

Detección de enfermedades en cultivos de maíz mediante imágenes con visión artificial: un caso práctico

Disease detection in corn crops through images with artificial vision: a practical case



José Ruiz Tamayo¹
jose.rt@purisima.tecnm.mx
<https://orcid.org/0000-0002-4837-3696>
Jazmín Trasviña Osorio²
rosa.to@purisima.tecnm.mx
<https://orcid.org/0000-0003-0895-2009>
Erick Rojas Mancera³
erick.rm@purisima.tecnm.mx
<https://orcid.org/0000-0002-5965-9120>

Recibido: 7/10/2023; Aceptado: 12/12/2023

RESUMEN

En México y el mundo, el maíz es una de las plantas más susceptible a padecimientos graves que afectan su desarrollo y el rendimiento de la semilla. Factores como el cambio climático y la llegada poco común de insectos vectores en la actualidad han propiciado que los patógenos que afectan este tipo de cultivos se vuelvan más resistentes. Tener la certeza del tipo de enfermedad que afecta a las plantas es importante en la agricultura ya que genera una mejor toma de decisiones sobre la actuación previa a afectaciones graves. En la actualidad se estima que el 65% del sector agrícola no cuenta con tecnología aplicada a la sanidad vegetal. Se ha trabajado constantemente en el desarrollo de herramientas de visión artificial, procesamiento digital de imágenes y aprendizaje automático para realizar diagnósticos de enfermedades en cultivos. El presente estudio brinda una perspectiva reciente de los avances tecnológicos en la detección de enfermedades en cultivos, su eficiencia y la relación con la búsqueda de la construcción de un sector agrícola productivo y sustentable. Se muestra además un caso de aplicación de detección de enfermedades comunes en cultivos del centro de México, donde se logró un error de identificación mínimo

¹Doctorado en Ciencias de la Ingeniería, Tecnológico Nacional de México / ITS de Purísima del Rincón, México

²Maestría en Ciencias y Tecnología en Ingeniería Industrial y Manufactura, Tecnológico Nacional de México / ITS de Purísima del Rincón, México

³Doctorado en Ciencias en Robótica y Manufactura Avanzada, Tecnológico Nacional de México / ITS de Purísima del Rincón, México

Palabras clave: maíz, enfermedades, redes convolucionantes, visión artificial, redes neuronales artificiales.

ABSTRACT

In Mexico and the world, corn is one of the plants most susceptible to serious diseases that affect its development and seed yield. Factors such as climate change and the unusual arrival of insect vectors today have caused the pathogens that affect this type of crops to become more resistant. Being certain of the type of disease that affects plants is important in agriculture since it generates better decision-making about action prior to serious damage. Currently, it is estimated that 65% of the agricultural sector does not have technology applied to plant health. Constant work has been carried out on the development of artificial vision, digital image processing and machine learning tools to diagnose diseases in crops. The present study provides a recent perspective of technological advances in the detection of diseases in crops, their efficiency, and the relationship with the search for the construction of a productive and sustainable agricultural sector. A case of application of detection of common diseases in crops in central Mexico is also shown, where a minimum identification error was achieved.

Keywords: Corn, diseases, convolutional networks, computer vision, artificial neural networks.

Introducción

El maíz (*Zea mays* L. subsp. *mays*) es la segunda especie más cultivada en el mundo y, junto con el arroz y el trigo, es uno de los tres principales cultivos de cereales. Para un tercio de la población mundial, en el África subsahariana, el sudeste asiático y América Latina, el maíz es el cultivo básico (Tanumihardjo, et al., 2020).

La producción de este grano es importante culturalmente y por tradición en gran parte de Latinoamérica y su demanda tiene una tendencia creciente. Esta alta demanda trae consigo grandes retos para el sector productivo y su cadena suministro.

Dentro de estos sectores estratégicos México tiene un papel de importador y exportador de este tipo de grano. Considerando la última actualización de 2021 realizada por la Secretaría de Agricultura y Desarrollo rural, en México se produjeron 27 millones de toneladas de maíz, ocupando el séptimo puesto a nivel mundial. En el año 2022 generó exportaciones de US\$8.58 mil millones en ventas internacionales y compró un estimado de US\$437 mil

millones de compras a diversos países, siendo Estados Unidos el mayor proveedor de este grano seguido por Brasil (Gobierno de México, 2023).

Para la Organización de las Naciones Unidas en su reporte sobre el panorama regional de seguridad alimentaria y nutricional América Latina y en el Caribe 2022 resalta que la inseguridad alimentaria es incidente en el 40% de esta población, sugiriendo que esta directriz puede explicarse, en parte, por el hecho de que esta región es la que presenta un mayor índice de desigualdad en el mundo y la que recibió un mayor impacto en diversos sectores derivado de la pandemia de COVID-19.

La necesidad de un campo sustentable, con mejores prácticas productivas es latente en la en los territorios de América Latina donde la inseguridad alimentaria es mayor. Alrededor de un 40.6% de la población de la zona enfrentó en 2021 inseguridad alimentaria moderada o grave, comparado con el promedio mundial de 29.3% (FAO, FIDA, OPS, PMA, UNICEF, 2023).

El Plan Nacional de Desarrollo (PND) (2019) el cual sigue los propósitos de los Objetivos de Desarrollo Sostenible marcados por la Organización de las Naciones Unidas (ONU) promueve la autosuficiencia en maíz y frijol durante la gestión de la administración actual en México.

Nuevas tecnologías como la Inteligencia Artificial (IA) aplicadas en los sectores agrícolas ofrecen posibilidad de ser una herramienta dinámica en el proceso de implementación de mejores prácticas agrícolas. Desde evitar no solo gran parte del trabajo físico de la producción agrícola, sino también el trabajo intelectual necesario para recopilar, analizar información por medio de datos y tomar decisiones. Por lo tanto, puede ayudar a poner en práctica la agricultura de precisión, ya que mejoran la puntualidad de las actividades y permiten aplicar los insumos de manera más precisa y eficiente (Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), 2022).

