

Detección de severidad de plagas utilizando RNC en cultivo del durazno en Departamento Norte De Santander, Colombia.

Pest Severity Detection Using CNN in Peach Crop in Norte De Santander Department, Colombia.

Recibido: 26 de agosto de 2022

Aprobado: 4 de diciembre de 2022

Forma de citar: A. L. Castellanos Corzo, E. López Meléndez, L. D. Lara Rodríguez, "Detección de severidad de plagas utilizando RNC en cultivo del durazno en Departamento Norte de Santander, Colombia", *Mundo Fesc*, vol. 13, no. 26, pp. 213-226, 2023. <https://doi.org/10.61799/2216-0388.1523>

Andrés Leonardo Castellanos-Corzo * 

Maestría en Ciencia de Datos para Negocios
alcastellanos@sena.edu.co
Servicio Nacional de aprendizaje SENA
Santander, Colombia

Elizabeth López-Meléndez 

Doctora en Ciencias en la Especialidad de Óptica
elizabeth.lopez@uth.edu.mx
Universidad Tecnológica de Huejotzingo
Puebla, México

Luis David Lara-Rodríguez 

Doctor en Ciencias en la Especialidad de Óptica
luis.lara406@uppuebla.edu.mx
Universidad Politécnica de Puebla
Puebla, México.

***Autor para correspondencia:**

luis.lara406@uppuebla.edu.mx



Detección de severidad de plagas utilizando RNC en Cultivo del durazno en Departamento Norte de Santander, Colombia.

Resumen

La creciente emergencia por aumentar los rendimientos de los cultivos, en pro de una menor carga negativa al ambiente, se han utilizado productos para protección de cultivos para impedir la aparición de plagas y enfermedades que generen pérdidas, o complicaciones de índole cuaternario que impacten mucho más en la comercialización y producción en la agricultura, esto ha causado que se generen herramientas tecnológicas para la detección de manera preventiva; para el manejo de las distintas plagas y enfermedades de cultivos agrícolas. En el manuscrito se presenta el uso de técnicas del aprendizaje automático como lo son las redes neuronales convolucionales que ayudan a la detección en especial del Torque y la Roya, las cuales son las principales afectaciones en la merma de la producción del durazno en la zona norte de Santander – Colombia.

Palabras clave: Roya, Torque, Redes Neuronales Convolucionales, Durazno, Aprendizaje Profundo

***Pest severity
detection using CNN
in peach crop in
Norte de Santander
Department,
Colombia.***

Abstract

The growing emergency to increase crop yields, in favor of a less negative load on the environment, products have been used for crop protection to prevent the appearance of pests and diseases that generate losses, or complications of a quaternary nature that have a much greater impact. in the commercialization and production in agriculture, this has caused the generation of technological tools for preventive detection; for the management of different pests and diseases of agricultural crops. In the manuscript, the use of machine learning techniques is presented, such as convolutional neural networks that help to detect especially Torque and Rust, which are the main affectations in the reduction of peach production in the northern zone. from Santander-Colombia.

Keywords: Rust Fungus, Torque,
Convolutional Neural Network, Peaches,
Deep Learning

Introducción

En Colombia frutas como banano, curuba, guanábana, papaya, piña, mango o uchuva son algunas de las plantaciones más importantes y que representan mayor movimiento económico al país, actualmente hay un cultivo que poco a poco ha ganado terreno, a tal punto que su comercialización está saturada se trata del durazno; enfocándose en el cultivo de durazno; el aprendizaje autónomo se puede aplicar para detección temprana de plagas y enfermedades, esto como un asistente, permitirá a los agricultores tomar medidas rápidas y precisas para prevenir o controlar los problemas anteriormente mencionados.

