

# Discriminación de malezas basada en la respuesta espectral del cultivo de maíz, Manabí, Ecuador

Weed discrimination based on the spectral response of the corn crop, Manabí, Ecuador

Discriminação de plantas daninhas com base na resposta espectral da cultura do milho, Manabí, Equador

Cinthya K. Pinargote Intriago<sup>1\*</sup> y Henry A. Pacheco Gil<sup>2</sup>

<sup>1</sup>Maestría en Ingeniería Agrícola, Instituto de Postgrado, Universidad Técnica de Manabí, Ecuador. Correo electrónico: [cinthyapinargote@gmail.com](mailto:cinthyapinargote@gmail.com), . <sup>2</sup>Facultad de Ingeniería Agrícola, Universidad Técnica de Manabí, Ecuador. Correo electrónico: [henrypacheco@gmail.com](mailto:henrypacheco@gmail.com), .

## Resumen

La agricultura de precisión permite ganar eficacia, sustentabilidad y rentabilidad, ya que aporta grandes beneficios en disminuir el impacto ambiental de la agricultura, los riesgos económicos y al mismo tiempo contribuye a controlar el vigor de los cultivos y mejorar la calidad del rendimiento de los mismos. El objetivo de esta investigación es discriminar malezas dentro del cultivo de maíz, basados en su respuesta espectral. Para ello se usó el avanzado Dron agrícola *EBEE SQ*, con el cual se capturó imágenes multiespectrales a través de su cámara *Parrot Sequoia*. Las imágenes fueron procesadas con software en Sistemas de Información Geográfica (SIG). Con las bandas multiespectrales se calcularon diferentes índices de vegetación tales como NDVI, NDVIAS, NGRDI, NDRE, GNDVI, usando herramientas de álgebra de mapas en programas especializados. A los diferentes índices se les aplicó una clasificación supervisada para discriminar las distintas coberturas de suelo, la cual obtuvo una precisión del 93% y un índice de Kappa de 0,93. Los resultados permitieron diferenciar claramente la cobertura de cultivos, malezas y suelo desnudo. Los datos mostraron que la maleza tanto de crecimiento temprano como las desarrolladas ocupan un 38% del área del cultivo. Con esta información se puede mejorar la planificación de prácticas agronómicas, agregando el herbicida en el sitio específico de las malezas.

**Palabras clave:** Vehículo aéreo no tripulado, detección remota, índices de vegetación, clasificación supervisada.

---

Recibido: 20-10-2020 • Aceptado: 11-01-2021.

\*Autor de correspondencia. Correo electrónico: [cinthyapinargote@gmail.com](mailto:cinthyapinargote@gmail.com)

## Abstract

Precision agriculture allows to gain efficiency, sustainability and profitability, since it provides great benefits in reducing the environmental impact of agriculture, economic risks and at the same time contributes to controlling the vigor of crops and improving the quality of their yield. The objective of this research is to discriminate weeds within the corn crop, based on their spectral response. For this, the advanced EBEE SQ agricultural drone was used, with which multispectral images were captured through its *Parrot Sequoia* camera. The images were processed with software in Geographic Information Systems (GIS). With the multispectral bands, different vegetation indices were calculated such as NDVI, NDVIAS, NGRDI, NDRE, GNDVI, using map algebra tools in specialized programs. A supervised classification was applied to the different indices to discriminate the different land covers, which obtained a precision of 93% and a Kappa index of 0.93. The results allowed to clearly differentiate the coverage of crops, weeds and bare soil. The data showed that both early-growing and developed weeds occupy 38% of the crop area. With this information, it is possible to improve the planning of agronomic practices, adding the herbicide at the specific site of the weeds.

**Keywords:** Unmanned aerial vehicle, remote sensing, vegetation index, supervised classification.

## Resumo

A agricultura de precisão permite ganhos de eficiência, sustentabilidade e rentabilidade, pois proporciona grandes benefícios na redução do impacto ambiental da agricultura, dos riscos econômicos e ao mesmo tempo contribui para controlar o vigor das lavouras e melhorar a qualidade de sua produção. O objetivo desta pesquisa é discriminar plantas daninhas na cultura do milho, com base em sua resposta espectral. Para isso, foi utilizado o drone agrícola EBEE SQ avançado, com o qual imagens multiespectrais foram capturadas por meio de sua câmera Parrot Sequoia. As imagens foram processadas com software em Sistemas de Informações Geográficas (SIG). Com as bandas multiespectrais, diferentes índices de vegetação foram calculados como NDVI, NDVIAS, NGRDI, NDRE, GNDVI, utilizando ferramentas de álgebra de mapas em programas especializados. Foi aplicada uma classificação supervisionada aos diferentes índices para discriminar as diferentes coberturas do solo, que obteve uma precisão de 93% e um índice Kappa de 0,93. Os resultados permitiram diferenciar claramente a cobertura de lavouras, ervas daninhas e solo descoberto. Os dados mostraram que tanto as ervas daninhas de crescimento precoce quanto as desenvolvidas ocupam 38% da área de cultivo. Com essas informações, é possível aprimorar o planejamento das práticas agronômicas, adicionando o herbicida no local específico das plantas daninhas.

**Palavras-chave:** Veículo aéreo não tripulado, sensoriamento remoto, índices de vegetação, classificação supervisionada.

## Introducción

En la agricultura, las malezas son parte constituyente de los componentes del agroecosistema por ser plantas inevitables e indeseables que se desarrollan de manera espontánea dentro o fuera de los cultivos, las mismas que mantienen un comportamiento muy dinámico en la composición florística, ya que generan cambios significativos en el suelo y en las plantas.

Actualmente en el Ecuador las malezas representan uno de los rubros más significativos dentro del sector agropecuario, ya que dada su fisiología son resistentes a los productos químicos e incluso toleran altas temperaturas ambientales, lo cual les resulta ventajoso para su supervivencia. De este modo van ganando espacio en los suelos para competir con las plantas cultivadas. Por ello, a los agricultores les está generando un importante consumo monetario siendo este aproximadamente de \$1045 por hectárea en la compra de insumos, manos de obra y riego para el cultivo de maíz (Páliz *et al.*, 2019; Martínez y Barrera, 2020).

Las malezas afectan de manera directa a la siembra, debido a que liberan sustancias que reducen el desarrollo del cultivo y aprovechan los recursos como agua, luz, nutrientes y espacio, que podrían estar disponibles para el cultivo durante su ciclo de crecimiento. Así mismo, perjudica de forma indirecta la preparación de la cama del cultivo y contamina el producto a cosechar dado que disminuye su calidad comercial.

