

## DETECCIÓN DE MALEZAS POR MEDIO DEL RECONICIMIENTO DE COLOR Y SU INTEGRACIÓN EN UNA APLICACIÓN MÓVIL

### WEED DETECTION THROUGH COLOR RECOGNITION AND ITS INTEGRATION INTO A MOBILE APP

Duque-Vazquez, E.F.<sup>1</sup>; Rostro-Gonzalez, H.<sup>2</sup>; Sánchez-Yáñez, R.E.<sup>2</sup>; Saldaña-Robles, N.<sup>1</sup>; Cepeda-Negrete, J.<sup>1\*</sup>

<sup>1</sup>*División de Ciencias de la vida Campus Irapuato-Salamanca, Universidad de Guanajuato. Ex Hacienda El Copal k.m. 9; carretera Irapuato-Silao; A.P. 311; C.P. 36500; Irapuato,*

<sup>2</sup>*División de Ingenierías Campus Irapuato-Salamanca, Universidad de Guanajuato. Carretera Salamanca - Valle de Santiago Km. 3.5 + 1.8; Comunidad de Palo Blanco; Salamanca, Gto.*

\* *E-mail: j.cepeda@ugto.mx (autor por correspondencia)*

Fecha de envío: 05, enero, 2023

Fecha de publicación: 30, junio, 2023

#### Resumen:

Las malezas son uno de los mayores problemas en la agricultura a nivel mundial, ya que compiten por luz, nutrientes del suelo y otros componentes esenciales para el correcto crecimiento de los cultivos. Las técnicas utilizadas para garantizar el apropiado desarrollo de los cultivos han generado consecuencias negativas para el medio ambiente y la salud, debido al uso excesivo de fertilizantes. Por esta razón, la agricultura moderna ha implementado procesos tecnificados que permiten mejorar la productividad y competitividad del cultivo. La inteligencia artificial ha surgido como una alternativa para solucionar problemas en diferentes sectores industriales, pero su uso en la agricultura es limitado. Por lo tanto, la implementación y desarrollo de una aplicación para dispositivos móviles que permita la detección de malezas en terrenos listos para cultivar representa un gran aporte para el sector agrícola. En la metodología propuesta, se muestra un análisis por color en el espacio CIELAB de un conjunto de imágenes de malezas verdes. Se graficaron todas las tonalidades de la maleza analizada y se clasificaron a través de paralelepípedos rectangulares. Posteriormente, se describe el desarrollo de una aplicación móvil para Android, la cual cuenta con tres funciones: detección de maleza mediante una imagen, video en tiempo real, o selección desde la galería de imágenes. El rendimiento del algoritmo desarrollado se evaluó con tres algoritmos de segmentación Mean Shift, Fuzzy C-Means, K-Means y Otsu, usando la métrica NPR. Los resultados obtenidos indican que el algoritmo desarrollado es el mejor en comparación con los algoritmos de referencia. Además, se presentan capturas de pantalla de la interfaz de usuario de la aplicación. La aplicación desarrollada tiene la intención de ser útil para personas involucradas en el área agrícola que buscan detectar automáticamente malezas en sus terrenos, lo que simplifica su trabajo. Con este aporte, el trabajo en la agricultura se vuelve más eficiente y menos complicado.

**Palabras clave:** maleza, CIELAB, paralelepípedos, aplicación móvil, segmentación

### **Abstract:**

Weeds are one of the biggest problems in agriculture worldwide, as they compete for light, soil nutrients, and other essential components for the proper growth of crops. Techniques used to ensure appropriate crop development have generated negative consequences for the environment and health due to excessive use of fertilizers. For this reason, modern agriculture has implemented technified processes that allow for improved productivity and competitiveness of crops. Artificial intelligence has emerged as an alternative to solving problems in various industrial sectors, but its use in agriculture is limited. Therefore, the implementation and development of a mobile application that allows for the detection of weeds in ready-to-cultivate lands represents a significant contribution to the agricultural sector. The proposed methodology shows a color analysis in the CIELAB space of a set of green weed images. All shades of the analyzed weeds were plotted and classified through rectangular parallelepipeds. Subsequently, the development of a mobile application for Android is described, which includes three functions: weed detection through an image, real-time video, or selection from the image gallery. The performance of the developed algorithm was evaluated with three segmentation algorithms: Mean Shift, Fuzzy C-Means, K-Means, and Otsu, using the NPR metric. Results indicate that the developed algorithm is the best in comparison to reference algorithms. Additionally, user interface screenshots of the application are presented. The developed application is intended to be useful for people involved in agriculture who seek to automatically detect weeds in their fields, which simplifies their work. With this contribution, work in agriculture becomes more efficient and less complicated.

**Keywords:** weed, CIELab, parallelepipeds, mobile app, segmentation.

### **INTRODUCCIÓN**

Una gran problemática en los cultivos y suelos mexicanos e internacionales, son las malezas (Osorio-Burgos, 2021). La maleza es un tipo de planta que crece en el suelo junto con las plantas de cultivo, estas plantas no deseadas agotan los nutrientes, agua y espacio asignado para el cultivo previsto (Amaya, 2018). Finalmente, causa una gran reducción en el rendimiento del cultivo, interfiere con las operaciones agrícolas, deteriora la calidad y actúa como anfitrión alternativo para varias plagas y enfermedades de insectos. También, algunas malezas liberan sustancias tóxicas que afectan el crecimiento del cultivo (Karam y Brighenti, 2022).