En la actualidad, en la agricultura se aplica la industria 4.0, que corresponde a la recolección y análisis de datos en campo donde se obtienen los factores necesarios para mejorar la cosecha; para este propósito es posible usar diversas tecnologías como drones, aplicaciones móviles, sensores y actuadores [1]. Algunas de las técnicas de aprendizaje autónomo utilizadas incluyen clasificación de imágenes, entre ellas, los algoritmos de aprendizaje autónomo que se entrenan utilizando imágenes de duraznos sanos y afectados por plagas o enfermedades, para clasificar nuevas imágenes y determinar si hay algún indicio de daño. La detección temprana de plagas y enfermedades en el cultivo de durazno a través del aprendizaje autónomo puede ayudar a reducir el uso de pesticidas, optimizar los recursos y mejorar la productividad de los cultivos [2, 3, 4]. De acuerdo con las cifras registradas por Agronet, la Red de Información y Comunicación del Sector Agropecuario de Colombia, liderada por el Ministerio de Agricultura y Desarrollo Rural, en 2016 la producción de este fruto llegó a las 27.290 toneladas. Según datos registrados por Agronet, aparte de Boyacá, los departamentos con mayor producción de este fruto en el país son: Norte de Santander que tiene una cosecha de 9.304 toneladas, seguido de Huila, que logra producir cerca de 1.157 toneladas de duraznos al año, números que muestran el potencial de este producto en regiones del país con condiciones climáticas cambiantes [5].

En el cultivo de durazno, la meta es aplicar principios de agricultura de precisión como aprendizaje autónomo para buscar que el manejo agronómico sea lo más específico posible, es decir a nivel de cada lote, realizando el procedimiento de toma de registros manual tanto para incidencias (plagas y enfermedades) como para severidad (pérdida económica); donde la imagen tomada es categorizada por la red neuronal buscando patrones y similitudes que generan un resultado, la inteligencia artificial usa las técnicas para estimar las características visuales de diferentes hojas y tallos de las plantas a través del procesamiento de imágenes donde los resultados demuestran ser de gran ayuda en el manejo de incidencias en diferentes cultivos agrícolas, tomando en cuenta una correcta manipulación y depuración de los datos a utilizar. También se ha establecido diferentes variables que intervienen en las enfermedades de las plantas y como han sido tratadas con técnicas de inteligencia artificial determinando que el tipo de suelo,

clima, temperatura y humedad son unas de las variables más importantes en el sector agropecuario [6, 7, 8, 9].

Martínez Guanter et al, analizó características de la roya amarilla (plaga) y su influencia en el trigo basado en imágenes hiperespectrales de barrido multitemporal; además se utilizó un modelo de regresión para predecir la severidad de la roya amarilla con éxito; por otro lado, clasificó cítricos usando imágenes hiperespectrales, debido a la importancia de la clasificación de la información y la depuración de la misma, la información puede ser utilizada a gran escala en procesos de predicción cada vez más acertados, la aplicación de técnicas de procesamiento de imágenes y algoritmos de aprendizaje autónomo en la detección y el reconocimiento de enfermedades y plagas en los cultivos es un área activa de investigación que muestra un gran potencial de estudio. El uso del aprendizaje automático en la detección de plagas y enfermedades del cultivo de durazno representa una revolución en la agricultura de precisión, al aprovechar el poder de los algoritmos de aprendizaje profundo, los agricultores pueden detectar y combatir de manera más efectiva las amenazas que afectan la salud y la productividad de sus cultivos, esta tecnología promete impulsar la sostenibilidad y la rentabilidad de la industria frutícola, al tiempo que garantiza una mayor seguridad alimentaria para las comunidades en todo el mundo

Actualmente existen varios métodos del aprendizaje automático utilizados para la detección de plagas y enfermedades entre los que se encuentran los difusos [10], agrupación de k-Means [11, 12], árbol de decisión [13], y redes bayesianas [14], visión artificial [15, 16], cadenas de Markov [17], sistema de inferencia borrosa [18], red neuronal convolucional profunda [19, 20, 21, 22].

Un concepto clave para el manejo de pestes es el promovido por la FAO que se denomina “manejo integrado de plagas” (IPM, por sus siglas en inglés). El IPM es un sistema que, en el contexto de un medio ambiente específico y una dinámica particular de diseminación de una plaga determinada, utiliza todas las técnicas y métodos posibles (por ejemplo, control químico, control cultural, regulación biológica o control microbiológico) en este caso aplicamos el control cultural como base que determina la trazabilidad de un cultivo para futuras decisiones y disminución del daño económico y así poder mantener la población de plagas por debajo de los niveles que puedan causar pérdidas económicas. Como se deduce de esa definición, existen dos elementos claves para el manejo integrado de pestes: la realización de muestreos para monitorear el nivel de diseminación de la plaga y la definición del umbral de población por encima del cual la productividad del cultivo se afecta de manera sustancial [23].

