

Detección de la enfermedad “Mancha de hierro” en hojas del cafeto utilizando Redes Neuronales Convolucionales



Colaboración

Balzhojt Roldán Ortega; Cecilia Irene Loeza Mejía; Instituto Tecnológico Superior de Misantla; Rajesh Roshan Biswal, ITESM / Campus Guadalajara

RESUMEN: La producción del café es una de las principales fuentes de ingresos principalmente en países en vías de desarrollo, pero esta producción puede ser mermada por la presencia de enfermedades en las fincas cafetaleras, trayendo consigo, pérdidas considerables en la economía local. Se sabe que la mancha de hierro es una de tantas enfermedades, y que para hacer un diagnóstico se requiere de personal experto. En este artículo se hace una propuesta de usar Redes Neuronales Convolucionales, para poder generar un modelo clasificador y poder detectar la enfermedad, con tan solo imágenes de las hojas de café. Los resultados que se obtuvieron de 96.80% y 90.65% en la precisión de entrenamiento y validación del modelo propuesto, nos indican que es posible generar dicho modelo y concluir que es viable desarrollar una herramienta que ayude a los cafeticultores a actuar en tiempo y forma cuando se presenten indicios de la enfermedad Mancha de Hierro.

PALABRAS CLAVE: Enfermedades del café, Mancha de Hierro, Redes Neuronales Convolucionales.

ABSTRACT: Coffee production is one of the main sources of income mainly in developing countries, but this production can be reduced by the presence of diseases that could occur on coffee farms bringing with them, losses considerable in the local economy. Iron stain is known to be one of many causing diseases, and that making a diagnosis requires expert staff. This article makes a proposal to use Convolutional Neural Networks, to be able to generate a classifying model and be able to detect the disease, with only images of the coffee leaves. The results obtained from 96.80% and 90.65% in the training accuracy and validation of the proposed model, indicate that it is possible to generate such a model and conclude that it is feasible to develop a tool that helps coffee growers to act in time and form when evidence of Iron Stain disease is present.

KEYWORDS: Coffee Diseases, Iron Stain, Coffee, Convolutional Neural Networks.

INTRODUCCIÓN

En el mundo en desarrollo, más del 80% de la producción agrícola es generada por pequeños agricultores [1], y las pérdidas de rendimiento de más del 50% debido a plagas y enfermedades son más comunes cada día [2]. Además, se cree que el 50% de personas con problemas de pobreza y hambruna, vive en estas zonas productivas [3], lo que hace que los pequeños agricultores sean un grupo particularmente vulnerable a situaciones precarias económicamente.

El café es un producto importante en la economía mundial, más importante en los países en vías de desarrollo ya que es una de las principales fuentes de divisas. Marcos Gottfried, director general de Expo Café 2017, dijo que en el periodo 2016-2017, México se colocó como el onceavo productor de café a nivel mundial, con 1.6% de la producción global y en el doceavo lugar a nivel internacional como exportador [4].

En México, la cafeticultura es importante por el número de productores que se dedican a ella, en año 2017 se registró la participación de 500 mil cafeticultores en todo el país, y es aquí donde radica desde el punto de vista social, la importancia del café, además de que considerando las familias de estos grupos y las del personal ligado a la transformación y comercialización del grano, alrededor de 3 millones de mexicanos dependen del café en algún grado. Este cultivo se encuentra actualmente en 484 municipios del país; 74 de ellos generan 70% de la producción nacional [4].

Para aumentar la producción, es necesario que el productor tenga buenas prácticas fitosanitarias, ya que las enfermedades pueden traer pérdidas considerables a la productividad. Una de las enfermedades es "Mancha de hierro", causada por el hongo *Cercospora coffeicola*, que ataca las hojas y los frutos del café en cualquier fase de crecimiento ocasionando pequeñas manchas redondas de color pardo claro o rojizo que terminan por defoliar la planta y afectar el crecimiento del fruto [5]. Esta plaga puede disminuir la productividad de 40-50% de la producción y causar la contracción del 30-40% del peso de los granos de café [6].

Existen metodologías tradicionales para hacer la evaluación de la enfermedad, que se basan principalmente en la observación del experto, es por eso que en este documento se pretende que con la ayuda de las Redes Neuronales Convolucionales en el reconocimiento de patrones se pueda entrenar un modelo clasificador y posteriormente determinar si existe presencia de la enfermedad cuando se le suministre una nueva muestra.

