

Redes neuronales convolucionales para la detección y clasificación de enfermedades de plantas basadas en imágenes digitales

Convolutional neural networks for detection and classification of plant diseases based on digital images

Maeda Gutiérrez Valeria ^{1✉}, Guerrero – Méndez Carlos¹, Carlos A. Olvera Olvera¹, Ma. Auxiliadora Araiza Esquivel¹, Gustavo Espinoza García¹, Raikel Bordón López¹.

¹Unidad Académica de Ingeniería Eléctrica, Universidad Autónoma de Zacatecas, Jardín Juárez 147, Centro, Zacatecas 98000, Zac. México

✉ Autor para correspondencia: valeria.maeda@uaz.edu.mx

Recibido: 15/09/2018

Aceptado: 15/11/2018

RESUMEN

Las enfermedades de plantas representan factores adversos que provocan una grave reducción en la calidad y cantidad en cultivos agrícolas. Comúnmente, los agricultores o biólogos expertos observan las plantas a simple vista para detectar enfermedades, pero este método suele ser inexacto y puede tomar gran cantidad de tiempo. En este estudio hacemos uso de técnicas de inteligencia artificial y visión computacional para alcanzar el objetivo del diseño y desarrollo de un autómata inteligente para la clasificación de enfermedades en hojas. Utilizamos la arquitectura de *AlexNet* para entrenarla usando un conjunto de datos de *PlantVillage – Dataset* conformado por 40,000 imágenes de hojas sanas y enfermas. El sistema de detección desarrollado, logró identificar 9 especies de plantas y 24 enfermedades, con una exactitud de 98.90% que fue el valor más exacto de todas las arquitecturas comparadas. Además, se demuestra que utilizando las capas de activación de la arquitectura *AlexNet* es que podemos realizar una eficiente detección y segmentación de lesiones presentes en la hoja de la planta de una manera rápida sin la necesidad de recurrir a procesos tediosos de entrenamiento de detectores de imágenes.

Palabras clave: Detección, enfermedades, plantas, deep learning.

ABSTRACT

Plant diseases represent adverse factors that cause a serious reduction in quality and quantity in agricultural crops. Commonly, farmers or expert biologists observe plants with the naked eye to detect diseases, but this method is often inaccurate and can take a great deal of time. In this study we make use of artificial intelligence techniques and computational vision to achieve the objective of the design and development of an intelligent automaton for the classification of leaf diseases. We use the architecture of *AlexNet* to train it using *PlantVillage – Dataset* consisting of 40,000 images of healthy and diseases leaves. The detection system developed was able to identify 9 plant species and 24 diseases with an accuracy of 98.90% which was the most accurate value of all the architectures compared. In addition, it is demonstrated that using activation layers of *AlexNet* is that we can perform an efficient detection and

segmentation of injuries present a the leaf of plant in a fast way without the need to resort to tedious processes of image detector training.

Keywords: Detection, diseases, plants, deep learning.

INTRODUCCIÓN

Las enfermedades de plantas pueden causar grandes daños a los cultivos agrícolas al disminuir significativamente su producción (Hanssen et al, 2012), debido a que restringen el crecimiento de los cultivos y conducen a una mala calidad de los productos (Thakre et al, 2017). Un método existente para la detección e identificación de enfermedades de hojas de plantas es la observación a simple vista (Barbedo, 2018). Sin embargo, este reconocimiento manual puede traer consecuencias puesto que puede ser diagnosticado erróneamente dado que se juzgan los síntomas según sus experiencias (Thakre et al, 2017). Además, se debe monitorear las plantas de una manera consistente para evitar la propagación de enfermedades. Este monitoreo continuo representa una tarea difícil, considerando que requiere una gran cantidad de tiempo (Brahimi et al, 2017). Debido a lo anterior han surgido técnicas computacionales para la detección automática tales como la propuesta de Mohanty (Mohanty et al, 2016), quienes desarrollaron un sistema de diagnóstico de enfermedades de hojas de plantas asistido por teléfonos inteligentes. Ellos utilizaron un conjunto de datos públicos de 54,306 imágenes de hojas enfermas y sanas, empleando dos arquitecturas de Redes Neuronales Convolucionales (CNN), AlexNet (Krizhevsky et al, 2012) y GoogleNet (Szegedy et al, 2015). Su modelo propuesto se entrenó y alcanzó una exactitud de 99.35% en la detección de enfermedades de hojas. No obstante, tuvo un rendimiento pobre al momento de probarse en

