

# Redes neuronales convolucionales para el reconocimiento de imágenes con presencia de cenicilla polvorienta en cultivos de tomate

Convolutional neural networks for image recognition with the presence of powdery mildew in tomatoes crops

Deny Lizbeth Hernández Rabadán<sup>1</sup>  y Juan Paulo Sánchez Hernández<sup>1</sup> 

Universidad Politécnica del Estado de Morelos, Boulevard Cuauhnáhuac #566, Col. Lomas del Texcal, Jiutepec, Morelos. CP 62550

\*Correo-e: juan.paulosh@upemor.edu.mx

## PALABRAS

### CLAVE:

Cenicilla polvorienta, redes neuronales convolucionales, procesamiento de imágenes.

## RESUMEN

La agricultura es considerada como una de las actividades que más impacta en la economía de los países. Por tal motivo, es de suma importancia atender los problemas que ésta enfrenta, entre los que destaca el control de enfermedades y plagas en los cultivos. Si este problema no es atendido se pueden presentar efectos graves en las plantas que afectarían la calidad y productividad del cultivo. En la actualidad, existen muchos trabajos de investigación enfocados en el desarrollo de sistemas inteligentes que permiten automáticamente diagnosticar enfermedades que presenta un cultivo a través del entrenamiento de Redes Neuronales Convolucionales (RNC) con un gran conjunto de imágenes. Sin embargo, la mayoría de las investigaciones entrenan sus modelos con imágenes adquiridas en ambientes controlados (iluminación y fondo), por lo que al ser entrenados con imágenes en un ambiente natural sus resultados no son tan eficientes. En este trabajo se presentan una metodología que implementa un proceso de mejora de la imagen para obtener un mejor resultado en los porcentajes de exactitud de la clasificación realizada por la RNC. El proceso ha sido aplicado al diagnóstico de la enfermedad cenicilla polvorienta en imágenes de cultivos de tomate. Las imágenes del cultivo fueron adquiridas en su ambiente natural, sin control de iluminación y fondo. Los resultados muestran que al aplicar la metodología el entrenamiento del RNC mejora en comparación de no aplicar en comparación del entrenamiento clásico.

## KEYWORDS:

Powdery Mildew, Convolutional Neural network, image processing.

## ABSTRACT

Agriculture is one of the activities that have a direct impact on countries' economies. Thus, it is very important to address the related problems, for instance, disease control or pests in crops. If this problem is not addressed, severe effects can occur on the plants that would affect the crop's quality and productivity. Many research works focused on developing intelligent systems for obtaining automatic diagnosing diseases using Convolutional Neural Networks (CNN) with a big set of images. However, many researchers train their models with images acquired in a controlled environment (lighting and background), so when they are trained with images in a natural environment, their results are not efficient. In this work, we present a methodology that implements an image enhancement process to obtain the best accuracy of the CNN classification. The process has been applied for the diagnosis of powdery mildew disease in tomato crop images. The images were acquired in their natural environment, without lighting and background control. The results show that when we apply our methodology, the CNN training improves, and we obtain very good results versus the classical CNN training.

• **Recibido:** 20 agosto 2021 • **Aceptado:** 9 de abril 2022 • **Publicado en línea:** 30 de noviembre 2022

## 1 INTRODUCCIÓN

Tradicionalmente, la agricultura se refiere a cultivar la tierra con el fin de obtener vegetales para la alimentación del ser humano o los animales. La agricultura moderna pretende manejar la producción agrícola apoyándose en la automatización y la aplicación de tecnologías avanzadas para hacerla más eficiente y sustentable [1]. Una de estas tecnologías es la visión computacional, la cual ha logrado penetrar en el campo de la agricultura debido a que es un método no destructivo de bajo costo. En el sector agrícola se han desarrollado muchas aplicaciones usando la tecnología de visión computacional con apoyo de metodologías basadas en el reconocimiento de patrones, el procesamiento y el análisis de imágenes digitales [2], tales como: detección de enfermedades y plagas, detección de maleza, clasificación de especies, entre otras.