## Introduction

In agriculture, weeds are a constituent part of agroecosystem because they are unavoidable and undesirable plants that develop spontaneously inside or outside the crops, which maintain a very dynamic behavior in the floristic composition, since they generate significant changes on soil and plants.

Currently in Ecuador, weeds are one of the most significant items within the agricultural sector, since given their physiology they are resistant to chemical products and even tolerate high environmental temperatures, which is advantageous for their survival. In this way they are gaining space in the soils to compete with cultivated plants. Therefore, it is generating significant money consumption for farmers, this being approximately US\$ 1045 per hectare in the purchase of inputs, labor and irrigation for cultivation of corn (Páliz *et al.*, 2019; Martínez and Barrera, 2020).

Weeds directly affect planting, because they release substances that reduce the development of the crop and take advantage of resources such as water, light, nutrients and space, which could be available for the crop during its growth cycle. Likewise, it indirectly impairs the preparation of the crop bed and contaminates the product to be harvested since it decreases its commercial quality. In addition, it hinders harvesting work, increases the risk of pests and diseases, acting as their hosts and generating economic losses due to

Además, obstaculiza las labores de cosecha, aumenta el riesgo de plagas y enfermedades, actuando como hospedantes de las mismas y generando pérdidas económicas por bajos rendimientos, menor calidad del cultivo y aumento en los costos de cosecha (Pérez *et al.*, 2014).

Para contrarrestar este tipo de inconvenientes los agricultores realizan un control de malezas de manera manual y tradicional con los herbicidas, esto solo genera altos costos en compra de estos productos químicos y además de las operaciones, lo que conlleva una inversión de tiempo y trabajadores para la aplicación del mismo (Santana, *et al.*, 2020). De manera que, el productor aplica el químico en zonas donde no hay maleza para evitar que esta llegue a crecer, pero esto en definitiva lo que causa es el desperdicio en gran medida del producto y a su vez afecta al suelo perjudicando sus propiedades físicas, químicas y biológicas, además que contamina el aire por el exceso del químico y perjudica la salud del cultivador.

Para tener un control y evitar la contaminación ambiental por el desperdicio del producto fitosanitario se debe aplicar métodos de teledetección para el manejo de la maleza. Es por eso que, en esta investigación se introduce una de las tecnologías más innovadoras como es el uso de vehículos aéreos no tripulados (UAV). Estos ofrecen la posibilidad de recopilación de datos para las resoluciones espaciales, temporales deseadas y en conjunto con sus cámaras obtienen imágenes

low yields, lower crop quality and increased harvest costs (Pérez *et al.*, 2014).

To counteract this kind of inconvenience, farmers carry out manual and traditional weed control with herbicides, this only generates high costs in the purchase of these chemical products and in addition to operations, which entails an investment of time and workers for its application (Santana, *et al.*, 2020). So, the producer applies the chemical in areas where there is no weed to prevent it from growing, but this ultimately causes the waste to a large extent of the product and in turn affects the soil, damaging its physical and chemical properties. and biological, besides that it pollutes the air due to excess of chemical and harms farmer's health.

To control and avoid environmental contamination by waste of the phytosanitary product, remote sensing methods must be applied for weed management. This research introduces one of the most innovative technologies, such as the use of unmanned aerial vehicles (UAV). These have the advantage of collecting data for the desired spatial and temporal resolutions and together with their cameras they obtain spectral images (Adão *et al.*, 2017; Cevallos *et al.*, 2019).

The images in the infrared and visible spectra are especially useful in agriculture, since chlorophyll concentrations in the leaves or rates of photosynthetic activity can be seen, detecting processes in crops such as stress in vegetation, due to the presence of pests and diseases, lack of

espectrales (Adão *et al.*, 2017; Cevallos *et al.*, 2019).

Las imágenes en el espectro infrarrojo junto con las del espectro visible, son especialmente útiles en agricultura, ya que se puede visualizar las concentraciones de clorofila en las hojas o tasas de actividad fotosintética, detectando procesos en los cultivos tales como el stress en la vegetación, producido por la presencia de plagas y enfermedades, falta de agua, problemas de suelos o baja de nutrientes (stress nutricional) (Saavedra *et al.*, 2018).

Diferentes investigaciones han establecidos que las imágenes antes mencionadas también ayudan al análisis discriminante de malezas, mediante los mapas de índices de vegetación que contribuyen a obtener el momento fenológico propicio para su discriminación y así mediante estudios tener la diferencia espectral existente entre el cultivo y los parches de maleza, a fin de realizar las aplicaciones de los agroquímicos en el sitio específico sin desperdicio alguno (Peña *et al.*, 2014; Campos *et al.*, 2019; Yang, 2020; Radoglou, *et al.*, 2020).

Por tal razón este trabajo de investigación se desarrolló con el fin de discriminar las malezas basada en la respuesta espectral del cultivo de maíz, para conocer la ubicación exacta de las malas hierbas y así proponer alternativas de manejo y uso sostenible de los productos químicos como los herbicidas. Es por ello que, con aplicación directa de los herbicidas en los parches de maleza, se reducirá tiempo, costos operacionales y existirá una cantidad menor de agroquímicos

water, soil problems or low nutrients (nutritional stress) (Saavedra *et al.*, 2018).

Different investigations have established that these images also help the discriminant analysis of weeds, through vegetation index maps that help to obtain the phenological moment conducive to their discrimination and thus, through studies, have the existing spectral difference between the crop and the weed patches, to perform agrochemical applications on the specific site without any waste (Peña *et al.*, 2014; Campos *et al.*, 2019; Yang, 2020; Radoglou, *et al.*, 2020).

For these reasons, this research was carried out to discriminate weeds based on the spectral response of the corn crop, to know the exact location of the weeds and thus propose alternatives for the management and sustainable use of chemicals such as herbicides. Therefore, with the direct application of herbicides in the weed patches, time, operational costs will be reduced and there will be a smaller amount of agrochemicals causing positive effects on the soil and the environment (Jiménez *et al.*, 2020; Sishodia *et al.*, 2020).