conjuntos de imágenes tomadas en diferentes condiciones. Por otro lado, Sladojevic (Sladojevic et al, 2016), realizaron un sistema basado en CNN para identificar 13 tipos de enfermedades comunes. Asimismo, los resultados lograron una precisión entre el 91% y 98% obteniendo un promedio general de 96.3%. Brahimi (Brahimi et al, 2017), aplicaron un modelo de CNN para clasificar enfermedades de tomate basadas en imágenes de hojas. Con el fin de analizar el modelo profundo han utilizado métodos de visualización para comprender los síntomas y localizar de este modo las regiones de la enfermedad de la hoja. Los resultados obtenidos alcanzaron el 99.18% de exactitud. En otra investigación, Lu (Lu et al, 2017), proponen el uso de CNN para la identificación de 10 enfermedades comunes de arroz, empleando imágenes naturales de hojas y tallos de arroz sanos y enfermos capturados del campo experimental. Finalmente, su modelo logró una exactitud del 95.48%. Kawasaki (Kawasaki et al, 2015), plantearon el uso de CNN para distinguir pepinos sanos de los infectados mediante el uso de imágenes de hojas. El sistema consiguió una exactitud promedio de 94.9% en la clasificación de pepinos en dos clases de enfermedades típicas y una clase saludable. Sin embargo, las investigaciones anteriormente mencionadas aplican un limitado número de arquitecturas. El presente trabajo propone evaluar el desempeño de CNN pre-entrenadas: AlexNet, GoogleNet, InceptionV3 (Szegedy et al, 2016), SqueezeNet (Iandola et al, 2016), ResNet50 y ResNet101 (He et al, 2016) con el fin de determinar cuál clasifica de mejor manera y obtiene resultados en menor tiempo. Este estudio, al abarcar nueve

tipos de especies de cultivos y 24 enfermedades se convierte en una completa herramienta para aquel investigador que requiera diseñar e implementar un autómata lo suficientemente completo en la clasificación de enfermedades de hojas de plantas utilizados en la agricultura. De igual manera, se empleó el uso de las capas de activación de la red AlexNet para realizar la detección de lesiones.

MATERIALES Y MÉTODOS

Descripción del dataset

PlantVillage – Dataset (Hughes et al, 2015) es un repositorio que contiene 54,323 imágenes

(recogidas bajo condiciones controladas) de 14 cultivos y 38 clases de enfermedades de plantas. Para este estudio se utilizaron 40,000 imágenes de hojas sanas y enfermas de las cuales nueve son especies de cultivos y 24 enfermedades. El dataset se dividió en dos, primero se encuentran los datos de entrenamiento y enseguida los datos de prueba con un porcentaje de 80% (32,011) – 20% (7,989). Esta elección de la relación se basa en la información expuesta por Mohanty (Mohanty et al, 2016). La **Tabla 1** muestra los pares de cultivos – enfermedades que fueron usadas para la realización de este estudio.

Tabla 1. Descripción del dataset.