El propósito de generar nuevas aplicaciones tecnológicas como la IA se busca implementar sistemas automatizados que permitan la interacción con la fuente del problema y la generación de escenarios de diagnóstico. Estas herramientas aplicadas en el sector agrícola generan una toma de decisiones sobre el diagnóstico de manera rápida y con una tasa de error mínima. Si los sistemas de diagnóstico son eficientes podrán entonces producir beneficios que ayuden en la sustentabilidad ambiental.

Para generar entornos de diagnóstico con IA se ha generado investigación continuamente como lo expuesto por (Venkataraju, et al., 2023) quienes plantean el estudio de las investigaciones existentes con uso de modelos de aprendizaje automático para identificar tipos de maleza en los cultivos. Los autores buscaron aquellas aplicaciones que realizan una correcta clasificación e intervención de crecimientos de hierba invasora.

Los autores encontraron 35 artículos de investigación 8 de los cuales tratan sobre el uso de Support Vector Machine, 10 usan redes neuronales y 17 usan técnicas misceláneas. El autor explora los problemas de investigación, el tipo de datos, su preprocesamiento y la exactitud de identificación. Otros ejemplos de uso de tecnología de IA para la detección de maleza han sido reportados por Wang, Zhang, & Wei, (2019), Espejo-Garcia, et al., (2020) y Gothai, et al., (2020)

El enfoque de uso de herramientas de IA para la predicción de rendimiento ha sido usado por diversos autores. Kim, et al., (2020), describen un modelo optimizado de predicción de rendimiento de maíz en condiciones climáticas extremas. Su implementación considera imágenes satelitales, obteniendo que, de los seis modelos diferentes de IA usados, la red neuronal de aprendizaje profundo obtiene mejores resultados.

En su investigación sobre el rendimiento de maíz híbrido Sarijaloo, et al., (2021), prueban diferentes modelos de aprendizaje siendo el XGBoost el que reduce el error cuadrático medio identificando mejor el rendimiento del maíz. El estudio comparativo de modelos de IA para estimar el rendimiento también se ha presentado por Shahhosseini, et al., (2020), Shahhosseini (2021) y Freire de Oliveira, et al., (2022),

Bajo el enfoque de detección de plagas y enfermedades presentadas en las plantas del maíz se han presentado diversas estrategias usando las nuevas herramientas de aprendizaje automático de la IA. Waheed, et al., (2020), desarrollan la implementación de detección de enfermedades usando la arquitectura de Red Convolutiva DenseNet, EfficientNet, VGG19net, NASNet y XceptionNet, siendo DenseNet la que logra una precisión de 98.06% para la detección cultivo sano, manchas por *Cercospora*, roya común y tizón foliar.

La investigación propuesta por Yu, et al., (2021), proponen un método basado en k-medias y un modelo de aprendizaje profundo mejorado para tres de las principales enfermedades

Ruiz, Trasviña, Rojas.

Detección de enfermedades en cultivos de maíz mediante imágenes con visión artificial: un caso práctico

(mancha gris, mancha foliar y roya) usando bases de datos logrando una eficiencia de 93% en el reconocimiento.

Fraiwani, Faouri, & Khasawneh, (2022) presentan el uso de Redes Neuronales Convolucionales para la detección de manchas ocasionadas por *Cercospora*, roya común y tizón foliar del norte logrando buenas logrando una precisión del 98% en la detección. Otras investigaciones que proponen el uso de redes convolucionales como herramienta para detección de padecimientos son los presentados por Mishra, Sachan, & Rajpal, (2020) aplicación en tiempo real de detección en cultivos en la India. Zeng, et al., (2022) realizan su trabajo clasificando enfermedades en maíz con la red SKPSNet-50 y (Yin, et al., 2022) creando la red DISE-Net con menor error que las otras redes convolucionales evaluadas.

Esta marcada tendencia de mejorar las decisiones y optimizar los rendimientos de diversos productos se repite de manera constante en todo el mundo. En este punto radica la necesidad de realizar un estudio focalizado en la región del centro de México con investigaciones que generen propuesta de implementación de técnicas de IA

Redes Convolucionales: principios de funcionamiento

La red neuronal convolucional es un tipo especial de red neuronal multicapa o arquitectura de aprendizaje profundo inspirada en el sistema visual de los seres vivos. La red es muy adecuada para diferentes campos de la visión por computadora y el procesamiento del lenguaje natural (Ghosh, Sultana, & Chakrabarti, 2020).

Una red neuronal convolucional generalmente consta de una o más capas convolucionales y capas completamente conectadas e incluye ReLU y capas de agrupación (Yamashita, Nishio, Do, & Togashi, 2018). Las neuronas de la capa convolucional están dispuestas en una matriz para formar un mapa de características multicanal. Una neurona en cada canal está conectada solo a una parte del mapa de características antes de esa capa (Liu & Wang, 2021).

La salida de la neurona se obtiene convolucionándola con un núcleo de convolución y luego usando una función de activación. Las neuronas ubicadas en el mismo mapa de características del canal de la misma capa convolucional se obtienen aplicando el mismo núcleo convolucional al mapa de características anterior de la capa. Guiada por características locales en mapas de características superiores, la capa convolucional busca

vínculos entre ellas, mientras que las capas de agrupación combinan datos con la misma semántica (Alzubaidi, et al., 2021). Un ejemplo de una red convolucionante se muestra en la figura 1 a continuación.