La detección de enfermedades en imágenes de un cultivo es un problema para el que se han desarrollado muchos trabajos de investigación. La mayoría de los sistemas de visión artificial se han enfocado en el diagnóstico de enfermedades del cultivo mediante el análisis de los síntomas visuales que se manifiestan en las hojas de las plantas. Además, la efectividad del reconocimiento de la enfermedad depende en gran medida de qué tan eficiente es la segmentación del área de interés, así como la caracterización de la misma [3]. Lo anterior es debido a que de esta manera se pueden entrenar modelos que aprendan las características visuales (coloración, forma de la afectación, textura, entre otros) que se presentan como síntomas de la enfermedad a reconocer. En ambientes controlados en iluminación y fondo, estos sistemas de visión computacional desarrollan sus metodologías principalmente para la caracterización y clasificación de las enfermedades de estudio, y en cuanto a la segmentación de la hoja del fondo, sus metodologías no integran técnicas de considerable complejidad puesto que con la utilización de umbrales obtienen una eficiente segmentación de la hoja [4].

El trabajo que se presenta en este artículo está enfocado en el diagnóstico de una enfermedad en el cultivo de tomate. Se eligió este fruto por ser uno de los más importantes en México, el cual representa un

elemento destacable en la dieta de los mexicanos, además de ser una fuente de ingreso para el país en términos económicos. Dicho fruto es atacado por muchos tipos de plagas y enfermedades que afectan las producciones de cultivos. Entre estas enfermedades se encuentra la cenicilla polvorienta, que afecta diferentes regiones de la planta tales como: la hoja, tallo o el fruto [5]. Esta enfermedad apareció por primera vez en México en el estado de Sinaloa [6] y posteriormente se desplazó a otros puntos de la república mexicana. Enfocándonos específicamente en las hojas de la planta, la cenicilla polvorienta presenta síntomas visuales característicos según el tipo de agente que la infecta. Cuando el agente es *Leveillula taurica*, estos síntomas pueden ser observados en las hojas como manchas amarillas en el haz que se vuelven necróticas en el centro, observándose un fieltro blanquecino en el envés. En el caso del agente *Oidium lycopersicum* se muestra micelio superficial de color blanco con ocasionales bordes amarillos en las hojas [7]. La importancia de elegir a la enfermedad de la cenicilla polvorienta para nuestro estudio es que presenta características visuales lo suficientemente discriminantes que nos permiten aplicar técnicas de visión computacional y tratamiento de imágenes. Es por tal motivo, que éste trabajo se centra en la aplicación de un procesamiento de imágenes que mejora las condiciones de iluminación en imágenes adquiridas en ambientes no controlados y la aplicación de las redes neuronales convolucionales (RNC).

Este artículo se encuentra organizado de la siguiente manera: en la sección uno se presenta la introducción del artículo en donde se establece el contexto del trabajo desarrollado; en la sección dos revisaremos los trabajos más relevantes en relación con lo propuesto en este artículo; en la sección tres presentamos y describimos el procesamiento de mejora de la imagen y la arquitectura de la red neuronal convolucional utilizada; en la sección cuatro se muestran los resultados y pruebas realizadas con el conjunto de imágenes utilizadas; finalmente, en la sección cinco, se presentan las conclusiones de este trabajo realizado y algunos de los trabajos futuros a desarrollar.

## 2 TRABAJOS RELACIONADOS

El diagnóstico automático de enfermedades en cultivos es un tema de especial interés en la comunidad científica, para el que se han desarrollado diversos trabajos de investigación. Muchos de estos sistemas para diagnóstico de enfermedades son aplicados en imágenes capturadas bajo ambientes controlados, en los cuales destaca el uso de las redes neuronales convolucionales como modelo para clasificar a la enfermedad. Tal es el caso del trabajo presentado en [8], quienes utilizaron la base de datos pública proporcionada por PlantVillage para entrenar una red neuronal convolucional e identificar 14 especies de cultivo y 26 enfermedades (o ausencia de ella) en las imágenes. El modelo entrenado logró alcanzar una eficacia de 99.35%.

Otros investigadores que también realizaron experimentación con la misma base de datos de PlantVillage fueron Ashqar y Naser [9]. Ellos realizaron pruebas entrenando dos modelos de red neuronal para reconocer 5 enfermedades del tomate, uno utilizando las imágenes a color (RGB) y el otro modelo con las imágenes en escala de grises. Con el primer modelo obtuvieron una eficacia del 99.84% y con el segundo de 95.54%.