Las técnicas utilizadas para garantizar el apropiado crecimiento de los cultivos han desencadenado consecuencias tanto al medio ambiente como a la salud, debido al uso excesivo de fertilizantes (Gómez-Ramos, 2020). Así mismo, afectan al laboreo constante del suelo con maquinaria (Pannacci y Tei, 2014; Annett et al., 2013).



Esto conlleva a implementar en la agricultura moderna, procesos tecnificados que permitan mejorar la productividad y competitividad del cultivo. Para lograrlo se integran tecnologías como el aprendizaje de máquina (Wang, 2019), sistemas de posicionamiento global (GPS) (Asha, 2022), sensores (Rosle, 2021) y sistemas de información.

El control mecánico presenta una gran demanda a nivel mundial, debido a las restricciones aplicadas por los gobiernos y a la necesidad de aportar una solución más eficiente para el control de maleza (Melander et al., 2015). Dichas soluciones se presentan en el uso de máquinas de labranza que afectan de diferente forma el desarrollo de la maleza, puesto que usualmente las herramientas efectúan un desraizado, corte y posterior reincorporación de los desechos al suelo, perturbando la supervivencia y competitividad de esta frente al cultivo. Del mismo modo, la intervención mecánica en el suelo promueve la germinación de especies, ya que modifica y moldea la estructura del terreno, permitiendo la circulación del aire y agua, las cuales favorecen al desarrollo del cultivo (Lundkvist y Verwijst, 2011).

La implementación de visión computacional en la agricultura permite trabajar en tiempo real otorgando al mecanismo la capacidad de identificar y clasificar las especies de maleza que se encuentran en el cultivo (Slaughter et al., 2008). El departamento de biología e ingeniería agrícola de la Universidad de California llevó a cabo en el 2012 una investigación del uso de imágenes hiperespectrales para la identificación de dos especies de maleza predominantes en un cultivo de tomate (Zhang et al., 2012). Este sistema fue acoplado a un actuador de propulsión a chorro el cual a través de microdosificación aplicaba aceite orgánico a alta temperatura, logrando con exactitud el control del 90% de las especies de maleza. Otros aspectos importantes que la visión computacional puede cubrir para la mejor producción de artículos agrícolas son:

- Control de calidad en la producción de alimentos,
- Automatización de cosechadoras y sembradoras,
- Medición automática del área foliar en diversas plantas para predecir su rendimiento,
- Medición de color no destructivo en productos agrícolas para su correlación con sus propiedades fisicoquímicas y su deterioro.



Desafortunadamente, la detección de malezas no ha sido ampliamente abordado mediante la visión computacional. Esto se debe principalmente, al temor en la manipulación de nuevas tecnologías por parte del personal agrícola tradicional. Aunque se ha observado, que actualmente es más sencillo para las personas manipular un dispositivo móvil debido a su fácil acceso por la reducción en los costos.

De acuerdo a lo mencionado, en este trabajo se propone una metodología para la detección automática de malezas verdes de forma computacional y mediante un algoritmo simple y rápido. Además, se desarrolla una aplicación para dispositivos móviles como una herramienta fácil de usar a los agricultores o personas en general que estén interesados en el tema.

En el resto del artículo se describirá el algoritmo desarrollado para la detección de malezas verdes. También se analizan los resultados cuantitativos de nuestra propuesta comparados con metodologías existentes. Por último, se discutirán los resultados cualitativos de la aplicación desarrollada para dispositivos móviles.

## **MATERIALES Y MÉTODOS**

El proceso llevado a cabo en este trabajo consta de dos fases, desarrollo de un algoritmo para la segmentación por el color de una maleza y desarrollo de una aplicación móvil en el entorno Android, los cuales son descritos en esta sección.

### **Desarrollo del algoritmo de segmentación**

La primera etapa consta del desarrollo de un algoritmo de segmentación por color para el cual se usó el espacio de color CIELAB. Normalmente las imágenes que son capturadas desde un dispositivo fotográfico se obtienen en un formato RGB, en este trabajo se hace una transformación a CIELAB por la facilidad que este espacio de color ofrece para analizar los colores presentes en la imagen con características de luminosidad diferentes.



## Espacio CIELAB

El espacio de color CIE 1976 ( $L^*$ ,  $a^*$ ,  $b^*$ ) es un espacio de color perceptualmente uniforme y fue propuesto por la CIE en 1976 (Schanda, 2007). Para la conversión de RGB a CIELAB, los datos primero son transformados al espacio CIEXYZ. Para transformar una imagen de RGB a CIEXYZ, el espacio RGB usado necesita establecerse. Aquí, sRGB es usado porque se basa en un espacio calibrado en colorimetría RGB (Stokes et al, 1996). Se aplica (1) donde  $\{R, G, B\} \in [0,1]$  son las componentes de color normalizadas. Los números de la matriz de conversión a continuación son exactos, con el número de dígitos especificado en los estándares CIE (Fairman, 1997).

