

Desarrollo de un sistema de monitoreo asistido por inteligencia artificial en Aeroponía

Oscar Valencia-Garaicochea
Facultad de Ingeniería
Universidad La Salle México
Ciudad de México, México
oscarvalencia@lasallistas.org.mx

Joel Valencia-González
Facultad de Ingeniería
Universidad La Salle México
Ciudad de México, México
joel.valencia@lasallistas.org.mx

Oscar-Rodrigo Palomares-Vargas
Facultad de Ingeniería
Universidad La Salle México
Ciudad de México, México
oscar.palomares@lasallistas.org.mx

José Ambrosio-Bastián
Vicerrectoría de Investigación
Universidad La Salle México
Ciudad de México, México
jose.ambrosio@lasalle.mx

Zizilia Zamudio-Beltrán
Vicerrectoría de Investigación
Universidad La Salle México
Ciudad de México, México
zizilia.zamudio@lasalle.mx

Resumen— Este proyecto aborda el uso de aeroponía asistida por inteligencia artificial, específicamente mediante el modelo de redes neuronales VGG16, para identificar plantas maduras listas para su recolección en jitomates cherries, manzanilla, lavanda, chile de árbol, fresa y lechuga. Se presenta el desarrollo de un sistema, el cual mediante una cámara se captura imágenes y se procesan aplicando transferencia de aprendizaje sobre redes convolucionales (CNN), con el fin de realizar una identificación precisa de las especies vegetales. Esta iniciativa tiene como meta mejorar la eficiencia y sostenibilidad de la producción agrícola en entornos controlados, además de automatizar el proceso de recolección en sistemas aeropónicos, aplicable tanto a escalas domésticas como industriales.

Palabras clave — Aeroponía, Inteligencia Artificial, Transferencia de aprendizaje, Identificación de Especies, Sostenibilidad Agrícola.

I. INTRODUCCIÓN

En la búsqueda constante por optimizar la producción agrícola y minimizar su impacto ambiental, la aeroponía emerge como una técnica innovadora que permite cultivos de alta densidad y un uso eficiente de los recursos. La creciente demanda mundial de alimentos, junto con la disminución de tierras agrícolas y la necesidad de adoptar prácticas sostenibles, ha impulsado el desarrollo de nuevas tecnologías en la agricultura. En este contexto, los sistemas de cultivo en entornos controlados, como la aeroponía, se presentan como una alternativa eficiente y sostenible frente a los métodos tradicionales, aunque la gestión y monitoreo efectivos de estos sistemas plantean desafíos significativos, especialmente en la identificación y manejo de diversas especies vegetales.

La aeroponía es una técnica de cultivo en la que las plantas se desarrollan en un entorno aéreo o de niebla, sin el uso de suelo (Fig. 1). El término "aeroponía" proviene de las palabras griegas *aero* (aire) y *ponos* (trabajo). A diferencia de la hidroponía y el cultivo *in vitro*, la aeroponía utiliza menos agua y optimiza el uso de recursos al reciclar la solución nutritiva, minimizando el desperdicio de agua [1], [2].

Entre las principales características de la aeroponía se destacan:

Mayor oxigenación de las raíces: Al estar expuestas al aire, las raíces reciben más oxígeno que en los métodos donde están sumergidas en agua o enterradas. Esto mejora el metabolismo de las plantas, promoviendo un crecimiento más rápido y vigoroso.

Ahorro de espacio y modularidad: Los sistemas aeropónicos son compactos y pueden disponerse en estructuras verticales, lo que los hace ideales para áreas reducidas, como apartamentos urbanos o terrenos no aptos para la agricultura tradicional. Además, son escalables, adaptándose tanto para uso doméstico como para operaciones comerciales a gran escala.

Reducción de enfermedades: Al evitar el contacto con el suelo, disminuye el riesgo de infecciones y plagas transmitidas por éste. Esto reduce la necesidad de pesticidas, haciendo que el sistema sea más seguro y ecológico.

Control preciso de las condiciones de cultivo: Los niveles de nutrientes, pH y otros factores se controlan con exactitud, lo que permite crear un entorno de cultivo óptimo y ajustable según las necesidades específicas de las plantas.

