



TIES Revista de Tecnología e Innovación en Educación Superior

ROBOT AUTÓNOMO PARA LA DETECCIÓN Y CLASIFICACIÓN DE FRESAS EN CAMPOS DE CULTIVO MEDIANTE DEEP LEARNING

DOI: 10.22201/dgtic.26832968e.2023.8.6

Luis Andrés Moreno (luismj@cio.mx)

Gesem Mejía (gmejia@cio.mx)

Todos los autores están adscritos al Laboratorio de
Percepción y Robótica del Centro de Investigaciones en
Óptica, León, Guanajuato, México



Andrés Montes de Oca (andresmr@cio.mx)

Gerardo Flores (gflores@cio.mx)

<http://www.ties.unam.mx/>

Fecha de recepción: julio de 2023 • Fecha de publicación: noviembre, 2023

Noviembre 2023 | número de revista 8 • ISSN 2683-2968

Acervos Digitales, Dirección General de Cómputo y de Tecnologías de Información y Comunicación, UNAM

Esta obra está bajo licencia de Creative Commons
Atribución-No Comercial 4.0 Internacional (CC BY-NC 4.0)

ROBOT AUTÓNOMO PARA LA DETECCIÓN Y CLASIFICACIÓN DE FRESAS EN CAMPOS DE CULTIVO MEDIANTE DEEP LEARNING

Resumen

Se realiza un acercamiento a las principales tecnologías para el desarrollo de aplicaciones móviles (*apps*) disponibles en el mercado actual. Se explican las principales características de las tecnologías: web móvil, de código nativo tanto tradicionales como híbridas, así como las ventajas y desventajas de utilizar cada una de ellas. Se abordan los problemas que los desarrolladores experimentan al emplear plataformas híbridas, se brindan sugerencias para la elección de la mejor tecnología y se ofrecen algunas conclusiones.

Palabras clave:

Agricultura, Deep Learning, Detección, Robot autónomo, Tecnología.

AUTONOMOUS ROBOT FOR STRAWBERRY DETECTION AND CLASSIFICATION IN CROP FIELDS THROUGH DEEP LEARNING

Abstract

The development of autonomous systems with applications in agriculture contributes significantly to achieve greater efficiency in daily tasks, such as monitoring production in the agricultural field. This work addresses precisely this issue through the proposal of an autonomous robot, which uses Deep Learning algorithms to detect and classify strawberries automatically according to their ripeness stage. This technological application aims to provide the farmer with precise information on the amount of strawberries present in a crop, as well as their state of maturity and exact location, which provides the farmer with tools to plan an efficient harvest. In real strawberry growing scenarios, there are factors that affect the accuracy of strawberry detection. However, given the results obtained in the field test, this system proves to be accurate in this task.

Keywords:

Agriculture, Deep Learning, Detection, Autonomous robot, Technology.

ROBOT AUTÓNOMO PARA LA DETECCIÓN Y CLASIFICACIÓN DE FRESAS EN CAMPOS DE CULTIVO MEDIANTE DEEP LEARNING

Introducción

La agricultura es una actividad muy importante para la humanidad [1], y a medida que la población siga creciendo, la innovación y el uso de métodos eficientes serán cada vez más importantes para aumentar la cantidad y calidad de la producción de alimentos. Uno de los retos de la agricultura es la recolección oportuna de frutos, una tarea delicada, ya que existe una ventana muy corta de tiempo de cosecha. A la vez, esta tarea también es tardada y requiere de arduo trabajo, especialmente en campos de cultivos grandes. Afortunadamente, los avances en la implementación de inteligencia artificial en robots autónomos están haciendo que estas tareas sean más eficientes [2], [3], [4] al permitir realizar la clasificación por nivel de madurez de forma autónoma.

En la actualidad, el aprendizaje profundo o Deep Learning [5], ha permitido desarrollar algoritmos capaces de imitar la manera en la que el cerebro humano procesa la información, utilizando redes neuronales artificiales que pueden aprender y reconocer patrones complejos. Estas redes se entrenan con grandes cantidades de datos para identificar patrones y características comunes entre ellos.