Algunos otros trabajos que también han aplicado las arquitecturas de RNC para diagnóstico de enfermedades del tomate, utilizando la base de datos proporcionada por PlantVillage, es el presentado por Rangarajan [10] y por Brahim [11]. En ambos trabajos se utilizaron arquitecturas de RNC preentrenadas. En Rangarajan [10] utilizaron las arquitecturas AlexNet y VGG16 para reconocer 6 enfermedades del tomate, alcanzando porcentajes de eficacia en clasificación del 97.49% y 97.29% respectivamente. Brahim [11] en su trabajo presenta resultados de clasificación de 9 tipos de enfermedades del tomate alcanzando una eficacia del 99.18%. Es importante mencionar que el repositorio de imágenes de PlantVillage está compuesto de imágenes con fondo controlado, iluminación semicontrolada y en cada imagen se presenta una sola hoja del cultivo con presencia de algún tipo de enfermedad.

Jadhav y otros [12] utilizaron dos redes neuronales pre-entrenadas para reconocer 3 enfermedades en imágenes de cultivo de soya, estas arquitecturas fueron GoogleNet y AlexNet. Los resultados que obtuvieron en

eficacia con cada una de las arquitecturas de RNC fue de un 98.75% con AlexNet y 96.25% con GoogleNet. Cabe resaltar que, en este trabajo, como en los mencionados anteriormente, las imágenes de la base de conocimiento fueron capturadas en ambientes controlados.

En la literatura existen muy pocos trabajos que presentan metodologías para el reconocimiento de enfermedades en cultivos que se encuentran en su ambiente natural, como lo es en campo abierto o un invernadero. Este tipo de ambientes naturales se caracteriza por la falta de control en la iluminación, lo que puede provocar artefactos visuales en las imágenes tales como: sombras, destellos, intensidades altas de brillo, cambios de tonalidad, entre otros. Además, generalmente en este tipo de ambiente resulta complicado tener control del fondo, de manera que sea uniforme para todas las imágenes. Los artefactos mencionados y el fondo complejo dificultan el proceso de segmentación de las áreas de interés, por lo que las metodologías aplicadas requieren ser más robustas. Uno de los trabajos que han aplicado el reconocimiento de enfermedades en imágenes complejas fue el realizado por Singh y Misra [13] quienes presentaron un algoritmo que aplica umbrales y Algoritmos genéticos para lograr segmentar las regiones de vegetación en la imagen, se extraen características de co-ocurrencia de la imagen con las cuales entrenan una máquina de soporte vectorial para lograr la clasificación de diferentes tipos de enfermedades. Con el algoritmo propuesto alcanzaron un 95.71% de eficacia en la clasificación de la enfermedad.

Algunos otros trabajos que también logran detectar la enfermedad en imágenes complejas, en donde existían variaciones en la intensidad de la iluminación y del fondo, es el presentado por Adhikari y otros [14]. El sistema propuesto logró reconocer 3 tipos de enfermedad del tomate alcanzando en promedio una exactitud del 76%. Para tal fin, la metodología propuesta incluyó una etapa de procesamiento de la imagen en donde fue delimitada manualmente el área de enfermedad para posterior entrenamiento con el modelo de red neuronal convolucional llamado YOLO.

A partir de la revisión del estado del arte en este tema de investigación, nos hemos dado cuenta de que las redes neuronales han demostrado alcanzar porcentajes altos de eficiencia para el problema de diagnóstico de

enfermedades en imágenes de un cultivo, por tal motivo surge el interés de integrarlas en la metodología propuesta. Toda y Okura [15] nos presentan una explicación detallada del proceso de inferencia realizado por las redes neuronales convolucionales aplicado al diagnóstico de enfermedades, lo que nos ayudó a comprender mejor este modelo.

### 3 METODOLOGÍA

La metodología propuesta en esta investigación se presenta en la Figura 1. Esta metodología se encuentra dividida en cuatro etapas principales, las cuales permiten la identificación de la enfermedad cenicilla polvorienta. A continuación, se describen las etapas principales de la metodología.