## Materials and methods

### Location of the study area

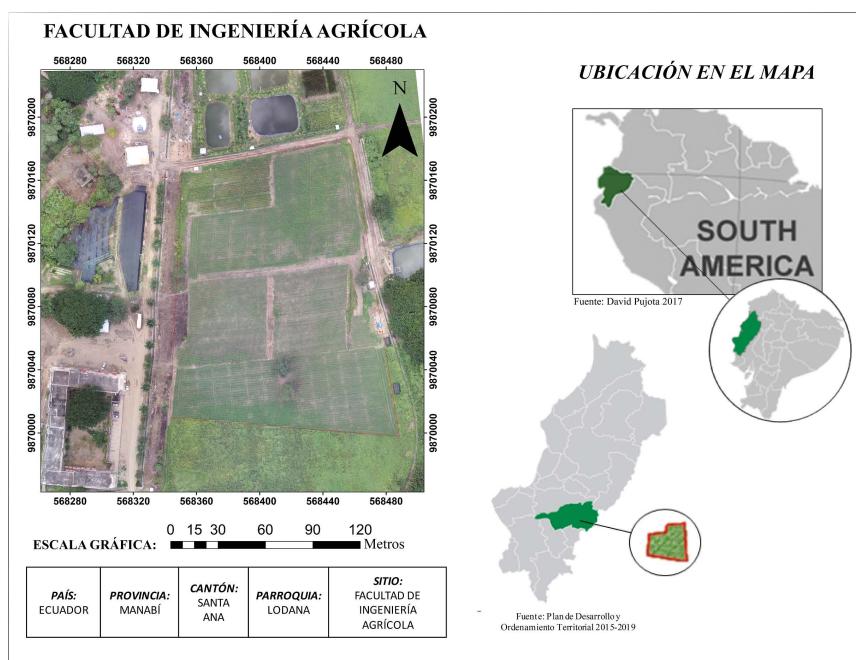
This research was carried out in the Ecuadorian coast, Manabí province, Santa Ana canton, Lodana parish, at the facilities of the Universidad Técnica de Manabí, campus of the Facultad de Ingeniería Agrícola, on a corn crop (*Zea mays*), located between geographic coordinates  $1^{\circ}10'30.3''S$

causando efectos positivos en el suelo y en el medio ambiente (Jiménez *et al.*, 2020; Sishodia *et al.*, 2020).

## Materiales y métodos

### Ubicación del área de estudio

La presente investigación se llevó a cabo en la Costa ecuatoriana, provincia de Manabí, cantón Santa Ana, de la parroquia Lodana, en las instalaciones de la Universidad Técnica de Manabí, campus de la Facultad de Ingeniería Agrícola, sobre un cultivo de maíz (*Zea mays*), ubicado entre las coordenadas geográficas  $1^{\circ}10'30,3''$  S y  $80^{\circ}23'06,05''$  W a 61 m.s.n.m., tal como se muestra en la figura 1.



**Figura 1. Ubicación del área de estudio.**

**Figure 1. Location of the study area.**

and  $80^{\circ}23'06.05''$  W at 61 m.a.s.l., as shown in Figure 1.

### Crop description

The corn crop covered an area of 21,631.2 m<sup>2</sup>, this was sown at the beginning of the rainy season, February 16, 2020, with a distance between rows of 1 m, and between plants of 0.30 m, maintaining a surface irrigation technology.

### Obtaining images

The images were taken using the EBEE SQ® unmanned aerial vehicle (UAV), instrumented with the Parrot Sequoia® camera, which captures images in the visible and multispectral green (GREEN), Red (RED), Red Edge bands. (EDGE) and Near Infrared

## Descripción del cultivo

El cultivo de maíz cubría un área de 21631,2 m<sup>2</sup>, este fue sembrado al inicio de la época de lluvia, 16 de febrero de 2020, con un distanciamiento entre hilera de 1 m, y entre planta de 0,30 m, manteniendo una tecnología de riego superficial.

## Obtención de imágenes

Se procedió a la toma de las imágenes mediante el vehículo aéreo no tripulado (UAV) *EBEE SQ*, instrumentado con la cámara *Parrot Sequoia*, la cual captura imágenes en el visible y las bandas multiespectrales verde (GREEN), Roja (RED), Borde Rojo (EDGE) e Infrarrojo cercano (NIR), (SenseFly a Parrot Company, 2018; Parrot Drone SAS, 2020).

## Planificación del vuelo

La planificación del vuelo se ejecutó con el software *Emotion AG*, en el cual se definió el área de trabajo, la altura de vuelo, resolución del pixel, solapamiento de las imágenes, así como el punto de despegue y aterrizaje. Los parámetros para los casos específicos del vuelo se muestran en el cuadro 1 y figura 2.

**Cuadro 1. Parámetros obtenidos por el software Emotion AG para la ejecución del vuelo.**

**Table 1. Parameters obtained by the Emotion AG software for the execution of the flight.**

Información	Emotion AG
Cámara	RGB (16 Mpix) + Multiespectral (1.2 Mpix)
Tipo	Sequoia 1.7.1
Tamaño de la imagen (cm/pixel)	11,00 cm/px
Tiempo obturación (s)	15:47 min
Área de vuelo	24,2 ha
Traslapo longitudinal (%)	80
Traslapo transversal (%)	70
Altura de vuelo (m)	150 m
Velocidad de vuelo (m s <sup>-1</sup> )	4 m/sec

(NIR), (SenseFly a Parrot Company, 2018; Parrot Drone SAS, 2020).

## Flight planning

The flight planning was executed with the *Emotion AG®* software, in which the work area, flight height, pixel resolution, image overlap, as well as the take-off and landing point were defined. Parameters for specific flight cases are shown in Table 1 and Figure 2.

The flight was kept under constant supervision with the modem signal, to verify that the equipment conditions were working properly and that high precision was achieved in the mission and a safe flight, guaranteeing the performance and quality of the data.

## Image processing

The images were processed by *Pix4D®* photogrammetry software, with which georeferenced, orthomosaic digital models in 2D and 3D were created, and separated spectral bands, of high precision from the drone images (Pix4D SA., 2019).

This process was developed



**Figura 2. Planificación del vuelo en la zona de estudio.**

**Figure 2. Flight planning in the study area.**

El vuelo se mantuvo en constante supervisión con la señal del modem, para verificar que las condiciones de los equipos funcionaran apropiadamente y se consiguió una alta precisión en la misión y un vuelo seguro, garantizando el rendimiento y calidad de los datos.

#### **Procesamiento de las imágenes**

Las imágenes fueron procesadas por el software de fotogrametría *Pix4D*, con el cual se crearon modelos digitales en 2D y 3D georreferenciados, ortomosaicos y bandas espectrales separadas, de alta precisión a partir de las imágenes de drones (*Pix4D SA., 2019*).

Este proceso se desarrolló en tres etapas, la primera fue la calibración de las imágenes individuales, la Triangulación Aérea (AAT) y Ajuste de Bloque de Paquete (BBA); en la segunda se llevó a cabo la generación de nubes de puntos y malla, y la

in three stages, the first was the calibration of the individual images, the Aerial Triangulation (AAT) and Packet Block Adjustment (BBA). In the second, the generation of point and mesh clouds and the construction of the Digital Surface Model (MDS) were carried out. Finally, the third, it was possible to obtain the orthomosaic and the reflectance in each of the bands. This processing was configured to run automatically in the software.