Imagine un vehículo terrestre de 25 centímetros de altura recorriendo un campo de fresas en el estado de Guanajuato, México, captando imágenes del entorno, clasificando automáticamente las fresas por su grado de

madurez, y generando un mapa con su posición a medida que avanza. Aunque pueda parecer demasiado idealista, esto es exactamente lo que se ha conseguido en un reciente proyecto de investigación [6]. Se ha desarrollado un sistema de monitoreo de fresas implementando un algoritmo de Deep Learning en un robot autónomo, lo que representa una solución innovadora y eficiente para la agricultura.

En este artículo, exploramos el desarrollo e implementación de esta tecnología en la tarea de detección y clasificación de fresas en la agricultura, así como los detalles técnicos del desarrollo del robot autónomo. A través de la descripción del proceso de integración del algoritmo de clasificación, el proceso de detección, los componentes clave del robot autónomo, y los resultados obtenidos, se presentará una visión completa de cómo se logró este avance tecnológico.

Alianza Tecnológica: LAPyR y Huawei-UNAM

El Laboratorio de Percepción y Robótica (LAPyR), fundado en 2017 por el Dr. Gerardo Flores, se ha destacado por su labor en la formación de investigadores en los campos de control, robótica e inteligencia artificial. El LAPyR fomenta la innovación a través de la sinergia entre teoría y práctica, centrándose en la resolución de problemas reales y en la creación de soluciones efectivas. Este laboratorio cuenta con un equipo interdisciplinario

especializado en áreas como Deep Learning aplicado a la percepción, agricultura de precisión, robótica móvil y visión artificial. Además, promueve la integración de estudiantes e investigadores de diferentes niveles académicos, desde universitarios hasta posdoctorados.

También mantiene colaboraciones activas a nivel nacional e internacional. En este contexto, se ha hecho una colaboración con Huawei-UNAM, enfocada en un innovador proyecto de monitoreo de fresas mediante algoritmos de Deep Learning y un robot autónomo. Huawei-UNAM ha apoyado el proyecto proporcionando recursos físicos (hardware), software (lógicos) y capacitación a los investigadores del LAPyR, además del acceso a los servidores avanzados de Huawei, foros para desarrolladores y transferencia tecnológica. A diferencia de otras convocatorias o colaboraciones, esta alianza ha proporcionado un apoyo integral y especializado en el ámbito de la inteligencia artificial. Esto ha permitido a los investigadores de LAPyR explorar y expandir sus conocimientos en el campo de la inteligencia artificial aplicada a la agricultura.

Evaluación de la madurez de las fresas y detección mediante inteligencia artificial

Estar en el campo rodeado de fresas de diferentes tamaños y colores e intentar cosechar las que están a punto de entrar a su madurez comercial es una tarea que requiere de mucho esfuerzo y dedicación, ya que si se cosechan demasiado verdes no madurarán y si están maduras llegarán a los centros de distribución en mal estado, por lo que hay que comprobar constantemente la madurez de la cosecha. Utilizando técnicas de procesamiento de imágenes se puede detectar la madurez de la fresa basándose en su cambio de color, de verde a rojo, como lo haría normalmente un agricultor.

¿Cómo se logra detectar este cambio en las imágenes? Mediante la transformación del espacio de color de una imagen, específicamente utilizando el espacio de color CIE Lab [7]. Este espacio de color cuenta con 3 canales, L (Luminosidad), a (tonos rojos y verdes), b (tonos azules y amarillos), que permiten percibir los cambios de color de manera uniforme. CIE Lab facilita la detección de diferencias entre el verde y el rojo en el canal a sin verse afectado por los cambios de iluminación.