En la literatura ya hay trabajos relacionados, como por ejemplo el de Mohanty et al. [7] donde realizaron 60 experimentos usando redes neuronales convolucionales profunda para identificar 14 especies de cultivos y 26 enfermedades, utilizando modelos entrenados como AlexNet [8] y GoogleNet [9] con el conjunto de datos de PlantVillage de 54,306 imágenes que contienen 38 clases de 14 especies de cultivos y 26 enfermedades (o su ausencia), logrando una precisión máxima del 99.35%. Otro trabajo que también utilizó Arquitectura ya entrenadas fue el de Khan et al. [10] para clasificar enfermedades del tomate, donde obtuvieron 32.23% usando la arquitectura AlexNetOWTbN y 33.27% para VGG16 [11]. También Ashqar & Abu [12] quienes realizaron un estudio que consistió en analizar 9000 imágenes de hojas de tomate, para producir un modelo con el propósito de identificar 5 tipos de enfermedades, donde obtuvieron resultados del 99.84% en precisión. Por otra parte, Arnal Barbedo [13], trabajó con redes neuronales convolucionales aplicándolas en el análisis de varios cultivos, buscando niveles de enfermedad en las plantas, pudiendo clasificar a cultivos sanos con un 89% de precisión, ligeramente enfermos con un 31%, moderadamente enfermos 87% y gravemente enfermos con un 94%.

Como se puede notar, existe un interés de varios autores por encontrar nuevas formas para detectar enfermedades en las hojas, haciendo que se justifique el uso de las redes neuronal convolucionales por su eficiencia en la detección de la enfermedad. Para este caso de estudio, se concentra en la mancha de hierro que afecta a las hojas del café.

MATERIAL Y MÉTODOS

Para llevar a cabo este trabajo de estudio, se siguió la metodología que se muestra en la figura 1. Donde primero se realizó la adquisición de las imágenes del conjunto de datos, luego se le hizo un preprocesamiento a las imágenes para que la ejecución del algoritmo fuera más eficiente y luego se probó la efectividad del modelo clasificador. A continuación, se describirán las etapas de la metodología.

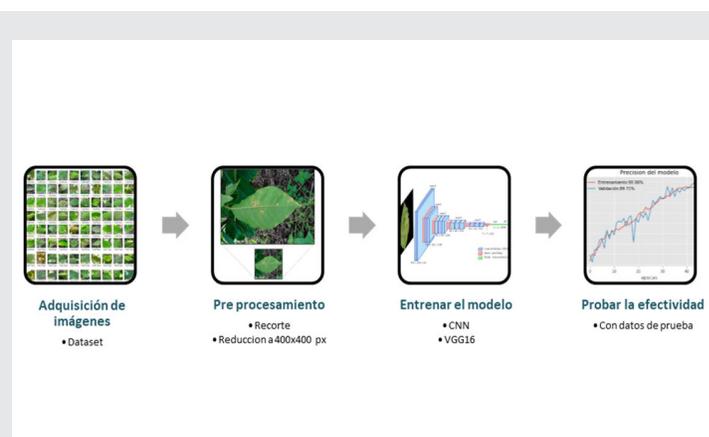


Figura 1: Metodología

Adquisición de imágenes

Para este experimento se utilizó el dataset de imágenes "RoCoLe: A robusta coffee leaf images dataset" (ParragaAlava, Cusme, Loor, & Santander, 2019). Dicho conjunto de datos está conformado por 770 imágenes de hojas que presentan signos de la enfermedad mancha de hierro y 792 que no presentan la enfermedad.

Preprocesamiento

Se aplicó un recorte de imagen a todo el lote, con el objetivo de centrar el área a analizar y disminuir el ruido en el entrenamiento, además se redujo el número de píxeles que estaban en el rango de (2048 x 1152 - 4128 x 2322) a unas imágenes con resolución más manejable de 400 x 400 píxeles.

Comúnmente en esta etapa, también se hace extracción de características, pero al trabajar con redes neuronales convolucionales, se hace prescindible éste paso, ya que la propia red aprende a extraerlas a través de sus capas convolucionales, creándose en ella los filtros requeridos para cada una de las características que definen a la clase, en este caso, los patrones de la enfermedad.

