecto al fenotipado de los cultivos, sino que también proporciona información valiosa, con la que los agricultores reciben apoyo al planificar estrategias de mejoramiento y otras labores agrícolas. Por lo tanto, la población de plantas determina la densidad del cultivo, como el número de plantas por hectárea cultivada. Esta estadística está estrechamente relacionada con diferentes aspectos, como la eficiencia de los recursos de agua y fertilizantes, o la susceptibilidad a los patógenos [3]. Además, desempeña un papel clave para evaluar las estimaciones de producción en cultivos arbóreos, y ayuda a los agricultores a diseñar esquemas de riego y / o fertilización [4]. La importancia de la población de plantas no se detiene aquí, y es importante cuando se solicitan subsidios públicos [5], se fijan precios en las plantaciones [6] o se evalúan las pérdidas después de cualquier tipo de afectación, como daños por incendios, plagas o desastres naturales. Sin embargo, los métodos de conteo tradicionales generalmente se basan en inspecciones visuales humanas en el campo. Entonces, como sucede con otras actividades de fenotipado [7, 8], implica tareas tediosas, que consumen mucho tiempo y son propensas a errores, principalmente cuando se trata de plantaciones a gran escala [3]. Debido a estas dificultades, existe una necesidad real de desarrollar nuevas técnicas destinadas a llevar a cabo el conteo de plantas de forma precisa, eficiente y no invasiva.

Hoy en día, los sistemas de aeronaves pilotadas a distancia (RPAS) se han popularizado como parte de las tecnologías de detección remota incorporadas en la agricultura de precisión, y se han utilizado notablemente en la investigación de fenotipado de cultivos [9,10]. Esto, principalmente debido a las ventajas que ofrecen sobre los sistemas de imágenes aéreas tradicionales, como una mayor flexibilidad con respecto a la adquisición de datos, menores costos operativos, menores restricciones climáticas, la posibilidad de operar en condiciones nubladas o mayores resoluciones espaciales con distancias de muestreo en tierra más bajas (GSD) [9,11–13]. Además, el crecimiento que el mercado relacionado con RPAS y los equipos de teledetección que están experimentando en este momento hace que esta tecnología sea cada vez más accesible y asequible. Por lo tanto, definitivamente son herramientas prometedoras dentro del alcance de la agricultura inteligente y la agricultura de precisión, con usos potenciales en las tareas de fenotipado de cultivos [9,14].

De hecho, cuando se habla del conteo de plantas, ya se puede encontrar una cantidad considerable de investigación donde la población de cultivos se determina a partir de imágenes basadas en RPAS. Las imágenes adquiridas se procesan, generando ortomosaicos y modelos digitales de superficie (DSM), que posteriormente se analizan para detectar y contar las plantas. Así, palmeras [5,15,16], sorgo [17–19], maíz [20,21], trigo [3], papa [22,23], vid [24], papaya [25], algodón [26], cítricos [27–30], tabaco [31], coco [4,32], colza [33], arroz [34], castaña [35], plátano y mango [32] son solo algunos ejemplos concretos de cultivos en los que esta tecnología se ha aplicado a ese fin.

Con respecto al caso del olivo, se pueden encontrar varios estudios en los que el fenotipo del olivo se aborda mediante el uso de imágenes aéreas basadas en RPAS. Por lo tanto, en [36] se intenta estimar la altura y el diámetro de la copa de los olivos a partir de capturas aéreas, mediante la reconstrucción de imágenes de Estructura-desde-Movimiento (SfM) y el análisis de imágenes geográficas basadas en objetos (GEOBIA). En el mismo sentido, [37] también propone una metodología para la estimación de diferentes características de los olivos. En particular, altura, volumen de la corona y área del dosel. Esto se logró, una vez más, generando un DSM a partir de imágenes aéreas y análisis de imágenes basadas en objetos (OBIA). Este estudio se extiende en [38], donde se prueban diferentes altitudes de vuelo y grados superpuestos para optimizar la generación de DSM, en términos de costo computacional. En [6], el conteo de olivos es el enfoque. En este caso, el RPAS utilizado para la adquisición de imágenes está equipado con una pequeña computadora integrada. Este dispositivo está destinado a procesar capturas a bordo y proporcionar, a través de servicios en la nube, estimaciones de recuento de plantas casi en tiempo real para el usuario final.

En este artículo, se propone una metodología para la detección, geolocalización y conteo de plantas en huertos de olivos, basada en imágenes aéreas y procesamiento y análisis de imágenes. Para ello, se utilizó un RPAS, con una cámara multiespectral montada, para llevar a cabo la adquisición de imágenes. Las imágenes multiespectrales obtenidas se procesaron para obtener un DSM. Esta estructura de datos se transformó posteriormente por medio de la morfología matemática, con el objetivo de segmentar individualmente los olivos que aparecen en las imágenes desde el suelo. Se realizó un análisis eventual de esa segmentación, obteniendo la población de plantas. Según los resultados obtenidos, el algoritmo desarrollado para calcular la detección y el conteo de árboles arrojó una mayor precisión cuando se compara con otros métodos mencionados anteriormente. Al mismo tiempo, al contrario de lo que sucede con otras propuestas, mostró una notable robustez al intentar diferenciar árboles cuyas coronas se tocaban entre sí.

Entonces, el presente manuscrito se estructura de la siguiente manera.

2. Materiales y métodos

2.1 Sitio de estudio

El olivar donde se realizó la adquisición de imágenes aéreas se encuentra en Gibrleón, provincia de Huelva (Andalucía, España). En particular, el área en estudio, centrada en las coordenadas DMS 7 ° 02'48.44 "W y 37 ° 20'39.80" N, corresponde a un huerto con una extensión aproximada de 16 Ha, donde se ha aplicado un sistema de cultivo intensivo, y un patrón de separación de plantas de 5.5x7m. La variedad de aceituna cultivada es Picual. Cabe señalar que este huerto muestra una notable variabilidad en términos de composición del suelo, así como el tamaño de la copa de los árboles. En la Figura 1 se muestra una captura aérea del sitio de estudio.




Fig 1. Captura aérea del sitio de estudio. Tenga en cuenta que el área de interés real, esta resaltada en rojo.

2.2 Aadquisición de imagenes

2.2.1 Equipamiento de imágenes aéreas

Las imágenes aéreas se realizaron utilizando un RPAS DJI Matrice 100 (SZ DJI Technology Co., Ltd., Shenzhen, Guangdong, China). Este avión es propulsado por cuatro rotores (cuadroptero), lo que permite su despegue y aterrizaje vertical. Con una distancia entre ejes diagonal de 650 mm y un peso máximo de despegue de 3.600 g, puede alcanzar una velocidad de 22 m/s y resiste una resistencia al viento de hasta 10 m / s. Se controla en una frecuencia de funcionamiento de 5.725 a 5.825 GHz, con una distancia de transmisión máxima de 5 km.

Las imágenes se tomaron con una cámara multispectral MicaSense RedEdge-M (MicaSense, Inc., Seattle, WA, EE. UU.), Montada en el RPAS. Este sistema de detección puede capturar cinco bandas espectrales diferentes. La Cuadro1 resume las características más relevantes relacionadas con ellas.

Tabla 1. Especificaciones de bandas espectrales capturadas por la cámara multispectral MicaSense RedEdge

Número de banda	Nombre de banda	Centro de longitud de onda (nm)	Ancho de banda (nm)
1	Azul	475	20
2	Verde	560	20
3	Rojo	668	10
4	Infrarrojo cercano	840	40
5	Borde Rojo	717	10

La cámara se montó junto con su propio dispositivo GPS con el fin de georreferenciar cada imagen capturada. También se incluyó un sensor de luz descendente (DSL) en la configuración, para calibrar los datos de acuerdo con las condiciones cambiantes de la luz ambiental. Finalmente, para una calibración precisa de la reflectancia del suelo, se utilizó un panel de referencia de

reflectancia MicaSense (referencia gris), para obtener imágenes tanto al comienzo como al final del vuelo. En la Fig. 2 se muestra el RPAS junto con todo el equipo descrito anteriormente.




