

Optimización del factor de dominancia de color para el segmentado de cultivos de jitomate.

Juan Pablo Guerra Ibarra
 Centro de Investigaciones en Óptica.
 León, Guanajuato, México
 juangi@cio.mx

Francisco Javier Cuevas de la Rosa
 Centro de Investigaciones en Óptica.
 León, Guanajuato, México
 fjcuevas@cio.mx

Abstract— La población a nivel mundial tiene una tendencia creciente, por lo tanto, los requerimientos para su sustentabilidad tienen el mismo comportamiento, en especial lo referente a la alimentación. La actividad agrícola es una de las principales productoras de alimentos para el ser humano, por ello desde sus inicios se ha beneficiado de los últimos desarrollos tecnológicos disponibles con el objetivo de aumentar su rendimiento. En años recientes, la aplicación de diferentes tipos de avances científicos en el cultivo de la tierra ha desarrollado un área de trabajo llamada agricultura de precisión. El proceso de análisis de datos en los sistemas de agricultura de precisión comienza con el filtrado de información. En el caso de que las fuentes de información disponibles sean imágenes, al proceso de filtrado se le llama segmentación. En este trabajo se presenta el proceso para la optimización del parámetro que acentúa la dominancia de color (α), lo que permite maximizar el resultado de la segmentación de hojas y frutos de plantas de jitomate medidos con la métrica IoU. Es importante que se desarrollen y perfeccionen los métodos de segmentado de imágenes, ya que los resultados de estos serán la base de sistemas de apoyo a la optimización de procesos y toma de decisiones en el ámbito agrícola.

Keywords—agricultura, segmentación de imágenes, umbrales, RGB, optimización

I. INTRODUCCIÓN

Para el ser humano la actividad agrícola es fundamental para la producción de alimentos, esta se ha desarrollado desde el principio de la civilización [1][2]. Se estima que la población mundial para el año 2050 sea de aproximadamente 10 billones, esto según datos de la Organización de las Naciones Unidas [3], por lo tanto, la producción de alimentos debe aumentar su rendimiento en lo referente a la cantidad y calidad.

La actividad agrícola continuamente se beneficia de los últimos desarrollos tecnológicos, por ejemplo: el establecimiento de campos de cultivos fijos, el desarrollo y uso del arado, desarrollo de sistemas de riego, cultivos bajo techo, entre otros. El desarrollo de herramientas computacionales a últimas fechas, en las cuales implementan diferentes tipos algoritmos inteligentes en combinación con otros desarrollos tecnológicos con el objetivo de mejorar la eficiencia en los procesos agrícolas, por ejemplo: el riego, fertilización, detección de enfermedades y carencias nutricionales [4][2][5][6][7] han creado lo que se conoce como agricultura de precisión (AP). La primera etapa de este tipo de sistemas consiste en proveerles de datos lo más limpios o filtrados de ruido, tanto como sea posible sin eliminar las características distintivas que se desean preservar.

En el presente trabajo se describe el proceso de optimización del valor del parámetro denominado α implementado en el algoritmo de segmentado de hojas y frutos de jitomate implementado en [8], el cual se basa en la dominancia de color presente de forma natural en el cultivo seleccionado y dicho parámetro tiene por objetivo acentuar dicha dominancia. Las imágenes son manejadas en el espacio de color de 3 canales: rojo, verde y azul o RGB (**R**ed, **G**reen, **B**lue) por sus siglas en inglés. El algoritmo de segmentado propuesto [8] se basa en la dominancia de color de alguno de los canales del modelo RGB para una determinada clase de interés [9][10] y se realiza en dos etapas, durante la segunda de ellas se utiliza un valor de α para mejorar los resultados de la segmentación medidos con la métrica IoU. Es de relevante el contar con información confiable al momento de alimentar sistemas de AP, por lo tanto, es menester el buscar los valores de los diferentes parámetros que mejoren los resultados de los procesos de filtrado de datos.

II. ANTECEDENTES

Existen en la literatura diversidad de aplicaciones para los algoritmos de segmentado de imágenes, entre ellas las implementadas en los procesos agrícolas. El objetivo primordial de cualquier método de segmentación es la separación de los elementos de interés en una de las categorías previamente definidas. Los métodos de segmentación por color han venido siendo desarrollados hace tiempo, mientras que los algoritmos de aprendizaje profundo como lo son las redes neuronales convolucionales que han presentado un crecimiento considerable recientemente.