En el presente trabajo se propone utilizar una red neuronal convolucional para detectar el tipo de plaga (roya y/o torque) y su severidad, como primer paso la recolección de las imágenes de durazno se realizó en la finca La Fabiola, Finca El Veranito, Finca La Dorada, Finca la Esperanza y Finca la Esmeralda de las Veredas Carrillo y Llano Grande

del municipio de Chitagá – Norte de Santander; en cultivos que corresponden a un terreno que se encuentra situado en la cordillera oriental sobre gigantescas arrugas, su terreno es quebrado.

Para el estudio en esas condiciones agroecológicas del cultivo del durazno se realizaron evaluaciones por cultivo cada uno de 2 hectáreas para la toma de requerimientos (imágenes) de incidencias clasificadas, quienes son el insumo principal para la ejecución del algoritmo de comparación; esta toma de requerimientos se realizó en varias jornadas y con diversos factores climáticos, lo que proporciona una categorización más exacta de las mismas en el espectro visible con modelo de color RGB, para este propósito se usaron cámaras de dispositivos móviles tal y como se plantea en la ejecución del proyecto.

Se dividió la hoja de durazno en cuatro secciones y cada una de 25% para determinar el tamaño de cubrimiento de la lesión y severidad, arrojando cuatro diferentes categorías por padecimiento con percentiles semejantes a los cuartiles de diagrama de caja.

Materiales y Métodos

El aprendizaje profundo permite que los modelos computacionales que se componen de múltiples capas de procesamiento aprendan representaciones de datos con múltiples niveles de abstracción, además descubre estructuras intrincadas en grandes conjuntos de datos mediante el uso del algoritmo de retropropagación para indicar cómo una máquina debe cambiar sus parámetros internos que se utilizan para calcular la representación en cada capa a partir de la representación en la capa anterior. Las redes convolucionales profundas han generado avances en el procesamiento de imágenes, video, voz y audio, mientras que las redes recurrentes han arrojado luz sobre datos secuenciales como texto y voz [24].

Las redes neuronales convolucionales (Convolutional Neural Networks, CNNs) son una aplicación proveniente del aprendizaje profundo, la cual nos permite clasificar y extraer características en imágenes; apuntando a mejores resultados que otro tipo de redes neuronales, ya que son muy efectivas porque fueron diseñadas con el fin de imitar la actividad de la corteza visual (parte del cerebro humano que procesa la información visual), por lo que son capaces de extraer y aprender las características de las imágenes de entrada por sí mismas mediante la configuración adecuada de sus capas [25].

Las RNC son un tipo de red neuronal donde se aplica la convolución en sus capas iniciales de la red, este tipo de redes tienen diferentes capas como se observa en la figura 1, que permiten un aprendizaje automático de las características de las imágenes. La imagen de entrada es convolucionada con una gama de filtros que producen características propias, para utilizarse por las capas posteriores de la red e iniciar la etapa de clasificación.

El detector de características dentro de una RNC, es la entrada a una capa convolucional

son datos que aún no ha sido procesados, creando una salida que corresponde a un mapa de características que se utilizan como la entrada a la siguiente capa convolucional, para ello la convolución se toma como la aplicación de un filtro en los datos de entrada para un tipo de información específica, esto sirve para examinar la posición de un objeto y características propias de la imagen como lo son bordes, texturas y rotaciones.




Figura 1. Arquitectura de una RNC

La convolución discreta en dos dimensiones se define en la ecuación 1.

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n) K(i - m, j - n) \quad (1)$$

Donde la entrada corresponde a una imagen I , el núcleo de convolución K en cada pixel en la posición (i, j) , y da un mapa de característica de la imagen como salida S .

Se tiene la capa convolucional donde se encuentra la función de activación, la cual ayuda a resaltar los bordes que conformaran las características de cada clase. Estas mismas son las que modifican el valor de salida de las neuronas que conforman las capas de las redes neuronales profundas, colocando un valor límite el cual no debe rebasar antes de propagarse a la siguiente capa. En la figura 2 se muestran las funciones de activación más comunes, la más utilizada dentro de estas redes es la unidad lineal rectificada (ReLU), si la entrada está por debajo de 0, la salida es 0.