Tipos de cultivos	Enfermedades (Nombre científico)
Manzana (3,171 imágenes)	<ol style="list-style-type: none"> 1. <i>Gymnosporangium juniperi-virginianae</i> 2. <i>Venturia inaequalis</i> 3. <i>Botryosphaeria obtuse</i>
Cereza (1,906 imágenes)	<ol style="list-style-type: none"> 1. <i>Podoshiera clandestine</i>
Maíz (3,852 imágenes)	<ol style="list-style-type: none"> 1. <i>Cercospora zae-maydis</i> 2. <i>Puccinia sorghi</i> 3. <i>Exserohilum turcicum</i>
Uva (4,062 imágenes)	<ol style="list-style-type: none"> 1. <i>Guignardia bidwellii</i> 2. <i>Phaeomoniella aleophilum, Phaeomoniella chlamydospora</i> 3. <i>Pseudocercospora vitis</i>
Durazno (2,657 imágenes)	<ol style="list-style-type: none"> 1. <i>Xanthomonas campestris</i>
Pimiento (2,475 imágenes)	<ol style="list-style-type: none"> 1. <i>Xanthomonas campestris</i>
Papa (2,152 imágenes)	<ol style="list-style-type: none"> 1. <i>Alternaria solani</i> 2. <i>Phytophthora infestans</i>
Fresa (1,565 imágenes)	<ol style="list-style-type: none"> 1. <i>Diplocarpon earlianum</i>
Tomate (18,160 imágenes)	<ol style="list-style-type: none"> 1. <i>Xanthomonas campestris pv. Vesicatoria</i> 2. <i>Alternaria solani</i> 3. <i>Phytophthora infestans</i> 4. <i>Passalora fulva</i> 5. <i>Septoria lycopersici</i> 6. <i>Tetranychus urticae</i> 7. <i>Corynespora cassiicola</i> 8. <i>Tobamovirus</i> 9. <i>TYLCV</i>

Especificaciones de la estación de trabajo

La fase de entrenamiento de los clasificadores requiere hardware dedicado como las Unidades de Procesamiento Gráfico (GPU) para reducir el tiempo de ejecución (Krizhevsky et al, 2012). Las GPU representan un componente

fundamental dado que sin ellas el trabajo llevaría muchos más días de entrenamiento. No obstante, la fase de prueba de un clasificador no solicita ningún hardware dedicado. Todos los experimentos realizados se ejecutaron en una súper computadora cuyas características se encuentran descritas en la **Tabla 2**.

Tabla 2. Características de la máquina.

Hardware y software	Características
Memoria	16 Gb
Procesador (CPU)	Intel Core i7-7700 CPU @ 3.60 GHz
Unidad de Procesamiento Gráfico (GPU)	GeForce GTX 1070 X 8 Gb
Sistema operativo	Windows 10, 64 bits

Arquitecturas pre-entrenadas de CNN utilizadas

Cada una de las arquitecturas utilizadas (ver **Tabla 3**) utilizaron los mismos hiperparámetros para su entrenamiento:

- Opción de entrenamiento: Descenso de gradiente estocástico con ímpetu

- Momento: 0.9000
- Tamaño de lote: 24
- Factor para regularizar el decaimiento de peso: $1.00e^{-04}$
- Tasa de aprendizaje: $1.00e^{-04}$

Tabla 3. Propiedades de las CNN pre-entrenadas

Arquitectura de CNN	Capas de profundidad	Tamaño de la imagen de entrada (píxeles)	Número de total de imágenes
AlexNet	8	227 X 227	40,000
GoogleNet	22	224 X 224	40,000
InceptionV3	48	299 X 299	40,000
SqueezeNet	18	227 X 227	40,000
ResNet50	50	224 X 224	40,000
ResNet101	101	224 X 224	40,000

RESULTADOS

En este estudio se realizó la evaluación de seis arquitecturas para la tarea de clasificación de enfermedades de plantas mediante imágenes digitales. La exactitud general que se obtuvo en el conjunto de datos utilizado varió de 98.90% (en el caso de AlexNet), mientras que el menor porcentaje fue de 96.22% (en el caso de InceptionV3). Cada una de las arquitecturas se

ejecutó con un total de 50 épocas, donde cada época es el número de iteraciones del entrenamiento. Como se puede observar en la **Figura 1** se muestra el comportamiento que siguió cada arquitectura en ajustarse a los valores del dataset. Sin embargo, SqueezeNet tarda en ajustarse a dichos valores, siendo demasiado inestable para poder modelar el fenómeno.

