

“SISTEMA DE MONITOREO DE SALUD DE STEVIA REBAUDIANA MORITA II USANDO REDES NEURONALES NO SUPERVISADAS”

¹Brizuela-Ramírez Jesús-Emmanuel, ¹García-Díaz Noel, ¹García-Virgen Juan, ¹Verduzco-Ramírez Jesús-Alberto, ¹Jardines-González Arturo-Iván, ¹Gutiérrez-Magaña Shanti-Maryse, ²Soriano-Equigua Leonel

¹Tecnológico Nacional de México Campus Colima

División de Estudios de Posgrado e Investigación

Av. Tecnológico No. 1 Villa de Álvarez, Col. C.P. 28976 Villa de Álvarez, Colonia Liberación

Tel.+523123126393

²Universidad de Colima / Facultad de Ingeniería Mecánica y Eléctrica Carretera Colima - Coquimatlán km 9,

Valle de las Huertas, 28400 Coquimatlán, Colima Teléfono: +523123161165

{g2346011, ngracia, jgarcia, averduzco, g2346013} @colima.tecnm.mx, lsoriano@uclm.com

RESUMEN.

La eficiencia en el rendimiento de los cultivos se ve impactada por enfermedades y otros elementos. En la actualidad, los métodos convencionales para identificar enfermedades en el follaje son complicados, caros, lentos y susceptibles a errores. El propósito es emplear inteligencia artificial, particularmente redes neuronales convolucionales no supervisadas, para clasificar imágenes y detectar enfermedades. El estudio presenta el diseño y desarrollo de SteviaClusterAI, un sistema de monitoreo de salud para el cultivo de Stevia rebaudiana Morita II utilizando este tipo de redes. El propósito principal es aumentar la productividad agrícola mediante la identificación precisa del estado de salud de las plantas, clasificando las imágenes en categorías de acidez baja, óptima y alcalinidad alta. Los resultados obtenidos demuestran una precisión del 96% en la clasificación, lo que resalta el potencial de esta herramienta para apoyar decisiones informadas en la agricultura moderna y mejorar el rendimiento de los cultivos.

Palabras Clave: Inteligencia Artificial, Redes Neuronales Convolucionales No Supervisadas, Cultivo, Acidez Baja, Alcalinidad Alta.

ABSTRACT.

The efficiency of crop yield is impacted by diseases and other factors. Currently, conventional methods for identifying diseases in foliage are complex, expensive, slow, and error-prone. The aim is to employ artificial intelligence, specifically unsupervised convolutional neural networks, to classify images and detect diseases. The study presents the design and development of SteviaClusterAI, a health monitoring system for Stevia rebaudiana Morita II cultivation using unsupervised convolutional neural networks. The primary goal is to enhance agricultural productivity by accurately identifying the health status of plants, classifying images into categories of low acidity, optimal, and high alkalinity. The results demonstrate a 96% accuracy in classification, highlighting the potential of this tool to support informed decision-making in modern agriculture and improve crop yield.

Keywords: Artificial Intelligence, Unsupervised Convolutional Neural Networks, Cultivation, Low Acidity, High Alkalinity.

1. INTRODUCCIÓN

1.1. Antecedentes

La agricultura ha sido fundamental para el desarrollo y la subsistencia de la sociedad humana a lo largo de la historia. Proporciona la mayoría de los alimentos básicos en la dieta mundial y es crucial para los planes de desarrollo de seguridad alimentaria. Sin embargo, se estima que la productividad agrícola actual no es suficiente para cubrir la demanda de una población en crecimiento. De acuerdo con [1] se proyecta que para 2050, se necesitará aumentar la producción de alimentos en al menos un 70% para garantizar la seguridad alimentaria de una población de 9.8 billones de personas.

Esto implica adoptar una agricultura moderna que maximice la productividad mediante el uso de alternativas que aseguren rentabilidad para los agricultores.