Existen diferentes formatos o espacios de color con características propias que son usados para manejar numéricamente los datos que apreciamos en las imágenes con la vista. El color es uno de los atributos más utilizado para discriminar el follaje del resto de la imagen. En el trabajo [9] se propone un método para segmentar plantas de arroz del fondo, el cual se basa en restar el valor del canal verde menos el del canal rojo, este valor es comparado contra un umbral que se establece basándose en el conocimiento a priori. En el trabajo [5] se usan umbrales con el sistema de color RGB y HSL (**H**ue, **S**aturation, **L**ightness) por sus siglas en inglés, para extraer texturas y morfologías de los cultivos. Otros investigadores han desarrollado métodos para estimar el área de las hojas en relación con el suelo presente en la toma [11][12], en los cuales se utilizan métodos estadísticos. Existen trabajos que detectan malas hierbas en condiciones de luz no controladas [13], mediante el uso de un robot autónomo para la toma de imágenes y el uso de umbrales establecidos por el usuario.

Las redes neuronales convolucionales pertenecen al área de conocimiento llamada “aprendizaje profundo” son una rama de algoritmos de procesamiento de imágenes de reciente aparición [4]. En el aprendizaje profundo se utilizan funciones que permiten la representación jerárquica de la información entre varias capas de profundidad para realizar reconocimiento y clasificación [14].

En [15] se usa el modelo ConNet para la clasificación de varios tipos de hojas en ambientes. Existen trabajos referentes a la detección de plagas y enfermedades en la agricultura. En [16] se usa de un modelo de red convolucional nombrado CafeNeT para la clasificación de granos de café. Hay trabajos en la literatura con el objetivo de detectar enfermedades en cultivos, por ejemplo en [17] se utilizan modelos más robustos para ese fin, como lo son AlexNet y GoogleNet. En [18] se utilizó un modelo RCNN para segmentar plantas de remolacha azucarera, malas hierbas y fondo utilizando imágenes RGB. Majeed [19] entrenó diferentes modelos en SegNet y FNC para segmentar cordones de vid y determinar su dirección.

III. DETERMINACIÓN DEL VALOR OPTIMO DE ALPHA QUE ACENTÚE LA DOMINANCIA DE COLOR Y MAXIMIZA LOS RESULTADO DE LAS SEGMENTACIÓN DE HOJAS Y FRUTOS EN CULTIVOS DE JITOMATE.

Los métodos de segmentación de imágenes clasifican los píxeles que conforman una imagen como perteneciente a una única clase entre por lo menos dos opciones. Las características que se deben de tomar en cuenta a la hora de trabajar con imágenes entre otras son las siguientes:

- Una imagen es representada como una función bidimensional $f(x,y)$, donde el valor de la función representa el color en la posición x, y .
- Dimensiones de la imagen $N \times M$ en donde N y M representan el ancho y alto de la imagen.
- Espacio o formato de color, es la representación del espectro de color visible. El formato RGB codifica los colores en base a una combinación rojo, verde y azul, el rango de valores va de 0 - 255.

La Figura 1 muestra un ejemplo de las imágenes que serán procesadas, las cuales tienen tomas de cultivos de jitomate cultivados dentro de invernaderos. Las clases con las que etiquetarán los píxeles son: hojas, frutos y fondo.



Figura 1 Ejemplo de imágenes de trabajo.