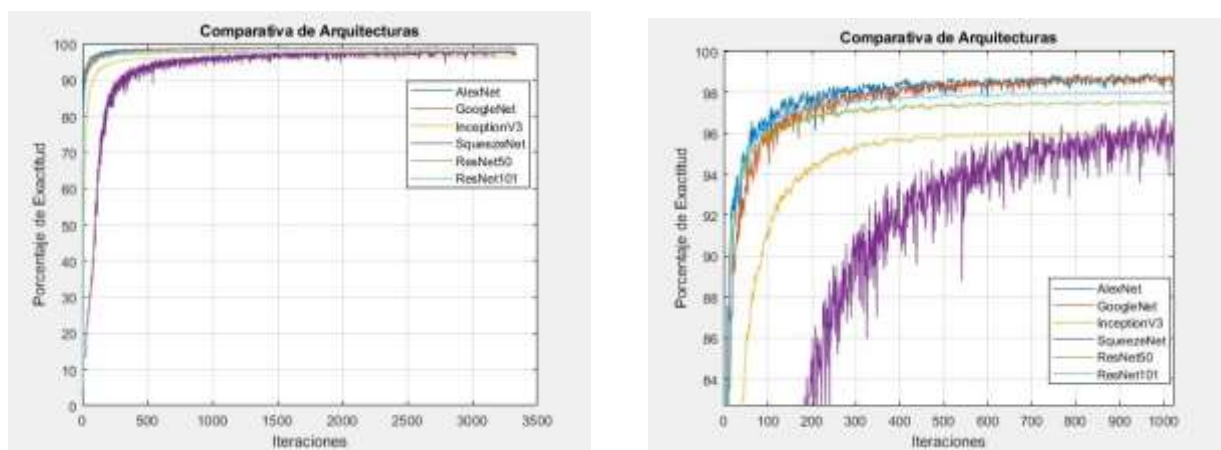


Figura 1. Comparativa de Arquitecturas

En la **Tabla 4** se muestran los tiempos obtenidos por cada una de las CNN. Durante cada uno de los entrenamientos nos percatamos sobre el costo computacional que emanan de los modelos

de entrenamiento profundo. La CNN que menos costo demandó fue SqueezeNet, en cambio la que mayor demanda obtuvo fue ResNet101.

Tabla 4. Resultado general.

Arquitectura de CNN	Porcentaje de exactitud	Tiempo
AlexNet	98.90%	1,360 min 13 seg
GoogleNet	98.85%	2,639 min 49 seg
InceptionV3	96.22%	7,143 min 5 seg
SqueezeNet	97.37%	1,217 min 34 seg
ResNet50	97.56%	4,878 min 6 seg
ResNet101	98.07%	7,672 min 15 seg

No obstante, se utilizó la arquitectura con mayor porcentaje de exactitud para detectar las lesiones por medio de las capas de activación de AlexNet, debido a que la red aprende a identificar

características útiles tales como los bordes y colores en la primera capa convolucional (Véase la **Figura 2**).




Figura 2. Primeras capas convolucionales de AlexNet

La posición de un píxel en la activación de un canal corresponde a la misma posición de la imagen original. En otras palabras, un píxel blanco en un lugar de canal indica que el canal está fuertemente activado en esa posición. La **Figura 3** hace una comparación entre la imagen original de la hoja enferma y la capa de convolución cinco donde los píxeles en blanco muestran de manera exacta la activación de las partes dañadas de la hoja. Por último, se remarcan las lesiones con el objetivo de que los agricultores inexpertos identifiquen las regiones de la enfermedad.




Figura 3. Comparación entre a) Imagen original, b) Capa de convolución, c) Lesiones remarcadas

DISCUSIÓN

El avance en el Aprendizaje Profundo (Deep Learning, DL) presenta una oportunidad de extender la investigación y la aplicación en base a la identificación de enfermedades de plantas usando imágenes digitales. Se requieren modelos rápidos y precisos para que las medidas adecuadas se puedan aplicar de manera temprana. Dependiendo del objetivo en maximizar o minimizar la arquitectura de la red seleccionada para el desarrollo de un sistema clasificador. Por un lado, si el problema requiere de reconfiguración constante la red SqueezeNet es la más rápida, sin embargo, es demasiado inestable para modelar. Si se desea obtener la exactitud alta en la clasificación, existen alternativas como AlexNet y GoogleNet. En el estudio realizado por Brahimi (Brahimi et al, 2017), se basó en clasificar enfermedades para algunas CNN. La arquitectura InceptionV3 obtuvo un 99.72% Asimismo, mencionan que AlexNet y SqueezeNet poseen una exactitud similar de 99.2% que es menor a los resultados de otras arquitecturas. Realizando la pequeña comparación en base a la exactitud y utilizando la misma técnica de transferencia de aprendizaje, InceptionV3 fue la que menor porcentaje de exactitud obtuvo, de igual manera AlexNet y SqueezeNet no lograron resultados similares, debido a que AlexNet fue la red que mejor resultados consiguió, mientras que SqueezeNet obtuvo un resultado de 97.37 muy por debajo de lo que los autores mencionan. Cabe destacar que el entrenamiento de los modelos conlleva demasiadas horas en una computadora con GPU de alto rendimiento. Finalmente, el conjunto de datos de *PlantVillage* no está equilibrado puesto que algunas clases tienen más imágenes que otras, lo que podría ser un factor en contra y resultaría llegar a un sobreajuste sino se entrena de manera correcta.

