

## Uso de tecnologías avanzadas de inteligencia artificial en aplicaciones agrícolas y botánicas

Manuel G. Forero, Andrés García-Vanegas, Juan Betancourt Lozano

Semillero Lún y semillero MEC-AUTRONIC, Universidad de Ibagué, Tolima (Colombia)  
[manuel.forero@unibague.edu.co](mailto:manuel.forero@unibague.edu.co) [jorge.garcia@unibague.edu.co](mailto:jorge.garcia@unibague.edu.co) [juan.betancourt@unibague.edu.co](mailto:juan.betancourt@unibague.edu.co)

### RESUMEN

Este artículo presenta el uso de tecnologías avanzadas de inteligencia artificial en aplicaciones agrícolas y botánicas, desarrolladas por los semilleros de investigación Lún y MEC-AUTRONIC del grupo de investigación D+TEC de la Universidad de Ibagué. La aplicación de la inteligencia artificial en la agricultura y el cuidado del medio ambiente tiene un gran campo de acción destacando el uso de técnicas como el procesamiento de imágenes, el aprendizaje de máquinas y la interacción con el entorno.

### Palabras Claves:

Procesamiento de imágenes, aprendizaje de máquinas, interacción con el entorno, inteligencia artificial, agricultura.

**Abstract:** This article presents the use of advanced artificial intelligence technologies in agricultural and botanical applications, developed by the Lún and MEC-AUTRONIC research seedbeds of the D+TEC group of the University of Ibagué. The application of artificial intelligence in agriculture and environmental care has a large field of action highlighting the use of techniques such as image processing, machine learning and interaction with the environment. The results shown allow observing the impact of these techniques in the enhancement of agricultural production, which are oriented both to improve crop production and to protect the environment.

**Keywords:** Image processing, machine learning, environment interaction, artificial intelligence, agriculture.

### INTRODUCCIÓN

El aumento de la población mundial ha hecho necesario el desarrollo de nuevas tecnologías con el fin de incrementar la producción de alimentos, haciendo un mejor aprovechamiento de los recursos, lo cual contribuye a la disminución del hambre en el mundo y al crecimiento económico de los países en desarrollo, cuya economía depende de la exportación de alimentos FAO (2009). Además, es necesario conocer y proteger la flora silvestre, la cual puede ser también una fuente económica de ingresos de los países en vías de desarrollo, como ocurre en el caso de Colombia, país exportador de flores. Por esta razón, distintos organismos e institutos de investigación han enfocado sus esfuerzos en el desarrollo y uso de nuevas tecnologías para la automatización de tareas y procesos necesarios para el desarrollo del campo. Una de las herramientas más utilizadas con este propósito en los últimos años es la inteligencia artificial (IA). Así, en la Universidad de Ibagué los semilleros de investigación en procesamiento de imágenes y reconocimiento de patrones Lún y diseño de sistemas mecatrónicos MEC-AUTRONIC, adscritos al grupo de investigación D+Tec desarrollan esfuerzos para el uso de estas técnicas en la agricultura y la botánica, algunos de cuyos trabajos se describen a continuación, los cuales han tenido impacto nacional e internacional.

La estructura del trabajo es la siguiente. En la Sección 2, se presentan los retos a los que se enfrenta la IA en el campo de la agricultura y la botánica. En la Sección 3, se presentan algunas de las aplicaciones desarrolladas aplicando técnicas de procesamiento de imágenes, aprendizaje de máquinas e interacción con el entorno. Finalmente, en la Sección 4, se presentan las conclusiones de este trabajo.

### Retos de la IA en la Agricultura y la Botánica

Existen diferentes definiciones de la Inteligencia Artificial. Rouhiainen (2018) define el concepto como "la habilidad de los computadores para hacer actividades que normalmente requieren inteligencia humana" (p.17). De acuerdo a la definición de Alan Turing, se entiende por inteligencia artificial un mecanismo que es capaz de interactuar con un ser humano, sin que este se de cuenta de que está haciéndolo con una máquina (Hardy, 2001). De acuerdo a este concepto, podría decirse que la IA consta de varias áreas, como se ilustra en la Figura 1, donde se observan aquellas desarrolladas actualmente en la Universidad de Ibagué. En cada una de estas áreas en forma combinada o separada hemos afrontado diferentes problemas relacionados con la agricultura de precisión y la botánica.