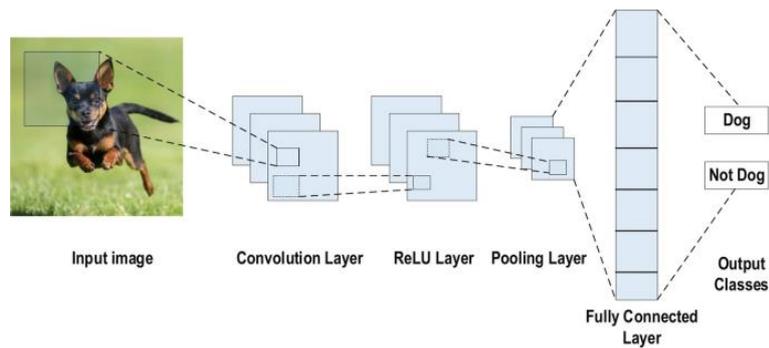


Figura 1: Ejemplo de arquitectura de Red Neuronal Convolutiva para la clasificación de imágenes
Fuente: Alzubaidi, et al., 2021

Enfermedades presentantes en hojas de maíz

El maíz, al ser una fuente de alimentos primordial en los pueblos de América Latina, debe ser cuidado de enfermedades originadas por hongos, bacterias, virus y parásitos. Regularmente el diagnóstico visual es la forma común de identificar que la planta presenta un padecimiento. Esta detección suele basarse en cambios de color, existencia de manchas, zonas podridas o secas en las hojas (Kusumo, Heryana, Mahendra, & Pardede, 2018), (Manavalan, 2020).

Considerando investigaciones y reportes presentados por investigadores como son el Centro Internacional de Mejoramiento de Maíz y Trigo (CIMMYT) (2004), Varón de Agudelo & Sarria Villa, en 2007, y Varón de Arguello, et al., en 2022, se ha generalizado una clasificación unificada de criterios para la categorización de enfermedades según el tipo de organismo que genera el daño cuyo resultado se muestra en la figura 2.

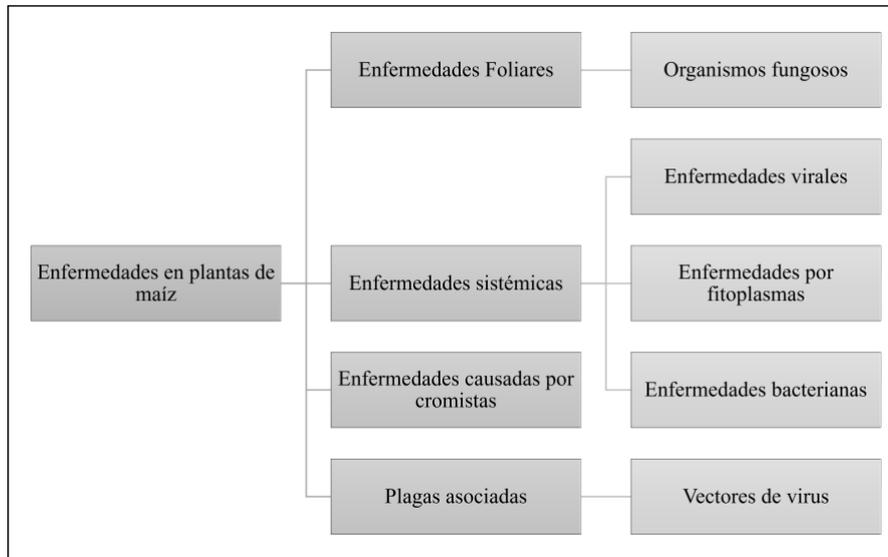


Figura 2: Clasificación de enfermedades de maíz y origen
Fuente: Elaboración propia

La categorización presentada considera únicamente infecciones que se presentan o manifiestan de manera directa o indirecta en el follaje de las plantas de maíz. Para el presente estudio se consideran las enfermedades foliares para la identificación con el uso de una Red Neuronal Convolutiva. Se descarta el diagnóstico para tallos, mazorca y espiga para unificar el criterio de identificación con la red y no generarle ruido.

Metodología para reconocimiento de patrones con Red Convolutiva

La investigación realizada parte de la aplicación de Redes Neuronales Convolutivas, en específico la arquitectura prediseñada GoogLeNet, modelo de red diseñada para la clasificación de imágenes. Para realizarla se consideró la siguiente estructura metodológica que permitió evaluar e identificar las enfermedades presentadas en el campo del centro de México.

La figura 3 muestra esquemáticamente el desarrollo de las etapas de la metodología seguida para el desarrollo de la investigación de enfermedades en las hojas de plantas de maíz. LA metodología se divide en dos etapas principales; la etapa de tareas documentales y toma de muestras y tareas de reconocimiento de patrones.