Fig 2. Configuración de captación imágenes aéreas

2.2.2 Planificación de vuelo y rendimiento

La planificación de la misión de vuelo se estableció con el software DJI Flight Planner (SZ DJI Technology Co., Ltd., Shenzhen, Guangdong, China). Se planificó de acuerdo con el criterio de minimizar el número de giros que realizará el RPAS, para cubrir toda el área en estudio. Por lo tanto, el vuelo se configuró para realizarse de forma autónoma, a una altura de 70 metros y a una velocidad de 15 km / h. La cámara multispectral se configuró con un período de tiempo entre capturas de 1,5 segundos. Con esta configuración, se pretendía capturar imágenes con superposiciones frontales y laterales del 85% y 65%, respectivamente, y con un GSD deseado de 0,05 m / píxel. El vuelo tuvo lugar el 13 de junio de 2019, aproximadamente entre las 11 a.m. y la 1 p.m. Se utilizó Software Litchi (VC Technology, Ltd., Londres, Reino Unido) para operar y monitorear la misión. Se adquirieron un total de 8865 imágenes por banda espectral.

2.3 Metodología de análisis de imagen para detección de olivos.

Como se indicó anteriormente, el objetivo principal que se persigue en esta investigación es el desarrollo de un procedimiento, capaz de realizar la detección y el conteo de olivos a partir de capturas aéreas mediante análisis de imágenes. Con ese fin, se diseñó una metodología bajo esos principios para, primero, transformar las imágenes adquiridas en un DSM, como una estructura de datos representativa de todo el huerto en estudio; y luego, explotar la información contenida en este DSM para llevar a cabo la detección de árbol eventual. En las siguientes subsecciones, se detalla profundamente las diferentes etapas que comprenden esta metodología.

2.3.1 Preprocesamiento de imágenes

Como primer paso, se procesaron las capturas obtenidas por imágenes aéreas para obtener los ortomosaicos correspondientes a cada una de las bandas espectrales consideradas.

Además, también se generó una nube de puntos 3D, para desarrollar más tarde el DSM representativo de la parcela de tierra sobrevolada. Por lo tanto, se alcanzó una nube de alta densidad, con un número total de 205,998,922 puntos, donde cada uno de ellos se volvió a proyectar en al menos 3 imágenes. Cada punto se caracterizó de acuerdo con un triplete de coordenadas, donde los dos primeros determinan la ubicación relativa del mismo, y el tercero se refiere a la elevación más alta en ese punto.

Cabe señalar que, durante este proceso, y antes de la generación de estos dos tipos de estructura de datos, se realizó una calibración radiométrica de las imágenes. Esto, con la información proporcionada por el sensor DLS de la cámara y el panel de referencia de reflectancia, de las capturas en las que apareció. La tarea de crear tanto el conjunto de ortomosaicos como la nube de puntos 3D se llevó a cabo utilizando el software Pix4D Mapper (Pix4D S.A., Lausana, Suiza)

2.3.2 Modelo Digital de Superficie

El DSM se generó mediante análisis espacial determinista, a partir de la nube de puntos 3D producida anteriormente. En particular, se le aplicó una interpolación de ponderación de distancia inversa (IDW) [39]. De acuerdo con este método, para estimar el valor del atributo (elevación en nuestro caso) de un punto no muestreado, se considera que el grado de correlación del mismo con los puntos conocidos circundantes es mayor cuanto más cerca estén estos últimos. En otras palabras, la influencia de los puntos muestreados conocidos disminuye a medida que aumenta su distancia con respecto al punto objetivo, por lo que su valor se calcula sobre la base de los valores de atributo de las observaciones del punto circundante, pesados de acuerdo a qué tan lejos están. Entonces, siendo s_0 un punto objetivo, su valor de interpolación $\hat{Z}(s_0)$ puede definirse matemáticamente de la siguiente manera:

$$\hat{Z}(s_0) = \sum_{i=1}^N \lambda_i Z(s_i) \quad (1)$$

donde $Z(s_i)$ es el valor observado por i-esimo punto circundante, s_i , y λ_i es el peso asignado a s_i de acuerdo con su distancia a s_0 . Por lo tanto, λ_i puede ser definido de la siguiente manera:

$$\lambda_i = \frac{d_{i0}^{-p}}{\sum_{i=1}^N d_{i0}^{-p}} \quad (2)$$

Con

$$\sum_{i=1}^N \lambda_i = 1 \quad (3)$$

Para calcular el DSM sobre la base de esta interpolación espacial IDW, se utilizó el software ArcGis 10.3 y su extensión de herramientas de análisis geoestadístico (Esri, Inc., Redlands, CA, EE. UU.). El tamaño de la celda se correspondía con el tamaño de la celda de los ortomosaicos calculados anteriormente. En el mismo sentido, el ráster de salida de interpolación también se limitó a las dimensiones de estos ortomosaicos. Además, debe tenerse en cuenta que, durante el análisis, la interpolación se configuró con una vecindad limitada por una búsqueda basada en un radio circular de 10 metros de largo y con un máximo de 4 puntos.

2.3.3 Algoritmo de análisis de imágenes de detección de árbol

El DSM, obtenido después de procesar las capturas aéreas iniciales, se usó como datos iniciales para eventualmente realizar la detención del olivo y posteriormente el conteo de ellos. Esto, explotando la información de altura que proporciona. De hecho, parece asumible tener en cuenta que cualquier ubicación en la que haya un olivo proporcionará un valor de elevación más alto que las observaciones de puntos sin árboles más cercanas. Por lo tanto, parece razonable considerar esta característica para abordar de alguna manera la segmentación de las plantas del suelo. Esto, para permitir eventualmente su identificación individual. Para ese propósito, esta estructura de datos, resultante de la interpolación de la nube de puntos 3D producida en la etapa de preprocesamiento, se consideró como una imagen en escala de grises. Dado que este DSM comprende un modelo en el que cada ubicación discreta conocida proporciona información sobre la altitud del punto más alto, este dato se tomó como el valor de intensidad del píxel correspondiente en esta imagen en escala de grises. La Fig 3 muestra una representación del DSM como una imagen en escala de grises.




Fig 3. Representación del DSM calculado como imagen de intensidad. Observe en el área ampliada, en rojo, las diferencias en términos de nivel de gris entre las regiones de píxeles que aparentemente pertenecen a los olivos y las del suelo circundante.

Cabe señalar que, en aras de facilitar su visualización, el rango de visualización de la imagen se estableció entre el valor mínimo mayor que cero del DMS y el máximo.

En este punto, la metodología fue conducida a la transformación de esta imagen en escala de grises, principalmente en base al análisis morfológico [40]. Esto, con el fin de lograr una imagen de intensidad más adecuada para ser binarizada con el fin de una segmentación precisa de las áreas de píxeles del árbol desde el fondo. Por lo tanto, dado DSM como la matriz 3-dimensional correspondiente al DMS previamente calculado, la matriz de intensidad, GS_{DSM} , que se acerca a este modelo como una imagen en escala de grises, se puede definir de la siguiente manera:

$$GS_{DSM}(x,y) = \begin{cases} DSM(x,y), & \text{si } DSM(x,y) > 0 \\ 0, & \text{en cualquier otro caso} \end{cases} \quad (4)$$

donde $DSM(x,y)$ es el valor de elevación proporcionado por el DSM correspondiente al punto muestreado (x,y) .