#### **Calculation of vegetation indices**

Using the map algebra tools of the *ArcGIS®* software, the calculations of five vegetation indices (table 2) were performed, which allowed discrimination between the soil, weed patches and the corn crop in the study area.

#### **Supervised classification**

This method used the tools of the *ArcGIS®* software. For this, the

construcción del Modelo Digital de Superficie (MDS); por último, la tercera, se logró obtener el ortomosaico y la reflectancia en cada una de las bandas. Este procesamiento se configuró para su ejecución automática en el software.

### Cálculo de índices de vegetación

Mediante las herramientas de álgebra de mapas del software ArcGIS se realizaron los cálculos de cinco índices de vegetación (cuadro 2), que permitieron la discriminación entre el suelo, los parches de maleza y el cultivo de maíz en el área de estudio.

NGRDI index was selected, which allowed the best identification of pixels colorimetry of each cells in the image. In this, a Shape file was built with the training areas of each of the coverages considered, for the recognition of the different categories.

Then the different classes were identified as bare soil, corn crop, weeds and the spectral signature file was generated with the software's "Creature Signatures" algorithm.

Later with the algorithm "Maximum Likelihood Classification", the classes for the whole image were generated using the signatures

**Cuadro 2. Índices de vegetación obtenido en el estudio.**

**Table 2. Vegetation indices obtained in the study.**

Índice	Relación entre bandas	Referencia
"Índice de Vegetación de Diferencia Normalizada"	$NDVI = \frac{NIR - RED}{NIR + RED}$	(Rouse <i>et al.</i> , 1973)
"Vegetación de Diferencia Normalizada Verde"	$GNDVI = \frac{NIR - GREEN}{NIR + GREEN}$	(Wu <i>et al.</i> , 2014)
"Índice de Vegetación de Diferencia Normalizada Ajustada al Suelo"	$NDVIAS = \frac{EDGE - RED}{EDGE + RED} (1 + L)$ $L = \text{Factor corrección brillo del suelo}$	(Filella y Penuelas 1994; Qi <i>et al.</i> , 1994)
"Índice de Diferencia Normalizada de Borte Rojo"	$NDRE = \frac{NIR - EDGE}{NIR + EDGE}$	(Li <i>et al.</i> , 2014)
"Índice de Diferencia Normalizada Verde-Rojo"	$NGRDI = \frac{(GREEN - RED)}{(GREEN + RED)}$	(Song and Park 2020)

### Clasificación supervisada

Este método utilizó las herramientas del programa informático ArcGIS. Para ello se seleccionó el índice NGRDI, el cual permitió identificar de la mejor manera la colorimetría de los pixeles de cada una de las celdas en la imagen. En este se construyó un archivo Shape con las áreas de entrenamiento de cada

previamente creada. Finally, the accuracy of the classification was verified using the Kappa index.

### Results and discussion

#### Obtaining the images

The *Parrot Sequoia®* multispectral camera from UAV *EBEE SQ®*, captured 379 photos with a pixel size

una de las coberturas consideradas, para el reconocimiento de las distintas categorías.

Luego se identificó las diferentes clases como suelo desnudo, cultivo de maíz, malezas y se generó el archivo de firmas espectrales con el algoritmo “Creature Signatures” del software.

Posteriormente con el algoritmo “Maximum Likelihood Classification”, se generaron las clases para toda la imagen usando las firmas antes creadas. Por último, se verificó la precisión de la clasificación por medio del índice de Kappa.

## Resultados y discusión

### Obtención de las imágenes

La cámara multiespectral *Parrot Sequoia* de *UAV EBEE SQ*, capturó 379 fotos con un tamaño de los pixeles de 11,00 cm, registradas en los formatos JPEG para la imagen RBG y las bandas multiespectrales “GREEN, RED, NIR, EDGE” en Geotiff. Estos resultados son consistentes con los reportes de Franzini *et al.* (2019), quienes ratifican la consistencia geométrica y radiométrica de imágenes multiespectrales de *Parrot Sequoia*, que permitió a los investigadores adquirir imágenes de excelente calidad para la obtención de mapas (NDVI) con buenos resultados, resaltando la utilidad del sensor para fines agrícolas.

### Procesamiento de las imágenes

En la primera etapa el software *Pix4D* generó como resultado un informe de calidad, donde reportó 73035 puntos característicos por imágenes, lo que permitió una muy

of 11.00 cm, recorded in the JPEG formats for the RBG image and the multispectral bands “GREEN, RED, NIR, EDGE” in Geotiff. These results are consistent with the reports by Franzini *et al.* (2019), who ratify the geometric and radiometric consistency of multispectral images of *Parrot Sequoia®*, which allowed researchers to acquire excellent quality images for obtaining maps (NDVI) with good results, highlighting the usefulness of the sensor for agricultural purposes.

### Image processing

In the first stage, the *Pix4D®* software generated a quality report as a result, where it reported 73,035 characteristic points per images, which allowed a very good reconstruction and optimization of the initial parameters of the camera and with an excellent image matching. In the report, a very high overlap could be seen in much of the image, which confirmed that these images were taken in the correct position (figure 3).

According to research by Kharuf *et al.* (2018), consider that the *Pix4D®* program is a tool with a high potential and flexibility in the creation of orthomosaics for the realization of remote sensing studies, it also allows the generation of vegetation indices offering reliable results.

The point cloud and textured mesh shows a preview of the orthomosaic and the Digital Surface Model (Figure 4). In addition, the four spectral bands GREEN, RED, EDGE and NIR were obtained, in “\*.TIF” format files.

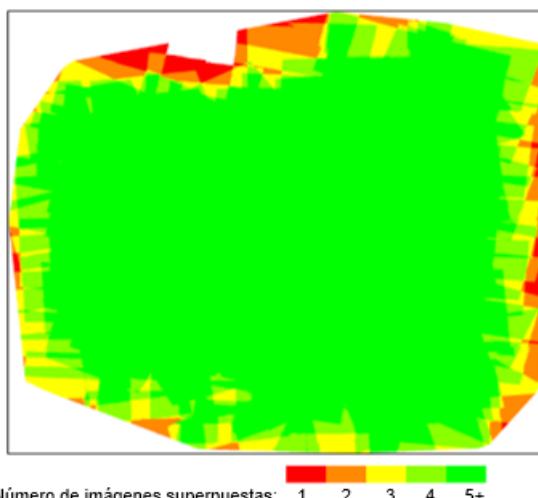
These results allow users to have quality images, because they have been automatically corrected in the

buenha reconstrucción y optimización de los parámetros iniciales de la cámara y con un excelente emparejamiento de imágenes. En el reporte, se pudo visualizar un solapamiento muy alto en gran parte de la imagen, lo que confirmó que estas imágenes fueron tomadas en una posición correcta (figura 3).

positioning of the X, Y and Z axes (Lárraga *et al.*, 2019; Stott *et al.*, 2020).