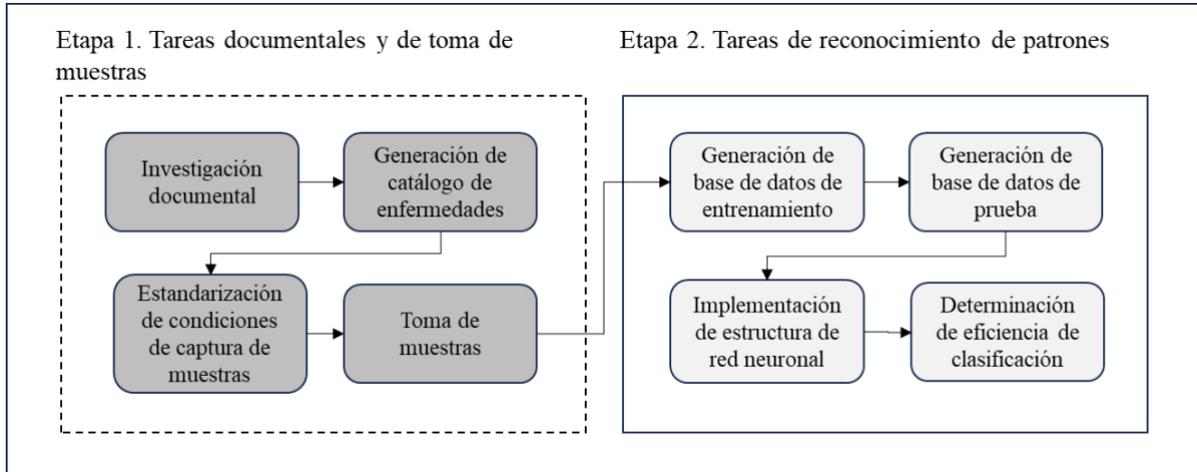


Figura 3: Etapas de la metodología para la identificación de enfermedades en maíz
Fuente: Elaboración propia

Etapa 1. Tareas documentales y de toma de muestras

- **Investigación documental**
Se recuperan información sobre los tipos de enfermedades de plantas de maíz que se presentan en diversos estudios y reportes técnico.
- **Generación de catálogo de enfermedades**
Derivado de la investigación es deseable generar un catálogo de enfermedades comunes en la zona de estudio.
- **Estandarización de condiciones de captura de muestra**
Estandarizar las condiciones de toma de fotografías a los ejemplares para ser consideradas objeto de estudio con la técnica de Redes Neuronales Convolucionales
- **Toma de muestras**
Proceder a la toma de muestras en campos de cultivo de maíz la inicial es la zona centro de México

Etapa 2. Tareas de reconocimiento de patrones

- **Generar de base de datos de entrenamiento y generar de datos de prueba**

Conformación de la base de datos definiendo el tipo de formato de la imagen, normalización, cantidad.

- Implementar de red neuronal
 - Generar el entrenamiento
 - Determinar los parámetros de operación de la red neuronal
 - Determinar de eficiencia de la red
- Verificar la correcta clasificación de enfermedades de maíz cuando la base de datos se somete a la prueba

Resultados y discusión

Resultados de Etapa 1. Tareas documentales y toma de muestras

Investigación y categorización de enfermedades foliares

El estudio se realizó en la zona centro de México, específicamente en la zona conocida como “Bajío” que durante siglos ha sido propicia para la producción agrícola. Este trabajo parte de la necesidad regional de diagnóstico de enfermedades por medio de IA en la región. Para esta primera etapa se logró definir el catálogo de enfermedades del maíz. En la Tabla 1 se muestran las enfermedades que se encuentran estacionadas en la región.

Tabla 1. Enfermedades con incidencia en zona Bajío y género científico

ENFERMEDADES CON INCIDENCIA EN MÉXICO Y ZONA BAJÍO	
Causadas por hongos	
Manchas foliares o tizón*	<i>Helmintosporium maydis</i> y <i>Cercospora</i>
Roya de maíz*	<i>Pukana sorghi</i> , <i>P polyspora</i> , <i>physopella zae</i>
Mancha Café (peca)	<i>Physoderma maydis</i>
Mildius vellosa (cenicillas)	<i>Peronoclespora</i> , <i>Selerospora</i>
Borde Blanco, tizón	Variades de <i>Marasmiellus</i>
Causadas por plaga	
Gusano soldado*	<i>Spodoptera exigua</i> en follaje
Picudos*	<i>Geraeus senilis</i> , <i>Nicentrites testaceipes</i>
Araña roja*	<i>Olygonychus mexicanus</i> , <i>Tetranidus sp</i>
Causadas por bacterias	
Marchitez de Stewar	<i>Erwinia stewartii</i>

Rayado Foliar Bacteriano	Variedades de <i>Pseudomonas</i> y <i>Rubrilineans</i>
Causadas por virus	
Moteado Clorótico del maíz	<i>Maize chlorotic mottle virus (MCMV)</i>
Virus rayado fino del maíz	<i>Maize rayado fino virus (MRFV)</i>
Virus del rayado del maíz*	<i>Maize streak virus (MVS)</i>

Fuente: elaboración propia

Para el presente estudio se determinó la selección de cuatro tipos de enfermedades a examinar; Roya de maíz, Manchas foliares o tizón, plagas y Virus del rayado del maíz. La elección de estos padecimientos se basó considerando dos criterios fundamentales. El primero se fundamentó en el factor endémico de la enfermedad, en otras palabras, considerando que cada año se presentan estas enfermedades de las hojas de maíz. El siguiente criterio fue la disponibilidad para la recuperación de muestras debido a los ciclos de siembra y cosecha.

Mancha foliar (*Cercospora*)

También se conoce como mancha gris de la hoja. Aparece en zonas con humedad y templadas. Las lesiones se manifiestan con afectaciones necróticas regulares y alargadas color café grisáceo. La afectación directa en la planta es la baja de rendimiento de grano (ver figura 4).

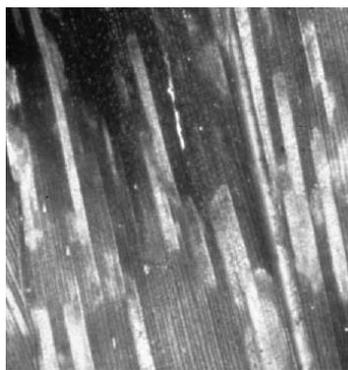


Figura 4: Manchas foliares por *Cercospora*
Fuente: CIMMYT (2004)

Roya de maíz

Afectación que se presenta regularmente en climas templados o tropicales. Es frecuente que se presente antes de la floración. Se presenta como pústulas pequeñas y polvosas. Comienzan con una coloración café, pero conforme avanza la infección y la epidermis rompe, su coloración puede cambiar a negra (ver figura 5).