Técnicas de visión por computador, en particular de procesamiento de imágenes han sido utilizadas para identificar células en tejidos vegetales, desarrollo de protocolos mediante la evaluación de condiciones de luz y enfoque de los equipos de adquisición utilizados con el fin de adquirir tomas de plantas o partes de ellas que permitan identificar variedades o sus características. Estos problemas plantean diferentes retos para encontrar una combinación de técnicas que se ajuste a condiciones adversas, permitiendo desarrollar métodos robustos y que permitan obtener buenos resultados.




Figura 1: Diagrama de las distintas áreas que abarcan la IA en la Universidad de Ibagué.

Si se hace una revisión de las técnicas desarrolladas en el área de aprendizaje de máquinas, se tienen diferentes problemas que tienen como común denominador la contaminación de las muestras con ruido durante la toma de datos. Este es un tema recurrente en este tipo de investigaciones debido a la dificultad que se tiene para filtrar las muestras sin eliminar información relevante. Otro problema común es la selección del modelo que mejor se ajuste a los datos. En la actualidad es común el uso de técnicas de aprendizaje profundo en las cuales lo importante es el resultado, y a veces se subestima el análisis de la técnica propiamente dicha para entender cómo funciona el método desarrollado, lo cual podría en algunos casos permitir resultados aún mejores, o en algunos casos, en particular cuando la cantidad de datos es pequeña a utilizar otras técnicas de aprendizaje clásico que pueden ayudar a resolver el problema en forma más rápida y eficiente.

En cuestión al robot que llevara a cabo todas estas tareas, se pueden apreciar diferentes adversidades sobre todo a las condiciones climáticas necesarias. Diferentes autómatas son diseñados para una misma tarea, pero el diseño que tenga en cuenta la mayor cantidad de variables de error, es el que mejor se podría desempeñar en el reto. Variables como el terreno, humedad, visibilidad, manejo de elementos, motricidad y control son las primeras temáticas que se evalúan a la hora del diseño.

## APLICACIONES

Son innumerables las aplicaciones de la IA en la agricultura, entre las cuales se destaca el procesamiento de imágenes, el aprendizaje de máquinas y los sistemas robotizados.

### 3.1. Procesamiento de imágenes

Entre los métodos desarrollados se encuentra un método para la segmentación del meristemo apical en imágenes de microscopía confocal (Rojas et al., 2020). El meristemo es el tejido vegetal encargado del crecimiento de la planta, en particular el apical da origen a tallos, hojas y flores. Las células del meristemo tienen una forma irregular y aparecen en las imágenes confocales como zonas oscuras rodeadas de otras brillantes, tal como se observa en la Figura 2. En este trabajo se utilizó una técnica llamada Parametric Segmentation Tuning, desarrollada también por el mismo equipo para la optimización de los parámetros de segmentación en imágenes de diatomeas (Rojas Camacho et al., 2017). La segmentación se basó en el uso de técnicas de morfología matemática y los parámetros óptimos del algoritmo se encuentran mediante un proceso iterativo que compara las imágenes segmentadas obtenidas por variaciones sucesivas de los parámetros. A continuación, se utiliza una función de optimización para determinar qué par de imágenes sucesivas permite la mejor segmentación. La técnica fue validada comparando sus resultados con los obtenidos por un algoritmo de conjuntos de niveles y una técnica de segmentación por globos. Los resultados mostraron que nuestra metodología ofrece mejores resultados que dos alternativas del estado del arte disponibles de forma gratuita, siendo superior en todos los casos estudiados.




Figura 2: Procesamiento para la identificación de células en meristemo de *Arabidopsis thaliana*, c.

dentro de la compleja red de la vida en los trópicos. La clasificación manual lleva mucho tiempo, es costosa y requiere de expertos que, a menudo, tienen una disponibilidad limitada. Para abordar estos problemas, se utilizaron tres métodos de clasificación de imágenes: SVM, KNN con distancias euclidianas y de intersección.

La base de datos utilizada para el entrenamiento, prueba y validación de los métodos comprende imágenes RGB tomadas en el hábitat natural de las Zingiberales, desde su germinación hasta su momento óptimo de corte. Las imágenes fueron pre procesadas, realizando un ajuste de balance de blancos, contraste y temperatura de color. Para separar los Zingiberales del fondo, se utilizó una técnica de segmentación gráfica mediante GrabCut. Los descriptores se obtuvieron mediante la técnica conocida como en inglés Bag of Words, encontrando que el número de palabras visuales más adecuado para la clasificación estaba entre 20 y 40. Se comprobó que se obtenía un mejor resultado de clasificación separando las flores de una especie en dos subclases, debido a su diferente coloración. Los mejores resultados se obtuvieron con el método KNN, utilizando los tres vecinos más cercanos, obteniendo una precisión del 97 % (Forero et al., 2021a).