1.2. Stevia

La Stevia rebaudiana Bertonii es una planta originaria de Paraguay, esta planta produce un edulcorante natural no calórico llamado estevósido, que es 300 veces más dulce que la sacarosa, captando la atención de diversos sectores [2].

La planta de Stevia se cultiva comercialmente en Argentina, Brasil, Colombia, Paraguay, China, Japón, Malasia, Corea del Sur, Vietnam, Israel, Australia, Kenia, Estados Unidos y México [3].

La Stevia fue introducida en México en 2010 a través del Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP), con una superficie potencial para la siembra de este cultivo de 4,487,902 toneladas en el año 2018[4].

En México, hay áreas con un gran potencial para el cultivo debido a las condiciones ecológicas favorables, que incluyen clima, suelos, vegetación, altitud, topografía, hidrología y otros factores propicios para su desarrollo [5].

Estas condiciones las cumplen los estados de Sinaloa, Nayarit, Jalisco, Michoacán, Guerrero, Oaxaca, Chiapas, Yucatán, Campeche, Quintana Roo, Veracruz, Puebla, Tamaulipas y Colima.

1.3. Rancho Tajeli

Uno de los principales productores en el Estado de Colima es “Rancho Tajeli” (<https://www.ranchotajeli.com/>), empresa familiar fundada en 2015, ubicada en el municipio de Cuauhtémoc, Colima, México, con coordenadas 19.2434116,-103.6603778, dicha empresa está especializada en cultivo de suelo como en invernadero.

Rancho Tajeli cuenta con condiciones climáticas favorables, sin embargo, enfrenta un desafío que afecta su productividad agrícola: la ausencia de un sistema de monitoreo de salud eficiente. Esta carencia impide la toma de decisiones fundamentadas y la implementación de medidas correctivas.



Figura 1. Vista Satelital “Rancho Tajeli”.

1.4. Inteligencia Artificial (IA)

La Inteligencia Artificial (IA) es la capacidad de una máquina de simular la inteligencia humana a través de la comunicación, engañando a un observador. Esto sentó las bases para definir y evaluar el grado de inteligencia de sistemas artificiales [6].

1.4.1. Redes Neuronales (RN)

Una Red Neuronal (RN), se describe como un sistema computacional que consiste en una gran cantidad de elementos de procesamiento simples, conocidos como neuronas, interconectadas y organizadas en capas. Estas redes tienen la capacidad de aprender y ejecutar tareas complejas al adaptar sus conexiones internas en función de la información recibida del entorno [7].

La analogía de una RN se basa en el funcionamiento del cerebro humano, donde las neuronas se activan en respuesta a estímulos y transmiten señales a través de conexiones sinápticas. La habilidad de aprendizaje de una RN radica en ajustar los pesos de estas conexiones para mejorar la respuesta de la red ante diferentes patrones de entrada.

En una RN se distinguen tres tipos principales de capas: capa de entrada, la cual se encarga de recibir los datos de origen y transmitirlos a las siguientes capas, sin realizar ningún tipo de procesamiento, las capas ocultas realizan el procesamiento principal de los datos, aplicando transformaciones y detectando características complejas mediante la combinación de los pesos y las funciones de activación, por último la capa de salida, las neuronas en la capa de salida recopilan la información procesada por las capas ocultas y generan el resultado de la red, que puede ser una predicción, clasificación, o cualquier otro tipo de resultado deseado según la tarea específica que se esté realizando.

Cada neurona en una capa está conectada a todas las neuronas de la capa siguiente y, generalmente, a las de la capa anterior, dependiendo de la arquitectura específica de la red. La información fluye desde la capa de entrada, a través de las capas ocultas, hasta la capa de salida, donde se produce el resultado final [7].