Entrenar el Modelo

Para la obtención del modelo clasificador, se realizaron pruebas para buscar el modelo óptimo y que se ajustara a los objetivos planteados. En primer lugar, se usó la técnica de transferencia de aprendizaje, que consiste en tomar una red pre entrenada, en este caso la VGG16, desmontar su estructura en capas separadas y luego volver a ensamblar con nuestras propias capas, pero siempre conservando los pesos pre entrenados de la red. En este caso se eliminó su última capa y posteriormente se ensambló la capa con la configuración propuesta para sólo dos posibles resultados como se muestra en la Figura 2. En segundo lugar, se diseñó una arquitectura propia llamada cafezh con estructura como se observa en la Figura 3, donde se realizaron varias pruebas de optimizadores para ver cuál daba mejor resultado.

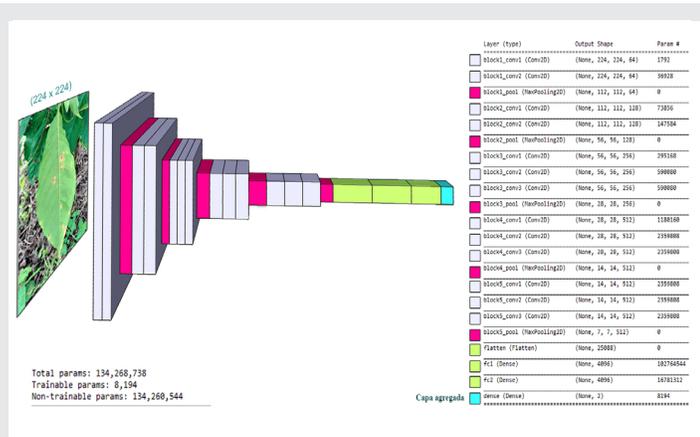


Figura 2: Arquitectura VGG16 usada para la transferencia de aprendizaje.

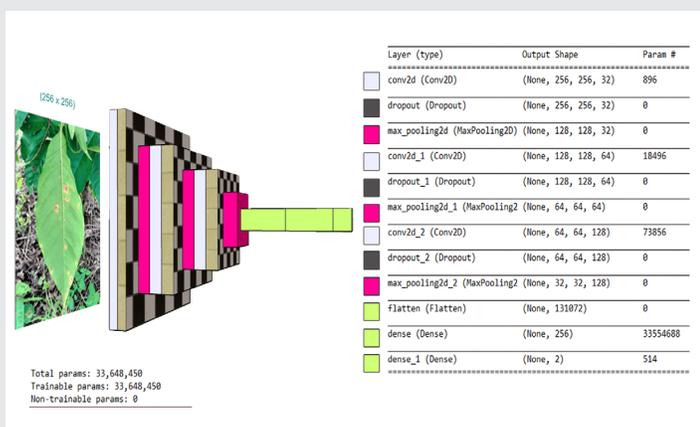


Figura 3: Arquitectura Propuesta Cafezh

Los optimizadores que se pusieron a prueba fueron: SGD, Adam, Adamax y Adadelta, todos ellos con sus valores predeterminados, tal como están configurados en Tensorflow. Los valores iniciales fueron:

- Entrada = lote de imágenes de 224x224 píxeles para la VGG16 y 256x256 para la arquitectura propuesta.

- Número de imágenes que se consideran para el entrenamiento = 1275.
- Número de imágenes que se utilizan en la validación = 311.
- Número de veces que se ejecutará la red sobre el conjunto de entrenamiento antes de empezar con la validación = 5 épocas.
- Aplicación de la técnica aumento de datos in situ para el entrenamiento.
- El equipo en el que se realizaron las pruebas tiene las siguientes características:
- Sistema Operativo Windows 10
- Procesador Intel i7 6ª generación.
- Memoria RAM 16384 MB
- Tarjeta Gráfica NVIDIA GeForce GTX 1070, 8192 MB, GDDR5.
- Python 3.7.4, Tensorflow-gpu 1.14, Keras-gpu 2.2.4.

RESULTADOS

Probamos la efectividad de las arquitecturas utilizando redes neuronales convolucionales y se observó que se obtuvieron mejores resultados con la arquitectura propuesta cafezh, ya que la técnica de transferencia de aprendizaje no dio buenos resultados, esto se pudo deber a que el optimizador y los parámetros de entrada no fueron los adecuados, como se puede observar, en la gráfica correspondiente a la arquitectura VGG16, pronto cae en un mínimo local. Por otro lado, la arquitectura propuesta, utilizando diferentes optimizadores, se logró mejorar la precisión. A continuación, se explican las arquitecturas utilizadas.