El proceso de clasificación comienza con la imagen RGB original, con canales rojo R, verde G, y azul B, a la cual se le aplica la transformación al espacio de color CIE

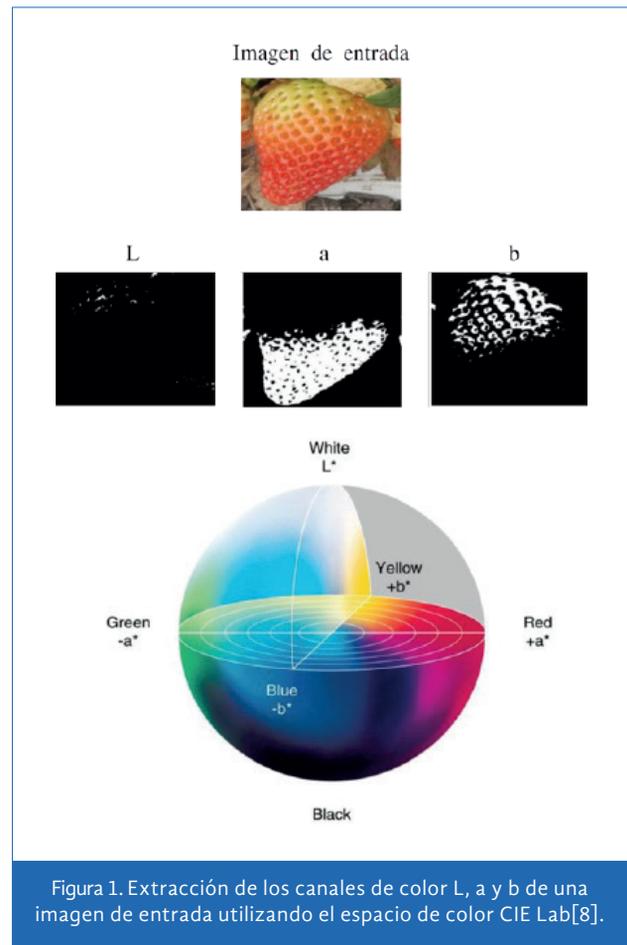


Figura 1. Extracción de los canales de color L, a y b de una imagen de entrada utilizando el espacio de color CIE Lab[8].

Lab. Posteriormente, a cada canal resultante (L, a, b) se le aplican límites para separar los tonos propios de la fresa del entorno. La Figura 1 muestra las tres capas del CIE Lab resultantes.

Tras esto se suman las capas (L + a + b), y se realizan algunas operaciones morfológicas para obtener una máscara con la forma aproximada de la fresa en la imagen original, sin perder información relevante de la misma, como forma y color. Ver figura 2.

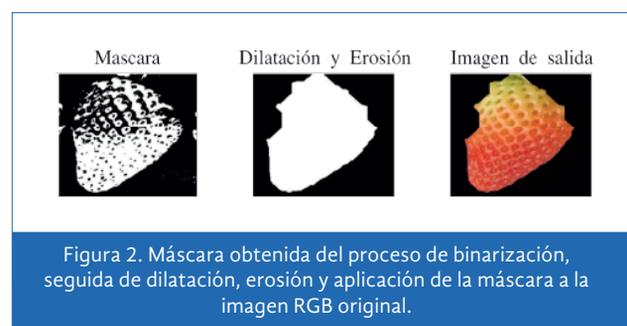


Figura 2. Máscara obtenida del proceso de binarización, seguida de dilatación, erosión y aplicación de la máscara a la imagen RGB original.

Una vez extraída la segmentación de la fresa en formato RGB, se utiliza el canal rojo R de la imagen para la clasificación de madurez, ya que está fuertemente relacionado con el nivel de madurez de la fresa. El nivel de la madurez de la fruta se clasifica en tres niveles: fresa inmadura, semi-madura, y madura, según la intensidad media de sus píxeles. Lo anterior se ilustra en la Figura 3. Si bien las técnicas de procesamiento de imágenes son muy útiles para clasificar la madurez de las fresas, tienen sus limitaciones, como la presencia de objetos diferentes a la fresa que compartan los mismos colores, lo que puede generar falsos positivos y que dichos objetos sean identificados como fresas sin serlo. Para solucionar este problema y mejorar la precisión en la detección de fresas, se aplica Deep Learning, específicamente utilizando redes neuronales convolucionales (CNN) para la identificación de las fresas por forma y textura.