Una vez que se obtuvo esta imagen en escala de grises, para homogeneizar los valores del nivel de gris de los cuervos de los árboles, que, en algunos casos, mostraban áreas más oscuras potencialmente relacionadas con huecos en el follaje, se aplicó una operación de relleno completo. Con eso, fue posible aumentar localmente la intensidad de esas áreas de píxeles que, como mínimos regionales no conectados al borde de la imagen, estaban completamente rodeados de regiones más claras. Esta operación se puede definir a partir de una reconstrucción morfológica de la siguiente manera:

$$I_{GS1} = R_{GS_{DSM}}^{\varepsilon}(GS_{DSM}), \quad (5)$$

donde R^{ε} se refiere a una reconstrucción morfológica, basada en la erosión iterativa ε de la imagen GS_{DSM} con respecto a sí misma, por un elemento estructurante unitario, hasta la idempotencia. Matemáticamente:

$$\begin{aligned} R_{GS_{DSM}}^{\varepsilon}(GS_{DSM}) &= \varepsilon_{GS_{DSM}}^i(GS_{DSM}), \\ \varepsilon_{GS_{DSM}}^i(GS_{DSM}) &= \varepsilon_{GS_{DSM}}^{i+1}(GS_{DSM}), \varepsilon_{GS_{DSM}}^i(GS_{DSM}) = \varepsilon_{\beta=1}(GS_{DSM}) \vee GS_{DSM} \end{aligned} \quad (6)$$

Posteriormente, para facilitar la posterior binarización, fue necesario normalizar de alguna manera la distribución de valores grises de la imagen. Dado que los datos de elevación iniciales se obtuvieron con respecto al nivel del mar, la variabilidad de la altitud del suelo observada en toda la parcela terrestre de estudio se transfirió al DSM y, posteriormente, a la imagen en escala de grises correspondiente. Como consecuencia, y hablando en términos de valor gris, las áreas de píxeles de los árboles eran, por regla general, fácilmente distinguibles del fondo en comparación con sus alrededores más cercanos, pero esta diferencia no era necesariamente significativa cuando se comparaban con las áreas de píxeles de tierra. ubicado en puntos adicionales y superiores dentro del sitio de estudio. Esta falta de homogeneidad de intensidad de píxeles entre el fondo y el primer plano puede conllevar algunas dificultades al binarizar la imagen; al menos cuando se aborda por medio de técnicas globales de umbral estadístico. Por lo tanto, para evitar este problema potencial, se realizó una estimación de fondo, para ser extraída posteriormente. Aquí, el objetivo primordial era la homogeneización de los píxeles de fondo con respecto a sus valores de gris, acercándolos lo más posible a 0. Para hacerlo, la imagen resultante del paso anterior, I_{GS1} , se sometió iterativamente a transformaciones de apertura de imagen. Dado que no se puede esperar homogeneidad en términos del tamaño de la copa del árbol, no es posible configurar un elemento estructurante único para filtrar correctamente todas las regiones de píxeles del árbol, por lo que era obligatorio abordar esta operación eliminando parcialmente esas regiones según su tamaño, aumentando el radio del elemento estructurante paso a paso. Por lo tanto, la imagen de intensidad de estimación de fondo, $I_{BE_{DEF}}$, se calculó de acuerdo con lo que se propone a continuación:

$$I_{BE_i} = \begin{cases} I_{GS1}, & \text{si } i = 0 \\ \text{MIN} \left(I_{BE_{i-1}}, \gamma_{\beta_i}(I_{BE_{i-1}}) \right) = \text{Min} \left(I_{BE_{i-1}}, \delta_{\beta_i} \left(\varepsilon_{\beta_i}(I_{BE_{i-1}}) \right) \right), & \text{en cualquier otro caso} \end{cases} \quad (7)$$

$$I_{BE_{DEF}} = I_{BE_{14}} \quad (8)$$

Donde δ_{β_i} y ε_{β_i} se refiere respectivamente a las operaciones morfológicas básicas de dilatación y erosión, que a su vez definen la apertura morfológica, γ_{β_i} . Ambos, realizados sobre la base de un elemento estructurante en forma de disco con un radio de $i \times 5$ píxeles. De hecho, de acuerdo con la variabilidad mostrada por los árboles con respecto a las dimensiones de sus coronas, se utilizó un elemento estructurante inicial con un radio de 5 píxeles, que se incrementó iterativamente en 5 unidades en cada paso. El límite superior fue impuesto por el árbol más grande de la imagen. Se comprobó que un radio de aproximadamente 70 píxeles para el elemento estructurante era suficiente para filtrar correctamente los olivos más grandes, definiendo así la última iteración de este procedimiento.

Una vez que se calculo I_{BEDEF} , se extrajo convenientemente de I_{GS1} :

$$I_{GS2} = I_{GS1} - I_{BEDEF} \quad (9)$$




Fig 4. (a) Estimación de fondo, I_{BEDEF} ; (b) imagen resultante I_{GS2} , después de extraer (a) de la imagen en escala de grises, I_{GS1} representativa del DSM.

Luego, se realizó la reconstrucción por dilatación de I_{GS2} de I_{GS2-1} . Esta transformación de H-extrema permitió eliminar todos los máximos inferiores a 1. En este punto, se debe recordar que la imagen en escala de grises se ha generado al acercarse a la intensidad gris valores con información de elevación proporcionada por el DSM en cada ubicación. En este sentido, el nivel de gris de un píxel dado puede verse como el punto de elevación más alto detectado para la ubicación correspondiente expresada en metros. Por lo tanto, filtrar la imagen I_{GS2} por una transformación H-extrema, con un valor umbral de 1, permitirá suprimir todos esos máximos con una altura inferior a 1 m.

$$I_{GS3} = HMAX_h(I_{GS2}) = R_{GS2}^\delta(I_{GS2} - h) \quad (10)$$

Donde $h=1$, y R^δ se refiere a la operación de reconstrucción morfológica, basado, en este caso en la dilatación iterativa (δ) de I_{GS2} con respecto $I_{GS2} - h$ hasta alcanzar la estabilidad.

En este punto, la imagen inicial en escala de grises, después de transformada de acuerdo con lo que se propone anteriormente, fue binarizada. Esto, por umbral global; específicamente, por la aplicación del método de Otsu [41]. Este método supone que la población de valores de nivel de gris de la imagen está compuesta por dos grupos o clases dominantes, que corresponden respectivamente a los píxeles de primer plano y de fondo. Por lo tanto, determina el valor de gris que maximiza la separabilidad de ambas clases, proporcionando la mayor distancia media entre ellos, o análogamente, la mínima varianza dentro de la clase. Este umbral óptimo se puede utilizar posteriormente para binarizar la imagen, segmentando los objetos de interés del fondo. Por lo tanto, dado el umbral, como resultado de aplicar el método de Otsu en I_{GS3} , la binarización de este último se puede definir de la siguiente manera:

$$I_{BIN1}(x, y) = \begin{cases} 255, & \text{si } I_{GS3}(x, y) > thresh \\ 0 & \text{en cualquier otro caso} \end{cases} \quad (11)$$

En la fig 5 es mostrado el resultado de la binarización, I_{BIN1} .




Fig 5. Resultado de la imagen binarizada, Observe en el área ampliada, en rojo, cómo las plantas potenciales se han segmentado con precisión del fondo.

Como resultado de esta binarización, los píxeles de la imagen se segmentaron en dos grupos, fondo y primer plano. Este último, prácticamente formado por esos píxeles pertenecientes a olivos. Por lo tanto, cualquier agrupación de píxeles blancos con una relación de vecindad, en lo sucesivo componente conectado, se consideraba potencialmente un árbol. Por lo tanto, para filtrar aquellos componentes con un tamaño anormal, demasiado pequeño para ser considerado como un árbol, se aplicó una apertura morfológica en la imagen binaria I_{BIN1} :

$$I_{BIN2} = \gamma_{\beta}(I_{BIN1}) \quad (13)$$


donde γ_{β} corresponde a la apertura morfológica realizada mediante el uso de un elemento estructurante en forma de disco con un radio de 5 píxeles, y que se ha aproximado mediante una secuencia de 8 elementos estructurantes de línea periódica. Finalmente, la imagen resultante, I_{BIN2} , se reconstruyó bajo la imagen binaria inicial I_{BIN1} :

$$I_{BIN3} = R_{I_{BIN1}}^{\delta}(I_{BIN2}), \quad (13)$$


donde R^δ se refiere a la reconstrucción por dilatación de la imagen del enmascarador I_{BIN2} bajo I_{BIN1} .

Después de eliminar el ruido, la imagen resultante, I_{BIN3} , se transformó sobre la base de una imagen de máscara hecha a mano, con el propósito de restringir el resto del análisis al sitio de estudio real y, por lo tanto, suprimir cualquier interferencia circundante. Esta máscara, que limita la región de interés (ROI) a analizar, se muestra en la Fig. 6, junto con el resultado de recortar I_{BIN3} con ella. Este resultado se obtuvo matemáticamente de la siguiente manera:

$$I_{BIN3}(x, y) \begin{cases} I_{BIN2}(x, y) & \text{si } I_{ROI}(x, y) > 0 \\ 0 & \text{en cualquier otro caso} \end{cases} \quad (13)$$



(a)



(b)

Fig 6. (a) imagen mascara del ROI; (b) imagen resultante del corte I_{BIN2} con (a).