Facilidad en la cosecha: Las plantas cultivadas aeropónicamente son más fáciles de recolectar, ya que no es necesario remover tierra ni tratar con estructuras complicadas, lo que agiliza el proceso de cosecha.

Crecimiento acelerado: Las plantas crecen más rápido debido a la constante disponibilidad de nutrientes y oxígeno. La mayor oxigenación de las raíces favorece un metabolismo vegetal más eficiente.

Uso eficiente de recursos: Además de usar menos agua, la aeroponía reduce la cantidad de fertilizantes necesarios y elimina la necesidad de suelo, lo que la convierte en una técnica más sostenible y ambientalmente responsable.



Fig. 1. Aeroponía [3]

Según la literatura y varios estudios dedicados a revisar la aeroponía, esta técnica agrícola se posiciona como una solución eficiente y sostenible frente a los métodos tradicionales de cultivo. Al mantener las raíces de las plantas suspendidas en el aire y rociarlas con una fina niebla rica en nutrientes, se elimina la necesidad de suelo, permitiendo un control óptimo de las condiciones ambientales. Esto la convierte en una opción más eficaz, económica y sostenible, contribuyendo significativamente a la seguridad alimentaria y al desarrollo sostenible [4]. Sin embargo, una revisión de 47 estudios resalta que, aunque tecnologías como la Industria 4.0 y los sistemas de detección han mejorado su eficiencia, persisten desafíos como la complejidad técnica y la dependencia energética [5]. Además, se han desarrollado prototipos de sistemas aeropónicos con atomizadores a presión y plataformas de visión por computadora para cuantificar el crecimiento vegetal, subrayando la importancia de la integración tecnológica [6]. Por otro lado, un trabajo reciente ha adaptado un sistema aeropónico asequible, reutilizando componentes como un humidificador industrial y un cubo de basura modificado, basado en un diseño del ingeniero René Odorico, lo que demuestra la versatilidad de esta técnica en distintas áreas de investigación [7].

Se ha observado un aumento significativo en el desarrollo de sistemas de visión como herramientas clave en la agricultura. En [8], se describe cómo los sensores hiperespectrales permiten la identificación rápida de enfermedades en plantas, mejorando el monitoreo automatizado en sistemas aeropónicos. Del mismo modo, en [9], se explora la aplicación de sensores de imagen para detectar enfermedades en cultivos, destacando su rol en la agricultura de precisión. Por su parte, en [10] se detalla el uso de drones equipados con sensores ópticos para la detección temprana de enfermedades, lo que permite un monitoreo eficiente a gran escala. La inteligencia artificial juega un papel crucial en la resolución de problemáticas en general. Un ejemplo es el presentado en [11], donde se analiza el impacto de las redes neuronales convolucionales en el reconocimiento preciso de imágenes, logrando buenos resultados en la generalización a otros conjuntos de datos. Combinando todos estos campos, se han desarrollado algunas iniciativas que integran la agricultura y los sistemas de visión mediante inteligencia artificial, por ejemplo, en [12] se presenta una revisión centrada en tres áreas principales: la categorización de los big data generados en la agricultura inteligente, sus aplicaciones y las técnicas de aprendizaje automático utilizadas para su análisis, identificando también los retos actuales. Finalmente, en [13] se analizan diversas técnicas de clasificación empleadas para identificar enfermedades en plantas en etapas tempranas, utilizando métodos como el procesamiento de imágenes, el aprendizaje automático, redes neuronales y aprendizaje profundo, subrayando la importancia de prevenir impactos negativos en los cultivos.

Este proyecto tiene como objetivo desarrollar un sistema de aeroponía inteligente que integra tecnologías avanzadas de inteligencia artificial para monitorear e identificar plantas maduras listas para su recolección de varias especies vegetales, incluyendo jitomates cherry, manzanilla, lavanda, chile de árbol, fresa y lechuga. Utilizando transferencia de aprendizaje sobre redes neuronales convolucionales basada en el modelo VGG16, el sistema identifica en tiempo real las especies cultivadas y recopilar datos esenciales sobre su desarrollo. Este enfoque permitirá una automatización precisa,

optimizando tanto el crecimiento de las plantas como el proceso de recolección.