- ✓ **Etapas 1.** En esta etapa se tomaron las imágenes de cultivos de tomate cultivados en estructuras de invernadero en el municipio de Jiutepec. Las imágenes se tomaron al medio día con una cámara de bajo costo Kodak EasyShare C913.
- ✓ **Etapas 2.** En la etapa dos se construye un repositorio eligiendo las imágenes que presentarán la enfermedad de la cenicilla. En total, se tienen 52 imágenes clasificadas como enfermas y 52 clasificadas como sanas, para dar un total de 104 imágenes utilizadas en el entrenamiento. Además, para evaluación se dejaron 13 imágenes sanas y 13 enfermas para dar un total de 26 imágenes para prueba.
- ✓ **Etapas 3.** En la etapa 3 se aplica un algoritmo para realizar un ajuste automático de color y brillo de las imágenes para lograr homogeneizarlas considerando una imagen de referencia. Este algoritmo fue propuesto por [16] y algunos trabajos lo han aplicado como parte de sus metodologías para segmentación de las áreas de vegetación, ayudándoles a mejorar sus resultados como el realizado por [17].

A continuación, se presentan los pasos a seguir:

1. Seleccionar una imagen de referencia que muestre menos efectos visuales causados por la iluminación variable, tal como inconsistencia en color, destellos, sombras e iluminación desigual.

2. Convertir del modelo de color RGB al modelo YIQ tanto de la imagen de referencia como de la imagen de entrada
3. Ajustar el color y brillo de la imagen de entrada utilizando las ecuaciones (1,2,3):

$$\mu_{im} = \frac{1}{m \times n} \sum_{n=1}^{m \times n} I(n) \tag{1}$$

$$\mu_{new} = \mu_{tar} - \mu_{im} \tag{2}$$

$$I_{new} = I(n) + \mu_{new} \tag{3}$$

Donde:

$I(n)$  es el valor de intensidad para cada canal Y, I, Q de la imagen de entrada;

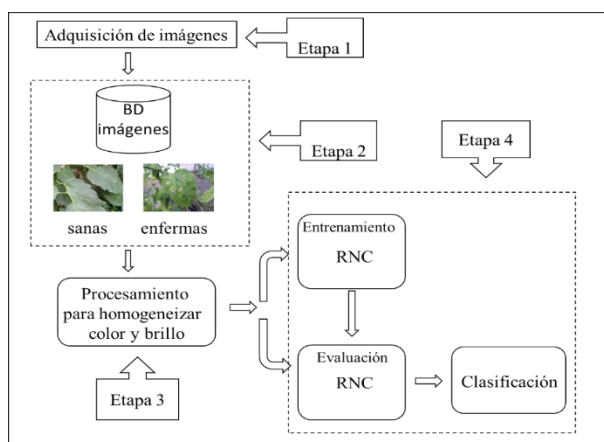
$\mu_{im}$  es el valor de la media para cada canal de la imagen de entrada;

$\mu_{tar}$  es el valor de la media para cada canal de la imagen de referencia con una matriz de tamaño  $m \times n$ ;

$I_{new}$  es la nueva imagen con ajuste en color y brillo para cada canal Y, I, Q.

4. La nueva imagen  $I_{new}$  con ajuste de color y brillo es convertida de YIQ a RGB.

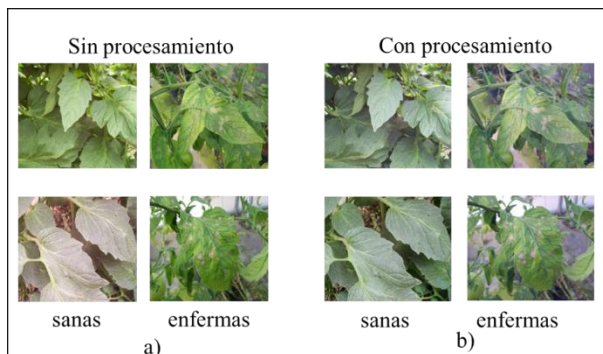
- ✓ **Etapas 4.** Esta etapa se construye una Red Neuronal Convolucional y se entrena con el conjunto de imágenes de prueba. Una vez que el modelo es entrenado se utiliza para la clasificación de imágenes con presencia de la enfermedad cenicilla.