2.3.4 Algoritmo de análisis de imágenes de detección de árbol

Como se puede ver en la Figura 6, I_{BIN3} proporciona una segmentación aparentemente precisa de los olivos del fondo. Un primer enfoque podría considerar la cantidad de componentes conectados en esa imagen binaria como la correspondiente a la cantidad de plantas. De hecho, esta es la idea en torno a la cual se ha desarrollado la metodología propuesta, para determinar la población de árboles. Sin embargo, debe considerarse la posibilidad de tener componentes conectados que no corresponden exactamente a un olivo único. Debido a la variabilidad en términos del tamaño de la copa que muestran los árboles de la parcela en estudio, cabe esperar la aparición de árboles que se superponen a su follaje. En esos casos, las coronas correspondientes podrían verse a partir de imágenes aéreas que se tocan entre sí y, como resultado, los componentes

conectados relacionados en la imagen binaria pueden aparecer fusionados incorrectamente. En la Figura 7 se ilustra este fenómeno.




Fig 7.(a) Subimagen de una representación RGB de los ortomosaicos previamente calculados, donde se puede observar un par de árboles con follaje superpuesto; (b) subimagen de la imagen binaria resultante de la segmentación realizada, correspondiente al área representada en (a). Observe cómo los dos olivos comparten el mismo componente conectado en la imagen binaria

Por lo tanto, se desarrolló un procedimiento de análisis de imagen destinado a proporcionar con precisión la población de plantas, basado en el conteo de los componentes conectados en la imagen binaria, pero teniendo en cuenta el problema que se acaba de exponer. Por lo tanto, el procedimiento se abordó analizando las dimensiones de cada componente conectado, para determinar de alguna manera el número más probable de árboles contenidos en cada uno de ellos. Con ese fin, los componentes de la imagen binaria se abordaron como elipses. Específicamente, para cada uno de ellos, se calculó la elipse correspondiente que comparte el mismo segundo momento central normalizado [42]. La determinación del número de plantas contenidas en cada componente conectado se realizó analizando la longitud de los ejes de la elipse correspondiente. En la Fig. 8 se representan gráficamente las elipses calculadas para el conjunto de componentes conectados contenidos en la subimagen propuesta.




Fig 8. (a) Subimagen de una representación RGB de los ortomosaicos previamente calculados; (b) subimagen de la imagen binaria resultante de la segmentación realizada, correspondiente al área

representada en (a); (c) representación en (b) de las elipses (en rojo) calculadas para cada componente conectado en la imagen, con sus correspondientes ejes mayor (en azul) y menor (en verde).

Como se puede apreciar en la Fig. 8, mientras que los ejes menores mantienen valores similares en toda la población de elipses, independientemente del número de plantas contenidas en los componentes correspondientes, las longitudes de los ejes principales muestran una fuerte dependencia con él. De hecho, los componentes superpuestos solo ocurren con árboles en las mismas filas, lo que refuerza la suposición de no esperar una gran variabilidad entre la población de longitudes de ejes menores, mientras que los ejes principales de las elipses crecen a medida que aumenta el número de árboles contenidos. Por lo tanto, para explotar esta característica con el fin de determinar el número real de plantas, dado el conjunto $CC_{I_{BIN3}}$ de componentes conectados de la imagen binaria I_{BIN3} para cada elemento de la misma, cc_i , se definieron sus ejes principales y menores correspondientes de la siguiente manera:

$$MajAx(cc_i) = MAX\{L_{D_1}(cc_i), L_{D_2}(cc_i)\}, \quad (15)$$

$$MinAx(cc_i) = MIN\{L_{D_1}(cc_i), L_{D_2}(cc_i)\}, \quad (16)$$

Donde $cc_i \in CC_{I_{BIN3}}$, y L_{D_1} y L_{D_2} respectivamente, se refieren a las longitudes de los ejes D_1 y D_2 de la elipse E_i , calculados para cc_i de acuerdo con lo que se definió anteriormente.

Luego, se calculó el elemento máximo dentro de la población total de ejes menores, como referencia para ser utilizado posteriormente en el resto del análisis. Así:

$$MAX_{MinAX} = MAX\{MinAx(cc_i) | cc_i \in CC_{I_{BIN3}}\}, \quad (17)$$

Se realizó un eventual conteo de árboles comparando MAX_{MinAX} con el eje principal de cada componente conectado. Por lo tanto, este máximo, aumentado en un 20%, se consideró como la medida básica para determinar el número potencial de árboles dentro de un componente conectado dado cc_i , calculado matemáticamente de la siguiente manera:

$$TreeNumber(cc_i) = \begin{cases} 1, & \text{Si } MajAx(cc_i) \leq MAX_{MinAX} \times 1.20 \\ \lceil MajAx(cc_i) / MAX_{MinAX} \rceil, & \text{en cualquier otro caso} \end{cases} \quad (18)$$

Por lo tanto, el número total de árboles, potencialmente contenidos por los componentes conectados en I_{BIN3} , se calculó sumando los resultados parciales proporcionados por la función *TreeNumber* para cada elemento en $CC_{I_{BIN3}}$

$$TotalTreePopulation = \sum_{cc_i \in CC_{I_{BIN3}}} TreeNumber(cc_i), \quad (19)$$

Obtenido el conteo eventual de árboles, como último paso, se intentó estimar el centro de masa de cada región de píxeles correspondiente a un olivo individual, para ubicar cada planta en la representación del sitio de estudio. Por lo tanto, se estableció la siguiente definición:

$$TreeCentroids(cc_i) = \{cT_{ij}\} = \{(x_{cT_{ij}}, y_{cT_{ij}})\}, \quad (20)$$

$$j = 1, \dots, TreeNumber(cc_i),$$

Que se refiere al conjunto de centroides de las regiones individuales de árbol-píxel contenidas en el componente conectado $cc_i \in CC_{I_{BIN3}}$. Cada uno de esos centroides está dado por sus coordenadas en el espacio de representación definido por la imagen I_{BIN3} . Para determinar con precisión esas coordenadas, debe considerarse diferentes factores, como la longitud del eje mayor

correspondiente y su orientación, el número de árboles que componen el componente conectado y si este número es par o impar. Incluso es necesario tener en cuenta si el árbol, correspondiente al centroide a calcular, está a la izquierda o a la derecha del centro de masa de la elipse correspondiente.

Según el análisis realizado anteriormente, el escenario de caso básico está representado por aquellos componentes conectados que contienen un olivo único. En esos casos, se supone que el centroide de la región de píxeles del árbol coincide con el de la elipse del componente conectado correspondiente:

$$\begin{aligned} TreeCentroids(cc_i) &= \{cE_i\} = \{(x_{E_i}, y_{E_i})\}, \\ Si\ TreeNumber(cc_i) &= 1, \end{aligned} \quad (21)$$

Donde cE_i corresponde al par de coordenadas en el que se ubica el centroide de la elipse del componente cc_i, E_i .

Por otro lado, con un componente conectado que comprende más de un árbol, se consideraron dos situaciones diferentes, dependiendo de si el número de plantas es par o impar. Centrándose en el primer caso, el punto de ubicación de la j -ésima región de píxel de árbol individual de un componente dado cc_i, cT_{ij} , definido por las coordenadas $x_{cT_{ij}}$ y $y_{cT_{ij}}$ se calculó de la siguiente manera:

$$\begin{aligned} cT_{ij} &= (x_{cT_{ij}}, y_{cT_{ij}}), \\ x_{cT_{ij}} &= \begin{cases} x_{E_i} + (j - 0.5) \times jump_i \times \cos(oE_i \times \pi/180 + \pi), & Si\ j \leq \lfloor TreeNumber(cc_i)/2 \rfloor \\ x_{E_i} + (j - 0.5) \times jump_i \times \cos(oE_i \times \pi/180), & en\ cualquier\ otro\ caso \end{cases}, \\ y_{cT_{ij}} &= \begin{cases} y_{E_i} + (j - 0.5) \times jump_i \times \sin(oE_i \times \pi/180 + \pi), & Si\ j \leq \lfloor TreeNumber(cc_i)/2 \rfloor\ and\ oE_i > 0 \\ y_{E_i} - (j - 0.5) \times jump_i \times \sin(oE_i \times \pi/180 + \pi), & Si\ j \leq \lfloor TreeNumber(cc_i)/2 \rfloor\ and\ oE_i \leq 0 \\ y_{E_i} + (j - 0.5) \times jump_i \times \sin(oE_i \times \pi/180), & Si\ j > \lfloor TreeNumber(cc_i)/2 \rfloor\ and\ oE_i > 0 \\ y_{E_i} - (j - 0.5) \times jump_i \times \sin(oE_i \times \pi/180), & Si\ j > \lfloor TreeNumber(cc_i)/2 \rfloor\ and\ oE_i \leq 0 \end{cases}, \\ jump_i &= MajAx(cc_i) / (TreeNumber(cc_i) + 1), \\ j &= 1, \dots, TreeNumber(cc_i), \end{aligned} \quad (22)$$