Las CNN, como señala LeCun, uno de los pioneros de la inteligencia artificial, son un tipo de red neuronal, diseñada para trabajar con imágenes, que utiliza convoluciones en lugar de multiplicaciones matriciales para aprovechar los datos de entrada [9]. En lugar de mirar toda la imagen y tratar de encontrar patrones, la CNN divide la imagen en diferentes partes y las procesa por separado, buscando patrones en los datos y extrayen-

do características generales como líneas o bordes, para luego utilizar estos patrones para formar objetos más complejos, permitiendo detectar y clasificar con mucha más precisión los objetos de la imagen, lo que es muy útil para tareas de reconocimiento.

En una CNN, como se muestra en la Figura 4, las múltiples capas trabajan juntas para realizar la tarea de clasificación. La primera etapa es la extracción de características, en la cual la CNN divide la imagen en fragmentos y procesa cada uno por separado para buscar

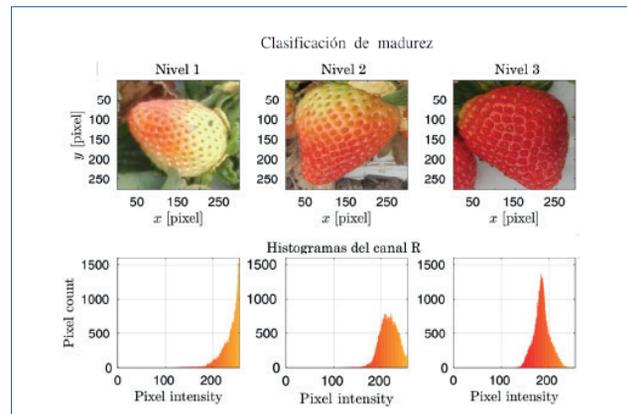


Figura 3. Histograma de color en el canal R de la imagen, clasificado en 3 niveles: inmaduro, semi-maduro y maduro.

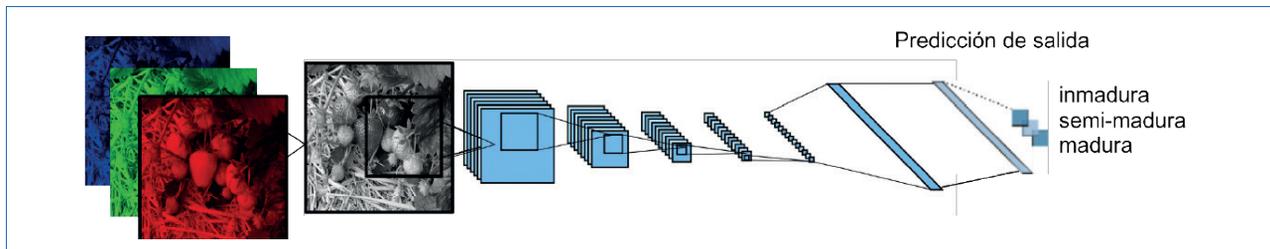


Figura 4. Arquitectura de la CNN utilizada en este trabajo.



Figura 5. Detección de fresas en el conjunto de datos. Imagen izquierda: Muestra la imagen segmentada correspondiente a la entrada de la imagen. Imagen derecha: Muestra las fresas maduras detectadas por la CNN, representadas por cuadros verdes en las regiones de interés.

patrones en los datos. A medida que la red avanza, las dimensiones se reducen, encontrando características cada vez más complejas. Al final de la red hay neuronas simples que realizan la clasificación en una o más clases, según las características encontradas.

En el caso de la detección de fresas, la CNN se entrenó con imágenes de fresas del popular conjunto de datos ImageNet [10], y se aumentó con un conjunto de imágenes de fresas en el campo de prueba, lo que le permitió a la red identificar la forma y textura de las fresas para su posterior clasificación. En este proyecto

se contó con la colaboración de Huawei, que proporcionó recursos de cómputo de alto desempeño, como sus servidores avanzados, lo que permitió un mayor rendimiento en el procesamiento de información y en el entrenamiento de la IA.