*Cirsium arvense* es una planta invasora que suele encontrarse en climas fríos y que afecta los cultivos de cereales. Por lo tanto, su detección es importante para mejorar la producción de los cultivos. En el Semillero Lún se introdujo una técnica de procesamiento de imágenes que genera resultados aún mejores que los encontrados con algoritmos de aprendizaje automático; lo cual se refleja en aspectos como la precisión y la velocidad de la detección de esta maleza en los cultivos de cereales. El método propuesto se basa en la detección del color verde extremo característico de esta planta con respecto a los cultivos. Para evaluar la técnica, se comparó con seis métodos populares de aprendizaje automático utilizando imágenes tomadas desde dos alturas diferentes: 10 y 50 m.

La precisión obtenida con las técnicas de aprendizaje automático fue del 97,07 % en el mejor de los casos con tiempos de ejecución de más de 2 minutos con imágenes de 200 x 200 píxeles, mientras que la precisión del método de procesamiento de imágenes propuesto fue del 98,23 % y su tiempo de ejecución fue inferior a 3 segundos (Forero et al., 2019b).

Otros trabajos en desarrollo incluyen la detección y reconstrucción de estructuras en tres dimensiones, detección de xilema en raíz de cacao, detección de enfermedades en arándano y manzano, detección de deficiencias nutricionales en café, evaluación de calidad de bananos, detección de *La sidiopodia theobromae* en aguacate (Mejía-Cabrera et al., 2020), clasificación de aguacates (Moreno et al., 2019), limones (Tuesta-Monteza et al., 2020) y fresas de acuerdo a su maduración, método de binarización para el análisis cromosómico de plantas primitivas, como la *Zamia tolimensis* y la *Zamia huilensis* (Torres-Benítez et al., 2021), análisis comparativo de técnicas de detección de puntos de interés para el registro de fotografías aéreas infrarrojas y visibles en cultivos (Forero et al., 2019a, 2021b).

### 3.2. Aprendizaje de máquinas

El aprendizaje de máquinas se ha utilizado en distintas aplicaciones de la agricultura para identificar objetos de flora y fauna teniendo en cuenta variables como el tiempo y precisión. Por ejemplo, Forero et al. (2019c) realizó un estudio que se centraba en la identificación semiautomática de cocodrilos a través de imágenes las cuales pudieran estar en entornos de diferentes fondos. El trabajo utilizó aprendizaje supervisado y no supervisado para obtener buenos resultados encontrando que el método de Gaussian Mixture Models (Reynolds, 2009) era el modelo que más se ajustaba y permitía extraer el animal de los demás datos. Otro ejemplo es Betancourt-Lozano et al. (2021) donde el foco principal era segmentar la fibrosis alada de quistes cerebrales generados por la neurocisticercosis en cerdos. En esta investigación se trabajaron modelos de aprendizaje no supervisado utilizando automatización de límites a través de las medidas de chucadrado y matrices de covarianza. Por su contra parte, en Montoya and Gómez (2022) se aplicaron técnicas de aprendizaje para la identificación de enfermedades que se pudieran presentar en hojas de arándano y manzano. Este proceso contó con utilizar aprendizaje supervisado mejorando los datos con un filtro de MeanShift que permitía resaltar los bordes de la imagen suavizando el resto de la información. Los resultados de las 3 investigaciones superan una precisión del 90 %. También se ha aplicado el aprendizaje de máquinas en otros proyectos que no solo utilizan información de imágenes. Por ejemplo, Murcia et al. (2022) utiliza información de nubes de puntos para reconstruir plántulas de maíz tridimensionales con las cuales poder adquirir fenotipos de los órganos a partir de aprendizaje de máquinas. Además de realizar esta tarea, liberaron una base de datos bastante extensa de los escaneos tomados, lo que permite validar los resultados y probar nuevos métodos.

En la Figura 3 se pueden apreciar los trabajos mencionados en esta sección.




Figura 3: Trabajos de aprendizaje de máquinas para la detección de objetos. a) Cocodrilos y fondo. b) Enfermedades en hojas de arándano. c) Fibrosis quística. d) Órganos de plántula de maíz.

### 3.3. Interacción con el entorno

La inteligencia artificial cuenta con diversos campos de acción en la agricultura, como por ejemplo, la predicción del rendimiento de cultivos, el pronóstico de precios, la pulverización inteligente, el conocimiento de la predicción, la robótica agrícola y, el seguimiento de cultivos y suelos. La interacción con el entorno es fundamental para la aplicación de la inteligencia artificial en la agricultura. Desde hace varios años se han estudiado y desarrolla diversos sistemas robotizados que permiten a través del uso de técnicas de la inteligencia artificial mejorar procesos agrícolas, obteniendo mejores productos y una mayor rentabilidad para el agricultor (Bechar and Vigneault, 2016).