Figura 2. Funciones de activación más comunes. Izquierda: Tangente hiperbólica, Centro: Unidad lineal rectificada, Derecha: Sigmoide

Dentro de la fase de extracción de características se utiliza una capa llamada reducción (Pooling), esta capa se coloca entre las capas convolucionales para reducir progresivamente el tamaño espacial de los datos para controlar el sobreajuste, la operación más utilizada es el Max Pooling, la cual consiste en agrupar un vecindario y que la salida tome el valor máximo del pixel dentro del vecindario de n vecindad, otra función de agrupación es el Average Pooling donde se incluye un promedio del vecindario anteriormente mencionado.

En la fase de clasificación, las neuronas de la capa están conectadas con cada neurona de la capa anterior, el calculo se muestra en ecuación 2,

$$f(x) = \sigma(W * x) \quad (2)$$

Donde F es la salida de las unidades, $W \in R$ son los pesos de la red y $\sigma: \mathbb{R} \rightarrow \mathbb{R}$ es la función de activación de la red.

Dentro de la capa final se utiliza un algoritmo de retropropagación para aumentar el rendimiento de la red, para esto se utiliza comúnmente la función Softmax, la cual se presenta en la ecuación 3.

$$S(x)_j = \frac{x^{x_i}}{\sum_{i=0}^N e^{x_i}} \quad (3)$$

Donde $S(x): \mathbb{R} \rightarrow [0,1]^N$, siendo N el vector de entrada, recordando que la capa de salida de una RNC tiene un tamaño igual al número de clases.

Estas redes aplican métodos que buscan el minimizar la función de pérdida con respecto a los parámetros de la función de predicción dependiendo del modelo propuesto, algunas de estos métodos son: Adam, gradiente descendiente, propagación de raíz cuadrática media entre otros. Estas funciones comparan el valor de salida de la red neuronal contra el valor de salida real para determinar la clasificación incorrecta de los datos de entrada, entre ellas tenemos al error cuadrático medio (MSE), pérdida de entropía cruzada, bisagra perdida entre otras. Esto se logra ajustando los hiperparámetros que mejoran su rendimiento, de los cuales se encuentran: número de capas y neuronas, magnitud, regularización (medida contra el sobreajuste), estrategias de inicialización de pesos, definir número de épocas y normalización de datos de entrada [26].

Resultados y Discusión

En este trabajo se utilizaron 1358 imágenes distribuidas en diferentes categorías de acuerdo al tipo de enfermedad y rango de severidad, para el caso de roya se contó con un total de 345 imágenes lo que corresponde a un 25.4% del total distribuidas en cuatro

diferentes categorías de severidad, para el caso de torque se contó con 1013 imágenes lo que corresponde al 74.6% del total de imágenes recolectadas y las cuales también fueron distribuidas en 4 categorías de severidad tal como lo muestra la Tabla I.

Tabla I. Número de imágenes para cada entrenamiento.

Enfermedad	Rango de Severidad (%)	Cantidad de Imágenes	Enfermedad	Rango de Severidad (%)	Cantidad de Imágenes
Roya	0 – 25	239	Torque	0 – 25	502
	26 – 50	77		26 – 50	209
	51 – 75	21		51 – 75	107
	76 – 100	8		76 – 100	195

En la figura 3 se observan una muestra de cada una de las 8 categorías conformadas por la afección de roya y torque con diferente cuartil de severidad. Las imágenes seleccionadas, se dividieron en dos subconjuntos: entrenamiento (80 %) y validación (20%). La arquitectura del modelo de RNC aplicada al conjunto de imágenes de entrenamiento y validación se ilustra en la figura 4; esta se implementó utilizando TensorFlow, la cual es una librería de aprendizaje automático de código abierto desarrollada por Google que permite la construcción y entrenamiento de redes neuronales para la detección de patrones similares al razonamiento humano [27].

Las imágenes de entrada a la RNC se han interpolado a una razón de dos para otorgarle a la red mayor información de entrada, seguida de la etapa de extracción de características conformada por: dos filtros de convolución bidimensionales de 32 y 64 filtros con función de activación ReLU, una etapa de reducción a la mitad de su tamaño aplicando la técnica de Max Pooling, finalizando esta etapa con una capa de convolución de 2D con 128 filtros y una de reducción con características iguales a las anteriores.



