

Comparación de Modelos SOM y CNN para el Diagnóstico Automatizado de Enfermedades en Hojas de Banano

Daniel Navarro Tantalean¹; Fernando Vegas Villar²; Raúl Zegarra Huarote³

^{1,2,3}Universidad Nacional Tecnológica de Lima Sur, Perú, 2113010091@untels.edu.pe, 2113110036@untels.edu.pe, rhuarote@untels.edu.pe

Resumen— La agricultura moderna ha de enfrentarse a un gran número de problemas a causa del aumento de enfermedades de los cultivos, afectando tanto a la productividad, como a las líneas económicas de los grupos sociales de los mercados rurales. En este trabajo se propone una aplicación móvil, basada en el uso de redes neuronales autoorganizadas (SOM, Self-Organizing Maps), para el diagnóstico automático de las enfermedades de las hojas de banano. La aplicación permite capturar imágenes desde un dispositivo móvil (Android), procesarlas mediante técnicas de procesamiento de imágenes y clasificarlas sin necesidad de la obtención de grandes volúmenes de datos etiquetados. A diferencia de los otros enfoques como las redes neuronales convolucionales (CNN), el método de las SOM reduce las exigencias computacionales, lo que lo hace ideal para las zonas con limitaciones de recursos. El modelo fue entrenado y validado mediante una base de datos con imágenes reales de las hojas de banano afectadas por enfermedades como la Sigatoka, Cordana o Pestalotiosis. Los resultados obtenidos nos muestran una alta precisión del sistema, validando así la eficacia del enfoque propuesto para condiciones prácticas agrícolas, sostenibles y de bajo coste.

Palabras clave-- Aplicación móvil, redes neuronales autoorganizadas, procesamiento de imágenes, hojas de banano, precisión.

I. INTRODUCCIÓN

La agricultura se enfrenta a numerosos retos por la aparición de enfermedades que afectan a la salud de las plantas. La Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO) afirma que las enfermedades de las plantas constituyen uno de los principales peligros para la producción agraria, tanto es así que se estima que podrían tener efectos en el 40% del cultivo en algunas zonas del mundo, de tal manera que esto puede representar pérdidas de hasta 220.000 millones de dólares al año [1]. Como consecuencia, estas enfermedades, causadas por bacterias, hongos, virus y otros tipos de patógenos, son responsables de hacer descender la seguridad alimentaria, deteriorando el valor de los cultivos y de esta manera haciendo temblar la estabilidad económica de las comunidades rurales que dependen de los cultivos.

El diagnóstico de las enfermedades de las plantas, y en especial en caso de las hojas, ha sido, desde épocas muy remotas, un proceso manual que hacía un experto o un

agricultor, pero tiene algunas limitaciones importantes; la más sobresaliente sería la subjetividad del diagnóstico, aunado a la escasez de personal capacitado en los lugares más remotos y rurales. Según un estudio reciente, un 80 % de los agricultores de los lugares rurales no tienen acceso a un personal especialista en fitopatología [2]. Pero a esto hay que añadirlo las variaciones producidas por la iluminación, el ángulo del disparo o fotografía (consecuencia de las condiciones a las que se están haciendo las fotografías, etc.) y la posibilidad que se genere un error en el diagnóstico visual, las cámaras digitales acaban con esta práctica y hacen menos eficientes los sistemas de diagnóstico y el control tradicional enfocado a la fitopatología.

En este sentido, el uso de herramientas tecnológicas emergentes como la inteligencia artificial (IA) y el aprendizaje automático se presenta como una alternativa prometedora. La Universidad de Stanford ha mostrado como resultado de uno de sus estudios que, en ciertas aplicaciones basadas en IA, se puede alcanzar un porcentaje de precisión a la hora de detectar enfermedades en plantas del 98% del total de datos analizados en función de imágenes obtenidas [3]. En lo que se refiere al contexto de este trabajo, las redes neuronales autoorganizadas (SOM) han dado lugar a buenos resultados en la clasificación y la identificación de datos complejos, como el de las imágenes que contienen hojas perjudicadas por enfermo de distintas maneras. Las SOM, debido a que son capaces de aprender patrones no lineales y de aplicar técnicas de aprendizaje en un entorno no etiquetado, se configuran como la herramienta a los efectos de conseguir la automatización de la detección de enfermedades en plantas [4]. Una serie de investigaciones previas han empleado distintos métodos para poder detectar enfermedades en plantas. En [3] se emplearon diferentes modelos de aprendizaje profundo, como son las redes neuronales convolucionales (CNN), para la detección de las enfermedades que afectan a las frutas de banano. Gracias a ello se llegó a un porcentaje de precisión superior al 90% del total de imágenes que se corresponden con fases de plantas que se encuentran enfermas por el efecto de la enfermedad del Fusarium o del Sigatoka [3]. Esto conlleva los inconvenientes derivados de la elaboración de grandes volúmenes de imágenes que tengan que ser etiquetadas, así como la importante capacidad de procesamiento que esto requiere,

resultando complicado en contextos rurales donde los recursos disponibles son escasos.