#### **Calculation of vegetation indices**

The data in table 3 show the descriptive statistics for the 5 indices calculated. The value of the indices shows different hydric, nutritional,



**Figura 3. Mapa de solapamiento del área de estudio obtenido por el reporte de calidad del Pix4D.**

**Figure 3. Overlapping map of the study area obtained by the Pix4D quality report.**

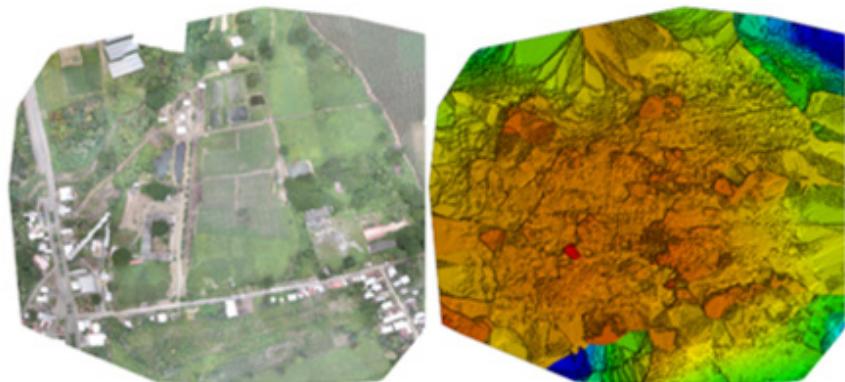
Según investigaciones de Kharuf *et al.* (2018), consideran que el programa *Pix4D* es una herramienta con un alto potencial y flexibilidad en la creación de ortomosaicos para la realización de estudios de teledetección, además permite la generación de índices de vegetación ofreciendo resultados confiables.

phytosanitary conditions and different densities of the vegetation cover. Studies carried out by Muñoz (2013) and Berrío *et al.* (2015), establish that these spectral values tend to measure the biomass or plant vigor within a pixel.

The visual interpretation of the indices allowed to discriminate the

La nube de puntos y malla texturizada muestra una vista previa del ortomosaico y el Modelo Digital de Superficie (figura 4). Además, se obtuvo las cuatro bandas espectrales GREEN, RED, EDGE y NIR, en ficheros de formato “\*.TIF”.

soil covers, but with greater ease in the case of the NGRDI (Green-Red Normalized Difference Index), which turned out to be very evident the discrimination of weeds, soils and crops (figure 5). Regarding this issue, a previous investigation is reported,



**Figura 4. Ortomosaico RGB y Modelo Digital de Superficie (MDS) generado por el programa informático Pix4D a partir de imágenes aéreas UAV.**

**Figure 4. RGB Orthomosaic and Digital Surface Model (MDS) generated by Pix4D software from UAV aerial images.**

Estos resultados permiten a los usuarios disponer de imágenes de calidad, porque han sido automáticamente corregidas en posicionamiento de los ejes X, Y y Z (Lárraga *et al.*, 2019; Stott *et al.*, 2020).

#### Cálculo de índices de vegetación

Los datos del cuadro 3 muestran los estadísticos descriptivos para los 5 índices calculados.

where it was found that the NGRDI presented the best results for the detection of grass weeds in rice fields (Barrero and Perdomo, 2018).

Although studies carried out by Castillejo-González *et al.* (2014) establish that the NDVI was the most appropriate index to separate the vegetation, that is, the cultivation of wild oats with the weeds; however, these results disagree with this

**Cuadro 3. Valores espectrales de los índices de vegetación en el cultivo de maíz.****Table 3. Spectral values of the vegetation indices in the corn crop.**

Índice	Promedio	Mínimo	Máximo	Desv. Est.
NDVI	0,977031	0,879261	0,993752	0,013842
NDVIAS	0,990727	0,090030	1,322890	0,206870
NGRDI	0,248019	-0,321352	0,593482	0,129516
NDRE	0,898981	0,829736	0,945052	0,007607
GNDVI	0,965510	0,845403	0,985863	0,009696

Desv. Est.= Desviación estándar.

Desv. Est.. = Standard deviation.

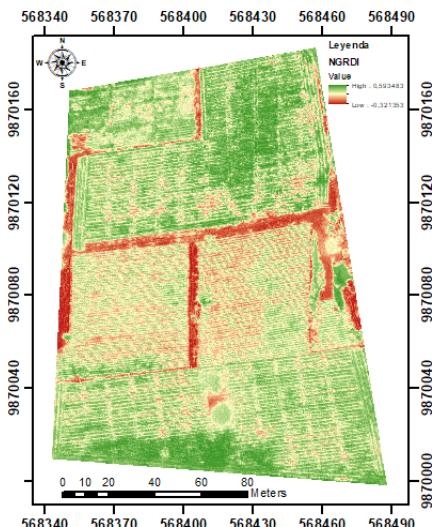
El valor de los índices muestra diferentes condiciones hídricas, nutricionales, fitosanitarias y distintas densidades de la cobertura vegetal. Estudios realizados por Muñoz (2013) y Berrió *et al.* (2015), establecen que estos valores espectrales tienden a medir la biomasa o vigor vegetal dentro de un pixel.

La interpretación visual de los índices permitió discriminar las coberturas del suelo, pero con una mayor facilidad para el caso del NGRDI (Índice de Diferencia Normalizada Verde-Rojo), el cual resultó ser muy evidente la discriminación de malezas, suelos y cultivos (figura 5). Respecto a este tema se reporta una investigación previa, donde se encontró que el NGRDI presentó los mejores resultados para la detección de malezas gramíneas en campos de arroz (Barrero y Perdomo, 2018).

research, where new NDVI, NVDIAS, NDRE, GNDVI indices were developed and it was found that these indices visually caused difficulties in the interpretation to distinguish and identify the vegetation cover (crop) with weeds, such as It is shown in figures 6, 7, 8 and 9. Thus, these figures combine the pixels of the vegetation cover of the ground and the weeds, as they do not show a separation of the same, and there is a saturation of green colorimetry, for hence, it was established that the NGRDI was the best in this study.