Figura 3. Arriba: Roya de izquierda a derecha 1er cuartil a 4to cuartil. Abajo: Torque de izquierda a derecha 1er cuartil a 4to cuartil

La etapa de clasificación es una RNA perceptrón multicapa, con un par de capas en serie de 250 neuronas con activación ReLU y una capa de categorización de salida tipo Softmax. Para evitar el sobreajuste y mejorar el entrenamiento de la red en sus capas ocultas, se

hace uso del mecanismo conocido como Dropout que impulsa la desactivación aleatoria de neuronas con sinapsis débiles que no contribuyen en el aprendizaje [28]. Se hizo uso del método adaptativo de aprendizaje Adagrad, que se caracteriza por ajustar la tasa de aprendizaje a los parámetros de la red [29, 30].

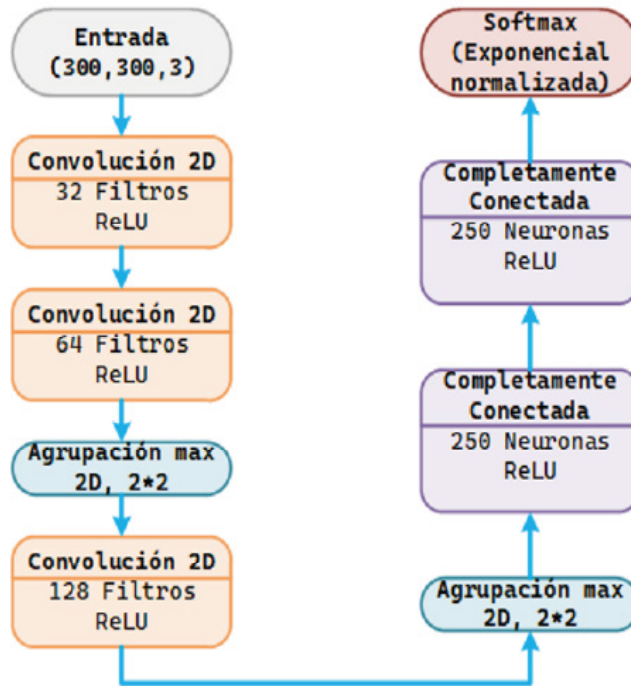


Figura 4. Arquitectura de la RNC

El modelo alcanzó 76% de precisión de entrenamiento y el 55% de validación a las 600 épocas; las curvas de precisión y pérdidas del modelo se visualizan en la figura 5, en las curvas de precisión se observa que la red tiende a un valor constante de validación indicando un sobreajuste en la red, el cual es confirmado en las curvas de pérdida con el aumento monótono del conjunto de validación y la disminución en el conjunto de entrenamiento. Esto es causado por el desbalanceo en la cardinalidad de elementos entre clases y la poca robustez del modelo aplicado.

Se hará uso de la técnica de aumento de datos, la cual consiente en generar imágenes a partir de los datos originales realizando una serie de transformaciones espaciales geométricas (rotación, escalamiento, reflejo, traslación) que aporten robustez al modelo, dichas transformaciones le otorgarán al modelo la propiedad de invariancia espacial presentes en imágenes del mundo real; asimismo, permitirá balancear las clases y con ello mejorar el rendimiento de la red. Además de las transformaciones espaciales, se aumentará las capas de extracción de características y clasificación de la arquitectura del modelo, en búsqueda de que este sea más certero en la clasificación.




Figura 5. Curvas de entrenamiento y validación del modelo. Izquierda: Precisión, Derecha: Pérdida

Conclusiones

La detección de plagas y enfermedades de torque y roya en el cultivo del durazno representa un avance significativo, ya que la RNC propuesta puede proporcionar una herramienta valiosa para los agricultores y contribuir a la protección de los cultivos dando una preclasificación de ellas, permitiéndoles realizar oportunamente acciones necesarias, en búsqueda de que el fruto no se vea comprometido.

Se puede interpretar de los resultados que el modelo tiene un nivel de precisión en detección de enfermedades en el cultivo del durazno con un 55% de precisión de validación con 600 épocas, por ende, el mejoramiento de la precisión se puede realizar con el aumento de datos y homologar la cardinalidad de imágenes en las categorías, debido a que los datos son insuficientes para el que modelo sea capaz de distinguir entre clases que dificulta el aprendizaje del modelo.