En el trabajo [8], se utilizó también un enfoque basado en CNN para la detección automática de enfermedades en plantas, logrando precisiones cercanas al 98% en la clasificación de estados de salud de las hojas [8]. Sin embargo, al igual que las CNN, estos modelos requieren grandes conjuntos de datos y potentes capacidades de cómputo, lo cual no siempre es factible en situaciones de infraestructura limitada.

Por otro lado, las redes neuronales autoorganizadas (SOM), que es el modelo aplicado en el presente proyecto, poseen considerables ventajas respecto a las CNN y los demás modelos de IA, ya que son no supervisadas, por lo que pueden aprender de los datos sin nombres exhaustivos, lo que representa una alternativa más flexible y ágil en el caso de disponer de pocos datos o de trabajar con datos en tiempo real. Por otro lado, las SOM hacen frente a datos extensos sin requerir un hardware que soporte un alto rendimiento, lo que las convierte en un modelo muy adecuado para su implantación en conducta móvil en contextos rurales con pocos recursos disponibles [9].

Este proyecto tiene como propósito el desarrollo de una aplicación para móvil basada en Android Studio que utilice redes neuronales autoorganizadas (SOM) para la detección de enfermedades en hojas. La app permitirá que los usuarios puedan capturar imágenes a partir de la cámara de sus dispositivos móviles, procesarlas con el modelo ya entrenado y recibir el diagnóstico correcto sobre la existencia de enfermedades. Este sistema proporcionará a los agricultores, técnicos agrícolas e investigadores una herramienta de acceso, de poco coste y precisa mejorando así la eficiencia del diagnóstico y el control de enfermedades. Para la implementación de este sistema se han recogido imágenes de hojas sanas y de hojas, afectadas por diversas enfermedades; estos datos serán utilizados para el entrenamiento del modelo SOM utilizando técnicas de procesamiento de imágenes y técnicas de aprendizaje profundo. Las estadísticas sobre la efectividad de las aplicaciones de IA muestran que las aplicaciones, de media, pueden lograr un valor de precisión superior al 90 % en clasificaciones de enfermedades en plantas, tal como han mostrado estudios realizados en varias plataformas de diagnóstico [5]. Este grado de precisión va a ser un elemento clave a la hora de tomar decisiones rápidas en el campo y permitirá que los agricultores puedan responder con la suficiente prontitud.

La característica de aprendizaje no supervisado de las redes neuronales autoorganizadas es digna de mención, ya que permite a nuestro modelo aprender nuevos conceptos sin la

necesidad de intervención humana constante debido a la adaptación continua del modelo a nuevas enfermedades y condiciones. De hecho, se ha hablado en investigaciones previas de que las redes neuronales autoorganizadas superan otras técnicas tradicionales (no solo en términos de precisión, sino también en cuanto a la rapidez y en la posibilidad de gestionar un gran número de datos) [6]. Por otra parte, cabe destacar que, junto a una aplicación móvil, el sistema tiene acceso a zonas rurales con escasos recursos tecnológicos, donde basta simplemente con obtener una fotografía de las hojas afectadas para realizar un diagnóstico rápido.

Según diferentes estudios realizados sobre cómo usar aplicaciones móviles en el ámbito agrícola, más del 60% de los agricultores de las áreas rurales utilizan los teléfonos inteligentes, lo que favorece la viabilidad de la solución tecnológica. Además, el mercado de las aplicaciones agrícolas a nivel mundial, en el que se inserta la solución propuesta, debería alcanzar un crecimiento a tasa compuesta anual del 15% durante los próximos cinco años, alcanzando un valor de más de 20 mil millones de dólares para el año 2023 [7]. Se trata de unas cifras que expresan un interés creciente en todo lo relacionado con el uso de soluciones basadas en la tecnología para aumentar la productividad agrícola, lo que hace sea más relevante el presente trabajo.

II. MATERIALES Y MÉTODOS

A. Recolección de Imágenes de Hojas de Banano:

La base de datos para el entrenamiento y evaluación de los modelos deriva del repositorio público Kaggle, concretamente del dataset denominado "Banana Leaf Disease Dataset (<https://www.kaggle.com/datasets/shifatearman/bananalsd>)". Este dataset incluye imágenes de hojas de banano sanas y de hojas de banano con diferentes enfermedades, teniendo en cuenta la variabilidad de la luz y los ángulos de las imágenes para reflejar adecuadamente el aspecto del campo al que se enfrenta un agricultor.