La clave de este proyecto reside en la integración de la inteligencia artificial en un sistema aeropónico, lo que permite ajustar de forma eficiente factores como la cantidad de nutrientes y agua, mejorando la productividad y reduciendo la intervención manual. Además, el sistema notificará al usuario cuando las frutas y verduras estén listas para su recolección, lo que lo hace una solución práctica tanto para aplicaciones domésticas como industriales.

II. METODOLOGÍA

En la siguiente sección se describen las fases que se desarrollaron en esta propuesta, las cuales fueron cinco etapas clave: se recopiló una base de datos de 600 imágenes por seis categorías de plantas, aplicando técnicas de aumento de datos. Las imágenes fueron preprocesadas para evitar el sobreajuste y se implementó una red neuronal VGG16, optimizada con funciones **ELU** y **ReLU** para clasificar las especies. Tras entrenar el modelo durante 100 épocas, se alcanzó una precisión del 100% a partir de la época 55. Finalmente, se validó el sistema con imágenes externas, asegurando una clasificación precisa de las especies y su estado de madurez, la síntesis de este desarrollo se puede observar en la Fig. 2.

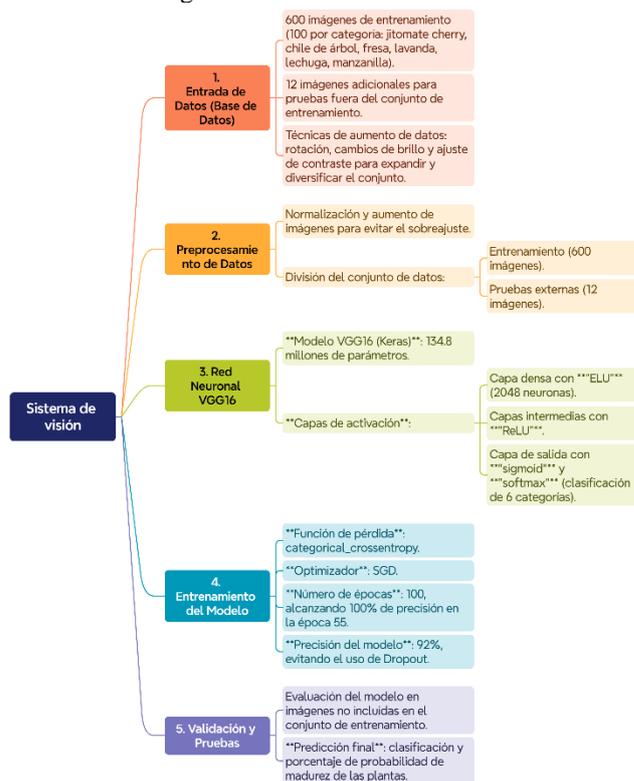


Fig. 2. Metodología implementada

A. BASE DE DATOS

La base de datos utilizada para el proyecto cuenta con un total de 600 imágenes de entrenamiento y 600 imágenes para pruebas (ver Fig. 3), distribuidas en seis categorías (ver Fig. 4): chile (0), jitomate cherry (1), fresa (2), lavanda (3), lechuga (4) y manzanilla (5), con 100 fotos por categoría para cada conjunto. Además, se incluyeron 12 imágenes adicionales (2 por cada categoría) que no fueron utilizadas durante el entrenamiento del modelo, sino que se reservaron

exclusivamente para probar la capacidad del sistema de reconocer imágenes fuera del conjunto original, evaluando así su capacidad de generalización.

```
train_dir = "/content/drive/MyDrive/IC/DF/Proyecto/DF_proyecto/train"
test_dir = "/content/drive/MyDrive/IC/DF/Proyecto/DF_proyecto/test"
train_datagen = ImageDataGenerator(rescale=1/255.,
                                  rotation_range=2,
                                  shear_range=0.2,
                                  zoom_range=0.1,
                                  horizontal_flip=True,
                                  )
test_datagen = ImageDataGenerator(rescale=1/255.,
```

Fig. 3. Procesamiento de imagen

Para mejorar el desempeño del modelo y maximizar el número de imágenes sin necesidad de incrementar significativamente el conjunto de datos, se realizaron modificaciones mínimas a las imágenes del entrenamiento, aplicando técnicas de aumento de datos como rotaciones o ajustes de iluminación. Estas modificaciones permitieron expandir el conjunto de imágenes sin introducir sesgos significativos, favoreciendo un entrenamiento más robusto del modelo en las distintas clases de vegetales y hierbas seleccionadas.