1.4.2. Redes Neuronales Convolucionales (CNN)

Las Redes Neuronales Convolucionales (por sus siglas en inglés, CNN) son modelos que imitan el sistema visual biológico y automatizan la aproximación de funciones complejas. Al igual que la corteza visual humana, aplican operaciones matemáticas como convolución y muestreo a datos de entrada con estructura espacial, como imágenes, para extraer características de bajo y alto nivel. Debido a este proceso jerárquico de representación, las CNN pueden aprender a reconocer y clasificar patrones visuales presentes en las imágenes sin necesidad de un procesamiento manual de características. De esta manera, emulan el funcionamiento del sistema visual humano para tareas como la detección y clasificación de objetos en imágenes [8].

1.4.2.1. Redes Neuronales Supervisadas

Las RN supervisadas son aquellas que aprenden a partir de un conjunto de datos etiquetados. Cada ejemplo de entrenamiento incluye una entrada y una salida deseada, conocida como etiqueta. El objetivo de la red es aprender una función que mapea las entradas a las salidas correctas. Este proceso implica ajustar los pesos internos de la red para minimizar la diferencia entre las salidas predichas por la red y las salidas reales (etiquetas) a través de un proceso llamado retropropagación del error [9].

1.4.2.2. Redes Neuronales No Supervisadas

Las RN no supervisadas, por otro lado, trabajan con datos que no están etiquetados. El objetivo principal es encontrar patrones o estructuras subyacentes en los datos. En lugar de aprender de un mapeo de entrada a salida, estas redes buscan agrupar la dimensionalidad de los datos de manera que se revele alguna estructura inherente [10].

En este trabajo de investigación aplicada, se utilizará este tipo de RN no supervisadas.

1.4.2.2.1. Codificador

Es la primera parte del autoencoder. Su función es transformar la entrada original en una representación comprimida o de menor dimensión [10].

1.4.2.2.2. Decodificador

Es la segunda parte del autoencoder. Su función es tomar la representación comprimida y reconstruir la entrada original lo más escrupulosamente posible [10].

1.5. Trabajos relacionados

En esta sección se examinan diversos estudios relacionados con la investigación actual, destacando las áreas de oportunidad que fueron encontradas. Enseguida, son descritos los siguientes trabajos en la Tabla 1.

Tabla 1. Trabajos relacionados.

Referencia	Cultivo	Metodología	Precisión	Observaciones
[11]	Manzana, Arándano, Cereza, Maíz, Uva, Naranja, Durazno, Entre otros.	CNN	99.35%	Utilizaron la base de datos PlantVillage, que incluye imágenes de hojas de diferentes cultivos con diversas enfermedades.
[12]	Manzana	CNN	96.30%	Implementaron una CNN para clasificar enfermedades de manzanas a partir de imágenes de hojas, logrando una alta
[13]	Uvas	Red Neuronal supervisada	94.67%	Emplearon procesamiento de imágenes y una red neuronal supervisada para detectar enfermedades en hojas de uva.
[14]	Trigo	Red Neuronal no supervisada	90.12%	Utilizaron imágenes hiperespectrales y Mapas Autoorganizados (SOM) para identificar patrones de enfermedades en trigo.
[15]	Tomate	CNN	97.27%	La red CNN se entrenó con imágenes de hojas de tomate, identificando diversas enfermedades con alta precisión.

Finalmente, es relevante señalar que los trabajos relacionados mostrados presentan resultados significativos, sin embargo, ninguno de los estudios revisados se ha empleado para evaluar los suelos para cultivos de Stevia utilizando una RN no supervisada.

2. DESARROLLO.

2.1. Parámetros de monitoreo de salud de Stevia

Para el desarrollo de este trabajo es necesario definir los parámetros de monitoreo de salud de Stevia identificando factores del suelo dominante. En el trabajo [16] se resaltaron que las regiones con suelos apropiados obtuvieron el máximo

rendimiento y calidad en el cultivo de Stevia en función de diferentes ubicaciones geográficas.

Basándose en los datos recopilados de [16], se definió como indicador relevante para el progreso del cultivo el potencial de hidrógeno (pH), lo cual se dividió en las categorías: "Acidez baja", "Óptimo" y "Alcalinidad Alta", tal como se ilustra en la Tabla 2.

Tabla 2. Factor del suelo dominante.