Donde x_{E_i} y y_{E_i} son las coordenadas del centroide de la elipse E_i calculada para cc_i , y es el ángulo (en grados) entre el eje x y el eje mayor de esta elipse.

$$x_{cT_{ij}} = \pi r^2, \quad (23)$$

Finalmente, en el caso de componentes conectados con un número impar de árboles, las coordenadas del centro de masas correspondiente se calcularon de acuerdo con lo que se propone a continuación:

$$\begin{aligned} cT_{ij} &= (x_{cT_{ij}}, y_{cT_{ij}}) \\ x_{cT_{ij}} &= \begin{cases} x_{E_i} + j \times jump_i \times \cos(oE_i \times \pi/180 + \pi), & Si\ j < \lfloor TreeNumber(cc_i)/2 \rfloor \\ x_{E_i}, & Si\ j = \lfloor TreeNumber(cc_i)/2 \rfloor \\ x_{E_i} + j \times jump_i \times \cos(oE_i \times \pi/180), & Si\ j < \lfloor TreeNumber(cc_i)/2 \rfloor \end{cases}, \end{aligned} \quad (24)$$

$$y_{cT_{ij}} = \begin{cases} y_{E_i} + j \times jump_i \times \sin(oE_i \times \pi / 180 + \pi), & \text{Si } j < \lfloor TreeNumber(cc_i) / 2 \rfloor \text{ and } oE_i > 0 \\ y_{E_i} - j \times jump_i \times \sin(oE_i \times \pi / 180 + \pi), & \text{Si } j \leq \lfloor TreeNumber(cc_i) / 2 \rfloor \text{ and } oE_i \leq 0 \\ y_{E_i}, & \text{Si } j = \lfloor TreeNumber(cc_i) / 2 \rfloor \\ y_{E_i} + j \times jump_i \times \sin(oE_i \times \pi / 180), & \text{Si } j < \lfloor TreeNumber(cc_i) / 2 \rfloor \text{ and } oE_i > 0 \\ y_{E_i} - j \times jump_i \times \sin(oE_i \times \pi / 180), & \text{Si } j < \lfloor TreeNumber(cc_i) / 2 \rfloor \text{ and } oE_i \leq 0 \end{cases},$$

$$jump_i = MajAx(cc_i) / (TreeNumber(cc_i) + 1),$$

$$j = 1, \dots, TreeNumber(cc_i),$$

En la Fig.9 se ilustra el resultado de calcular estos puntos potenciales de ubicación del árbol. Para ello, se han marcado en rojo en la subimagen binaria ya propuesta en la figura 9.




Fig 9. Resultado del cálculo de los puntos de ubicación de los árboles individuales.

2.4 Evaluación del rendimiento de la metodología de análisis de imagen

Con el fin de evaluar el rendimiento de la metodología propuesta, en primer lugar, fue necesario determinar el número exacto de olivos en la parcela de tierra en estudio. Esto se realizó manualmente mediante el análisis visual de una imagen ad-hoc del sitio de estudio, resultado de la combinación de algunos de los ortomosaicos producidos anteriormente, correspondientes a las diferentes bandas espectrales capturadas. Específicamente, las bandas, azul, infrarrojo cercano y borde rojo fueron seleccionadas. Se utilizaron respectivamente como canales R (rojo), G (verde) y B (azul) de una imagen RGB. Esta imagen, convenientemente escalada, es la que se propone aquí a continuación en la Fig 10.




Fig 10. Imagen RGB, donde sus canales, rojo, verde y azul se han alimentado con la información proporcionada, respectivamente, correspondientes a los ortomosaicos azul, borde rojo y NIR.

Este complejo ortomosaico se generó con el propósito de facilitar esta tarea en términos de visualización. Entonces, la evaluación de la metodología se realizó comparando el número de árboles detectados para el algoritmo de análisis de imágenes diseñado con el número real de plantas. Para evaluar cuantitativamente esta comparación, se propuso el conjunto de métricas definidas a continuación:

- *Precisión*: establece la relación entre el número de árboles correctamente detectados por el algoritmo y el total de componentes obtenidos, que potencialmente pertenecen a una planta. Matemáticamente:

$$\text{Precisión} = \frac{TP}{TP+FP}, \quad (14)$$

donde TP (Positivos verdaderos) es el número de componentes conectados cuyos píxeles corresponden realmente a un árbol, y de manera análoga, FP (Positivos falsos) se refiere a aquellos componentes propuestos erróneamente por el algoritmo como posibles olivos.

- *Sensibilidad*: se refiere a la relación entre el número de árboles correctamente detectados por el algoritmo y el total real de la imagen procesada. Entonces:

$$\text{Sensibilidad} = \frac{TP}{TP+FN}, \quad (15)$$

donde FN (falsos negativos) se define como el número de olivos no detectados por el algoritmo.

- *F-score*: como la media armónica de las dos métricas recién descritas, matemáticamente definida de la siguiente manera

$$\text{Puntuación F1} = 2 * \frac{(\text{Precisión} * \text{Sensibilidad})}{(\text{Precisión} + \text{sensibilidad})} \quad (16)$$

3. Resultados y Discusión

3.1 Modelo Digital de Superficie

La metodología adquisición de datos favoreció significativamente a la reconstrucción de las copas de los árboles, sin embargo se nota un único árbol, observado en la Fig 11a no se encuentra presente en el DSM (Fig 11c), y esto se debe a que no se obtiene una superposición adecuada en ese punto específico en el momento de la adquisición de imágenes, y como consecuencia el

número de puntos coincidentes entre imágenes no fueron suficientes para crear la nube de puntos del árbol ausente mostrado en la Figura 11b. Del total de los árboles situados dentro del área de estudio se consigue reconstruir un 99.97 por ciento en la nube de puntos, por consiguiente, en el DSM se representa la misma cantidad de árboles. Torres-Sánchez et al. 2018 investiga la importancia de la influencia de las superposiciones, al momento de planificar la adquisición de imágenes con RPAS en el cultivo de olivo, en su trabajo asevera que mientras mayor sea el porcentaje en la superposición hacia adelante mejor es la calidad de la nube de puntos y por ende esto aumenta la información para la generación del DSM mientras que la superposición lateral desde el 65% ofrece buenos resultados. Por lo tanto, una densidad de puntos de baja calidad conduce a una reconstrucción más pobre de la copa de los árboles. De acuerdo con Torres-Sánchez et al. 2018 el incrementar las superposición de avance en la adquisición de imágenes, se obtendrán mejores resultados en el DSM.




Fig 11. Imágenes para el análisis del DSM, la imagen (a) es el árbol no generado en la imagen (c), esto derivado por la ausencia de información en la nube de puntos observado en la imagen (b).

3.2 Detección de coronas de olivo

La detección de las coronas de los árboles se consigue con éxito con el método de morfología matemática en el sitio de estudio El dirigir el método en análisis de datos DSM y la aplicación de morfología matemática, nos permite discriminar el fondo (suelo, sombra, malezas), llegando así a la binarización.

Mediante el análisis visual, se observa la detección de los árboles, para hay varios casos, donde dos o más coronas de árboles se unen debido a la frondosidad de estos. La distribución en la que se encuentra la plantación influye en el hecho que solo las copas de los árboles solo se unan entre arboles donde la separación es menor lo descrito anteriormente se observa en la Fig 12. En Salami et al. 2019 trabajaron en el conteo de olivos donde el inconveniente que tiene su método es el no poder detectar un árbol cuando está muy cercano a otros, debido a que el ajuste de su modelo es mediante una plantilla circular con determinado diámetro, el cual si es demasiado grande tenía el inconveniente de no detectar los árboles pequeños y de tener dos árboles cercanos detectarlos como uno solo. El mismo inconveniente tuvo Torres-Sánchez et al. 2018 en uno de sus campos de estudio al intentar detectar automáticamente la cantidad de árboles con el procedimiento OBIA, debido a que los árboles presentaban copas grandes y se conectaban entres si, lo que le hizo imposible poder detectarlos de forma individual.