Fig. 4. Base de datos

B. MODELO VGG16

Para el desarrollo del proyecto se realizó un análisis entre diferentes modelos de aprendizaje profundo disponibles en <https://keras.io/api/applications/>, a fin de compararlos y determinar en ambiente real el modelo que presentara el mejor desempeño de reconocimiento en la aplicación web utilizando una webcam. Finalmente se determinó implementar una red neuronal basada en el modelo VGG16 utilizando la biblioteca Keras y empleando transferencia de aprendizaje [14]. Se mantuvo estática la sección del extractor de características y se modificó la parte del clasificador como puede observarse en la Fig. 5. Este modelo ha sido ampliamente adoptado debido a su eficiencia en el uso de recursos, tanto en procesadores CPU como en GPU, y por ofrecer una precisión en el *top-5 Accuracy* del 90.1% con un total de 138.4 millones de parámetros con una carga computacional en CPU de 69.5, mientras que en GPU se reporta de 4.2, lo que permitió un rendimiento balanceado y eficiente [15]. VGG16 fue seleccionado por su trayectoria de excelentes resultados en tareas de clasificación, permitiendo alcanzar altos porcentajes de precisión de manera más rápida y con menos capas.

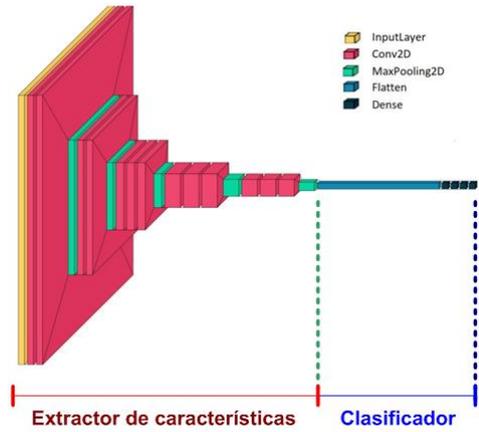


Fig. 5. Arquitectura del Modelo VGG16

Durante el desarrollo del proyecto, el modelo alcanzó una precisión del 92%, lo que eliminó la necesidad de usar técnicas como Dropout, que, aunque aceleraban el entrenamiento, redujeron la precisión a un 87%. En las capas del modelo, se empleó "ELU" en la primera capa densa, que contiene 2048 neuronas, debido a que esta función de activación bloquea menos neuronas en comparación con "ReLU" (ver Fig. 6), permitiendo una mejor convergencia del modelo y superando el 90% de precisión de manera eficiente. Posteriormente, se utilizó "ReLU" en las capas intermedias, ya que, aunque no maneja tantas neuronas como en la primera capa, acelera el proceso de aprendizaje evitando que muchas neuronas se bloqueen por alcanzar valores negativos. La capa sigmoide, al estar cerca de la salida, asigna valores entre 0 y 1 para distinguir mejor entre las distintas categorías. Finalmente, la capa de salida "softmax", clasifica las seis categorías de plantas y verduras objetivo del proyecto. La elección de "ELU" con 2048 parámetros de salida se debió a su capacidad para mejorar la convergencia del modelo, logrando superar el 90% de precisión de manera eficiente.

```
[ ] # Agregar nuevas capas utilizando la API funcional de KERAS
x = Flatten()(pre_trained_model.output)
x = Dense(2048, activation=ELU())(x)
#x = Dropout(.08)(x)
x = Dense(783, activation='relu')(x)
#x = Dropout(.2)(x)
x = Dense(16, activation='sigmoid')(x)
predicciones = Dense(6, activation='softmax')(x)
```

Fig. 6. Propuesta de transferencia de aprendizaje

Para el entrenamiento, se empleó la función de pérdida "categorical_crossentropy", adecuada para la clasificación multiclase, y se utilizó el optimizador "SGD", lo cual se puede observar en la Fig. 7.

```
#Compilar modelo
modelo.compile(loss='categorical_crossentropy', optimizer='sgd', metrics=['accuracy'])

#Entrenar modelo
history = modelo.fit(train_data, validation_data=test_data, epochs=100, batch_size=100)
```

Fig. 7. Entrenamiento del modelo

El resumen de la propuesta final del modelo basado en VGG16 está constituido por las capas mostradas en la Fig. 8.