### Supervised classification

Figure 10 represents the raster image of the classified NGRDI index, where it shows good results to separate the different covers and it manages to discriminate very well the weeds of the crops and the bare soil. The Supervised Classification develops iterative processes by comparing the sum of the squared



**Figura 5. Cultivo de maíz aplicando el índice NGRDI.**

**Figure 5. Corn cultivation applying the NGRDI index.**

Aunque estudios realizados por Castillejo-González *et al.* (2014) establecen que el NDVI fue el índice más apropiado para separar la vegetación, es decir, el cultivo de avena silvestre con la maleza; sin embargo, esos resultados discrepan con esta investigación, donde se desarrollaron nuevos índices NDVI, NVDIAS, NDRE, GNDVI y se encontró que estos índices visualmente provocaron dificultades en la interpretación para distinguir e identificar la cobertura vegetal (cultivo) con las malezas, tal como se muestra en las figuras 6, 7, 8 y 9. De modo que, estas figuras combinan los pixeles de la cobertura vegetal del suelo y la maleza, al no evidenciar una separación de las misma, y al existir saturación de colorimetría verde, por ende, se estableció que el NGRDI fue el mejor en este estudio.

deviations between classes with the average values (ArcGIS, 2016).

With the classification, it was possible to accurately identify the exact site where the weeds are found, which can facilitate the planning of agronomic control treatments. As can be seen in figure 10, the central plots of the corn crop present small patches of weed (yellow), while in the plots of the upper and lower part of the image large patches of weed are observed (red), which it causes the crop to compete enormously for acquisition of water and nutrients for its growth.

In figure 10 weed was easily discriminated, being able to differentiate its abundance. Therefore, it is corroborated that the supervised classification process obtained a lot of validation since it reached 0.93 of concordance, very good in the Kappa

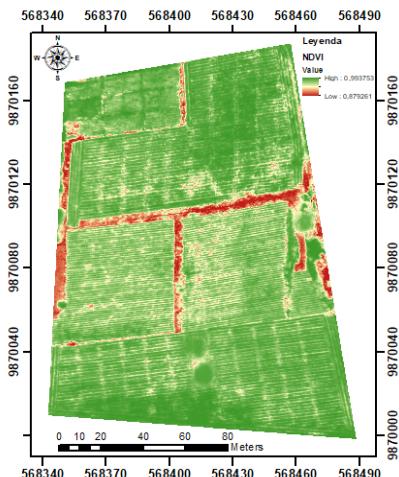


Figura 6. Cultivo de maíz aplicando el índice NDVI.

Figure 6. Corn crop applying the NDVI index.

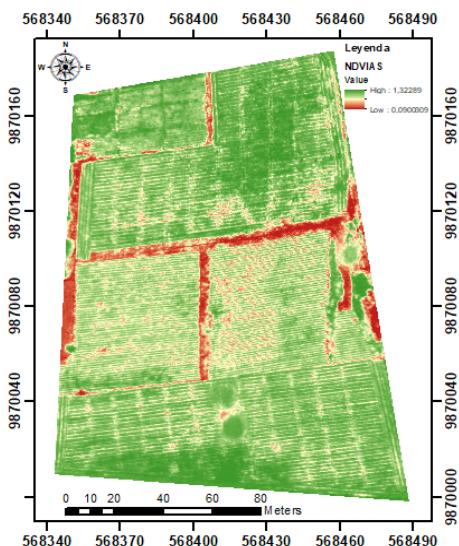


Figura 7. Cultivo de maíz aplicando el índice de NDVIAS.

Figure 7. Corn crop applying the NDVIAS index.

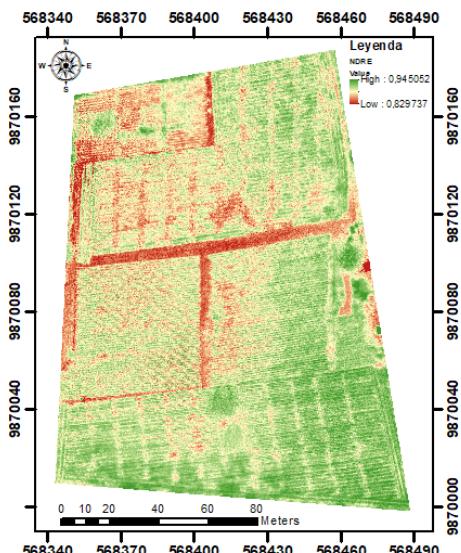


Figura 8. Cultivo de maíz aplicando el índice de NDRE.

Figure 8. Corn crop applying the NDRE index.

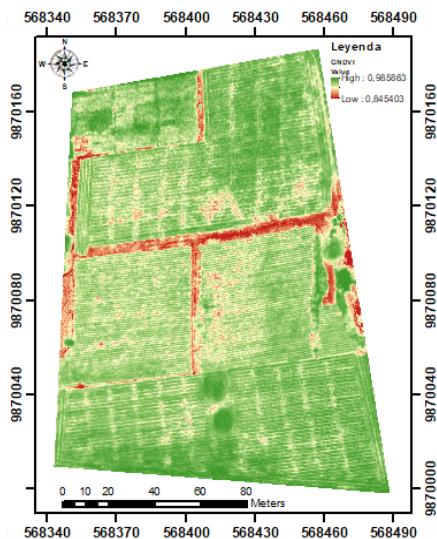


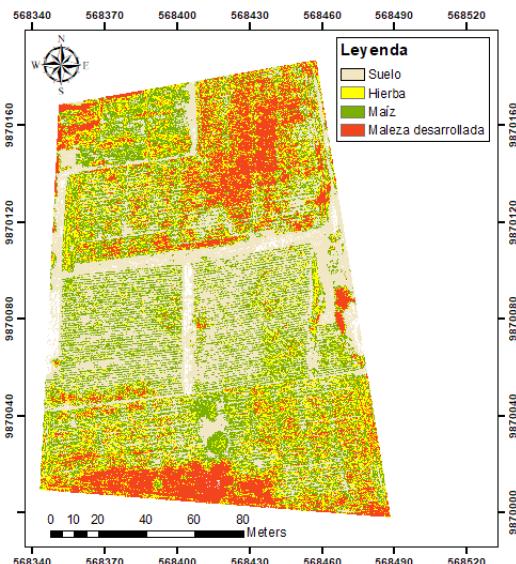
Figure 9. Corn cultivation applying the GNDVI index.