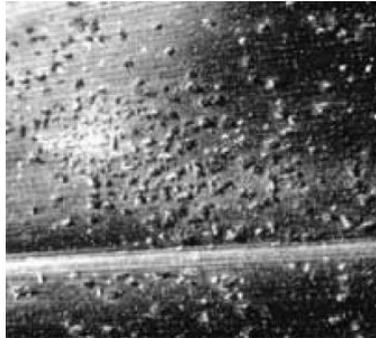


Figura 5: Afectación presentada por roya de maíz
Fuente: CIMMYT (2004)

Plagas

La presencia de plagas en la toma de muestra permitió identificar tres insectos que son considerados plaga en el cultivo de maíz y, en caso de no tomar medidas de saneamiento, tienen repercusiones en las hojas del maíz y en el rendimiento del grano (ver figura 6).

El gusano soldado: la larva pasa por cinco instares, pero en el cuarto instar se come hasta el 80% de todo el follaje que consumirá al terminar el ciclo de maduración. La hembra llega a colocar hasta 2,000 huevos, lo que sugiere una alta tasa de reproducción.

Picudos: tiene como característica que no rompe la hoja del maíz, solo come una milimétrica parte superficial dejando una marca “blanca” sobre la hoja. Cuando existen muchos insectos en el cultivo, las líneas son trazadas una y otra vez, por lo que el aspecto visual es el de una mancha blanca. Su incidencia aumenta en la época de temporal.

Araña roja: es una plaga que en los cultivos presenta una estacionalidad de siete generaciones. Su ciclo de reproducción es constante con hasta 19 huevos por día. El daño con mayor impacto es cuando en fase de ácaros dañan las hojas superiores y la mazorca, manifestación que tiene mucha similitud al que presenta la planta cuando se presenta estrés por sequía, incluso llegando a ser confundidas estas afectaciones.

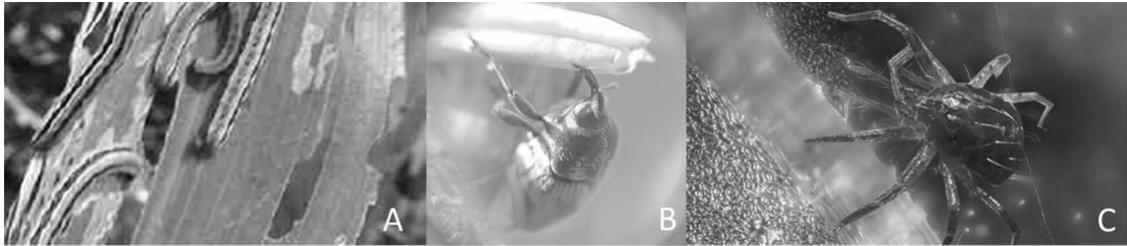


Figura 6: Plagas a) Gusano soldado b) picudos, c) araña roja
Fuente: CASAVEG (2020), Pioneer (2022)

El virus rayado del maíz

Es un virus que se transmite por medio de insectos vectores como las chicharritas del género *Cicadulina spp.* Entre ellas, *C. mbila (Naudé)* es la especie más importante, ya que, al alimentarse en una planta infectada, el insecto se convierte en portador y propaga la infección. Los primeros síntomas de la enfermedad, que consisten en manchas muy pequeñas, redondas y aisladas en las hojas más nuevas, se manifiestan siete días después del contagio.

El número de manchas aumenta a medida que la planta crece. Las hojas desarrolladas muestran una clorosis con rayas discontinuas amarillas a lo largo de las nervaduras, que contrastan con el color verde oscuro del follaje normal. Si la infección es demasiado grave la planta deja de crecer (ver figura 7).

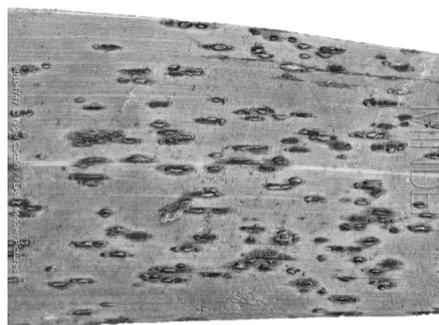


Figura 7: Afectación por virus rayado del maíz
Fuente: Licencia libre

Estandarización de captura y muestreo

Ruiz, Trasviña, Rojas.

Detección de enfermedades en cultivos de maíz mediante imágenes con visión artificial: un caso práctico

Para la toma de muestras solo se consideraron tres factores importantes:

- La resolución de la imagen no debe ser menor a 8 megapíxeles ni mayor a 16 megapíxeles.
- El formato de archivo de las imágenes debió ser en JPG
- La toma debió ser en exterior con luz natural solar, evitando el uso de luz adicional (evitando el uso de flash), y con posiciones de captura de imagen que evitaran el reflejo de la propia luz natural.

Resultados de Etapa 2. Tareas de identificación de patrones

Generación de bases de datos para entrenamiento, validación y prueba.

Esta investigación usó el software MatLab 2022b el módulo de diseño de redes “Deep Network Desing”.

Para generar la identificación usando una Red Neuronal Convolutiva se contó con una base de datos inicial. Cada una de las enfermedades se convirtió en niveles de clase para la red. Para el proceso de entrenamiento la red neuronal no requirió tratamientos previos de la imagen ya que el trabajo de estandarización se programa al diseñar la red. Las de cuatro tipos de enfermedades examinadas fueron; Roya de maíz, Manchas foliares o tizón, plagas y Virus del rayado del maíz. Las bases de datos para cada proceso de la red se muestran en la tabla 2.