Propuesta Modelo VGG16

| Layer (type) | Output Shape | Param # |
|----------------------------|-----------------------|----------|
| input_1 (InputLayer) | [(None, 224, 224, 3)] | 0 |
| block1_conv1 (Conv2D) | (None, 224, 224, 64) | 1792 |
| block1_conv2 (Conv2D) | (None, 224, 224, 64) | 36928 |
| block1_pool (MaxPooling2D) | (None, 112, 112, 64) | 0 |
| block2_conv1 (Conv2D) | (None, 112, 112, 128) | 73856 |
| block2_conv2 (Conv2D) | (None, 112, 112, 128) | 147584 |
| block2_pool (MaxPooling2D) | (None, 56, 56, 128) | 0 |
| block3_conv1 (Conv2D) | (None, 56, 56, 256) | 295168 |
| block3_conv2 (Conv2D) | (None, 56, 56, 256) | 590080 |
| block3_conv3 (Conv2D) | (None, 56, 56, 256) | 590080 |
| block3_pool (MaxPooling2D) | (None, 28, 28, 256) | 0 |
| block4_conv1 (Conv2D) | (None, 28, 28, 512) | 1180160 |
| block4_conv2 (Conv2D) | (None, 28, 28, 512) | 2359808 |
| block4_conv3 (Conv2D) | (None, 28, 28, 512) | 2359808 |
| block4_pool (MaxPooling2D) | (None, 14, 14, 512) | 0 |
| block5_conv1 (Conv2D) | (None, 14, 14, 512) | 2359808 |
| block5_conv2 (Conv2D) | (None, 14, 14, 512) | 2359808 |
| block5_conv3 (Conv2D) | (None, 14, 14, 512) | 2359808 |
| block5_pool (MaxPooling2D) | (None, 7, 7, 512) | 0 |
| flatten_1 (Flatten) | (None, 25088) | 0 |
| dense_4 (Dense) | (None, 2048) | 51382272 |
| dense_5 (Dense) | (None, 783) | 1604367 |
| dense_6 (Dense) | (None, 16) | 12544 |
| dense_7 (Dense) | (None, 6) | 102 |

Total params: 67713973 (258.31 MB)
 Trainable params: 52999285 (202.18 MB)
 Non-trainable params: 14714688 (56.13 MB)

Fig. 8. Modelo VGG16 implementado

C. APLICACIÓN WEB

Para el proyecto, se desarrolló una página web que utiliza la cámara del dispositivo para identificar contornos de objetos y dibujar recuadros alrededor de las figuras reconocidas (ver Fig. 9). Cuando el sistema detecta una figura, toma una captura de la imagen y la procesa a través del modelo preentrenado e integrado a la página WEB con la librería *TensorFlow.js*. Durante el procesamiento, la imagen capturada se compara con los datos almacenados en el modelo. Primero, el sistema identifica la especie de planta y luego evalúa su estado de madurez. Si la planta no está madura, no se muestra ningún resultado. En caso contrario, el sistema proporciona un porcentaje que indica la probabilidad de que la planta esté en su punto óptimo de maduración.



Fig. 9. Aplicación web desarrollada

III. RESULTADOS

Una vez finalizadas las sesiones de entrenamiento, que se llevaron a cabo durante 100 épocas, el modelo alcanzó una precisión del 100% a partir de la 55ª época.