El departamento del Tolima, es una región con un alto potencial agrícola, debido a la riqueza de sus suelos, con una gran variedad de productos, siendo uno de los principales productores de arroz, café, maíz, algodón, aguacate, panela y algunos frutales (ADR, 2019). Universidades, grupos de investigación y empresas han venido desarrollando estudios e investigaciones en el desarrollo de sistemas automatizados y robotizados con la implementación de técnicas de inteligencia artificial para mejorar procesos como la siembra, el riego, la inspección de plantas, la manipulación, recolección y clasificación de frutos, entre otros.

En diversas aplicaciones agrícolas es indispensable el uso de sistemas de visión por computador que permitan identificar los cultivos, las plantas y en especial los frutos, para poder identificar requerimientos en todo su proceso de cosecha y post-cosecha, como por ejemplo, el uso de sistema de calibración, seguimiento o control por visión de un robots para la automatización de cultivos a pequeña escala (García-Vanegas et al., 2019) (García-Vanegas et al., 2022). Estos sistemas permite el posicionamiento de herramientas, también llamadas efectores finales en la robótica, para la inspección de plántulas para identificar características de su fenotipado, la aspersión de agua o la aplicación de nutrientes de forma puntual, la identificación y eliminación de maleza. Estos sistemas de visión utilizando puntos de referencia y los propios cultivos para el procesamiento de imágenes y el análisis de su colorimetría para diagnosticar necesidades de los cultivos durante su proceso de crecimiento y recolección, como se ilustra en la Figura 4.



Figura 4: Interfaz gráfica para el control y monitoreo del robot AgroCablebot para la automatización de procesos de siembra, riego e inspección de plántulas en cultivos a pequeña escala.

### CONCLUSIONES

Debido al aumento de la población mundial, el cambio climático y la deforestación se hace necesario el desarrollo de esfuerzos para mejorar la producción agrícola, mientras que simultáneamente se protegen las especies nativas. Con estos objetivos en mente, los semilleros en procesamiento de imágenes y reconocimiento de patrones Lún y diseño de sistemas mecatrónicos MEC-AUTRONIC de la Universidad de Ibagué desarrollan nuevos métodos para su uso en la agricultura y la botánica, algunos de los cuales fueron presentados en este artículo con el fin de darlos a conocer a la comunidad en general, ya sea para su uso o para promover el desarrollo de nuevos trabajos donde la experiencia y capacidades de estos semilleros puedan aportar nuevas soluciones en la agricultura y la protección de los recursos vegetales.

### REFERENCIAS

1. ADR, Agencia de Desarrollo Rural, F. (2019). Plan integral de desarrollo agropecuario y rural con enfoque territorial.
2. Bechar, A. and Vigneault, C. (2016). Agricultural robots for field operations: Concepts and components. *Biosystems Engineering*, 149:94-111.
3. Betancourt-Lozano, J. J., Vargas, M. G. F., and Santana, L. E. B. (2021). Detección de fibrosis aleadaña a quistes producidos por neurocisticercosis mediante procesamiento de imágenes y reconocimiento de patrones. *SPIE*, page 58.
4. FAO (2009). La agricultura mundial en la perspectiva del año 2050. Last accessed 10 October 2022.
5. Forero, M. G., Acosta, A., Ducuara, A., Godoy, Y., and Moreno, J. G. (2019a). Comparative analysis of interest points detection techniques for the registration of infrared and visible aerial photographs in pasture crops. In Tescher, A. G. and Ebrahimi, T., editors, *Applications of Digital Image Processing XLII*, volume 11137, page 11137OG. International Society for Optics and Photonics, SPIE.
6. Forero, M. G., Beltrán, C. E., and González-Santos, C. (2021a). Automatic classification of zingi berales from rgb images. In Roman-Rangel, E., Kuri-Morales, A. F., Martínez-Trinidad, J. F., Carrasco-Ochoa, J. A., and Olvera-López, J. A., editors, *Pattern Recognition*, pages 198-206, Cham. Springer International Publishing.
7. Forero, M. G., Beltrán, C. E., Troncoso, A., and González-Santos, C. (2020). Classification of cattleya trianae and its varieties by using colorimetry. In Figueroa
8. Mora, K. M., Anzurez Marín, J., Cerda, J., Carrasco-Ochoa, J. A., Martínez-Trinidad, J. F., and Olvera-López, J. A., editors, *Pattern Recognition*, pages 35-44, Cham. Springer International Publishing.