**Figura 1.** Metodología de reconocimiento de cultivos enfermos de cenicilla.


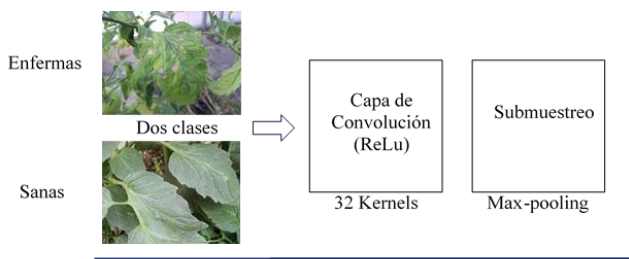
#### 4 PRUEBAS Y RESULTADOS OBTENIDOS

Las imágenes utilizadas en la experimentación corresponden al follaje de plantas de tomate enfermas de cenilla polvorienta. Las imágenes fueron capturadas en el ambiente natural en el que se encontraba la planta (un invernadero), donde la iluminación era variante y no se tenía control del fondo. En la Figura 2, se presenta una muestra de las imágenes, en el inciso a) las imágenes sin procesamiento y en el b) aplicando el algoritmo de mejora en color y brillo. Se puede observar, por simple inspección visual, que las imágenes procesadas son más homogéneas en color y brillo.



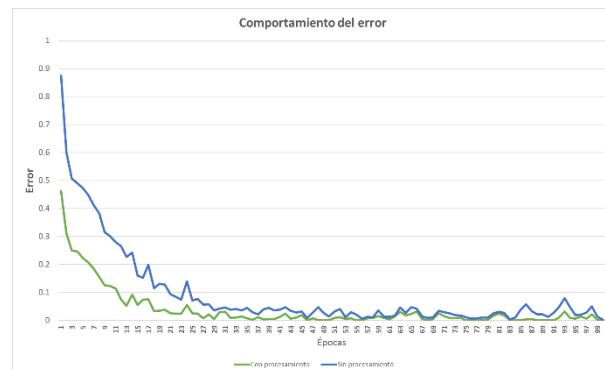
**Figura 2.** Ejemplo de imágenes enfermas y sanas a) sin procesamiento y b) con procesamiento.

Para el proceso de entrenamiento de nuestra red neuronal convolucional con el optimizador Adam, se experimentó con una estructura representada en la Figura 3. Además, las ejecuciones fueron realizadas en GPU en una tarjeta gráfica NVIDIA Quadro M3000M con 1024 núcleos.



**Figura 3.** Capas de la red neuronal convolucional utilizada en la experimentación.

Para mostrar la eficiencia del modelo propuesto se presentan los resultados de la exactitud con 100 épocas (ciclos de entrenamiento). En cada una de ellas se obtienen las métricas de error cuadrático medio (mse), exactitud (accuracy) y pérdida (loss). En la Figura 4, se presenta la pérdida del modelo entrenado aplicando el procesamiento de mejora de la imagen (línea verde) y no aplicándola (línea azul). En esta figura, se observa que el uso de la metodología propuesta con mejora de la imagen obtiene un mejor comportamiento de pérdida respecto a no aplicar la mejora.



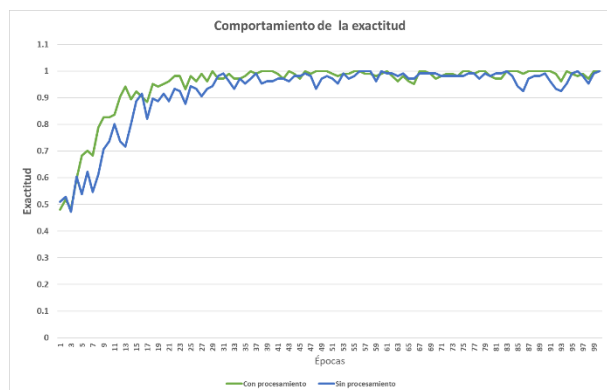
**Figura 4.** Resultados de la pérdida en el entrenamiento con 100 épocas.

Por otro lado, en la Figura 5, se presenta el error cuadrático medio con la misma cantidad de épocas. Se puede observar el mismo comportamiento, es decir, el error se minimiza rápidamente en comparación a no aplicar ningún tipo de mejora en la imagen.