Para el algoritmo desarrollado en este trabajo lo anterior no genera conflicto, ya que permite contar las coronas a pesar que en la imagen binarizada no todas las componentes conexas se representan de forma individualizada las coronas.




Fig 12. (a) Imagen de copas de árboles con separación entre ellos en (a) se muestran en la imagen binarizada. En la imagen (d) se muestran componentes conexas que contienen dos árboles debido a la frondosidad de los árboles que se muestran en (c).

3.3 Conteo de coronas de olivo

Se obtiene del resultado de conteo por el algoritmo un total de 3909 observaciones, de las cuales conto erróneamente 3 (FP). Los FP sucede en situaciones diferentes:

1. Uno de los errores se debe que el automóvil (Fig 13a) tiene un área y altura tal que no pudo ser discriminando por el proceso morfológico, dejando una pequeña identidad observable en la figura 5b.

2. Otro error es causado por el estado de la copa del árbol la cual se encuentra inusualmente dañada, seccionándose en dos partes (Fig 13d), provocando así el conteo de dos coronas para un solo árbol (Figure 13c).

3. El tercer error sucede por la cantidad de coronas de árboles pegados lateralmente (Figure 13f) genera un conflicto en el algoritmo considerando la existencia en esa área de 8 árboles (Figure 13e), cuando en realidad son 7.

Los diferentes FP no mostraron recurrencia, sin embargo, queda la evidencia bajo que situaciones es posible que sucedan.




Fig 13. En la imagen se observa los tres casos donde ocurrieron los FP.

No se consiguen contar 13 árboles (FN), de los cuales 1 se debe a que no es reconstruido en la nube de puntos. El resto son arboles con poco crecimiento, por lo que, al realizar la detección de las coronas mediante sus valores de altura, estos no alcanzaron la altura mínima establecida para la correcta separación entre las coronas y el fondo.

3.4 *Parametros estadísticos de evaluación*

Los resultados de la evaluación del rendimiento de nuestro método se presentan en la Tabla 2 se logró una precisión y sensibilidad altas. El buen porcentaje en la media armónica (puntuación F1) significa la baja tasa de observaciones de FP y FN, de modo que es contado automáticamente la gran mayoría de árboles existentes en el sitio de estudio (Datos-Verdad).

Tabla 2. Número de observaciones en la clasificación False Positive (FP), False Negative (FN) y True Positive (TP). Resultados porcentuales de los tres parámetros de medida para la evaluación.

Área de estudio	Datos verdad	FP	FN	TP	Conteo Automático	Precisión	Sensibilidad	Puntuación F1
19 ha	3919	3	13	3906	3909	99.92%	99.67%	99.75%

Trabajos anteriores consiguen los siguientes resultados: Salamí et al. 2019 logra una precisión promedio del 99.84%. Mientras que Torres-Sánchez et al. 2018, alcanzando un 97% de precisión.

Los resultados que se obtienen y el registro de resultados de trabajos anteriores en olivos, distinguen la viabilidad de la metodología aquí propuesta para el conteo de población de plantas en huertos de olivo. La metodología tiene la posibilidad de replicabilidad para distintas alturas de vuelo del RPAS y sobre distintos cultivos arbóreos, mediante la adaptabilidad del elemento estructurante al tamaño máximo de la corona en el DSM en relación con la altura de vuelo, y estimando el valor adecuado de altura capaz de segmentar los árboles del fondo.

4. Conclusiones

Se desarrolló un método para el conteo automático en una plantación de olivo que presenta: diferentes tamaños de olivo, copas de árboles entrelazadas entre sí, ausencia de árboles en el marco de plantación, un fondo con diversas características de suelo y maleza, y donde el relieve del terreno no es plano, teniendo así un escenario complejo de abordar. El método consistió en hacer uso de DSM generado a partir de imágenes multiespectrales de alta resolución con RPAS, para desarrollar una aplicación de morfología matemática que separo exitosamente el fondo de 3918 árboles, de esta manera se obtiene una imagen binarizada de la detección de coronas. El método es capaz de contabilizar árboles que entrelacen sus copas entre sí.

Los resultados obtenidos de la evaluación de rendimiento (precisión de 99.92%, sensibilidad del 99.62% y puntuación F1 del 99.75%) sostienen la viabilidad del enfoque desarrollado, además demostrando su funcionalidad sobre una plantación de 19 ha con distintas características, no obstante, los parámetros pueden mejorar, solucionando la detección de árboles pequeños.

Financiación: Esta investigación y APC fueron financiados por el Programa de Cooperación INTERREG V-A ESPAÑA-PORTUGAL (POCTEP) 2014-2020, y cofinanciado con fondos del FEDER, número de subvención 0155_TECNOLIVO_6_E, dentro del alcance del Proyecto TecnOlive.

Agradecimientos: El diseño experimental en la Universidad de Huelva. Se agradece especialmente al grupo TecnOlive, perteneciente al grupo de investigación TEP 192, por proporcionar los conocimientos y herramientas tecnológicas para el desarrollo de la investigación.

Los autores desean agradecer a la cooperativa de aceite de oliva "Virgen de la Oliva" por ofrecer generosamente sus huertos para llevar a cabo este trabajo.

Se da agradecimiento al Consejo Nacional de Ciencia y Tecnología (CONACYT) por apoyar el desarrollo de la investigación.

Conflictos de interés: Los autores declaran no tener conflicto de intereses.

Referencias

1. Tilman, D.; Balzer, C.; Hill, J.; Befort, B. L. Global food demand and the sustainable intensification of agriculture. *Proc. Natl. Acad. Sci. U. S. A.* 2011, 108, 20260–4, doi:10.1073/pnas.1116437108. 331
2. Araus, J. L.; Cairns, J. E. Field high-throughput phenotyping: the new crop breeding frontier. *Trends Plant Sci.* 2014, 19, 52–61, doi:10.1016/J.TPLANTS.2013.09.008. 333
3. Jin, X.; Liu, S.; Baret, F.; Hemerlé, M.; Comar, A. Estimates of plant density of wheat crops at emergence from very low altitude UAV imagery. *Remote Sens. Environ.* 2017, 198, 105–114, 335 doi:10.1016/J.RSE.2017.06.007. 336
4. P, A.; MP, H.; Sounder, H.; K, N.; P V, V.; Hebbar, R. CNN Based Technique for Automatic Tree Counting Using Very High-Resolution Data. In 2018 International Conference on Design Innovations for 3Cs Compute Communicate Control (ICDI3C); IEEE, 2018; pp. 127–129. 339
5. Malek, S.; Bazi, Y.; Alajlan, N.; AlHichri, H.; Melgani, F. Efficient Framework for Palm Tree Detection in UAV Images. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 2014, 7, 4692–4703, doi:10.1109/JSTARS.2014.2331425. 342
6. Salami, E.; Gallardo, A.; Skorobogatov, G.; Barrado, C. On-the-Fly Olive Trees Counting Using a UAS and Cloud Services. *Remote Sens.* 2019, 11, 316, doi:10.3390/rs11030316.
7. Shakoor, N.; Lee, S.; Mockler, T. C. High throughput phenotyping to accelerate crop breeding an monitoring of diseases in the field. *Curr. Opin. Plant Biol.* 2017, 38, 184–192, doi:10.1016/J.PBI.2017.05.006.
8. Furbank, R. T.; Tester, M. Phenomics – technologies to relieve the phenotyping bottleneck. *Trends Plant Sci.* 2011, 16, 635–644, doi: 10.1016/J.TPLANTS.2011.09.005.
9. Sankaran, S.; Khot, L. R.; Espinoza, C. Z.; Jarolmasjed, S.; Sathuvalli, V. R.; Vandemark, G. J.; Miklas, P. N.; Carter, A. H.; Pumphrey, M. O.; Knowles, N. R.; Pavak, M. J. Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review. *Eur. J. Agron.* 2015, 70, 112–123, 351 doi:10.1016/J.EJA.2015.07.004.
10. Yang, G.; Liu, J.; Zhao, C.; Li, Z.; Huang, Y.; Yu, H.; Xu, B.; Yang, X.; Zhu, D.; Zhang, X.; Zhang, R.; Feng, 353 H.; Zhao, X.; Li, Z.; Li, H.; Yang, H. Unmanned Aerial Vehicle Remote Sensing for Field-Based Crop Phenotyping: Current Status and Perspectives. *Front. Plant Sci.* 2017, 8, 1111, doi:10.3389/fpls.2017.01111.
11. Tripicchio, P.; Satler, M.; Dabisias, G.; Ruffaldi, E.; Avizzano, C. A. Towards Smart Farming and Sustainable Agriculture with Drones. In 2015 International Conference on Intelligent Environments; IEEE, 2015; pp. 140–143.
12. Hunt, E. R.; Daughtry, C. S. T. What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture? *Int. J. Remote Sens.* 2018, 39, 5345–5376, doi:10.1080/01431161.2017.1410300.
13. Peña, J. M.; Torres-Sánchez, J.; de Castro, A. I.; Kelly, M.; López-Granados, F. Weed Mapping in Early-Season Maize Fields Using Object-Based Analysis of Unmanned Aerial Vehicle (UAV) Images. *PLoS One* 2013, 8, e77151, doi:10.1371/journal.pone.0077151.
14. Floreano, D.; Wood, R. J. Science, technology and the future of small autonomous drones. *Nature* 2015, 521, 460–466, doi:10.1038/nature14542.
15. Bazi, Y.; Malek, S.; Alajlan, N.; AlHichri, H. An automatic approach for palm tree counting in UAV images. In 2014 IEEE Geoscience and Remote Sensing Symposium; IEEE, 2014; pp. 537–540.