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.412 & 0.357 & 0.180 \\ 0.212 & 0.715 & 0.072 \\ 0.019 & 0.119 & 0.950 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (1)$$

El espacio de color CIELAB es calculado desde CIEXYZ usando (2)-(5), para obtener cada una de las componentes.

$$L^* = 116f\left(\frac{Y}{Y_n}\right) - 16, \quad (2)$$

$$a^* = 500 \left[ f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right], \quad (3)$$

$$b^* = 200 \left[ f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right], \quad (4)$$

$$f(t) = \begin{cases} t^{\frac{1}{3}} & \text{si } t > \sigma^3 \\ \frac{t}{3\sigma^2} + \frac{16}{116} & \text{si } t \leq \sigma^3 \end{cases} \quad (5)$$

## Etapas de entrenamiento

Se creó una base de datos de malezas de tal manera que obtuvieran las diferentes tonalidades en verde que comúnmente suele tomar (Figura 1).



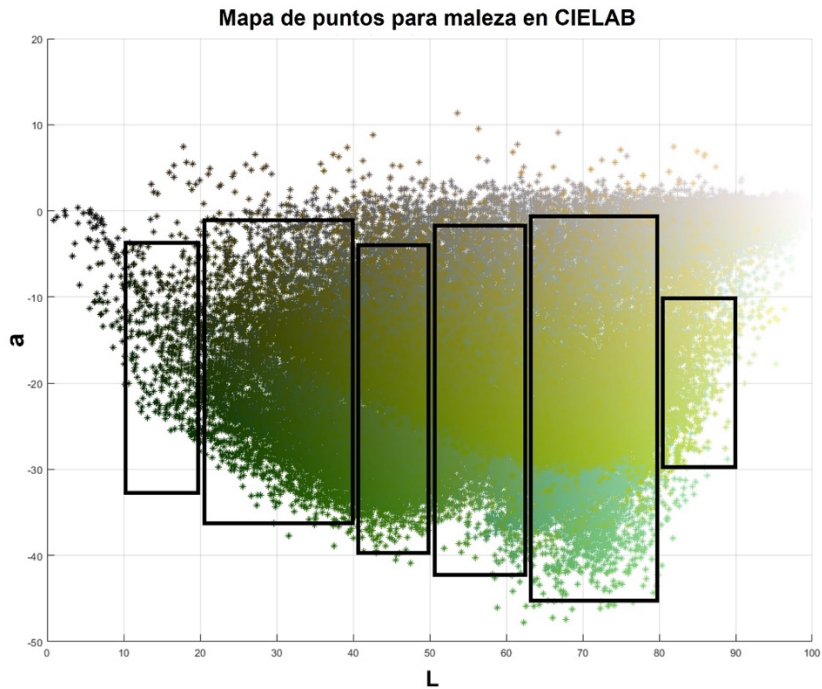


**Figura 1.** Imágenes de las malezas que fueron usadas en el entrenamiento.

**Figure 1.** Images of the weeds that were used in the training.

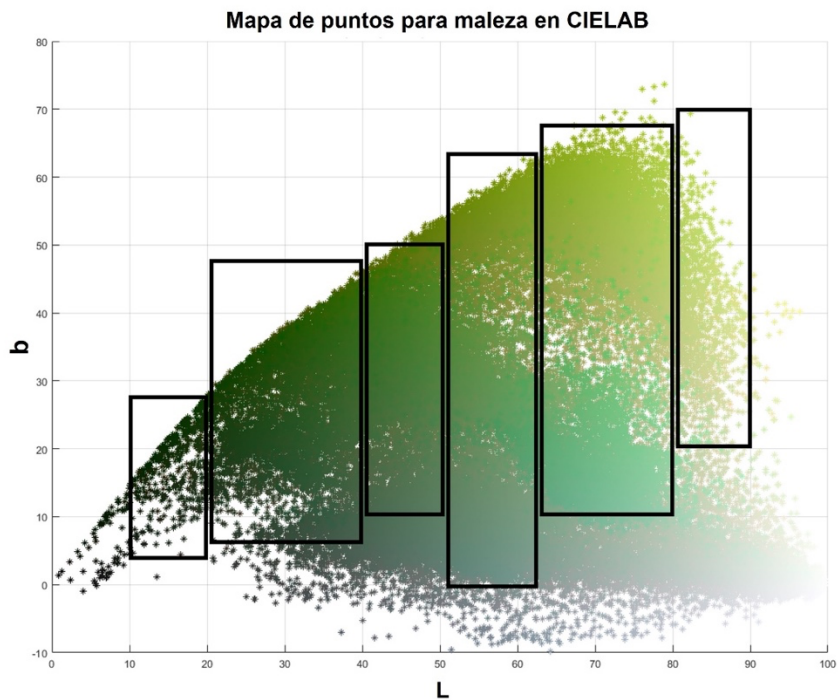
Paso siguiente, se construyó un mapa de puntos usando las intensidades de cada píxel a fin de observar los distintos tipos de luminosidad del color verde, con esto se procedió a la creación de varios paralelepípedos mediante experimentación por prueba y error con la componente  $L$  para encontrar los valores aproximados en los canales  $a$  y  $b$ . Las Figuras 2 y 3, muestran los seis paralelepípedos creados usando como referencia la componente  $a$  (Figura 2) y  $b$  (Figura 3), que encierran las diferentes tonalidades que la maleza puede tomar en color verde. En el eje  $L$ , en cada gráfica, los valores van desde 10 (tonalidades de verde oscuras), hasta 90 (tonalidades de verde claros).