Es necesario para comprender el proceso de optimización del valor de α describir el algoritmo de en el cual es usado. Este se basa en la dominancia natural del color verde para las hojas y el rojo para los frutos y el manejo de estos colores de forma directa en el espacio de color RGB. El algoritmo se

lleva a cabo en dos etapas de segmentación sucesivas. La primera de ellas aprovecha la dominancia del color verde en los píxeles que forman las hojas y del color rojo para los que forman los frutos de las plantas de jitomate. Esto es expresado en la Ecuación 1 para las hojas y en la 2 para los frutos.

$$h(x,y) = \begin{cases} f(x,y), & \text{si } (f_G(x,y) > f_R(x,y)) \text{ y } (f_G(x,y) > f_B(x,y)) \\ 0, & \text{en otro caso} \end{cases} \quad (1)$$

$$j(x,y) = \begin{cases} f(x,y), & \text{si } (f_R(x,y) > f_G(x,y)) \text{ y } (f_R(x,y) > f_B(x,y)) \\ 0, & \text{en otro caso} \end{cases} \quad (2)$$

Un ejemplo de aplicar las Ecuaciones 1 y 2 en las imágenes seleccionadas se muestran en la Figura 2 la segmentación de las hojas y en la Figura 3 la segmentación de los frutos de la planta de jitomate.



Figura 2 Dominancia del color verde.



Figura 3 Dominancia del color rojo.

La segunda etapa de la segmentación por dominancia de color consiste en establecer dos umbrales para ser comparados con las diferencias de los canales de color dominantes con respecto a los otros dos del espacio de color RGB.

Para el caso de la segmentación de los píxeles de las hojas las diferencias se calculan restando al valor del canal verde los valores de los canales rojo y azul, mediante las Ecuaciones 3 y 4.

$$\Delta_G^R(x,y) = h_G(x,y) - h_R(x,y) \quad (3)$$

$$\Delta_G^B(x,y) = h_G(x,y) - h_B(x,y) \quad (4)$$

Las diferencias para la segmentación de los píxeles que forman los frutos se establecen al restar los valores de los canales verde y azul al canal de color rojo. Observe las ecuaciones 5 y 6.

$$\Delta_R^G(x,y) = j_R(x,y) - j_G(x,y) \quad (5)$$

$$\Delta_R^B(x,y) = j_R(x,y) - j_B(x,y) \quad (6)$$

Los umbrales para segmentación de las hojas se establecen mediante las Ecuaciones 7 y 8.

$$U_G^R(x, y) = \frac{h_G(x, y)}{M_G} * \sigma_G^R * \alpha. \quad (7)$$

$$U_G^B(x, y) = \frac{h_G(x, y)}{M_G} * \sigma_G^B * \alpha. \quad (8)$$

Por su parte, los umbrales de segmentación para las frutas se realizan con las Ecuaciones 9 y 10.

$$U_R^G(x, y) = \frac{j_R(x, y)}{M_R} * \sigma_R^G * \alpha. \quad (9)$$

$$U_R^B(x, y) = \frac{j_R(x, y)}{M_R} * \sigma_R^B * \alpha. \quad (10)$$

Las Ecuaciones 11 y 12 usan los umbrales y las diferencias de los canales de color dominantes para llevar a cabo la segmentación final de los píxeles de las hojas y frutos.

$$h_F(x, y) = \begin{cases} h(x, y), & \text{si } (\Delta_R^G(x, y) > U_G^R(x, y)) \text{ y } (\Delta_R^B(x, y) > U_G^B(x, y)) \\ 0, & \text{en otro caso} \end{cases} \quad (11)$$

$$j_F(x, y) = \begin{cases} j(x, y), & \text{si } (\Delta_R^G(x, y) > U_R^G(x, y)) \text{ y } (\Delta_R^B(x, y) > U_R^B(x, y)) \\ 0, & \text{en otro caso} \end{cases} \quad (12)$$

Aplicando la Ecuación 11 la segmentación final de los píxeles que forman las hojas se muestra en la Figura 4.



Figura 4 Segmentación final de las hojas.

Por su parte, aplicando la Ecuación 12 se logra la segmentación de los píxeles que forman los frutos, observe la Figura 5.



Figura 5 Segmentación final los frutos.

La descripción de las diferentes variables involucradas en las Ecuaciones 1 - 12 son:

- $f(x, y)$ representa la imagen a ser segmentada.
- $h(x, y)$ y $j(x, y)$ son funciones que almacenan la primera segmentación de las hojas y los frutos respectivamente.
- $h_F(x, y)$ y $j_F(x, y)$ son funciones que almacenan el resultado final de las segmentación de las hojas y frutos.
- x, y representan la posición de un píxel en la imagen.
- *Los subíndices y superíndices R, G y B* hacen referencia a las bandas de color primarios rojo, verde y azul en el espacio de color RGB.
- Δ representa las diferencias del canal dominante contra los dos.
- σ almacena la desviación estándar de las diferencias del canal dominante.
- M son los valores máximos de las bandas de color rojas y verdes.
- U son los umbrales usados para la etapa final de segmentación.
- α es un valor que se utilizado para aumentar o disminuir el valor de los umbrales basados en la dominancia de color.