16. Miserque Castillo, J. Z.; Laverde Diaz, R.; Rueda Guzmán, C. L. Development of an aerial counting system in oil palm plantations. *IOP Conf. Ser. Mater. Sci. Eng.* 2016, 138, 012007, doi:10.1088/1757-899X/138/1/012007.
17. Ribera, J.; Chen, Y.; Boomsma, C.; Delp, E. J. Counting plants using deep learning. In 2017 IEEE Global Conference on Signal and Information Processing (GlobalSIP); IEEE, 2017; pp. 1344–1348.
18. Chen, Y.; Ribera, J.; Boomsma, C.; Delp, E. Locating Crop Plant Centers From UAV-Based RGB Imagery 2017, 2030–2037.
19. Guo, W.; Zheng, B.; Potgieter, A. B.; Diot, J.; Watanabe, K.; Noshita, K.; Jordan, D. R.; Wang, X.; Watson, J.; Ninomiya, S.; Chapman, S. C. Aerial Imagery Analysis – Quantifying Appearance and Number of Sorghum Heads for Applications in Breeding and Agronomy. *Front. Plant Sci.* 2018, 9, 1544, doi:10.3389/fpls.2018.01544.
20. Gnädinger, F.; Schmidhalter, U. Digital Counts of Maize Plants by Unmanned Aerial Vehicles (UAVs). *Remote Sens.* 2017, 9, 544, doi:10.3390/rs9060544.
21. Hall, O.; Dahlin, S.; Marstorp, H.; Archila Bustos, M.; Öborn, I.; Jirstrom, M. Classification of Maize in Complex Smallholder Farming Systems Using UAV Imagery. *Drones* 2018, 2, 22, 382 doi:10.3390/drones2030022. 383
22. Sankaran, S.; Quirós, J. J.; Knowles, N. R.; Knowles, L. O. High-Resolution Aerial Imaging Based Estimation of Crop Emergence in Potatoes. *Am. J. Potato Res.* 2017, 94, 658–663, doi:10.1007/s12230-017-9604-2.
23. Li, B.; Xu, X.; Han, J.; Zhang, L.; Bian, C.; Jin, L.; Liu, J. The estimation of crop emergence in potatoes by UAV RGB imagery. *Plant Methods* 2019, 15, 15, doi:10.1186/s13007-019-0399-7.
24. Primicerio, J.; Caruso, G.; Comba, L.; Crisci, A.; Gay, P.; Guidoni, S.; Genesio, L.; Ricauda Aimonino, D.; 389 Vaccari, F. P. Individual plant definition and missing plant characterization in vineyards from high-resolution UAV imagery. *Eur. J. Remote Sens.* 2017, 50, 179–186, doi:10.1080/22797254.2017.1308234. 391
25. Jiang, H.; Chen, S.; Li, D.; Wang, C.; Yang, J. Papaya Tree Detection with UAV Images Using a GPU-392 Accelerated Scale-Space Filtering Method. *Remote Sens.* 2017, 9, 721, doi:10.3390/rs9070721.
26. Chen, R.; Chu, T.; Landivar, J. A.; Yang, C.; Maeda, M. M. Monitoring cotton (*Gossypium hirsutum* L.) germination using ultrahigh-resolution UAS images. *Precis. Agric.* 2018, 19, 161–177, doi:10.1007/s11119-017-9508-7.
27. Koc-San, D.; Selim, S.; Aslan, N.; San, B. T. Automatic citrus tree extraction from UAV images and digital surface models using circular Hough transform. *Comput. Electron. Agric.* 2018, 150, 289–301, doi:10.1016/J.COMPAG.2018.05.001.
28. Csillik, O.; Cherbini, J.; Johnson, R.; Lyons, A.; Kelly, M. Identification of Citrus Trees from Unmanned Aerial Vehicle Imagery Using Convolutional Neural Networks. *Drones* 2018, 2, 39, doi:10.3390/drones2040039.
29. Ampatzidis, Y.; Partel, V. UAV-Based High Throughput Phenotyping in Citrus Utilizing Multispectral Imaging and Artificial Intelligence. *Remote Sens.* 2019, 11, 410, doi:10.3390/rs11040410.
30. Selim, S.; Sonmez, N. K.; Coslu, M.; Onur, I. Semi-automatic Tree Detection from Images of Unmanned Aerial Vehicle Using Object-Based Image Analysis Method. *J. Indian Soc. Remote Sens.* 2019, 47, 193–200, doi:10.1007/s12524-018-0900-1.
31. Fan, Z.; Lu, J.; Gong, M.; Xie, H.; Goodman, E. D. Automatic Tobacco Plant Detection in UAV Images via Deep Neural Networks. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 2018, 11, 876–887, doi:10.1109/JSTARS.2018.2793849.
32. Kestur, R.; Angural, A.; Bashir, B.; Omkar, S. N.; Anand, G.; Meenavathi, M. B. Tree Crown Detection, Delineation and Counting in UAV Remote Sensed Images: A Neural Network Based Spectral–Spatial Method. *J. Indian Soc. Remote Sens.* 2018, 46, 991–1004, doi:10.1007/s12524-018-0756-4.
33. Zhao, B.; Zhang, J.; Yang, C.; Zhou, G.; Ding, Y.; Shi, Y.; Zhang, D.; Xie, J.; Liao, Q. Rapeseed Seedling Stand Counting and Seeding Performance Evaluation at Two Early Growth Stages Based on Unmanned Aerial Vehicle Imagery. *Front. Plant Sci.* 2018, 9, 1362, doi:10.3389/fpls.2018.01362.