Al localizar los rangos de la componente en  $L$ , se creó una máscara (imagen en blanco y negro), en donde si el valor de los canales ( $L$ ,  $a$ ,  $b$ ) del píxel en la imagen a analizar está entre los rangos de algún paralelepípedo, el píxel toma un valor de 1, de otra forma toma un valor de 0. A este proceso lo podemos considerar como nuestra binarización o etiquetado de la imagen, recordando que negro (cero) no corresponde a maleza, y blanco (uno) sí corresponde a la misma.



**Figura 2.** Gráfica del mapeo de datos dividida en intervalos entre las componentes  $L$  y  $a$ .

**Figure 2.** A graph of the data mapping divided into intervals between the  $L$  and  $a$  components.



**Figura 3.** Gráfica del mapeo de datos dividida en intervalos entre las componentes  $L$  y  $b$ .

**Figure 3.** A graph of the data mapping divided into intervals between the  $L$  and  $b$  components.



## Metodología de la aplicación móvil

Habiendo desarrollado el algoritmo que detecta las malezas por color, se procedió a la implementación del algoritmo de la aplicación móvil, tomando en cuenta el siguiente orden:

1. Conversión de la imagen capturada por el dispositivo del formato *uint8* a *double* y normalización.
2. Conversión de *RGB* a *CIELab*.
3. Segmentación de la imagen por el algoritmo desarrollado.
4. Uso de operaciones morfológicas para mejorar la segmentación.
5. Sobre posición de la imagen original sobre la imagen obtenida del algoritmo de segmentación.

Finalmente, en la Figura 4 se muestra un diagrama de bloques con el proceso completo llevado a cabo.

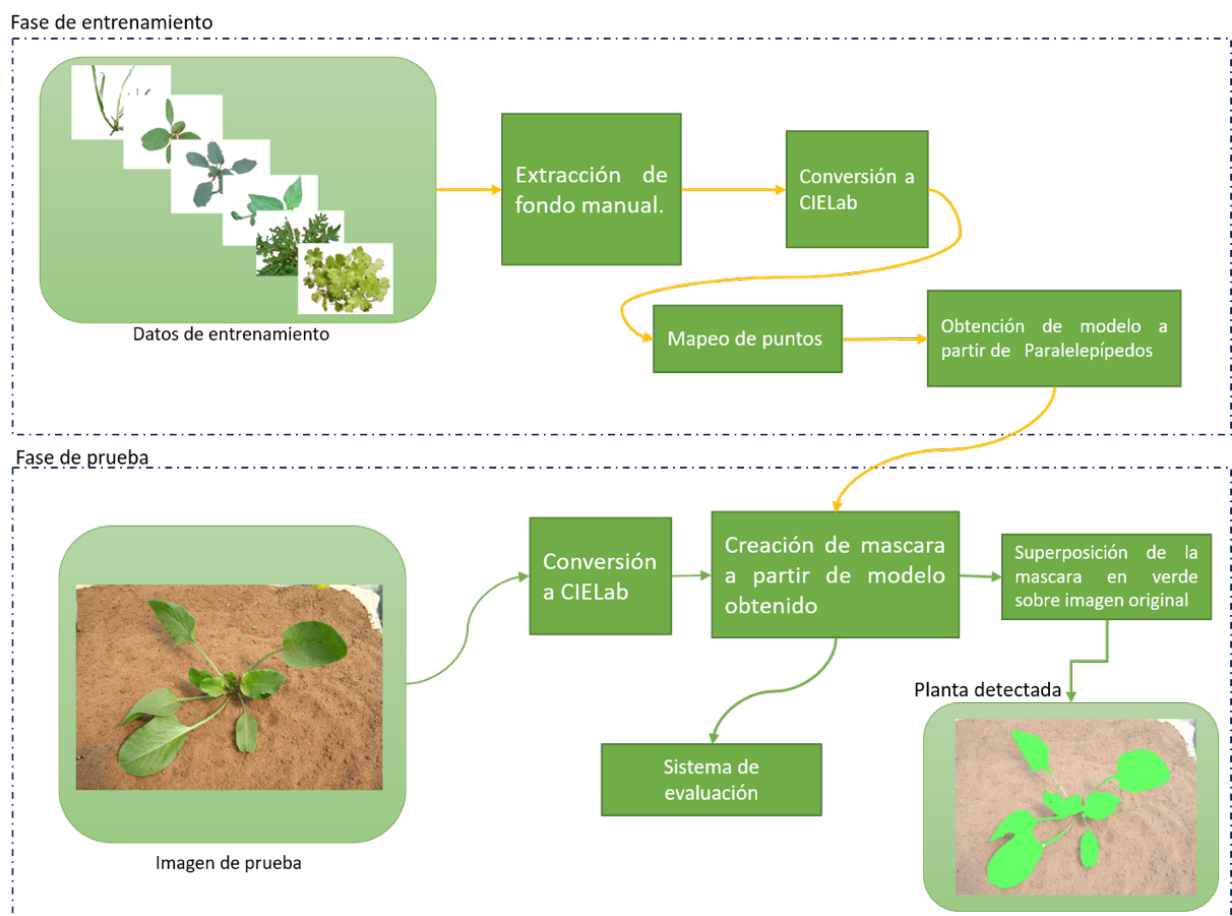


Figura 4. Diagrama de bloques de la aplicación desarrollada.

Figure 4. Block diagram of the developed application.