CONCLUSIÓN

El Aprendizaje Profundo ha logrado grandes resultados en muchos campos de investigación debido a la gran capacidad de formar características de una manera totalmente automatizada sin la intervención de los humanos. En la protección de enfermedades de plantas muchos trabajos han propuesto el uso del DL para detectar y clasificar enfermedades, es por eso que hemos planteado el uso de CNN con el objetivo de crear una herramienta para aquel investigador que requiera diseñar e implementar un autómata de clasificación de enfermedades de hojas de plantas, brindándole los datos precisos sobre la arquitectura que más le convenga utilizar. Por otro lado, ResNet50 es computacionalmente más costoso en términos de tiempo de ejecución. Además, ResNet50, ResNet101 e InceptionV3 siendo las redes más profundas demuestran que no fueron tan precisas a pesar del gran número de capas de profundidad. Finalmente, se propuso analizar diferentes CNN en tiempo y desempeño. AlexNet logró obtener un mejor resultado, mientras que SqueezeNet lo logra en menor tiempo estando por debajo de un 1.53%. Igualmente, en nuestro estudio hacemos uso de las capas de activación de AlexNet con el fin de detectar y localizar las regiones de la enfermedad.

LITERATURA CITADA

- Barbedo, J. G. (2018). Factors influencing the use of deep learning for plant disease recognition. *Biosystems Engineering*, 172, 84-91.
- Brahimi, M., Boukhalfa, K., & Moussaoui, A. (2017). Deep learning for tomato diseases: classification and symptoms visualization. *Applied Artificial Intelligence*, 31(4), 299-315.

- Hanssen, I. M., & Lapidot, M. (2012). Major tomato viruses in the Mediterranean basin. En *Advances in virus research* (Vol. 84, págs. 31-66). Academic Press.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. En *Proceedings of the IEEE conference on computer vision and pattern recognition* (págs. 770-778).
- Hughes, D., & Salathé, M. (2015). An open access repository of images on plant health to enable the development of mobile disease diagnostics. *arXiv preprint arXiv:1511.08060*.
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., & Keutzer, K. (2016). Squeezenet: Alexnet-level accuracy with 50x fewer parameters and < 0.5 mb model size. *arXiv preprint arXiv:1602.07360*.
- Kawasaki, Y., Uga, H., Kagiwada, S., & Iyatomi, H. (2015). Basic study of automated diagnosis of viral plant diseases using convolutional neural networks. En *International Symposium on Visual Computing* (págs. 638-645). Springer, Cham.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. En *Advances in neural information processing systems* (págs. 1097-1105).
- Lu, Y., Yi, S., Zeng, N., Liu, Y., & Zhang, Y. (2017). Identification of rice diseases using deep convolutional neural networks. *Neurocomputing*, 267, 378-384.
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in plant science*, 7, 1419.
- Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., & Stefanovic, D. (2016). Deep neural networks based recognition of plant diseases by leaf image classification. *Computational intelligence and neuroscience*, 2016.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., . . . Rabinovich, A. (2015). Going deeper with convolutions. En *Proceedings of the IEEE conference on computer vision and pattern recognition* (págs. 1-9).
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. En *Proceedings of the IEEE conference on computer vision and pattern recognition* (págs. 2818-2826).
- Thakre, G., More, A. R., & Gajakosh, K. S. (2017). A Study On Real Time Plant Disease Diagnosis System. *International Journal of Advance Research, Ideas and Innovations in Technology*, 3, 1118-1124