34. Wu, J.; Yang, G.; Yang, X.; Xu, B.; Han, L.; Zhu, Y. Automatic Counting of in situ Rice Seedlings from UAV Images Based on a Deep Fully Convolutional Neural Network. *Remote Sens.* 2019, 11, 691, doi:10.3390/rs11060691.
35. Marques, P.; Pádua, L.; Adão, T.; Hruška, J.; Peres, E.; Sousa, A.; Sousa, J. J. UAV-Based Automatic Detection and Monitoring of Chestnut Trees. *Remote Sens.* 2019, 11, 855, doi:10.3390/rs11070855.
36. Díaz-Varela, R.; de la Rosa, R.; León, L.; Zarco-Tejada, P. High-Resolution Airborne UAV Imagery to Assess Olive Tree Crown Parameters Using 3D Photo Reconstruction: Application in Breeding Trials. *Remote Sens.* 2015, 7, 4213–4232, doi:10.3390/rs70404213.
37. Torres-Sánchez, J.; López-Granados, F.; Serrano, N.; Arquero, O.; Peña, J. M. High-Throughput 3-D Monitoring of Agricultural-Tree Plantations with Unmanned Aerial Vehicle (UAV) Technology. *PLoS One* 2015, 10, e0130479, doi: 10.1371/journal.pone.0130479.
38. Torres-Sánchez, J.; López-Granados, F.; Borra-Serrano, I.; Peña, J. M. Assessing UAV-collected image overlap influence on computation time and digital surface model accuracy in olive orchards. *Precis. Agric.* 2018, 19, 115–133, doi:10.1007/s11119-017-9502-0.
39. Shepard, D.; Donald A two-dimensional interpolation function for irregularly-spaced data. In *Proceedings of the 1968 23rd ACM national conference on* -; ACM Press: New York, New York, USA, 1968; pp. 517–524.
40. Soille, P. *Morphological Image Analysis: Principles and Applications*; Springer Berlin Heidelberg, 2004; ISBN 9783662050880.
41. Otsu, N. A Threshold Selection Method from Gray-Level Histograms. *IEEE Trans. Syst. Man. Cybern.* 1979, 9, 62–66, doi:10.1109/TSMC.1979.4310076.
42. Jain, A. K. *Fundamentals of digital image processing*; Prentice Hall, 1989; ISBN 0133361659.



© 2019 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

APÉNDICE A. Diagrama de flujo del análisis de imágenes.



APENDICE B. Código de composición de bandas para ortomosaico RENB

```
B=imread('Vuelo75m_transparent_mosaic_blue.tif');
RedEdge=imread('Vuelo75m_transparent_mosaic_red edge.tif');
nir=imread('Vuelo75m_transparent_mosaic_nir.tif');
img_ReNB=uint16(ones(size(Ro(:,:,1),1),size(Ro(:,:,1),2),3));
img_ReNB(:,:,1)=RedEdge(:,:,1);
img_ReNB(:,:,2)=nir(:,:,1);
img_ReNB(:,:,3)=B(:,:,1);
imshow(img_ReNB);
```

APÉNDICE C. Procedimiento interpolación IDW para generación del DSM.

El Modelo Digital de Superficie se realizó utilizando el software ArcGis 10.3 (ESRI, Inc., California, Estados Unidos) con el siguiente procedimiento:

1. El archivo .txt de la nube de puntos se importó en la tabla de contenido de ArcGis.
2. Se ejecutó la herramienta IDW, ubicada en la extensión Geoestatistical Analyst Tools.
3. Se introdujo como datos de entrada la capa generada por la importación del archivo .txt y los valores de altura para el valor de Z.
4. El tamaño de celda se hizo coincidir con el tamaño de celda del ortomosaico compuesto, y reaster de superficie interpolada de salida se limitó a las dimensiones del ortomosaico, con el Processing Extent incluido en la herramienta IDW.
5. Se estableció una búsqueda fija de vecindad mediante una distancia de radio estándar circular de 10 metros, y un número máximo de puntos de vecindad de 4. De esta manera se aseguró que la interpolación se ha realizado con los puntos más cercanos a la celda interpolada.
6. El DSM generado se exporta en formato .tiff

APÉNDICE D. Código de detección y conteo automático de olivos.

```
lalturas = imread('AlturasAltaDensidad.tif');
ROI = single(imread('ROI.tif'))./255;

[n, m] = size(lalturas);

lalturas(find(lalturas<0)) = 0;

lalturas = imfill(lalturas,'holes');

lmin = single(zeros(n,m)+9999.9);

for i=5:5:70
    SE = strel('disk', i);
    lopen = imopen(lalturas,SE);
    lmin = min(lopen,lmin);
end

lrealce = lalturas-lmin;

lhmax = imreconstruct(lrealce-1,lrealce);

level = graythresh(lhmax);

bw = lhmax>level;

[n,m] = size(bw);

SE = strel('disk', 5, 8);

bwo = imopen(bw, SE);

bw = logical(imreconstruct(bwo, bw).*ROI);

s = regionprops(bw, 'Orientation', 'MajorAxisLength', 'MinorAxisLength', 'Centroid');

for i=1:length(s)
    radiosMin(i) = s(i).MinorAxisLength;
end

MaxRadiosMin = max(radiosMin);

for i=1:length(s)
    if s(i).MajorAxisLength > MaxRadiosMin*1.20 %20 porc mayor que un arbol grande. El
seleccionado media 155
        s(i).arboles = round(double(s(i).MajorAxisLength)/MaxRadiosMin);
    else
        s(i).arboles = 1;
    end
end
end
```

```

numCand = 1;
candidatos = [];

for i=1:length(s)
    if s(i).arboles == 1
        candidatos(numCand).arboles = s(i).Centroid;
        numCand = numCand + 1;
    else
        if mod(s(i).arboles, 2) == 1 %numero impar de arboles, vale tambien el centroide de la
        elipse
            numArb = s(i).arboles;
            mitadArb = floor(s(i).arboles/2);

            salto = double((s(i).MajorAxisLength)/(numArb+1));

            for j = 1:mitadArb
                Centroid(1,1) = s(i).Centroid(1,1) + j*salto*cos((s(i).Orientation*pi/180.0) + pi);
                if s(i).Orientation > 0
                    Centroid(1,2) = s(i).Centroid(1,2) + j*salto*sin((s(i).Orientation*pi/180.0) + pi);
                else
                    Centroid(1,2) = s(i).Centroid(1,2) - j*salto*sin((s(i).Orientation*pi/180.0) + pi);
                end

                candidatos(numCand).arboles = [Centroid(1,1) Centroid(1,2)];
                numCand = numCand + 1;
            end
            for j = 1:mitadArb
                Centroid(1,1) = s(i).Centroid(1,1) + j*salto*cos((s(i).Orientation*pi/180.0));
                if s(i).Orientation > 0
                    Centroid(1,2) = s(i).Centroid(1,2) + j*salto*sin((s(i).Orientation*pi/180.0));
                else
                    Centroid(1,2) = s(i).Centroid(1,2) - j*salto*sin((s(i).Orientation*pi/180.0));
                end

                candidatos(numCand).arboles = [Centroid(1,1) Centroid(1,2)];
                numCand = numCand + 1;
            end

            candidatos(numCand).arboles = s(i).Centroid;
            numCand = numCand + 1;
        else
            numArb = s(i).arboles;
            mitadArb = floor(s(i).arboles/2);
            salto = double((s(i).MajorAxisLength)/(numArb+1));

            for j = 1:mitadArb
                Centroid(1,1) = s(i).Centroid(1,1) + (j-0.5)*salto*cos((s(i).Orientation*pi/180.0) + pi);
                if s(i).Orientation > 0
                    Centroid(1,2) = s(i).Centroid(1,2) + (j-0.5)*salto*sin((s(i).Orientation*pi/180.0) + pi);
                else
                    Centroid(1,2) = s(i).Centroid(1,2) - (j-0.5)*salto*sin((s(i).Orientation*pi/180.0) + pi);
                end
            end
        end
    end
end

```

```

        candidatos(numCand).arboles = [Centroid(1,1) Centroid(1,2)];
        numCand = numCand + 1;
    end
    for j = 1:mitadArb
        Centroid(1,1) = s(i).Centroid(1,1) + (j-0.5)*salto*cos((s(i).Orientation*pi/180.0));
        if s(i).Orientation > 0
            Centroid(1,2) = s(i).Centroid(1,2) + (j-0.5)*salto*sin((s(i).Orientation*pi/180.0));
        else
            Centroid(1,2) = s(i).Centroid(1,2) - (j-0.5)*salto*sin((s(i).Orientation*pi/180.0));
        end

        candidatos(numCand).arboles = [Centroid(1,1) Centroid(1,2)];
        numCand = numCand + 1;
    end
end
end
end

save('candidatos.mat', 'candidatos');

```

Código de marcación de los olivos y presentación de resultados.

```

I = imread('Vuelo70m_transparent_mosaic_ReNB.tif');

for i = 1:length(candidatos)
    i;
    I = insertMarker(I,[candidatos(i).arboles(1,1)
        candidatos(i).arboles(1,2)], '*', 'color', 'red', 'size', 30);
end

imwrite(I, 'Resultado.tif', 'TIFF');

```