Tabla 2. Distribución de datos para el funcionamiento de la Red Convolutiva

Cantidad de datos	Datos de entrenamiento	Porcentaje destinado a validación	Datos de prueba
400 imágenes iniciales	280 (70% de los datos iniciales)	120 datos (30% de los datos iniciales)	40 nuevos datos

Fuente: Elaboración propia

Estructura de la red neuronal y parámetros de operación

La red queda definida para el procesamiento de imágenes con una tarea de clasificación. La red compleja queda definida con un total de 144 capas y 170 conexiones.

La red estuvo compuesta por 11 unidades de procesamiento de entrada. Las capas de convolución contaron además de elementos adicionales como son las funciones de activación. Cada capa de la red consideró con unidades de procesamiento lineal cuya entrada va a influir en la capa de salida. Un ejemplo de una sección capas de procesamiento de la Red Convolutiva se muestra en la figura 8.

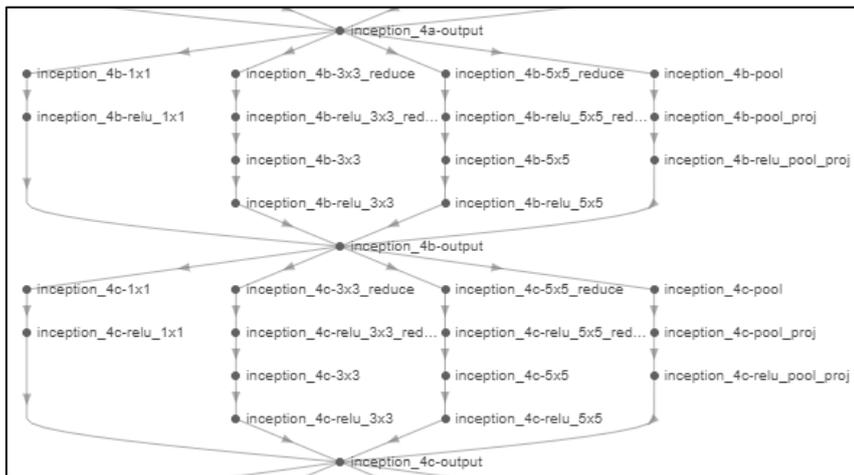


Figura 8: Capas de la Red Neuronal Convolutiva
Fuente: Elaboración propia

Carga de bases de datos para alimentar a la red

Los datos se nombraron y almacenaron en carpetas identificables de acuerdo con la enfermedad que se trataba. Primero se creo la red y valido que no existieran errores o alertas en su estructura que comprometieran los procesos posteriores de procesamiento. La figura 9 muestra como la red logra leer los folders con cada clase de enfermedad.

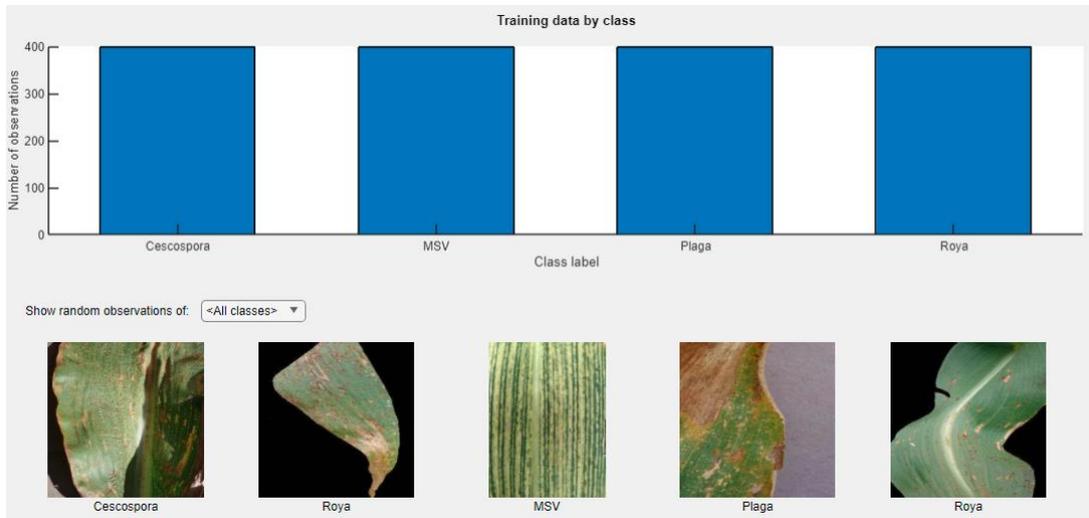


Figura 9: Identificación de categorías en la red neuronal
Fuente: MaLlab 2022b

El entrenamiento y validación de los datos se realizó en un total de 50 iteraciones en aproximadamente 10 épocas (ver figura 10). Conforme la red avanza en su entrenamiento el error de identificación de patrones de imágenes se hace más fuerte. Al finaliza el desempeño de red para al lograr la validación fue de 85.32%, esto asegura que cuando nuevas imágenes de enfermedades en hojas de maíz tendrá dicho porcentaje de asertividad.