Parámetros	Rangos		
	Acidez Baja	Óptimo	Alcalinidad Alta
pH	< 6.0	6.0-7.0	> 7.0

2.2. Adquisición de datos.

Para la obtención de los datos se utilizó el detector de suelo portátil JXBS-3001-SCY-PT como se observa en la Figura 2. El detector de sonda de sensor de suelo cuenta con una pantalla LCD, interfaz interactiva, función de almacenamiento de datos, alta sensibilidad y velocidad de respuesta rápida.



Figura 2. Detector de sonda de sensor.

2.3. Adquisición de imágenes.

La adquisición de imágenes fue llevada a cabo en Rancho Tajeli, obteniendo una muestra de 170 imágenes.

La captura de imágenes se realizó con una cámara de celular marca Xiaomi redmi 9 con especificaciones de 13MP + 8MP + 5MP + 2MP cámara cuádruple, la cual se adaptó una caja de luz para fotografía portátil (Figura 3), cuyas dimensiones son 60 x 60 x 70 cm, integrando un aro de luz en el techo con una iluminación de 2,878 lux.



Figura 3. Caja de luz para fotografías portátiles.

2.4. Aumento de datos y preprocesamiento de imágenes.

Es fundamental aplicar técnicas de normalización al procesar imágenes para garantizar su uniformidad o estandarización en las muestras. De acuerdo a [17] el aprendizaje profundo depende de grandes conjuntos de datos para evitar el sobreajuste. Existen diferentes técnicas de ampliación de datos como transformaciones geométricas, de color, filtrado de kernel, mezcla de imágenes, borrado aleatorio, aumento del espacio de características, entrenamiento adversario, estilo neural, entre otras.

2.5. Métricas de evaluación.

Es esencial seleccionar los indicadores correctos. De acuerdo a [17], los indicadores de evaluación ampliamente empleados para medir el desempeño de modelos de clasificación en el análisis de imágenes incluyen la Precision (1), Recall (2), F1- score (3) y Accuracy (4). Las métricas se calculan con las evaluaciones de verdaderos positivos y otros componentes que se derivan de la matriz de confusión. La matriz de confusión es una tabla que se utiliza para describir el desempeño de un modelo de clasificación en un conjunto de datos de prueba cuyos valores verdaderos son conocidos [18]. Las métricas se calculan con las evaluaciones de verdaderos positivo, donde verdadero negativo (TN) indica la cantidad de instancias negativas predichas correctamente como negativas, falso positivo (FP) es el recuento de instancias negativas incorrectamente predichas como positivas, falso negativo (FN) denota el número de instancias positivas erróneamente predichas como negativas, y verdadero positivo (TP) representa la cantidad de instancias positivas predichas correctamente como positivas. Las fórmulas para la obtención de cada métrica se observan en la Figura 4.

$$\text{Precisión (P)} = \frac{TP}{TP+FP} \quad (1)$$

$$\text{Recall (R)} = \frac{TP}{TP+FN} \quad (2)$$

$$\text{F1-score} = 2 * \frac{(PXR)}{P+R} \quad (3)$$

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

Figura 4. Métricas de evaluación.

La matriz de confusión no solo permite calcular estas métricas, sino que también proporciona una visión detallada sobre qué tipos de errores está cometiendo el modelo, tal cual se observa en la Tabla 3.

Tabla 3. Matriz de confusión.

	Valores Actuales	
Valores predichos	TN	FN
	FP	TP

2.8. Arquitectura del modelo propuesto.

La red propuesta se denomina SteviaClusterAI. Este modelo es un autoencoder convolucional no supervisado que emplea PyTorch para analizar y clasificar el estado de salud de las plantas de Stevia. La estructura del modelo se organiza en un codificador y un decodificador, diseñados para comprimir y reconstruir las imágenes de entrada, respectivamente. El modelo SteviaClusterAI está compuesta por múltiples capas convolucionales y de agrupamiento, diseñadas específicamente para analizar y clasificar el estado de salud de las plantas de Stevia (Figura 5).