Es importante poder realizar un análisis cuantitativo de los resultados de los resultados generados. La métrica seleccionada es *Intersección sobre Unión (IoU)* [20]. La forma básica de la métrica de *IoU* se expresa en la Ecuación 13.

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (13)$$

Para poder implementar la métrica *IoU*, es necesario contar con un etiquetado de las clases de interés, por lo general este proceso se realiza manualmente utilizando una herramienta de etiquetado. Las máscaras de las imágenes se realizaron usando la herramienta WEB “Computer Vision Annotation Tool”, disponible en la liga <https://www.cvat.ai/>. La Figura 6 se muestra un ejemplo de las máscaras.



Figura 6 Ejemplo de máscara de una imagen.

El valor máximo que se puede generar al usar la métrica *IoU* es igual a 1, lo que indicaría que la segmentación y la máscara coinciden al 100%.

IV. METODOLOGÍA USADA.

El dataset de imágenes de plantas de jitomate cultivadas en condiciones semihidroponicas dentro de invernaderos

disponible en la dirección WEB <https://www.kaggle.com/datasets/andrewmvd/tomato-detection>, consta de 850 imágenes.

La estrategia para encontrar el valor de α que optimiza el resultado de la segmentación medida con la métrica IoU , consistió en seleccionar de forma aleatoria 100 imágenes del total dataset, lo que representa un 12% de muestra. El algoritmo se aplicó a los elementos de seleccionados forma interactiva disminuyendo o aumentando el valor de α hasta encontrar el valor que mejor rendimiento genere.

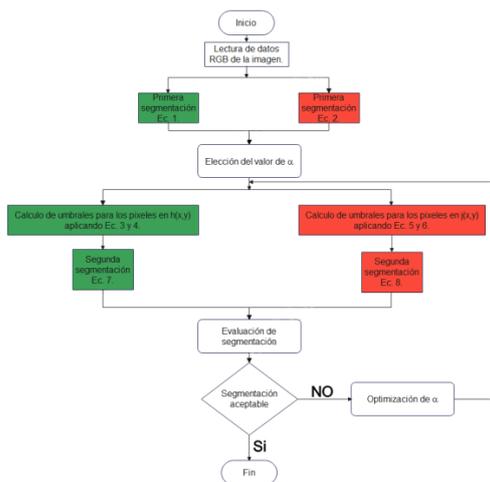


Figura 7 Proceso general de optimización del parámetro α

Los valores de α con los que se probó el algoritmo van de desde 0.1 hasta 10. Un valor alto produce un filtrado excesivo eliminando píxeles de más y viceversa en caso de un valor bajo.

V. RESULTADOS

Los experimentos de segmentado con las imágenes del conjunto de prueba fueron ejecutados una computadora con las siguientes características de hardware:

- Intel(R) Core(TM) i7-10750H CPU @ 2.60GHz
- 16 GB de memoria RAM
- La codificación del algoritmo fue realizada con Python 3.8 y se utilizó la librería OpenCV [21].

En la Tabla 1 se muestran los resultados de probar diferentes valores de para α .

Tabla 1 Resultados de experimentos de segnetación de las hojas.

Valor de α	Media IoU	Desv. estd.	Valor menor	Valor mayor
1	0.7021	0.3031	0.0035	0.9747
2	0.7888	0.2979	0.0041	0.9769
3	0.8214	0.2938	0.0085	0.9777

3.5	0.8256	0.2911	0.0132	0.9784
4	0.8223	0.2877	0.0157	0.9786
5	0.7920	0.2926	0.0231	0.9784
6	0.7815	0.2899	0.0347	0.9790

Tabla 2 Resultados de experimentos de segnetación de los frutos.