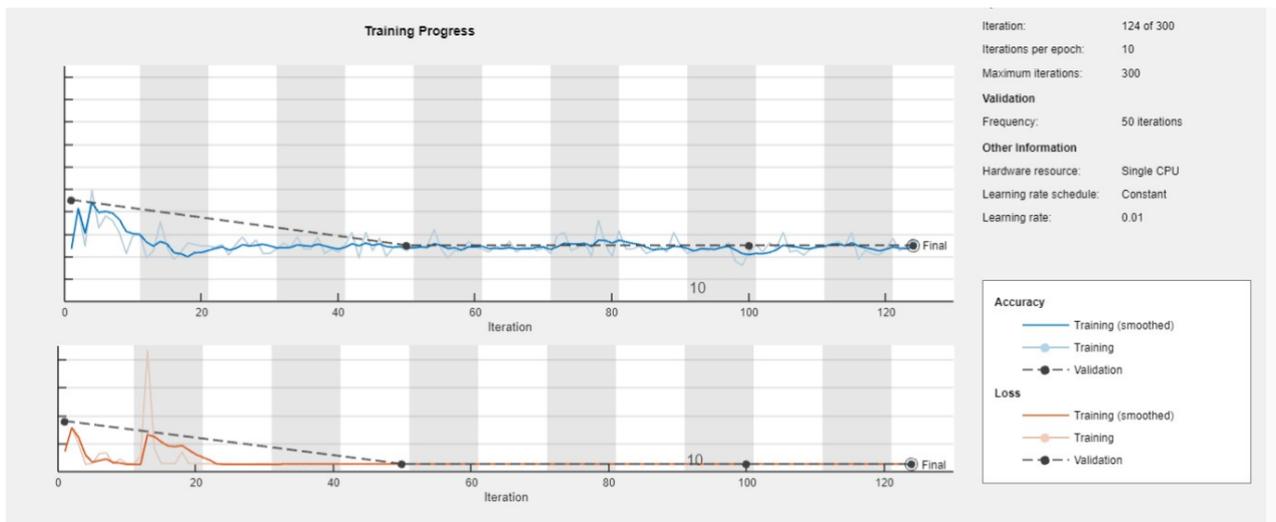


Figura 10: Identificación de categorías en la red neuronal
Fuente: MatLab 2022b

En la figura 11 se muestra un ejemplo de una correcta identificación de enfermedad causada por el virus del rayado del maíz (*Maíz streak virus, MSV*).

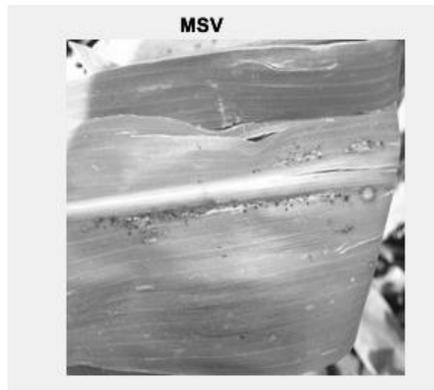


Figura 11: Correcta identificación del virus de rayado del maíz
Fuente: MatLab 2022b

Conclusiones

El uso de nuevas tecnologías como la IA, son fundamentales para potencializar las decisiones que se toman en el sector agrícola. La implementación de Redes Neuronales Convolucionales resulta una estrategia viable para identificar enfermedades foliares en el maíz.

Esta red representa una opción factible que permite tomar decisiones sobre el tratamiento más adecuado a realizar en las siembras que se ven afectadas. Si bien las enfermedades que afectan las hojas de maíz parecieran no estar relacionadas con el fruto, cuando éstas se presentan merman la calidad, cantidad del grano y la integridad de la mazorca de maíz. Es por esto por lo que esta red, como herramienta de detección temprana, busca que las decisiones que se tomen impacten en la reducción de pérdidas y maximicen la eficiencia global de la zona de cultivo.

El uso de Redes Neuronales Convolucionales y de las tecnologías de IA disponibles en el sector agrícola pueden significar un avance en la mejora de las condiciones para que el campo brinde más alimentos a la población y sea sustentable en beneficio de la sociedad.

A partir del funcionamiento reportando en este trabajo se plantea como trabajo futuro mejorar las condiciones de operación de la red con la finalidad de que la efectividad de detección sea más robusta.

Referencias bibliográficas

- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., . . . Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *J. Big Data*, 8(53). doi:<https://doi.org/10.1186/s40537-021-00444-8>
- Centro Internacional de Mejoramiento de Maíz y Trigo (CIMMYT). (2004). *Enfermedades del maíz: una guía para su identificación en el campo*. Ciudad de México: CIMMYT.
- Espejo-Garcia, B., Mylonas, N., Athanasakos, L., Spyros Fountas, S., & Vasilakoglou, I. (2020). Towards weeds identification assistance through transfer learning. *Comput. Electron*, 171, 105306. doi:<https://doi.org/10.1016/j.compag.2020.105306>
- FAO, FIDA, OPS, PMA, UNICEF. (2023). *Panorama regional de la seguridad alimentaria y nutricional - América Latina y el Caribe 2022: hacia una mejor asequibilidad de las dietas saludables*. Santiago de Chile: Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO).
- Fraiwani, M., Faouri, E., & Khasawneh, N. (2022). Classification of Corn Diseases from Leaf Images Using Deep Transfer Learning. *Plants*, 11(20), 2668. doi:<https://doi.org/10.3390/plants11202668>
- Freire de Oliveira, M., Valezka Ortiz, B., Trimer Morata, G., Jiménez, A. F., de Souza Rolim, G., & Pereira da Silva, R. (2022). Training Machine Learning Algorithms Using Remote Sensing and Topographic Indices for Corn Yield Prediction. *Remote Sensing*, 14(23), 1-24. doi:<https://doi.org/10.3390/rs14236171>
- Ghosh, A., Sultana, F., & Chakrabarti, A. (2020). Fundamental Concepts of Convolutional Neural Network. En V. Balas, R. Kumar, & R. Srivastava, *Recent Trends and Advances in Artificial Intelligence and Internet of Things. Intelligent Systems Reference Library* (Vol. 172, págs. 519-567). Springer, Cham. doi:https://doi.org/10.1007/978-3-030-32644-9_36
- Gobierno de México. (2019). *Plan Nacional de Desarrollo 2019-2024*. Gobierno de México.
- Gobierno de México. (15 de 08 de 2023). *Gobierno de México*. Obtenido de Data México: <https://www.economia.gob.mx/datamexico/es/profile/product/corn?internationalSalesStartYearSelector2=2021>
- Gothai, E., Natesan, P., Aishwariya, S., Aarthy, T. B., & Brijpal Singh, G. (2020). 2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC). *Weed Identification using Convolutional Neural Network and Convolutional Neural Network Architectures* (pp. 958-965). Erode, India. doi:10.1109/ICCMC48092.2020.ICCMC-000178.
- Kim, N., Na, S.-I., Park, C.-W., Huh, M., Oh, J., Ha, K.-J., . . . Lee, Y.-W. (2020). An Artificial Intelligence Approach to Prediction of Corn Yields under Extreme Weather Conditions Using Satellite and Meteorological Data. *Applied Sciences*, 10((11)), 37585. doi:<https://doi.org/10.3390/app10113785>
- Kusumo, B. S., Heryana, A., Mahendra, O., & Pardede, H. F. (2018). Machine Learning-based for Automatic Detection of Corn-Plant Diseases Using Image Processing. *2018 International Conference on Computer, Control, Informatics and its Applications (IC3INA)*, 93-97. doi:10.1109/IC3INA.2018.8629507.
- Liu, J., & Wang, X. (2021). Plant diseases and pests detection based on deep learning: A review. *Plant Methods*, 17(22). doi: <https://doi.org/10.1186/s13007-021-00722-9>