Arquitectura: VGG16

En la figura 4 se observa que con el uso de transferencia de aprendizaje utilizando la arquitectura VGG16, no es posible obtener resultados satisfactorios, ya que a partir de la primera época, se estanca el entrenamiento, y deja de aprender, eso puede deberse a que la arquitectura no es adecuada para el conjunto de datos que se ha proporcionado, ya que la documentación explica que se ha entrenado para 1000 cosas, pero no preci-

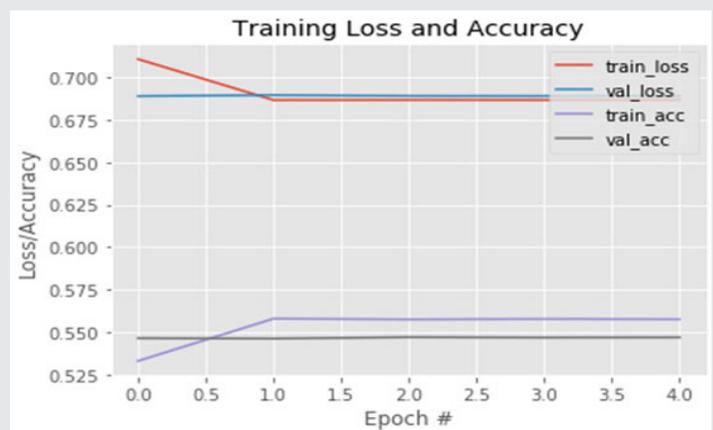


Figura 4. Resultados Arquitectura: VGG16

samente hojas de café, y aunque en su última capa se agregaron los nuevos datos, da la posibilidad que no fueron suficientes, aun así, se realizó el experimento, sólo para ver el comportamiento del modelo. Los resultados de 55.76% de precisión en el entrenamiento y 54.69% en la validación lo demuestran.

Arquitectura: cafezh1

En la figura 5, se muestran los resultados obtenidos utilizando el optimizador SGD. Se obtuvo 89.43% en precisión para el entrenamiento y 83.63% de precisión para la evaluación. Se observa que la precisión sube con las épocas, pero en la pérdida de validación se estanca y queda lejos de la de pérdida de entrenamiento,



Figura 5. Resultados Arquitectura: cafezh1

esto hace pensar que se puede mejorar el modelo.

Arquitectura: cafezh2

En la figura 6 se muestran los resultados del siguiente experimento, donde se pudo obtener 96.73% en precisión para el entrenamiento y 89.03% de precisión para la validación, utilizando el optimizador Adamax. Se observa que la precisión sube con las épocas dando indicios de que se está mejorando. Aunque la pérdida en la validación tiende a subir, pero después de la época 3 empieza su bajada con tendencia a seguir bajando, prueba de que se puede llegar a buenos resultados si

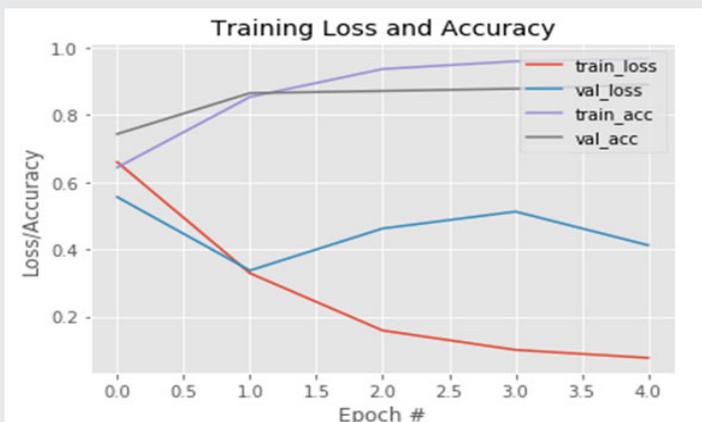


Figura 6. Resultados Arquitectura: cafezh2

prosigue el entrenamiento.

Arquitectura: cafezh3

En la figura 7, se muestran los resultados obtenidos utilizando el optimizador Adadelta. Se alcanzó 96.80% en precisión para el entrenamiento y 90.65% de precisión para la evaluación. Aunque la pérdida en la validación tiende a subir, pero después de la época 3 empieza su bajada con tendencia a seguir bajando, esto da un indicio de que si se continua con el entrenamiento, se



Figura 7. Resultados Arquitectura: cafezh3

puede llegar a resultados satisfactorios.