Resultado en las últimas 5 iteraciones

| | |
|---------------|---|
| Epoch 95/100 | 19/19 [=====] -16s 837ms/step - loss: 0.0888 - accuracy: 1.0000 - val_loss: 0.3215 - val_accuracy: 0.9169 |
| Epoch 96/100 | 19/19 [=====] -16s 830ms/step - loss: 0.0875 - accuracy: 1.0000 - val_loss: 0.3133 - val_accuracy: 0.9219 |
| Epoch 97/100 | 19/19 [=====] -15s 795ms/step - loss: 0.0873 - accuracy: 1.0000 - val_loss: 0.5215 - val_accuracy: 0.9136 |
| Epoch 98/100 | 19/19 [=====] -15s 827ms/step - loss: 0.0846 - accuracy: 1.0000 - val_loss: 0.3003 - val_accuracy: 0.9153 |
| Epoch 99/100 | 19/19 [=====] -15s 807ms/step - loss: 0.0840 - accuracy: 1.0000 - val_loss: 0.3052 - val_accuracy: 0.9166 |
| Epoch 100/100 | 19/19 [=====] -16s 831ms/step - loss: 0.0842 - accuracy: 0.9983 - val_loss: 0.3074 - val_accuracy: 0.9236 |

Fig. 10. 5 iteraciones finales

Además, la precisión de validación se mantuvo entre el 89% y el 90% hasta el término del entrenamiento, lo que indica un buen equilibrio entre el ajuste del modelo y su capacidad de generalización, en la Fig. 10 se presenta el resultado obtenido en las últimas 5 iteraciones.

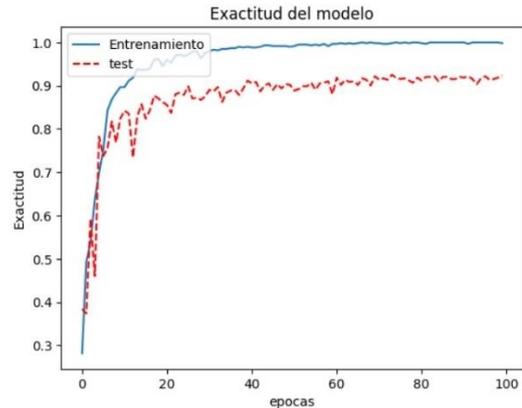


Fig. 11. Resultados de la exactitud del modelo

La precisión y las pérdidas del modelo pueden verse representadas en la Fig. 11 y Fig. 12 respectivamente.

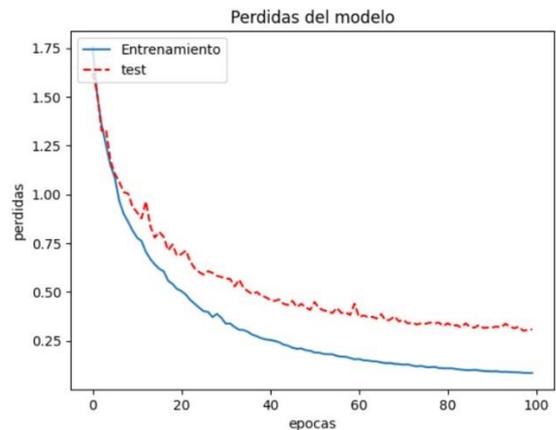


Fig. 12. Resultados sobre las pérdidas del modelo

Algunas pruebas experimentales pueden ser observadas en la Fig. 13, en donde por medio de la aplicación web desarrollada se escoge la cámara por la cual se estará visualizando alguna de las 6 categorías establecidas. Las pruebas que se presentan son con fresa y jitomate cherry y se observa su correcta identificación.



Fig. 13. Identificación exitosa en aplicación web

En la Fig. 14, se observa que el algoritmo implementado es capaz de reconocer las categorías al mismo tiempo, como es el caso de la fresa y el jitomate cherry.



Fig. 14. Identificación de varias categorías

La aplicación es capaz de reconocer cuando las frutas se encuentran en el momento exacto para ser cosechadas.

IV. CONCLUSIONES

En conclusión, el proyecto ha logrado con éxito desarrollar un sistema de aeroponía inteligente que integra tecnologías avanzadas de inteligencia artificial, cumpliendo plenamente con los objetivos establecidos. Al implementar una red neuronal convolucional basada en el modelo VGG16, el sistema ha demostrado su capacidad para identificar en tiempo real las especies vegetales que están listas para su recolección, incluyendo jitomates cherry, manzanilla, lavanda, chile de árbol, fresa y lechuga. Esta identificación precisa permitirá que en la implementación real pueda recopilar datos esenciales sobre el desarrollo de las plantas, facilitando así una automatización efectiva en el proceso de monitoreo y recolección.