El uso de los servidores avanzados de Huawei en este proyecto permitió acelerar significativamente el tiempo de entrenamiento de la CNN y mejorar su capacidad para trabajar con conjuntos de datos más grandes, lo que permitió a la red generalizar de mejor manera las características que describen a una fresa. Estos servidores de alto desempeño son especialmente útiles en el campo de la inteligencia artificial, ya que pueden manejar eficientemente la gran cantidad de datos y operaciones matemáticas necesarias para entrenar una red neuronal.

Integración de un robot autónomo

La columna vertebral de este proyecto es el vehículo robótico terrestre, ya que en él se monta y aplica el hardware y software desarrollado. Si bien las redes neuronales convolucionales son muy útiles, requieren de un alto nivel de procesamiento computacional y, por lo tanto, necesitan equipos de mayor tamaño y consumo de energía. Esto dificulta el uso de vehículos compactos que puedan trasladarse entre los surcos del campo. La solución a esto es el uso de computadoras



Figura 6. Plantío de fresas en Pénjamo, Guanajuato, México.

embebidas, en este caso la Jetson Xavier, que pueden procesar una gran cantidad de información gracias a su GPU integrada. Con esto, se tiene la capacidad de ejecutar algoritmos de Deep Learning sin necesidad de estar conectado a equipos externos. Además, su bajo consumo de energía facilita su uso con baterías, lo que la hace ideal para su integración en robots autónomos y en tareas de monitoreo.

El terreno en el que se trabajará, mostrado en la Figura 6, es representativo de la mayoría de los cultivos en México, con un suelo irregular y espacios estrechos. Por esta razón, se seleccionó un Trail Crawler modelo TRX-4 de la marca Traxxas® adaptado para convertirse en un vehículo tipo rover.

Una vez que se tiene el vehículo adecuado, es necesario adaptarlo para que se convierta en un robot autónomo, aquí es donde la instrumentación cobra importancia. Este vehículo se ha equipado con un controlador automático y otros sensores como GPS, una cámara estereoscópica ZED mini, ver Figura 7. Así, el rover puede navegar automáticamente mediante un programa de planificación de trayectoria o manualmente con un control remoto.

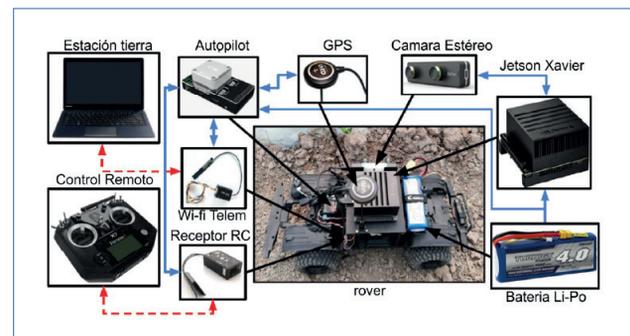


Figura 7. Componentes principales del vehículo.

Lo más importante es que estas características hacen que el rover sea ligero y compacto, lo que le permite navegar fácilmente por el campo de fresas, recolectando información importante y fiable de las fresas. Este robot podría ser una herramienta valiosa para la investigación agrícola y un ejemplo de cómo la tecnología puede contribuir al avance en este sector.