Figura 5. Arquitectura del modelo propuesto.

Este autoencoder no supervisado, implementado en PyTorch, trabaja comprimiendo y reconstruyendo imágenes de entrada de forma eficiente. La arquitectura del SteviaClusterAI ha sido minuciosamente diseñada y optimizada mediante diversas pruebas en la configuración de parámetros, tales como el número de filtros, el tamaño de las ventanas de análisis, las funciones de activación y los esquemas de agrupamiento (KMeans). Estas pruebas aseguran que el modelo pueda extraer y reconstruir características complejas de las imágenes, logrando así una clasificación precisa del estado de las plantas de Stevia.

2.8.1. Codificador

El codificador incluye dos capas principales de procesamiento de imágenes y dos capas de reducción de tamaño. La primera capa utiliza 16 filtros (3x3) para analizar la imagen de entrada que tiene 3 colores: rojo, verde y azul. Esta capa mueve su

ventana de análisis de 3x3 píxeles en pasos de 2 píxeles a la vez, lo que reduce el tamaño de la imagen y la cantidad de cálculos necesarios. Para evitar perder información en los bordes, se añade un borde de ceros alrededor de la imagen. Después de esta capa, se aplica una función llamada ReLU que ayuda a que el modelo pueda detectar patrones complejos. La siguiente capa, llamada MaxPooling, reduce aún más el tamaño

de la imagen seleccionando los valores más importantes en áreas de 2x2 píxeles. Luego, se aplica otra capa de análisis con 8 filtros de 3x3, también moviéndose en pasos de 2 píxeles y con borde de ceros alrededor. Posteriormente otra aplicación de la función ReLU, se usa una segunda capa de MaxPooling que realiza una reducción de tamaño adicional con áreas de 2x2 píxeles.

2.8.2. Decodificador

El decodificador del modelo se encarga de reconstruir la imagen original usando tres capas principales. La primera capa del decodificador usa 8 filtros de 3x3 y mueve su ventana de análisis en pasos de 2 píxeles, lo que aumenta el tamaño de la imagen. Se añade un borde de ceros alrededor y se asegura que la salida tenga el tamaño correcto añadiendo un píxel extra al final si es necesario. Una función llamada ReLU se aplica para permitir la detección de patrones complejos. La siguiente capa también usa 16 filtros de 3x3 con las mismas especificaciones, y nuevamente se aplica la función ReLU. Finalmente, una tercera capa usa 3 filtros para reconstruir la imagen a su tamaño original con sus tres colores. Esta última capa utiliza una función llamada Sigmoid para normalizar los valores de los píxeles entre 0 y 1, asegurando que los colores sean correctos. Una vez que las características del conjunto de validación han sido extraídas utilizando el autoencoder, se aplica el algoritmo de agrupamiento KMeans para agrupar las imágenes en 3 clusters: "Acidez baja" (clase 0), "Óptimo" (clase 1), y "Alcalinidad Alta" (clase 2). El agrupamiento en clústeres es un método de aprendizaje automático no supervisado cuyo objetivo es agrupar puntos similares en el mismo clúster según ciertos criterios y asignar puntos diferentes a otros clústeres. Entre los muchos algoritmos disponibles, K-means destaca por ser eficiente y sencillo. Este algoritmo no supervisado asigna etiquetas a las imágenes en función de la similitud de sus características extraídas, lo que permite clasificar sin necesidad de etiquetas predefinidas. El proceso de agrupación con K-means se realiza directamente sobre las características extraídas, sin la intervención de un modelo supervisado adicional, lo que implica que la tarea se lleva a cabo sin utilizar redes neuronales supervisadas [18].