CONCLUSIONES

Como cualquier enfermedad, la prontitud con que se diagnostique hará la diferencia en la efectividad del tratamiento, y por ello, se concluye que el uso de Las redes Neuronales Convolucionales, pueden ser de gran ayuda para crear un modelo clasificador de la enfermedad "Mancha de Hierro" ya que los resultados fueron superiores al 90% de precisión. El modelo cafezh puede utilizarse para crear una herramienta que determine si existe presencia de la enfermedad cuando se le suministre una nueva muestra, todo ello sin la rigurosa supervisión de un experto, ayudando así al productor cafetalero a actuar en tiempo y forma ante la presencia de la enfermedad, además, disminuyendo la subjetividad del diagnóstico.

BIBLIOGRAFÍA

[1] Tai, A. P. K., Martin, M. V., & Heald, C. L. (2014). Threat to future global food security from climate change and ozone air pollution. *Nature Climate Change*, 4(9), 817–821. <https://doi.org/10.1038/nclimate2317>

[2] Harvey, C. A., Rakotobe, Z. L., Rao, N. S., Dave, R., Razafimahatratra, H., Rabarijohn, R. H., ... MacKinnon, J. L. (2014). Extreme vulnerability of smallholder farmers to agricultural risks and climate change in Madagascar. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 369(1639). <https://doi.org/10.1098/rstb.2013.0089>

[3] Sanchez, P. A., & Swaminathan, M. S. (2005). Cutting world hunger in half. *Science*, 307(5708), 357–

359. <https://doi.org/10.1126/science.1109057>

[4] CEDRSSA (2018). *Reporte el café en México diagnóstico y perspectiva*. Obtenido de [http://www.cedrssa.gob.mx/files/10/30El café en México: diagnóstico y perspectiva.pdf](http://www.cedrssa.gob.mx/files/10/30El%20café%20en%20México%20diagnóstico%20y%20perspectiva.pdf)

[5] Guzmán Piedrahíta, O. A., & Rivillas Osorio, C. A. (2007). *Relación de Glomus manihotis y G. fasciculatum con el crecimiento de plantas de café y la severidad de la mancha de hierro*. *Cenicafe*, 58(3), 236–257.

[6] Guzmán, Ó. A., Gómez, E. O., Rivillas Osorio, C. A., Carlos, ;, Oliveros Tascón, E., & Electrónico, I. (2003). *Utilización Del Procesamiento De Imágenes Para Determinar La Severidad De La Mancha De Hierro , En Hojas De Café*. 258 *Cenicafé*, 54(3), 258–265. Retrieved from <http://biblioteca.cenicafe.org/bitstream/10778/244/1/arc054%2803%29258-265.pdf>

[7] Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). *Using deep learning for image-based plant disease detection*. *Frontiers in Plant Science*, 7(September), 1–10. <https://doi.org/10.3389/fpls.2016.01419>

[8] Jansen, K., & Zhang, H. (2007). *Scheduling malleable tasks*. *Handbook of Approximation Algorithms and Metaheuristics*, 45-1-45-16. <https://doi.org/10.1201/9781420010749>

[9] Zeng, G., He, Y., Yu, Z., Yang, X., Yang, R., & Zhang, L. (2016). *Preparation of novel high copper ions removal membranes by embedding organosilane-functionalized multi-walled carbon nanotube*. *Journal of Chemical Technology and Biotechnology*, 91(8), 2322–2330. <https://doi.org/10.1002/jctb.4820>

[10] Khan, S., n, meera, Shaikh, A. A., Ansari, H., & Ansari, N. (2019). *Disorder Detection in Tomato Plant Using Deep Learning*. *SSRN Electronic Journal*, 2154–2160. <https://doi.org/10.2139/ssrn.3358226>

[11] Simonyan, K., & Zisserman, A. (2014). *Very Deep Convolutional Networks for Large-Scale Image Recognition*. 1–14. Retrieved from <http://arxiv.org/abs/1409.1556>

[12] Ashqar, B. A. M., & Abu-naser, S. S. (2018). *Image-Based Tomato Leaves Diseases Detection Using Deep Learning*. 2(12), 10–16.

[13] Arnal Barbedo, J. G. (2019). *Plant disease identification from individual lesions and spots using deep learning*. *Biosystems Engineering*, 180(2016), 96–107. <https://doi.org/10.1016/j.biosystemseng.2019.02.002>