Implementación en el campo de fresas y resultados

Una vez completados los pasos para implementar la clasificación y la detección de las fresas por el robot autónomo, el funcionamiento del robot se realiza de acuerdo con lo mostrado en la Figura 8. En esta figura se observa

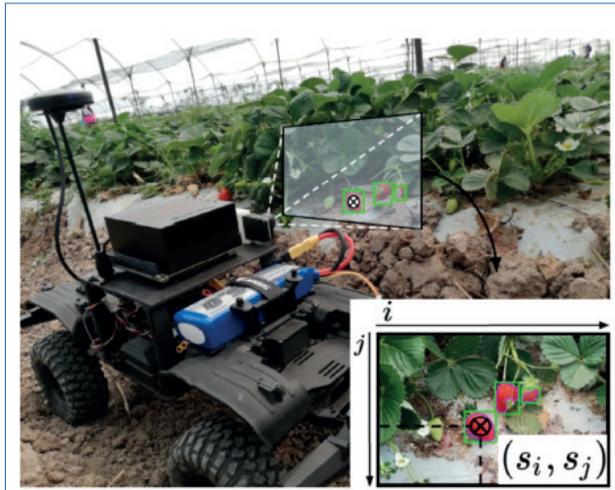


Figura 8. Rover detectando fresas en un entorno natural. En la esquina inferior derecha se puede ver la imagen capturada con las coordenadas del centroide de la fresa detectada (s_i, s_j).

cómo el rover navega paralelo a las fresas, y gracias a la cámara estereoscópica ubicada en su costado, a medida que avanza, el sistema identifica las fresas en su campo de visión, calcula su centroide y, mediante transformaciones geométricas, determina su posición local y global.

Sorprendentemente, el sistema logra detectar el 72% de las fresas totales en el campo y alcanza una precisión de detección del 93.75% en los escenarios más complejos como se ve en la Figura 9. Estos resultados superaron a los obtenidos por otros sistemas similares [11], [12]. Además, la colaboración con Huawei-UNAM generó valiosas oportunidades y lecciones aprendidas



Figura 9. Se muestra la detección de fresas maduras en el campo utilizando el rover. Se puede apreciar las fresas maduras, mientras que las fresas inmaduras se han ignorado.

en términos de capacidades tecnológicas y transferencia tecnológica. Un ejemplo concreto de esto es la generación de código en GitHub, disponible para su uso por otros investigadores, la industria agrícola y estudiantes interesados en el desarrollo de soluciones similares.

Adicionalmente, el sistema demostró ser eficiente en términos de velocidad de detección, procesando 23 imágenes por segundo, lo que demuestra que la integración de este tipo de robots autónomos es eficaz. Con esto se permite la navegación autónoma en el campo y la obtención de imágenes de alta calidad para su análisis posterior.

Por último, se calcula la posición de las fresas y se colocan en un mapa distinguiendo su nivel de maduración, facilitando al agricultor la identificación de su cosecha. La Figura 10 ilustra el proceso completo de este sistema: detección de la fresa mediante Deep Learning, extracción de información de intensidad para definir madurez, identificación de posición respecto al vehículo, su transformación a coordenadas globales y, finalmente, visualización de detecciones y ubicaciones en un mapa.

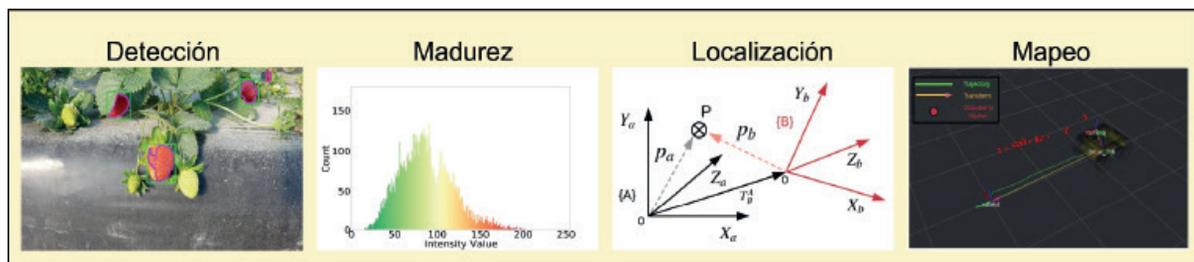


Figura 10. Se muestra una visión general del sistema completo propuesto, que consta de varios componentes clave.