**Figura 5.** Resultados del error en el entrenamiento con 100 épocas.

En la Figura 6, se puede apreciar el comportamiento de la exactitud en el proceso de entrenamiento de la red neuronal convolucional aplicando el procesamiento de mejora versus sin procesamiento. Como se observa en el comportamiento con 100 épocas, la mejor exactitud del modelo es con mayor frecuencia la que se obtiene con imágenes sometidas al proceso de mejora en color y brillo. La exactitud final obtenida del entrenamiento fue del 97.11%, en contraste al 92.16% del RNC sin la mejora de la imagen.



**Figura 6.** Resultados del comportamiento de la exactitud en el entrenamiento con 100 épocas.

Una vez que el modelo fue entrenado se utilizó un conjunto de 52 imágenes diferentes al proceso de entrenamiento. Este conjunto de imágenes, son divididas en 26 sanas y 26 enfermas, las cuales fueron tomadas el 50% para ser procesadas con nuestra metodología y el 50% no se le aplicó ninguna mejora en cada una de las imágenes. En la Tabla 1, muestra la matriz de confusión para el caso de las imágenes no procesadas y la exactitud calculada fue de 69.23%.

Tabla 1. Matriz de confusión de imágenes sin procesamiento.

		Predicción		
		Enfermas	Sanas	
Real	Enfermas	6	7	46.15%
	Sanas	1	12	92.30%
		92.30%	46.15%	<b>Exactitud</b> = 69.23%

En la Tabla 2, se presenta la matriz de confusión de la clasificación de las imágenes procesadas con nuestra metodología y puede observarse que la exactitud fue de 80.76%. Lo anterior, muestra que para este conjunto de imágenes utilizar la metodología propuesta con mejoramiento de la imagen es mejor que no aplicar nada.

Tabla 1. Matriz de confusión de imágenes con procesamiento.

		Predicción		
		Enfermas	Sanas	
Real	Enfermas	11	2	84.61%
	Sanas	3	10	76.92%
		76.92%	84.61%	<b>Exactitud</b> = 80.76%

## 5 CONCLUSIONES

En este artículo se presenta la aplicación de las redes neuronales convolucionales a cultivos de tomate con la enfermedad de cenicilla polvorienta. Las imágenes utilizadas para el entrenamiento fueron adquiridas en el ambiente natural en el que se encontraba la planta, sin control de iluminación y fondo y capturando gran parte del follaje de la misma. Además, es importante mencionar que dicho conjunto se formó con captura de imágenes con una cámara de bajo costo (sin adicionar ningún tipo de filtro), por lo que lograr el entrenamiento con una precisión arriba del 97% es notable. El tratamiento aplicado a las imágenes utilizando como referencia una con buenas condiciones (estable visualmente en color y brillo) permite homogeneizar a la imagen procesada a valores cercanos a los de la referencia. Lo anterior, contribuye a mejorar claramente el entrenamiento de la red neuronal convolucional, como se observa en las figuras mostradas en la sección de pruebas y resultados. Además, se realizó una prueba de clasificación con un conjunto de imágenes de prueba y

se observó que para este conjunto de datos aplicar la mejora en las imágenes mejora notablemente la clasificación de la RNC.

Como trabajo futuro se propone implementar nuevas estrategias de mejora de la imagen para incrementar la calidad de la exactitud del proceso de entrenamiento y clasificación. Así también, un modelo de segmentación automática basado en clustering, el cual consideramos puede mejorar mucho más la calidad del aprendizaje y en consecuencia la clasificación.