Figura 9. Cultivo de maíz aplicando el índice GNDVI

## Clasificación supervisada

La figura 10 representa la imagen raster del índice NGRDI clasificada, donde muestra buenos resultados para separar las diferentes coberturas y logra discriminar muy bien las malezas de los cultivos y el suelo desnudo. La Clasificación Supervisada, desarrolla procesos iterativos al comparar la suma de las desviaciones cuadradas entre clases con los valores promedios (ArcGIS, 2016).

index and a precision of 93 %. With these results, the efficiency of the method is ratified, which has also been used in the research of Polanco (2012), who carried out a supervised classification in the Belmira páramo with Landsat images, which allowed him to identify the various classes of land use coverage from the soil, in addition this method presented a precision of 80 % and a Kappa index = 0.8.



**Figure 10. Maize, soil and weed crop coverage maps by supervised classification.**

**Figura 10. Mapas de cobertura del cultivo de maíz, suelo y malezas mediante la clasificación supervisada.**

Con la clasificación se logró identificar con precisión el sitio exacto donde se encuentran las malezas, lo cual puede facilitar la planificación de tratamientos agronómicos de control. Como se observa en la figura

On the other hand, these results (figure 10) allowed to know the percentages of the coverage of each class (table 4) and with this it was determined that 38 % of the crop area is affected by the presence of herbs

10, las parcelas centrales del cultivo de maíz presentan pequeños parches de maleza (amarillo), mientras que en las parcelas de la parte superior e inferior de la imagen se observan grandes manchas de maleza (rojo), lo cual ocasiona que el cultivo compita enormemente por la adquisición de agua y nutrientes para su crecimiento.

En la figura 10 la maleza se logró discriminar con facilidad, pudiendo diferenciar su abundancia. Por ello se corrobora que el proceso de la clasificación supervisada obtuvo mucha validación ya que alcanzó el 0,93 de concordancia, muy buena en el índice de Kappa y una precisión del 93%. Con estos resultados se ratifica la eficiencia del método, que también ha sido utilizado en la investigación de Polanco (2012), quien realizó una clasificación supervisada en el páramo de Belmira con imágenes Landsat, lo cual le permitió identificar las diversas clases de coberturas del uso del suelo, además este método presentó una precisión del 80% y un índice de Kappa = 0,8.

Por otro lado, estos resultados (figura 10) permitieron conocer los porcentajes de las coberturas de cada clase (cuadro 4) y con ello se determinó que el 38% del área del cultivo, está afectada por la presencia de hierbas (20%) y maleza desarrollada (18%), además de encontrar su ubicación exacta dentro del área de estudio.

Está información permite mejorar significativamente las prácticas agronómicas, por cuanto se podría planificar con precisión la cantidad, el momento y lugar exacto para la aplicación del control de malezas,

(20 %) and developed weed (18 %), in addition to finding its exact location within the study area.

This information makes it possible to significantly improve agronomic practices, since the exact amount, time and place for the application of weed control could be planned with precision, detecting the different coverage of land use, and especially the weeds within the crops, which is a major challenge for precision agriculture (De Castro *et al.*, 2020).

## Conclusions

Of the indices analyzed, the NGRDI “Green-Red Normalized Difference Index” was the one that managed to show in a more efficient way the spatial distribution of weeds, crop and soil.

Through the supervised classification of spectral indices, the coverage percentages in each of the classes were determined.

In the study area, herbs cover 20 %, while the more developed weeds 18 % of the cultivation area.

By knowing the exact location of the weeds, it is also possible to determine the surface they occupy, which contributes to programming control treatments in specific sites with the precision of the amount of herbicides that must be applied and consequently in reducing economic costs. and environmental as established by precision agriculture.

---

*End of English Version*

---

detectando las distintas coberturas del uso del suelo, y sobre todo las malezas dentro de los cultivos, lo

cual es un importante desafío para la agricultura de precisión (De Castro *et al.*, 2020).

#### Cuadro 4. Valores de las áreas cubiertas por el método de clasificación supervisada.

**Table 4. Values of the areas covered by the supervised classification method.**

Clase	Área (m <sup>2</sup> )	Porcentaje (%)
Suelo	7.030,83	32
Hierba	4.232,79	20
Maíz	6.487,73	30
Maleza desarrollada	3.879,85	18

## Conclusión

De los índices analizados el NGRDI “Índice de Diferencia Normalizada Verde-Rojo” fue el que logró mostrar de manera más eficiente la distribución espacial de las malezas, el cultivo y el suelo.

Mediante la clasificación supervisada de los índices espectrales se determinó los porcentajes de cobertura en cada una de las clases.

En la zona de estudio las hierbas cubren el 20%, mientras que la maleza más desarrollada el 18% del área de cultivo.

Al conocer la ubicación exacta de las malezas también se logra determinar la superficie que estas ocupan, lo cual contribuye a programar tratamientos de control en sitios específicos con la precisión de la cantidad de herbicidas que debe ser aplicado y consecuentemente en la disminución de los costos económicos y ambientales según lo establece la agricultura de precisión.

## Literatura citada

- Adão, T., J. Hruška, L. Pádua, J. Bessa, E. Peres, R. Morais and J. Sousa. 2017. Hyperspectral Imaging: A Review on UAV-Based Sensors, Data Processing and Applications for Agriculture and Forestry. Journal Remote Sens. 9(11), 2-30.
- ArcGIS. 2016. Método de clasificación. Plataforma de representación cartográfica. Disponible en: <https://doc.arcgis.com/es/maps-for-office/4.0/design-and-use/classification-methods.htm>. Fecha de consulta: agosto 2020.
- Barrera, O. and S. Perdomo. 2018. RGB and multispectral UAV image fusion for Gramineae weed detection in rice fields. Journal Precision Agric. 19, 809–822.
- Berrío, V., J. Mosquera y D. Alzate. 2015. Uso de drones para el análisis de imágenes multiespectrales en agricultura de precisión. Rev. Cienc. Tec. Aliment. 13(1), 28-40.
- Campos, J., M. Gallart, J. Llop, R. Salcedo, P. Ortega, E. Armengol y E. Gil. 2019. Comprobación de un sistema de aplicación variable basado en mapas de vegetación obtenidos con un vehículo aéreo no tripulado (UAV).