3. RESULTADOS

Para evaluar el rendimiento del modelo, el conjunto de datos se particionó empleando el método Hold-out [19], consiste en dividir el conjunto de datos en dos subconjuntos, uno para el entrenamiento del modelo y otro para su validación. En este trabajo, se realizaron tres particiones: 90/10, 80/20, y 70/30, lo que significa que se utilizaron el 90%, 80% y 70% de los datos para entrenamiento, respectivamente, mientras que el 10%, 20% y 30% restante se destinaron para la validación del modelo. De estas particiones, la división 80/20, con 136 datos para entrenamiento y 34 datos para validación, resultó la mejor precisión para el modelo, como se muestra en la Tabla 4.

Tabla 4. Resultado de particiones holdout.

Partición	Accuracy
90/10	0.91
80/20	0.94
70/30	0.89

Estos resultados se reportan en la Figura 6, obteniendo un 94% de precisión. Estos datos sugieren que el sistema de monitoreo propuesto es altamente efectivo para el cultivo de Stevia, proporcionando una herramienta valiosa para la toma de decisiones en la agricultura.

Accuracy (Validación): 0.9411764705882353
 Classification Report (Validación):

	precision	recall	f1-score	support
0	0.88	1.00	0.93	7
1	0.95	0.95	0.95	20
2	1.00	0.86	0.92	7
accuracy			0.94	34
macro avg	0.94	0.94	0.94	34
weighted avg	0.94	0.94	0.94	34

Figura 6. Reporte de métricas de evaluación.

Además, se obtuvo la matriz de confusión con los resultados de la partición 80/20, el cual distingue entre tres clases: "Acidez baja" (clase 0), "Óptimo" (clase 1), y "Alcalinidad Alta" (clase 2), como se muestra en la Figura 7. Cada fila representa la clase verdadera, mientras que cada columna muestra las predicciones del modelo.

En la primera fila, que corresponde a la clase "Acidez baja", el modelo acertó en los 7 ejemplos fueron correctamente clasificados como "Acidez baja" (verdaderos positivos), indicando una predicción precisa sin falsos positivos ni falsos negativos. La segunda fila, que representa la clase "Óptimo", muestra que acertó en 19 casos (verdaderos positivos), pero erró al predecir 1 caso de "Óptimo" como "Acidez baja" (falso negativos). En la tercera fila, correspondiente a la clase "Alcalinidad Alta", muestra que 6 casos fueron correctamente predichos como "Alcalinidad Alta" (verdaderos positivos), sin embargo, erró 1 caso de "Alcalinidad Alta" como "Óptimo" (falso negativos).

Matriz de confusión

	0	1	2
0	7	0	0
1	1	19	0
2	0	1	6

Predicciones

Figura 7. Matriz de confusión SteviaClusterAI.

Asimismo, se realizó interfaz gráfica en tkinter para la carga y predicción del estado de cultivo a través de imágenes, donde de igual manera las clasifica en las categorías: "Acidez baja", "Óptimo" y "Alcalinidad Alta", como se observan en las Figuras 8, 9 y 10.



Figura 8. Predicción para acidez baja.




Figura 9. Predicción para óptimo.



Figura 10. Predicción para alcalinidad alta.

4. CONCLUSIÓN

El presente estudio ha demostrado la efectividad del uso de redes neuronales no supervisadas para el monitoreo del estado de salud de la planta de Stevia. La implementación de la arquitectura SteviaClusterAI ha alcanzado una precisión del 94%, lo que resalta su potencial como una herramienta valiosa para la agricultura moderna.

El sistema desarrollado no solo facilita la identificación rápida y precisa de problemas de acidez o alcalinidad del suelo, sino que también apoya la toma de decisiones informadas para mejorar el rendimiento del cultivo. La interfaz gráfica basada en Tkinter permite una utilización práctica y accesible para los agricultores, clasificando las imágenes de los cultivos en categorías de acidez baja, óptima y alcalinidad alta.

En conclusión, este trabajo sienta las bases para futuros desarrollos en la agricultura digital, destacando la importancia

de la innovación tecnológica en la mejora de la producción agrícola y la sostenibilidad alimentaria.

5. TRABAJO A FUTURO

A pesar de los logros alcanzados, se identificaron áreas de mejora y expansión futura que podrían consolidar y extender los beneficios de esta tecnología a nivel global.