- Manavalan, R. (2020). Automatic identification of diseases in grains crops through computational approaches: A review. *Computers and Electronics in Agriculture*, 178, 105802. doi:<https://doi.org/10.1016/j.compag.2020.105802>
- Mishra , S., Sachan, R., & Rajpal, D. (2020). Deep Convolutional Neural Network based Detection System for Real-time Corn Plant Disease Recognition. *Procedia Computer Science*, 167, 2003-2010. doi:<https://doi.org/10.1016/j.procs.2020.03.236>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO). (2022). *El estado mundial de la agricultura y la alimentación 2022. Aprovechar la automatización de la agricultura para*. Roma: Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO).
- Sarijaloo, F. B., Porta, M., Taslimi, B., & Pardalos, P. M. (2021). Yield performance estimation of corn hybrids using machine learning algorithms. , *Artificial Intelligence in Agriculture*, 5, 82-89. doi:<https://doi.org/10.1016/j.aiia.2021.05.001>.
- Secretaría de Agricultura y Desarrollo Rural. (10 de 03 de 2023). *Gobierno de Mexico*. Obtenido de Maíz, Cultivo de México: <https://www.gob.mx/agricultura/articulos/maiz-cultivo-de-mexico#:~:text=Cultivo%20de%20ma%C3%ADz%20en%20M%C3%A9xico,los%2032%20estados%20del%20pa%C3%ADs>.
- Shahhosseini, M., Hu, G., & Archontoulis, S. V. (2020). Forecasting Corn Yield With Machine Learning Ensembles. *Frontiers in Plant Science: Methods*, 11, 1-16. doi:<https://doi.org/10.3389/fpls.2020.01120>
- Tanumihardjo, S. A., McCulley, L., Roh, H., López-Ridaura, S., Palacios-Rojas, N., & Gunaratna, N. S. (2020). Maize agro-food systems to ensure food and nutrition security in reference to the Sustainable Development Goals. *Global Food Security*, 25.
- Varón de Agudelo, F., & Sarria Villa , G. A. (2007). *Enfermedades del maíz y su manejo*. Palmira: Instituto Colombiano Agropecuario.
- Varón de Arguello, F., Rodríguez Chalarca, J., Villalobos Saa, J. C., & Parody Restrepo , J. (2022). *Manual de enfermedades y plagas del maíz*. Ciudad de México: Advanta Seed.
- Venkataraju, A., Arumugam, D., Stepan, C., Kiran, R., & Peters, T. (2023). A review of machine learning techniques for identifying weeds in corn. *Smart Agricultural Technology*.
- Waheed, A., Goyal, M., Gupta, D., Khanna, A., Hassanien, A. E., & Pandey, H. M. (2020). An optimized dense convolutional neural network model for disease recognition and classification in corn leaf. *Computers and Electronics in Agriculture*, 175, 105456. doi:<https://doi.org/10.1016/j.compag.2020.105456>.
- Wang, A., Zhang, W., & Wei, X. (2019). A review on weed detection using ground based machine vision and image processing techniques. *Comput. Electron. Agric*, 226-240. doi:<https://doi.org/10.1016/j.compag.2019.02.005>
- Yamashita, R., Nishio, M., Do, R., & Togashi, K. (2018). Convolutional neural networks: An overview and application in radiology. *Insights Imaging*, 9, 611-629. doi:<https://doi.org/10.1007/s11063-020-10244-5>
- Yin, C., Zeng, T., Zhang , H., Fu, W., Wang, L., & Yao, S. (2022). Maize Small Leaf Spot Classification Based on Improved Deep Convolutional Neural Networks with a Multi-Scale Attention Mechanism. *Agronomy*, 14(2). doi:<https://doi.org/10.3390/agronomy12040906>

- Yu, H., Liu, J., Chen, C., Heidari, A. A., & Zhang, Q. (2021). Corn Leaf Diseases Diagnosis Based on K-Means Clustering and Deep Learning. *IEEE Access*, *9*, 143824-143835. doi:10.1109/ACCESS.2021.3120379
- Zeng, W., Li, H., Hu, G., & Liang, D. (2022). Identification of maize leaf diseases by using the SKPSNet-50 convolutional neural network model. *Sustainable Computing: Informatics and Systems*, *35*, 100695. doi:https://doi.org/10.1016/j.suscom.2022.100695