Agradecimiento

Se agradece a la UTEL por la formación académica que ha desarrollado durante el estudio de su maestría en Ciencia de Datos para Negocios y al SENA. Elizabeth agradece al UTEL por el apoyo por conducir trabajos de grado en la maestría de Ciencia de Datos. Luis David agradece al Sistema Nacional de Investigadores (SNI-CONAHCYT) con el apoyo a través de la concesión No. 332238.

Referencias

- [1] O. E. Apolo Apolo, D. Andújar Sánchez, D. Rieser, M. Pérez Ruíz and J. Martínez Guanter, "Deep-learning-based detection of in-field tomatoes using a terrestrial mobile platform", *Precision agriculture'21*, pp. 319-329, 2021.
- [2] W. Alosaimi, H. Alyami and M. I. Uddin, "PeachNet: Peach Diseases Detection for

Automatic Harvesting", *Computers, Materials & Continua*, vol. 67, no. 2, 2021

- [3] U. Shruthi, V. Nagaveni and B. Raghavendra, "A review on machine learning classification techniques for plant disease detection", *2019 5th International conference on advanced computing & communication systems (ICACCS)*, pp. 281-284, 2019
- [4] O. E. Apolo Apolo, M. Pérez Ruíz, J. Martínez Guanter and G. Egea, "Estimación de parámetros biofísicos de interés para la mejora de trigo usando inteligencia artificial", *X Congreso Ibérico de Agroingeniería*, pp. 959-966, 2019
- [5] A. -. G. d. Colombia, "Conozca cómo funciona el negocio del durazno en el mercado colombiano," 24 10 2018. [En línea]. Disponible en: <https://agronet.gov.co/Noticias/Paginas/Conozca-c%C3%B3mo-funciona-el-negocio-del-durazno-en-el-mercado-colombiano.aspx>
- [6] J. Torres Sánchez, A. Escolá, A. I. Castro, F. López Granados, J. Rosell, F. Jiménez-Brenes, R. Sanz, E. Gregorio, F. Sebé and J. Peña, "UAV photogrammetry vs mobile terrestrial laser scanning for woody crops characterization", *Precision agriculture'23*, pp. 1019-1026, 2023
- [7] O. E. Apolo Apolo, J. Martínez Guanter , G. Egea, P. Raja and M. Pérez Ruíz, "Deep learning techniques for estimation of the yield and size of citrus fruits using a UAV", *European Journal of Agronomy*, vol. 115, p. 126030, 2020
- [8] M. Gomez Selvaraj, A. Vergara, F. Montenegro, H. Alonso Ruíz, N. Safari, D. Raymaekers, W. Ocimati and Ntamwira, "Detection of banana plants and their major diseases through aerial images and machine learning methods: A case study in DR Congo and Republic of Benin", *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 169, pp. 110-124, 2020
- [9] L. Tan, J. Lu and H. Jiang, "Tomato Leaf Diseases Classification Based on Leaf Images: A Comparison between Classical Machine Learning and Deep Learning Methods," *AgriEngineering, Special Issue "Information and Communications Technology in Agriculture"*, vol. 3, no. 3, pp. 542-558, 2021
- [10] S. Sampathkumar and R. Rajeswari, "An automated crop and plant disease identification scheme using cognitive fuzzy c-means algorithm" *IETE Journal of Research*, vol. 68, no. 5, pp. 3786-3797, 2022
- [11] R. Anand, S. Veni and J. Aravinth, "An application of image processing techniques for detection of diseases on brinjal leaves using k-means clustering method", *2016 international conference on recent trends in information technology (ICRTIT)*, pp. 1-6, 2016