El desarrollo de la aplicación móvil fue llevado a cabo mediante los siguientes softwares: Android Studio, OpenCV y OpenCV Manager.

La interfaz de la aplicación móvil se añadió el logo de la aplicación y en la parte inferior de la interfaz se agregaron cuatro botones:

- Botón Capturar: Botón parte superior izquierda, su función principal es capturar una imagen para después ser procesada por el algoritmo ya creado.
- Botón Examinar: Botón parte superior derecha, su función principal es examinar en la galería la imagen deseada para posteriormente el usuario la seleccione y pueda ser procesada por el algoritmo ya creado.
- Botón Tiempo Real: Botón inferior izquierda, su función principal es procesar por el algoritmo ya creado la imagen captada por la cámara en tiempo real.
- Botón Info: Botón inferior derecha, su función es proporcionar información sobre la aplicación.

## RESULTADOS Y DISCUSIÓN

### Evaluación del algoritmo propuesto

Para evaluar el rendimiento del algoritmo desarrollado, se utilizaron 100 imágenes distintas a las empleadas durante la etapa de entrenamiento descrita en la metodología. Para cada una de estas 100 imágenes, se elaboró una "verdad de referencia" mediante la eliminación manual del fondo, lo que permitió obtener una imagen que mostraba únicamente la maleza de interés. Posteriormente, se aplicó un proceso de umbralización para obtener una imagen binaria con dos colores: blanco para la maleza de interés y negro para el fondo. Se puede observar un ejemplo de esta imagen binaria en la Figura 5.



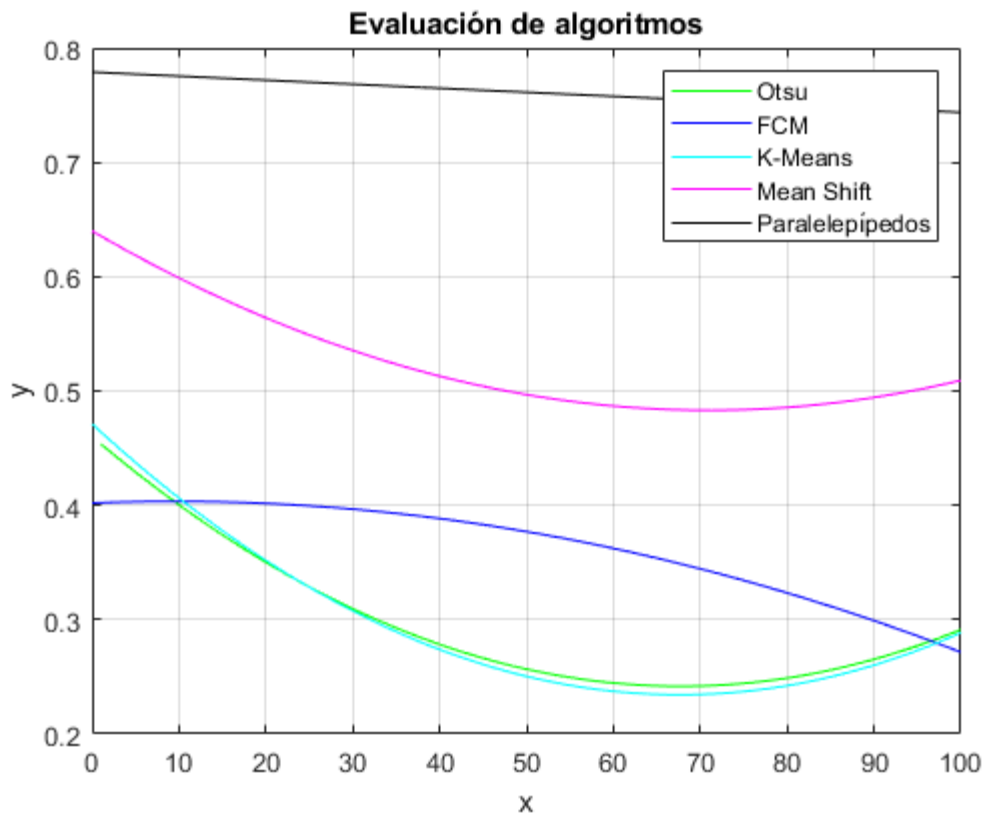


**Figura 5.** Ejemplo de seis imágenes usadas en la evaluación. a) Imágenes con el fondo extraído manualmente, b) binarización de a).

**Figure 5.** Example of six images used in the evaluation. a) Images with manually extracted background, b) Binarization of a)

Se consideraron cuatro algoritmos de segmentación en la evaluación: Mean Shift (Ball & Hall, 1967), K-Means (MacQueen, 1967), Fuzzy C-Means (Cannon, 1986) y la umbralización de Otsu (Otsu, 1979). Para ello, se segmentaron las 100 imágenes de malezas utilizando cada uno de los algoritmos mencionados, así como el algoritmo propuesto en este trabajo. Posteriormente, se compararon las imágenes resultantes de cada segmentación con la "verdad de referencia" mediante el uso de la métrica NPR. Cabe señalar que si los valores obtenidos de la métrica eran cercanos a 1, esto indicaba una alta similitud entre la imagen segmentada y la referencia. En caso contrario, si los resultados de la métrica eran cercanos a 0, la similitud entre ambas era nula.