Conclusión

La colaboración con Huawei-UNAM impulsó el desarrollo de este proyecto que combina tecnología avanzada, Deep Learning y cooperación empresarial-académica, logrando soluciones de inteligencia artificial aplicadas en la agricultura. El sistema desarrollado ha demostrado ser eficiente y preciso en la detección y clasificación

de fresas en el campo. A pesar de los desafíos, como la detección de fresas ocultas y la variedad de estados de maduración, este proyecto representa un avance significativo. Es necesario continuar investigando para aplicar este enfoque a otros cultivos, buscando mejorar la productividad y sostenibilidad agrícola en beneficio de una población en constante crecimiento.

BIBLIOGRAFÍA

- [1] M. A. Altieri, "La agricultura tradicional como legado agroecológico para la humanidad," *PH: Boletín del Instituto Andaluz del Patrimonio Histórico*, vol. 29, no. 104, pp. 180-197, 2021.
- [2] H. Bhardwaj et al., "Artificial intelligence and its applications in agriculture with the future of smart agriculture techniques," in *Artificial Intelligence and IoT-Based Technologies for Sustainable Farming and Smart Agriculture*, IGI Global, 2021, pp. 25-39.
- [3] S. T. Doddamani, S. Karadgi, and A. C. Giriapur, "Multi-Label Classification of Cotton Plant with Agriculture Mobile Robot," in *Data Intelligence and Cognitive Informatics: Proceedings of ICDICI 2021*, Singapore, Springer Nature Singapore, 2022, pp. 759-772.
- [4] A. Sharma et al., "Machine learning applications for precision agriculture: A comprehensive review," in *IEEE Access*, vol. 9, pp. 4843-4873, 2020.
- [5] Z. Niu, G. Zhong, and H. Yu, "A review on the attention mechanism of deep learning," in *Neurocomputing*, vol. 452, pp. 48-62, 2021.
- [6] G. Mejía, A. M. de Oca, and G. Flores, "Strawberry localization in a ridge planting with an autonomous rover," in *Engineering Applications of Artificial Intelligence*, vol. 119, pp. 105810, 2023.
- [7] B. Hill, T. Roger, and F. W. Vorhagen, "Comparative analysis of the quantization of color spaces on the basis of the CIELAB color-difference formula," in *ACM Transactions on Graphics (TOG)*, vol. 16, no. 2, pp. 109-154, 1997.
- [8] E. Agudo, P. J. Pardo, H. Sánchez, Á. L. Pérez, and M. I. Suero, "A low-cost real color picker based on Arduino," in *Sensors*, vol. 14, no. 7, pp. 11943-11956, 2014.
- [9] LeCun, Y. Bengio, and G. Hinton, "Deep learning," in *Nature*, vol. 521, no. 7553, pp. 436-444, 2015.
- [10] Deng, W. Dong, R. Socher, L. J. Li, K. Li, and L. Fei-Fei, "ImageNet: A large-scale hierarchical image database," in *2009 IEEE Conference on Computer Vision and Pattern Recognition*, June 2009, pp. 248-255.
- [11] T. Shao, Y. Wang, G. Xuan, Z. Gao, Z. Hu, C. Gao, and K. Wang, "Assessment of strawberry ripeness using hyperspectral imaging," in *Analytical Letters*, vol. 54, no. 10, pp. 1547-1560, 2020.
- [12] Liu and D. Xiao, "Recognition method of mature strawberry based on improved SSD deep convolutional neural network," in *Bio-inspired Computing: Theories and Applications: 14th International Conference, BIC-TA 2019, Zhengzhou, China, November 22-25, 2019, Revised Selected Papers, Part II*, vol. 14, pp. 271-281, Singapore, 2020.

Fecha de recepción: julio, 2023

Fecha de publicación: noviembre de 2023

Cómo se cita:

L. A. Moreno, G. Mejía, A. Montes de Oca, G. Flores, "Robot Autónomo para la detección y clasificación de fresas en campos de cultivo mediante Deep Learning," *TIES, Revista de Tecnología e Innovación en Educación Superior*, n.o. 8, noviembre, 2023. [En línea]. Disponible en: <https://ties.unam.mx/> [Consultado en mes día, año].