Valor de α	Media IoU	Desv. estd.	Valor menos eficiente	Valor más eficiente
1	0.72283	0.2138	0.1612	0.9429
2	0.8035	0.1841	0.1799	0.9602
3	0.8132	0.1738	0.1914	0.9595
3.5	0.8155	0.2050	0.1925	0.9514
4	0.8136	0.1749	0.1864	0.9545
5	0.8097	0.1815	0.1702	0.9554
6	0.7925	0.1815	0.1655	0.9586

Se aplicó el método de segmentado por dominancia de color a un conjunto de imágenes logrando alcanzar un promedio de 82.6% y 81.5% para las hojas y los frutos respectivamente con la métrica IoU con un valor de $\alpha=3.5$.

VI. CONCLUSIONES

La búsqueda manual del valor adecuado de α que maximice los resultados de la segmentación medidos con la métrica IoU resulta un proceso largo y poco eficiente, ya que no se cuenta con alguna estrategia defina para ir cambiando al valor que se esté probando. De igual modo quedan valores fraccionarios sin explorar que puede dar mejores resultados.

Un dato para tener en cuenta es que los resultados de la métrica IoU pueden ser afectados debido no solo al resultado de la segmentación del método propuesto, sino también entra en juego la calidad del etiquetado manual realizado en las imágenes.

VII. TRABAJOS FUTUROS

Se presentan tres vertientes de trabajo futuro por medio de las cuales se pueden realizar mejoras a los resultados de la segmentación. La primera de ellas se relaciona con la forma de probar el valor de α usado en las Ecuaciones 7 – 10 para determinar los umbrales, ya que este se asignó de forma empírica y se fue mejorando sumando o restando diferentes magnitudes en pruebas sucesivas. Se pretende implementar un algoritmo metaheurístico que permita establecer el valor óptimo α y mejore los resultados de la métrica seleccionada, por medio de diferentes estrategias evolutivas. Otra oportunidad para mejorar el resultado es probar con dos valores diferentes de α , uno para las hojas y otro para los frutos. La última vertiente pasa por el hecho de mejorar el marcado de las imágenes, lo que permita una mejor medición de los resultados de la segmentación de las hojas y frutos de las plantas de jitomate.

Otra ruta de investigación pretende explorar la aplicación de modelos de redes neuronales computacionales para poder hacer lo que se denomina segmentación semántica y tener con

ello otro método segmentado contra el cual comparar los resultados obtenidos.

VIII. AGRADECIMIENTOS

Es importante dar reconocimiento a las Instituciones y Empresas que hicieron posible la realización de esta investigación al brindar apoyo financiero y acceso a sus instalaciones.

- Consejo Nacional de Ciencia y Tecnología.
- Centro de Investigaciones en Óptica A.C.
- Instituto Tecnológico de Estudios Superiores de Zamora,
- Empresa Opus Farms.