Para observar el comportamiento de los resultados obtenidos mediante la métrica NPR, se utilizó una gráfica de tendencia en la que se empleó un polinomio de segundo grado (véase Figura 6). El objetivo de esta gráfica fue simplificar la visualización de los valores obtenidos de la métrica NPR para cada uno de los algoritmos evaluados. En ella, se puede apreciar una menor precisión en la tendencia de los algoritmos propuestos para la evaluación, en comparación con el algoritmo desarrollado. Esta diferencia en precisión se debe a que el algoritmo propuesto fue diseñado específicamente para detectar un objeto en particular, mientras que los demás algoritmos utilizan una metodología más "genérica" para detectar objetos.



**Figura 6.** Gráfica da ajuste polinomial de grado 2 de los resultados entre los algoritmos tradicionales de segmentación y el algoritmo propuesto contra las imágenes de referencia.

**Figure 6.** Graph showing the second-degree polynomial fit of the results between traditional segmentation algorithms and the proposed algorithm against the reference images.

Con el objetivo de resumir los valores obtenidos en las comparaciones, se emplearon cuatro medidas estadísticas: promedio, mediana, trimedia y desviación estándar, las cuales se presentan en la Tabla 1. Se observa que el algoritmo propuesto supera de manera contundente a los algoritmos tomados como referencia en cada una de estas medidas. En segundo lugar, se encuentra el algoritmo Mean Shift, el cual, en promedio, presenta mejores resultados en contraste con los demás algoritmos de segmentación evaluados. Es importante destacar que no todos los algoritmos son perfectos, algunos suelen ser más efectivos para cierto tipo de imágenes. En este caso, el algoritmo propuesto demuestra ser efectivo para la mayoría de las imágenes evaluadas.

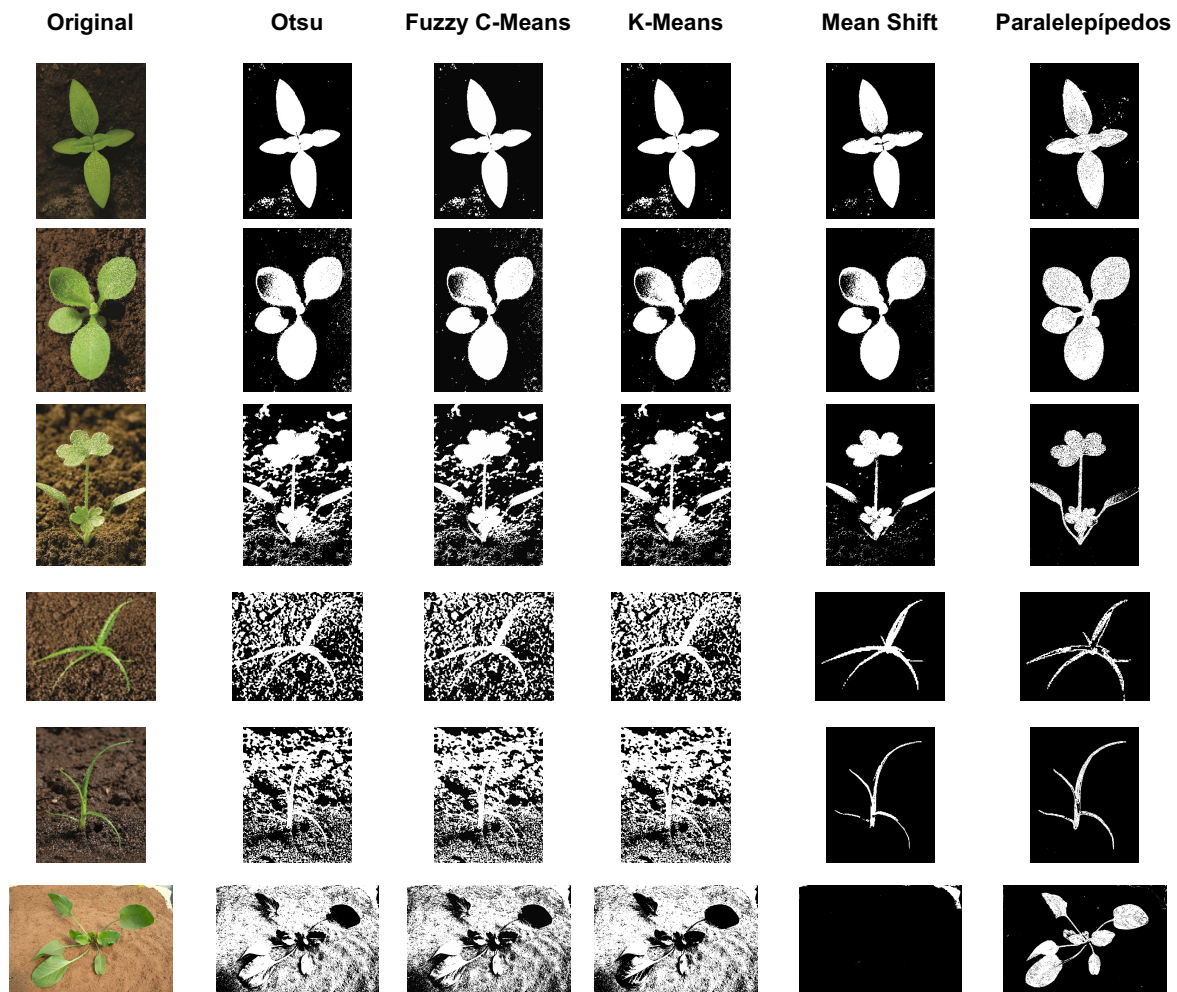
**Tabla 1.** Resultados estadísticos de la comparación de cada uno de los algoritmos contra las imágenes de referencia usando la métrica NPR.