- La integración de otros parámetros como la temperatura, humedad, y niveles de nutrientes del suelo podría proporcionar un análisis más comprensivo del estado de salud de los cultivos.
- El desarrollo de modelos más complejo: Combinar redes neuronales convolucionales con otros enfoques de inteligencia artificial, como las redes neuronales recurrentes (RNN).
- La expansión del sistema a otros cultivos para verificar la versatilidad del sistema y su aplicación a nivel global, favoreciendo a una mayor variedad de agricultores.

6. REFERENCIAS.

- [1] D. Vinchira-Villarraga and N. Moreno-Sarmiento, "Control biológico: Camino a la agricultura moderna", Revista Colombiana de Biotecnología, vol. 21, no. 1, pp. 2-5, 2019.
- [2] Ramírez-Jaramillo, M. G. Lozano-Contreras, "Productive potential of Stevia rebaudiana Bertonii under irrigation conditions in Mexico," Agroproductividad, vol. 9, no. 12, pp. 76-81, Dec. 2016.
- [3] Samuel et al., "Stevia Leaf to Stevia Sweetener: Exploring Its Science, Benefits, and Future Potential", The Journal of Nutrition, vol. 148, no. 7, pp. 1186S-1205S, 2018
- [4] P. Samuel et al., "Stevia Leaf to Stevia Sweetener: Exploring Its Science, Benefits, and Future Potential", The Journal of Nutrition, vol. 148, no. 7, pp. 1186S-1205S, 2018.
- [5] V. de la Cruz Delgado and J. Flores Galaviz, "Plan de negocio para elevar la competitividad de las PYMES productoras de stevia: caso municipio Valle de Chalco, estado de México", Eumed.net, 2022.
- [6] A. Escrig Vidal, "Alan Turing y el nacimiento de la inteligencia artificial", Antena de Telecomunicación, No 167, Mar., pp. 44-48, 2007.
- [7] Haykin, S. Neural Networks and Learning Machines, 3rd ed. Pearson, 2009.
- [8] A. Hajian y P. Styles, Application of soft computing and intelligent methods in geophysics. Cham, Suiza: Springer, 2018.
- [9] Duda, R. O., Hart, P. E., & Stork, D. G. . Pattern Classification. Wiley-Interscience. 2001
- [10] Kohonen, T. Self-Organizing Maps. Springer.2015
- [11] S. Mohanty, D. Hughes, and M. Salathé, "Deep Learning for Image-Based Plant Disease Detection," 2016.
- [12] J. Sladojevic et al., "Automated Vision-Based Plant Health Monitoring Using Convolutional Neural Network," 2016.
- [13] A. Kaur and B. Kaur, "Plant Disease Detection Using Image Processing and Neural Networks," 2015.
- [14] M. A. Khan et al., "Unsupervised Learning Approach for Disease Detection in Wheat Plants Using Hyperspectral Imagery," 2020.
- [15] S. Arsenovic et al., "Detection of Tomato Plant Diseases Using Convolutional Neural Networks," 2019.
- [16] Xinjuan Xu et al, "Identification of geographic, climatic, and soil factors dominating Stevia rebaudiana yield and quality," J. Agric. Sci., vol. 166, no. 5, pp. 782-791, May 2024. doi: 10.1016/j.jas.2024
- [17] Zhao, Peng & Li, Chen & Rahaman, Md & Yang, Hechen & Jiang, Tao & Grzegorzec, Marcin. A Comparison of Deep Learning Classification Methods on Small-scale Image Data set: from Convolutional Neural Networks to Visual Transformers. 2021
- [18] Merhad Ay, et. al., Fixed-centered K-means algorithm, Expert Systems with Applications, Volume 211, 2023, 118656, ISSN 0957-4174, <https://doi.org/10.1016/j.eswa.2022.118656>.
- [19] Machine Learning: A Probabilistic Perspective" by Kevin P. Murphy