9. Forero, M. G., Herrera-Rivera, S., 'avila Navarro, J., Franco, C. A., Rasmussen, J., and Nielsen, J. (2019b). Color classification methods for perennial weed detection in cereal crops. In Vera Rodriguez, R., Fierrez, J., and Morales, A., editors, *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications*, pages 117-123, Cham. Springer International Publishing.
10. Forero, M. G., Lozano, J. J., and Balaguera-Reina, S. A. (2019c). Individual identification au tomaton in crocodylians through imagery processing: American crocodile as a study case. In *Applications of Digital Image Processing XLII*, volume 11137, pages 586-595. SPIE.
11. Forero, M. G., Mambuscay, C. L., Monroy, M. F., Miranda, S. L., Méndez, D., Valencia, M. O., and Gómez Selvaraj, M. (2021b). Comparative analysis of detectors and feature descriptors for multispectral image matching in rice crops. *Plants*, 10(9):1791.
12. García-Vanegas, A., Leiton-Murcia, C., Forero, M. G., Gonzalez-Rodriguez, A., and Castillo García, F. (2022). Cable-driven parallel robot controlled by servo-vision system. In Vergara Villegas, O. O., Cruz-Sánchez, V. G., Sossa-Azuela, J. H., Carrasco-Ochoa, J. A., Martínez Trinidad, J. F., and Olvera-López, J. A., editors, *Pattern Recognition*, pages 291-302, Cham. Springer International Publishing.
13. García-Vanegas, A., Liberato-Tafur, B., Forero, M. G., Gonzalez-Rodriguez, A., and Castillo García, F. (2019). Automatic vision based calibration system for planar cable-driven parallel robots. In Morales, A., Fierrez, J., Sánchez, J. S., and Ribeiro, B., editors, *Pattern Recognition and Image Analysis*, pages 600-609, Cham. Springer International Publishing.
14. Hardy, T. (2001). Ia (inteligencia artificial). *Polis: Revista Latinoamericana*, 1(2):18. 6
15. Mejía-Cabrera, H. I., Flores, J. N., Sigüenas, J., Tuesta-Monteza, V., and Forero, M. G. (2020). Identification of Lasiodiplodia Theobromae in avocado trees through image processing and machine learning. In Tescher, A. G. and Ebrahimi, T., editors, *Applications of Digital Image Processing XLIII*, volume 11510, page 115102F. International Society for Optics and Photonics, SPIE.
16. Montoya, X. and Gómez, D. (2022). Estudio comparativo de técnicas de agrupamiento para la segmentación de imágenes cromáticas.
17. Moreno, G. A., Forero, M. G., Gómez, F., and Ramirez, M. (2019). Hass avocado classification by color and volume using a Kinect sensor. In Tescher, A. G. and Ebrahimi, T., editors, *Applications of Digital Image Processing XLII*, volume 11137, page 111371P. International Society for Optics and Photonics, SPIE.
18. Murcia, H. F., Forero, M. G., Méndez, D., and Betancourt-Lozano, J. (2022). Lidar platform for acquisition of 3d plant phenotyping database. *Plants*, 11(17):2199.
19. Reynolds, D. A. (2009). Gaussian mixture models. *Encyclopedia of biometrics*, 741(659-663).
20. Rojas, O., Forero, M. G., Menéndez, J. M., Jones, A., Dewitte, W., and Murray, J. A. H. (2020). Segmentation of meristem cells by an automated optimization algorithm. *Applied Sciences*, 10(23):8523.
21. Rojas Camacho, O., Forero, M. G., and Menéndez, J. (2017). A tuning method for diatom segmentation techniques. *Applied Sciences*, 7(8):762.
22. Rouhiainen, L. (2018). *Inteligencia artificial*. Madrid: Alienta Editorial.
23. Torres-Benitez, A., Aldana, M., and Forero, M. G. (2021). Binarization method for chromosomal analysis of primitive plants: the case of Zamia tolimensis and Zamia huiensis (Cycadales, Zamiaceae). In Tescher, A. G. and Ebrahimi, T., editors, *Applications of Digital Image Processing XLIV*, volume 11842, page 118421X. International Society for Optics and Photonics, SPIE.
24. Tuesta-Monteza, V., Alcarazo, F., Mejía-Cabrera, H. I., and Forero, M. G. (2020). Automatic classification of citrus aurantifolia based on digital image processing and pattern recognition. In Tescher, A. G. and Ebrahimi, T., editors, *Applications of Digital Image Processing XLIII*, volume 11510, page 115100K. International Society for Optics and Photonics, SPIE.