**Table 1.** Comparison of statistical results of traditional algorithms and our proposed algorithm against reference images using the NPR metric.

<b>Algoritmo</b>	<b>Promedio</b>	<b>Mediana</b>	<b>Trimedia</b>	<b>Desviación estándar</b>
<b>Otsu</b>	0.2955	0.1872	0.2106	0.2935
<b>Fuzzy C-Means</b>	0.3629	0.3403	0.3435	0.2446
<b>K-Means</b>	0.2926	0.1840	0.2068	0.2935
<b>Mean Shift</b>	0.5221	0.6157	0.5644	0.3496
<b>Paralelepípedos</b>	<b>0.7610</b>	<b>0.8146</b>	<b>0.8052</b>	<b>0.1780</b>

A continuación, se muestra una galería de seis imágenes pertenecientes al conjunto usado en la evaluación del algoritmo, donde se pueden observar los resultados obtenidos por cada método (Figura 7). Cada columna representa: la imagen original, los resultados de la metodología Otsu, los resultados del algoritmo Fuzzy C-Means, los resultados del algoritmo K-Means, los resultados del algoritmo Mean Shift y los resultados del algoritmo propuesto. Es importante destacar que cuando el color de la maleza resalta en comparación con el fondo, cualquier algoritmo puede detectarla correctamente. El problema surge cuando el color de fondo es más contrastante que el de la maleza, momento en que los algoritmos Otsu, Fuzzy C-Means y K-Means suelen fallar, mientras que el algoritmo propuesto se destaca.







**Figura 7.** Galería de seis imágenes con sus respectivos resultados.

**Figure 7.** Gallery of six images with their respective results.

### Resultados de la aplicación


La Figura 8, muestran la interfaz de la aplicación desarrollada. La aplicación desarrollada se probó en las versiones Android 6 Marshmallow (Android Studio, 2019a), Android 8.0 Oreo (Android Studio, 2019b) y Android 9 Pie (Android Studio, 2019c), en las cuales funcionó de forma correcta. Para un funcionamiento adecuado de la aplicación, se debe instalar una aplicación llamada openCVManager. Cuando se inicia la aplicación móvil por primera vez, se comprueba si se ha instalado la aplicación mencionada. Si no es el caso, la aplicación redirigirá a una página web donde el usuario podrá descargar e instalar la versión correspondiente de la aplicación a su dispositivo.



**Figura 8.** Interfaz de usuario de la aplicación móvil desarrollada.

**Figure 8.** User interface of the developed mobile application.

A continuación, se describe el funcionamiento de cada uno de los elementos dentro de la interfaz de usuario de la aplicación desarrollada. Cuando el usuario presionó el botón capturar, la aplicación mostrará la cámara del dispositivo, con la cual, se podrá tomar una fotografía de la maleza de interés. La aplicación mostrará la galería cuando el botón examinar sea pulsado, desde ahí se podrá elegir una imagen de interés a analizar. Si la elección es el botón RealTime, se podrá detectar la maleza en tiempo real (video). La Figura 9, muestra una captura de pantalla del funcionamiento de la función RealTime.



**Figura 9.** Captura de pantalla del funcionamiento de la función RealTime. a) Escena antes del procesamiento, b) Procesamiento de la escena en tiempo real.

**Figure 9.** Screenshot of the RealTime function in action. a) Scene before processing, b) Real-time processing of the scene.

Por último, se tomó como referencia la imagen binarizada del algoritmo propuesto para desplegar la imagen resultado en la aplicación. Se comprobó píxel a píxel si existía el valor 1 (color blanco). Si el valor 1 existía, el píxel tomaba un color verde sobre la imagen original, mostrando la maleza detectada, en caso contrario, se tomaban los valores de la imagen original (Figura 10).



**Figura 10.** Algoritmo de segmentación por paralelepípedos. a) Maleza, b) maleza procesada por el algoritmo propuesto resaltado con un color verde.

**Figure 10.** Parallelepiped segmentation algorithm. a) Weeds, b) Weeds processed by the proposed algorithm highlighted in green.

## CONCLUSIÓN

En conclusión, el algoritmo desarrollado en este trabajo ha demostrado ser una herramienta efectiva para detectar malezas en imágenes agrícolas. La elección del espacio de color CIELAB resultó esencial para abordar el desafío de la variabilidad de la iluminación en las imágenes. Además, la visualización de los datos a través de gráficas y la creación de paralelepípedos permitieron una mejor comprensión y clasificación de las malezas. La aplicación desarrollada tiene como objetivo ser útil para agricultores y profesionales del sector, permitiéndoles detectar de manera automática las malezas en sus terrenos y mejorar su trabajo de forma sencilla y eficiente. La posibilidad de utilizar algoritmos más complejos como las redes neuronales convolucionales o cualquier otro método basado en el aprendizaje ofrece la oportunidad de mejorar aún más la capacidad de detección de la aplicación. En resumen, este trabajo proporciona una base sólida para futuras investigaciones en la detección automática de malezas en imágenes agrícolas.