- Huesca. Universidad Politécnica de Cataluña. X Congreso Ibérico de Agroingeniería. Disponible en: <https://zaguán.unizar.es/record/84473/files/3431.pdf>. Fecha de consulta: marzo 2020.
- Castillejo-González, I., Peña-Barragán, J., Jurado-Expósito, M., Mesas-Carrascosa, F., and López-Granados, F. 2014. Evaluation of pixel- and object-based approaches for mapping wild oat (*Avena sterilis*) weed patches in wheat fields using QuickBird imagery for site-specific management. European Journal of Agronomy. 59(3), 57-66.
- Cevallos, H., L. Vargas y J. Vargas. 2019. Uso de índices espectrales en la agricultura de precisión: caso de estudio campus de la Facultad Técnica de Machala. Rev. Alternativas. 19(1), 71-79.
- De Castro, A., J. Peña, J. Torres, F. Jiménez, F. Valencia, J. Recasens and F. López. 2020. Mapping *Cynodon Dactylon* Infesting Cover Crops with an Automatic Decision Tree-OBIA Procedure and UAV Imagery for Precision Viticulture. Remote Sensing of Environment. 12(56), 2-23.
- Franzini, M., G. Ronchetti, G. Sona and V. Casella. 2019. Geometric and radiometric consistency of Parrot Sequoia multispectral images for precision agricultural applications mdpi magazine. Journal Appl. Sci., 9(24), 1-24.
- Filella, I. and J. Penuelas. 1994. The red edge position and shape as indicators of plant chlorophyll content, biomass and hydric status. Journal Remote Sens., 15(7), 1459-1470.
- Jiménez, Á., D. Camargo y D. García. 2020. Sistema inteligente para el manejo de malezas en cultivos de piña con conceptos de agricultura de precisión. Rev. Cienc. y Agric. 17(3), 122-136.
- Kharuf, S., L. Hernández, R. Orozco, O. Aday y I. Delgado. 2018. Análisis de imágenes multiespectrales adquiridas con vehículos aéreos no tripulados. Rev. Ing. Elec. Autom. Comun. 39(2), 79-91.
- Lárraga, H., A. Piedad, D. Hernández y E. Guerrero. 2019. Modelo de clasificación espacial de textura aplicada a unidades de vegetación. Rev. Teetzapic. 5(2), 29-39.
- Li, F., Y. Miao, G. Feng, F. Yuand, S. Yaea and X. Gaoa. 2014. Improving estimation of summer maize nitrogen status with red edge-based spectral vegetation indices. Journal Field Crops Research, 157, 111-123.
- Martínez, N., y E. Barrera. 2020. Ecofisiología de la germinación de tres malezas efímeras periurbanas en Morelia, Michoacán, México. Rev. La Granja. 31(1), 47-55.
- Muñoz, P. 2013. Índices de vegetación. Apuntes de Teledetección. Disponible en: <http://bibliotecadigital.ciren.cl/bitstream/handle/123456789/26389/Tema%20Indices%20de%20vegetacion%20C3%20B3n%20C%20Pedro%20Mu%C3%B1oz%20A.pdf?sequence=1&isAllowed=y>. Fecha de consulta: julio del 2020.
- Páliz, C., M. Vera, M. Goyes, F. Beltrán y M. López. 2019. Costes, beneficios y rentabilidad en el cultivo de maíz. Primera Edición. Centro de Investigación y Desarrollo Profesional Babahoyo, 94p.
- Parrot Drone SAS. 2019. Parrot Sequoia. Manual de Especificaciones Técnicas. Disponible en: [http://www.uavseñefly.cl/PDF/Ficha\\_Tecnica\\_Sequoia\\_V2.pdf](http://www.uavseñefly.cl/PDF/Ficha_Tecnica_Sequoia_V2.pdf). Fecha de consulta: febrero 2020.
- Peña, J., J. Torres-Sánchez, A. Serrano y F. López. 2014. Detección de malas hierbas en girasol en fase temprana mediante imágenes tomadas con un vehículo aéreo no tripulado (UAV). Rev. de Teledet. 42(1), 39-47.
- Pérez, L., C. Castañeda, M. Ramos y J. Tafoya. 2014. Control químico preemergente de la maleza en tomate de cáscara. Rev. Interciencia, 39(6), 422-427.
- Pix4D SA. 2019. Pix4D Mapper. Software en fotogrametría para mapeo profesional con drones. Disponible en: <https://www.pix4d.com/es/producto/pix4dmapper-fotogrametria-software>. Fecha de consulta: marzo 2020.
- Polanco, J. 2012. Teledetección de la vegetación del páramo de Belmira

- con imágenes Landsat. Rev. DYNA, 79(171), 222-231.
- Qi, J., A. Chehbouni, A. Huete, Y. Kerr and S. Sorooshian. 1994. A Modified Soil Adjusted Vegetation Index. *Remote Sens. Environ.* 48, 119-126.
- Radoglou, P., P. Sarigiannidis, T. Lagkas and L. Moscholios. 2020. A Compilation of UAV Applications for Precision Agriculture. *Journal Computer Networks* 172, 1-18
- Rouse, J., Haas, R., Schell, J., and Deering, D. 1973. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. Index DataBase. Disponible en: <https://www.indexdatabase.de/db/r-single.php?id=675>. Fecha de consulta: mayo del 2020.
- Saavedra, D., A. Cubillos, L. Machado, V. Murcia y D. Méndez. 2018. Análisis de índices de vegetación en el cultivo de arroz en la finca La Tebaida del Municipio de Campoalegre. *Rev. La Angostura*. 5(5), 19-28.
- Santana, F., S. Trueba, A. Villafuerte, W. Vera, C. Bravo y R. Bravo. 2020. Evaluación de la selectividad del herbicida Pledge, en mezcla con pre-emergentes en el cultivo de maíz (*Zea mays L.*). *Rev. Cienc. e Inv.* 5(1), 75-89.
- SenseFly a Parrot Company. 2018. The advanced agricultural drone. Handbook. Disponible en: <https://geo-matching.com/uploads/default/m/i/migrationpv4pzg.pdf>. Fecha de consulta: febrero 2020.
- Sishodia, R., R. Ray and S. Singh. 2020. Applications of Remote Sensing in Precision Agriculture: A Review. *Journal Remote Sens.* 12(19), 2-31.
- Song, B. and K. Park. 2020. Detection of Aquatic Plants Using Multispectral UAV Imagery and Vegetation Index. *J. Remote Sens.* 12, 2-16.
- Stott, E., R. Williams and T. Hoey. 2020. Ground Control Point Distribution for Accurate Kilometre-Scale Topographic Mapping Using an RTK-GNSS Unmanned Aerial Vehicle and SfM Photogrammetry. *Journal Drones*. 4(55), 1-21.
- Wu, W., W. Al-Shafie, A. Mhaimeed, F. Ziada, V. Nangia and W. Payne. 2014. Soil Salinity Mapping by Multiscale Remote Sensing in Mesopotamia, Iraq. *IEEE J. Sel. Top. App. Earth Obs. Remote Sens.*, 7(11), 4442-4452.
- Yang, C. 2020. Precision agricultural technologies and remote sensing for the detection and management of crop diseases with a practical application example. *Journal Engineering*. 6(5), 528-532.