REFERENCIAS

- [1] Y. Awasthi, "Press 'a' for artificial intelligence in agriculture: A review," *Int. J. Informatics Vis.*, vol. 4, no. 3, pp. 112–116, 2020, doi: 10.30630/joiv.4.3.387.
- [2] P. P. Ray, "Internet of things for smart agriculture: Technologies, practices and future direction," *J. Ambient Intell. Smart Environ.*, vol. 9, no. 4, pp. 395–420, 2017, doi: 10.3233/AIS-170440.
- [3] FAOSTAT, "FAOSTAT." <http://www.fao.org/faostat/es/#data/QC>.
- [4] A. Kamilaris and F. X. Prenafeta-Boldú, "Deep learning in agriculture: A survey," *Comput. Electron. Agric.*, vol. 147, no. July 2017, pp. 70–90, Apr. 2018, doi: 10.1016/j.compag.2018.02.016.
- [5] D. Story, M. Kacira, C. Kubota, A. Akoglu, and L. An, "Lettuce calcium deficiency detection with machine vision computed plant features in controlled environments," *Comput. Electron. Agric.*, vol. 74, no. 2, pp. 238–243, 2010, doi: 10.1016/j.compag.2010.08.010.
- [6] L. Chen *et al.*, "Identification of nitrogen, phosphorus, and potassium deficiencies in rice based on static scanning technology and hierarchical identification method," *PLoS One*, vol. 9, no. 11, pp. 1–17, 2014, doi: 10.1371/journal.pone.0113200.
- [7] R. González Perea, E. Camacho Poyato, P. Montesinos, and J. A. Rodríguez Díaz, "Optimization of Irrigation Scheduling Using Soil Water Balance and Genetic Algorithms," *Water Resour. Manag.*, vol. 30, no. 8, pp. 2815–2830, 2016, doi: 10.1007/s11269-016-1325-7.
- [8] J. P. Guerra Ibarra and F. J. Cuevas, "Segmentation of Leaves and Fruits of Tomato Plants by Color Dominance," *AgriEngineering*, pp. 1846–1864, 2023.
- [9] Y. Wang, D. Wang, G. Zhang, and J. Wang, "Estimating nitrogen status of rice using the image segmentation of G-R thresholding method," *F. Crop. Res.*, vol. 149, pp. 33–39, 2013, doi: 10.1016/j.fcr.2013.04.007.
- [10] E. Hamuda, M. Glavin, and E. Jones, "A survey of image processing techniques for plant extraction and segmentation in the field," *Comput. Electron. Agric.*, vol. 125, pp. 184–199, 2016, doi: 10.1016/j.compag.2016.04.024.
- [11] J. Rasmussen, M. Norremark, and B. M. Bibby, "Assessment of leaf cover and crop soil cover in weed harrowing research using digital images," *Weed Res.*, vol. 47, no. 4, pp. 299–310, Aug. 2007, doi: 10.1111/j.1365-3180.2007.00565.x.
- [12] K. Kirk, H. J. Andersen, A. G. Thomsen, J. R. Jørgensen, and R. N. Jørgensen, "Estimation of leaf area index in cereal crops using red-green images," *Biosyst. Eng.*, vol. 104, no. 3, pp. 308–317, 2009, doi: 10.1016/j.biosystemseng.2009.07.001.
- [13] H. Y. Jeon, L. F. Tian, and H. Zhu, "Robust crop and weed segmentation under uncontrolled outdoor illumination," *Sensors*, vol. 11, no. 6, pp. 6270–6283, 2011, doi: 10.3390/s110606270.
- [14] J. Schmidhuber, "Deep Learning in neural networks: An overview," *Neural Networks*, vol. 61, pp. 85–117, 2015, doi: 10.1016/j.neunet.2014.09.003.
- [15] D. Hall, C. McCool, F. Dayoub, N. Sünderhauf, and B. Upcroft, "Evaluation of features for leaf classification in challenging conditions," *Proc. - 2015 IEEE Winter Conf. Appl. Comput. Vision, WACV 2015*, pp. 797–804, 2015, doi: 10.1109/WACV.2015.111.
- [16] S. Sladojevic, M. Arsenovic, A. Anderla, D. Culibrk, and D. Stefanovic, "Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification," *Comput. Intell. Neurosci.*, vol. 2016, 2016, doi: 10.1155/2016/3289801.
- [17] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using deep learning for image-based plant disease detection," *Front. Plant Sci.*, vol. 7, no. September, pp. 1–10, 2016, doi: 10.3389/fpls.2016.01419.
- [18] T. Anand *et al.*, "AgriSegNet: Deep Aerial Semantic Segmentation Framework for IoT-Assisted Precision Agriculture," *IEEE Sens. J.*, vol. 21, no. xxxx, pp. 17581–17590, 2023, doi: 10.1016/j.inpa.2023.02.001.
- [19] Y. Majeed, M. Karkee, Q. Zhang, L. Fu, and M. D. Whiting, "Determining grapevine cordon shape for automated green shoot thinning using semantic segmentation-based deep learning networks," *Comput. Electron. Agric.*, vol. 171, no. November 2019, p. 105308, 2020, doi: 10.1016/j.compag.2020.105308.
- [20] J. Yu *et al.*, "Learning Generalized Intersection Over Union for Dense Pixelwise Prediction," in *Proceedings of the 38th International Conference on Machine Learning*, 2021, vol. 139, pp. 12198–12207, [Online]. Available: <https://proceedings.mlr.press/v139/yu21e.html>.
- [21] OpenCV, "Home - OpenCV," 2022. <https://opencv.org/> (accessed Sep. 11, 2022).