- [12] R. M. Prakash, G. Saraswathy, G. Ramalakshmi, K. Mangaleswari and T. Kaviya, "Detection of leaf diseases and classification using digital image processing", *2017 international conference on innovations in information, embedded and communication systems (ICIIECS)*, pp. 1-4, 2017
- [13] A. Mengistu, S. G. Mengistu and D. Melesew, "An automatic coffee plant diseases identification using hybrid approaches of image processing and decision tree", *Indones. J. Electr. Eng. Comput. Sci.*, vol. 9, no. 3, pp. 806-811, 2018
- [14] C. Pérez Ariza, A. E. Nicholson and M. J. Flores, "Prediction of coffee rust disease using Bayesian networks", *Proceedings of the Sixth European Workshop on Probabilistic Graphical Models*, vol. 6, pp. 259-266, 2012
- [15] E. Amaro García, J. Canales Cervantes, J. Cabrera Espejal, S. Ruíz and L. Farid García, "Identification of diseases and pests in tomato plants through artificial vision", *Intelligent Computing Methodologies: 16th International Conference, ICIC 2020, Bari, Italy, October 2--5, 2020, Proceedings, Part III 16*, pp. 98-109, 2020
- [16] J. Negrete, "Artificial vision in mexican agriculture for identification of diseases, pests and invasive plants", *Journal of Advancements in Plant Science*, vol. 1, no. 1, p. 1, 2018
- [17] G. J. Gibson, "Markov chain Monte Carlo methods for fitting spatiotemporal stochastic models in plant epidemiology", *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, vol. 46, no. 2, pp. 215-233, 1997
- [18] W. A. Lozada-Portilla, M. J. Suárez-Baron and E. Avendaño-Fernández, "Aplicación de redes neuronales convolucionales para la detección del tizón tardío *Phytophthora infestans* en papa *Solanum tuberosum*" *La Revista U.D.C.A Actualidad & Divulgación Científica*, vol. 24, no. 2, 2021
- [19] I. Ahmed and P. K. Yadav, "Plant disease detection using machine learning approaches", *Expert Systems*, vol. 40, no. 5, p. e13136, 2023
- [20] J. Trivadi, Y. Shamani and R. Gajjar, "Plant leaf disease detection using machine learning", *Emerging Technology Trends in Electronics, Communication and Networking: Third International Conference, ET2ECN 2020, Surat, India, February 7-8, 2020, Revised Selected Papers 3*, pp. 267-276, 2020
- [21] Y. Kaya and E. Gursoy, "A novel multi-head CNN design to identify plant diseases using the fusion of RGB images", *Ecological Informatics*, vol. 75, p. 101998, 2023
- [22] K. Zhang, Z. Xu, S. Dong, C. Cen and Q. Wu, "Identification of peach leaf disease infected by *Xanthomonas campestris* with deep learning", *Engineering in Agriculture*,

Environment and Food, vol. 12, no. 4, pp. 338-396, 2019

- [23] J. A. Martinez Chiguachi, A. G. Fajardo, J. S. Esquivel, D. M. González, Á. G. Prieto and D. Rincón, "Manejo integrado del cultivo de mango *Mangifera indica* L", *Ciencias Agropecuarias*, vol. 6, no. 1, pp. 51-78, 2020
- [24] Y. Bengio, "Learning Deep Architectures for AI", *Foundations and Trends in Machine Learning*, vol. 2, no. 1, pp. 1-127, 2009
- [25] L. Deng and Y. Dong, "Deep Learning: Methods and Applications", *Foundations and Trends in Signal Processing*, vol. 7, no. 3-4, pp. 197-387, 2014
- [26] A. Krizhevsky, I. Sutskever and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks", *Advances in Neural Information Processing Systems* 25, pp. 1097-1105, 2012
- [27] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean and M. Devin, "Tensorflow: Large-scale machine learning on heterogeneous distributed systems", *arXiv preprint arXiv:1603.04467*, 2016
- [28] A. Poernomo and D.-K. Kang, "Biased dropout and crossmap dropout: learning towards effective dropout regularization in convolutional neural network", *Neural networks*, vol. 104, pp. 60-67, 2018
- [29] H. Saad Hikmat and A. Adnan Mohsin, "COMPARISON OF OPTIMIZATION TECHNIQUES BASED ON GRADIENT DESCENT ALGORITHM: A REVIEW", *PalArch's Journal of Archaeology of Egypt / Egyptology*, vol. 18, no. 4, pp. 2715-2743, 2021
- [30] J. K. Fang, C. M. Fong, P. Yang, C. K. Hung, W. L. Lu and C. W. Chang, "AdaGrad Gradient Descent Method for AI Image Management", *{2020 IEEE International Conference on Consumer Electronics - Taiwan (ICCE-Taiwan)}*, pp. 1-2, 2020