## Agradecimientos

Edgar Francisco Duque Vazquez agradece al Consejo Nacional de Ciencia y Tecnología, CONACyT, por el apoyo proporcionado por medio de la beca escolar (CVU 1081409).

## LITERATURA CITADA

- Amaya, A., Santos, M., Morán, I., Vargas, P., Comboza, W., & Lara, E. (2018). Malezas presentes en cultivos del cantón Naranjal, Provincia Guayas, Ecuador. *Investigatio*, (11), 1-16.
- Asha, K. R., Mahore, A., Malkani, P., Gaddikeri, V., Rathod, S. K., Satpute, A. N., & Stanly, N. M. (2022). An overview of Automation, Robotics, and Sensor-based Approaches in Weed Detection and Control. *Indian Journal of Ecology*, 49(6), 2140-2148.
- Android Studio, (2019). Marshmallow. Recuperado de: <https://www.android.com/versions/marshmallow-6-0/>.
- Android Studio Studio., (2019) 8.0 oreo. Recuperado de: <https://www.android.com/versions/oreo-8-0/>,
- Android Studio Studio., (2019) 9 pie. Recuperado de: <https://www.android.com/versions/pie-9-0/>.
- Annett, R., Habibi, H.R. & Hontela, A. (2014), Impact of glyphosate and glyphosate-based herbicides on the freshwater environment. *Journal of Applied Toxicology*, 34: 458-479. <https://doi.org/10.1002/jat.2997>.
- Ball, G. H., & Hall, D. J. (1967). A clustering technique for summarizing multivariate data. *Behavioral science*, 12(2), 153-155.
- Cannon, R. L., Dave, J. V., & Bezdek, J. C. (1986). Efficient implementation of the fuzzy c-means clustering algorithms. *IEEE transactions on pattern analysis and machine intelligence*, (2), 248-255.
- Fairman, H. S., Brill, M. H., & Hemmendinger, H. (1997). How the CIE 1931 color-matching functions were derived from Wright-Guild data. *Color Research & Application: Endorsed by Inter-Society Color Council, The Colour Group (Great Britain), Canadian Society for Color, Color Science Association of Japan, Dutch Society for the Study of Color, The Swedish Colour Centre Foundation, Colour Society of Australia, Centre Français de la Couleur*, 22(1), 11-23.
- Gómez-Ramos, M. Y., Ruiz-Castilla, J. S., & Garcia-Lamont, F. (2020). Clasificación de plantas de maíz y maleza: Hacia la mejora de la fertilización en México.
- Karam, D., & Brighenti, A. (2022). Identificación y control de malezas. Ministerio de agricultura, Pecuaria y Abastecimiento (MAPA), 97 – 103.
- Lundkvist, A., & Verwijst, T. (2011). Weed biology and weed management in organic farming. *Research in Organic Farming*, 10-41.



- MacQueen, J. (1967, June). Classification and analysis of multivariate observations. In 5th Berkeley Symp. Math. Statist. Probability (pp. 281-297). Los Angeles LA USA: University of California.
- Melander, B., Lattanzi, B., & Pannacci, E. (2015). Intelligent versus non-intelligent mechanical intra row weed control in transplanted onion and cabbage. *Crop Protection*, 72, 1-8.
- Osorio-Burgos, O., Salazar-Pinilla, L. C., & Cornejo-López, S. (2021). Identificación de malezas en el cultivo de ñame (*Dioscorea alata* L.). *Ciencia Agropecuaria*, (32), 51-70.
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66.
- Pannacci, E., & Tei, F. (2014). Effects of mechanical and chemical methods on weed control, weed seed rain and crop yield in maize, sunflower and soyabean. *Crop protection*, 64, 51-59. doi: 10.1016/j.cropro.2014.06.001.
- Rosle, R., Che'Ya, N. N., Ang, Y., Rahmat, F., Wayayok, A., Berahim, Z., ... & Omar, M. H. (2021). Weed detection in rice fields using remote sensing technique: A review. *Applied Sciences*, 11(22), 10701.
- Schanda, J. (Ed.). (2007). *Colorimetry: understanding the CIE system*. John Wiley & Sons.
- Singh, R., Srivastava, P., Singh P., Upadhyay, S., & Raghubanshi, A. (2019). Human overpopulation and food security: Challenges for the agricultura sustainability. In *urban agriculture and food systems: Breakthroughs in research and practice. IGI Global*, 439-467.
- Slaughter, D. C., Giles, D. K., & Downey, D. (2008). Autonomous robotic weed control systems: A review. *Computers and electronics in agriculture*, 61(1), 63-78.
- Stokes, M. A. (1996). *An introduction to tree-ring dating*. University of Arizona Press.
- Unnikrishnan, R., & Hebert, M. (2005). Measures of similarity. In 2005 Seventh IEEE Workshops on Applications of Computer Vision (WACV/MOTION'05)-Volume 1 (Vol. 1, pp. 394-394). IEEE.
- Wang, A., Zhang, W., & Wei, X. (2019). A review on weed detection using ground-based machine vision and image processing techniques. *Computers and electronics in agriculture*, 158, 226-240.
- Zhang, Y., Staab, E. S., Slaughter, D. C., Giles, D. K., & Downey, D. (2012). Automated weed control in organic row crops using hyperspectral species identification and thermal micro-dosing. *Crop Protection*, 41, 96-105.