## REFERENCIAS

- [1] Bastida Tapia, A. Coordinación, Manejo y operación de invernaderos agrícolas. México. Universidad Autónoma Chapingo. 2006.
- [2] Chen, Y.-R., K. Chao, and M.S. Kim, Machine vision technology for agricultural applications. *Computers and Electronics in Agriculture*, 36: p. 173-191. 2002.
- [3] Gao, Y., Kerle, N., Mas, J. F., Navarrete, A., & Niemyer, I. (2007). Optimized image segmentation and its effect on classification accuracy. *Spatial Data Quality*.
- [4] Weizheng S., et al. Grading Method of Leaf Spot Disease Based on Image Processing. *International Conference on Computer Science and Software Engineering*, 2008.
- [5] Guzmán-Plazola, Remigio A., Fajardo-Franco, M. Liza, García-Espinosa, Roberto, & Cadena-Hinojosa, M. Armando. (2011). Desarrollo epidémico de la cenicilla y rendimiento de tres cultivares de tomate en la comarca lagunera, Coahuila, México. *Agrociencia*, 45(3), 363-378. Recuperado en 17 de enero de 2021, de [http://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S1405-31952011000300009&lng=es&tlng=es](http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1405-31952011000300009&lng=es&tlng=es).
- [6] Sánchez, C. M. A. 1983. La cenicilla del tomate causada por *Oidiopsis taurica* (Lev) Salmon. Una nueva enfermedad en el estado de Sinaloa, México. *Rev. Mex. Fitopatol.* 2: 3-6.
- [7] Productores de hortalizas. (2006). Plagas y enfermedades del tomate. Guía de identificación y manejo. México. Recuperado el 28 de septiembre de 2015. [http://vegetablemndonline.ppath.cornell.edu/NewsArticles/Tomato\\_Spanish.pdf](http://vegetablemndonline.ppath.cornell.edu/NewsArticles/Tomato_Spanish.pdf)
- [8] Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in plant science*, 7, 1419.
- [9] Ashqar, B. A., & Abu-Naser, S. S. (2018). Image-based tomato leaves diseases detection using deep learning.
- [10] Rangarajan, A. K., Purushothaman, R., & Ramesh, A. (2018). Tomato crop disease classification using pre-trained deep learning algorithm. *Procedia computer science*, 133, 1040-1047.
- [11] Brahimi, M., Boukhalfa, K., & Moussaoui, A. (2017). Deep learning for tomato diseases: classification and symptoms visualization. *Applied Artificial Intelligence*, 31(4), 299-315.
- [12] Jadhav, S. B., Udupi, V. R., & Patil, S. B. (2020). Identification of plant diseases using convolutional neural networks. *International Journal of Information Technology*, 1-10.
- [13] Singh, V., & Misra, A. K. (2017). Detection of plant leaf diseases using image segmentation and soft computing techniques. *Information processing in Agriculture*, 4(1), 41-49.
- [14] Adhikari, S., Shrestha, B., Baiju, B., & Saban, K. C. (2018). Tomato plant diseases detection system using image processing. In *1st KEC Conference on Engineering and Technology*, Lalitpur (Vol. 1, pp. 81-86).
- [15] Toda, Y., & Okura, F. (2019). How convolutional neural networks diagnose plant disease. *Plant Phenomics*, 2019.
- [16] A. Meunkaewjinda. Hybrid artificial intelligence approach for grape leaf disease diagnosis system from color imagery, Suranaree University of Technology, Nakhon-Ratchasima, Thailand, 2007.
- [17] Hernández-Rabadán, D. L., Ramos-Quintana, F., & Guerrero Juk, J. (2014). Integrating SOMs and a Bayesian classifier for segmenting diseased plants in uncontrolled environments. *The Scientific World Journal*, 2014.

*Acerca de los autores*



**Juan Paulo Sánchez Hernández.** Es Doctor en Ciencias Computacionales por el Instituto Tecnológico y de Estudios Superiores de Monterrey campus Cuernavaca en donde desarrolla su tesis en el área de optimización combinatoria.

Actualmente es profesor en la Universidad Politécnica del Estado de Morelos desde 2012 en donde realiza investigación en el área de optimización combinatoria y el reconocimiento de patrones.



**Deny Lizbeth Hernández Rabadán.** Es Doctora en Ciencias Computacionales por el Instituto Tecnológico y de Estudios Superiores de Monterrey en donde desarrolla su tesis en el área de procesamiento de imágenes. Ha colaborado en proyectos de investigación con el centro de investigación en biotecnología (CEIB) de la UAEM. Actualmente es profesora de tiempo completo en la Universidad Politécnica del Estado de Morelos en donde realiza labores de docencia e investigación. Sus principales intereses son el reconocimiento de patrones y la visión computacional.