La integración de inteligencia artificial permitirá ajustar de manera eficiente factores críticos, como la cantidad de nutrientes y agua, lo que no solo mejora la productividad, sino que también reduce significativamente la necesidad de intervención manual. Además, la funcionalidad de notificación al usuario sobre la madurez de las frutas y verduras proporciona una solución práctica y accesible tanto para el uso doméstico como para aplicaciones industriales.

Con este enfoque, el proyecto busca contribuir a la sostenibilidad y la seguridad alimentaria, adaptándose a los cambios en la producción agrícola en entornos controlados y urbanos. Al facilitar el acceso a una tecnología eficiente, esta propuesta no solo incrementa la eficiencia en la producción, sino que también responde a las necesidades de un modelo de agricultura más sostenible y tecnológicamente avanzado.

REFERENCIAS

- [1] Kumari, R., & Kumar, R. (2019). Aeroponics: A review on modern agriculture technology. *Indian Farmer*, 6(4), 286-292.
- [2] Lakhari, I. A., Gao, J., Syed, T. N., Chandio, F. A., Buttar, N. A., & Qureshi, W. A. (2018). Modern plant cultivation technologies in agriculture under controlled environment: A review on aeroponics. *Journal of Plant Interactions*, 13(1), 338-343. <https://doi.org/10.1080/17429145.2018.1485812>
- [3] OpenAI. (2024). Aeroponic system for plant cultivation [Imagen generada por IA]. DALL-E. <https://chat.openai.com/>
- [4] Garzón, J., Montes, L., & Lampropoulos, G. (2023). Systematic Review of Technology in Aeroponics: Introducing the Technology Adoption and Integration in Sustainable Agriculture Model. *Agronomy*, 13(10), 2517. <https://doi.org/10.3390/agronomy13102517>
- [5] Min, A., et al. (2023). Aeroponic systems design: considerations and challenges. *Journal of Agricultural Engineering*, 54(1), 78-90. <https://doi.org/10.4081/jae.2023.1387>
- [6] Li, C., et al. (2023). A modified aeroponic system for growing small-seeded legumes to study root systems. *Plant Methods*, 19(1), 17. <https://doi.org/10.1186/s13007-023-01017-9>
- [7] Li, C., Wang, A., & Yang, Y. (2022). Hyperspectral Sensing of Plant Diseases: Principles and Methods. *Agronomy*, 12(6), 1451. <https://doi.org/10.3390/agronomy12061451>
- [8] Mahlein, A. K. (2016). Plant Disease Detection by Imaging Sensors. *Plant Disease*, 100(2), 241-251. <https://doi.org/10.1094/PDIS-03-15-0340-FE>
- [9] Veroustraete, F. (2015). Drones in Plant Disease Assessment, Efficient Monitoring, and Detection. *Agriculture*, 5(2), 356-364. <https://doi.org/10.3390/agriculture5020356>
- [10] Simonyan, K., & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv preprint*. <https://arxiv.org/abs/1409.1556>
- [11] Ahmed, N., & Hameed, I. A. (2021). A survey on intelligent agriculture: The role of machine learning and data mining in automated agriculture. *Computers and Electronics in Agriculture*, 189, 106148. <https://doi.org/10.1016/j.compag.2021.106148>
- [12] Nigam, S., & Jain, R. (2022). Plant disease identification using Deep Learning: A review. *Indian Journal of Agricultural Sciences*, 90(2), 99-106. <https://doi.org/10.56093/ijas.v90i2.98996>
- [13] Aeroponía Mexicana. (n.d.). Aeroponía Mexicana. <https://www.aeroponiamexicana.com/>
- [14] Azamar-Avilés, S., Granados-Reyes, M., Ambrosio-Bastián, J., Zamudio-Beltrán, Z. (2024). Evaluating the Effectiveness of an AI Model with Transfer of Learning in the Educational Attendance Record. In: Mezura-Montes, E., Acosta-Mesa, H.G., Carrasco-Ochoa, J.A., Martínez-Trinidad, J.F., Olvera-López, J.A. (eds) Pattern Recognition. MCPR 2024. Lecture Notes in Computer Science, vol 14755. Springer, Cham. https://doi.org/10.1007/978-3-031-62836-8_17
- [15] Keras. (n.d.). Keras applications. Keras. <https://keras.io/api/applications/>