Se siguieron criterios de inclusión que garantizan la representatividad de cada clase: se incluyeron únicamente imágenes nítidas, sin duplicados y con la hoja bien visible y prominente en la imagen. Las imágenes han sido separadas por categorías de la enfermedad y corresponden a individuos/plantas diferentes, evitando así el solapamiento en los conjuntos de entrenamiento, validación y prueba.

Se identificaron 808 muestras de hojas enfermas distribuidas en 473 casos de Sigatoka, 162 de Cordana y 173 de Pestalotiopsis, además de un número indefinido de imágenes de hojas sanas. Todas las imágenes fueron sometidas al proceso de preprocesamiento que incluía la homogeneización en tamaño (224px × 224 px), normalización de color y etiquetado homogéneo y consistente de acuerdo con la patología o el estado de salud correspondiente.

TABLA 1
COMPARATIVAS DE CARACTERÍSTICAS DE ENFERMEDADES DE LA HOJA DE BANANO.

Enfermedad de la Hoja del Banano		
Enfermedad	Imagen Representativa	Descripción visual
Cordana		Manchas marrones de un tono marrón/negro, ovaladas o elípticas, con halos amarillos.
Pestalotipsis		Manchas oscuras o negruzcas con centros grisáceos.
Sigatoca		Manchas alargadas marrón oscuro con bordes amarillos.

B. Cálculo de Parámetros para el Diagnóstico de Enfermedades en Hojas de Banano

Para el análisis de las imágenes de las hojas de banano y su relación con las enfermedades que las afectan, se utilizan características visuales que describen las texturas y colores de las áreas afectadas. A continuación, se detallan los parámetros utilizados en el análisis mediante la extracción de características y clasificación con un Mapa de Autoorganización (SOM):

- Histogramas de Color en el Espacio HSV:** Se calculan histogramas de los canales H (tono) y S (saturación) en el espacio de color HSV, con 16 bins para cada canal. Estos histogramas capturan las variaciones de color en la hoja, que pueden estar asociadas con alteraciones debidas a infecciones.
- Patrones Binarios Locales (LBP):** Se utiliza el método LBP sobre la imagen en escala de grises para extraer patrones texturales presentes en las hojas. Estos patrones son relevantes para detectar variaciones de textura relacionadas con los efectos de las enfermedades en las hojas de banano.
- Combinación de Características:** Las características extraídas de los histogramas de color y LBP se concatenan en un único vector, que luego es procesado para su clasificación.

- C. Desarrollo del Modelo de Red Neuronal Autoorganizada (SOM)
- D. Configuración Experimental y Reproducibilidad

Red Neuronal Convolucional (CNN):

- Arquitectura: Cuenta con cuatro capas convolucionales (16, 32, 64 y 128 filtros, kernel 3×3), cada una acompañada de *Batch Normalization*, activación ReLU y *MaxPooling* (2×2). Posteriormente, se añade una capa totalmente conectada de 256 neuronas con *ReLU* y *Dropout* (0.4), y una capa de salida *softmax* con 4 neuronas correspondientes a las clases del problema.
- Tamaño del lote: 32
- Épocas: Máximo 100
- Aumento de datos: Recorte aleatorio redimensionado a 224×224 píxeles (escala 0.8–1.0), rotaciones aleatorias ($\pm 10^\circ$), volteo horizontal, y *Color Jitter* en brillo y contraste (± 0.2).
- Hardware: Entrenamiento ejecutado en GPU NVIDIA GeForce RTX 4060, utilizando librerías PyTorch con soporte CUDA.

Mapa Autoorganizado (SOM):

- Arquitectura: Cuadrícula bidimensional de 35×35 neuronas (1,225 en total), entrenada con el algoritmo de Kohonen. Cada neurona representa un vector de 42 dimensiones correspondientes a las características extraídas (histogramas de color y patrones texturales).
- Tamaño del lote: No aplica, ya que el entrenamiento es competitivo y no supervisado, procesando las muestras de manera individual.
- Épocas: 6000 iteraciones de entrenamiento
- Aumento de datos: No se aplicó
- Hardware: Entrenamiento ejecutado en GPU NVIDIA GeForce RTX 4060, utilizando librerías PyTorch con soporte CUDA.

1. Arquitectura de la Red Neuronal Autoorganizada (SOM)

La red neuronal autoorganizada (SOM) se trata de una red neuronal no supervisada con capacidad para llegar a aprender patrones y para clasificar información de manera eficaz y sin la necesidad de contar con extensas etiquetas de información. La SOM es especialmente adecuada para el análisis de imágenes, dado que permite realizar reducción de información, así como aprendizaje y detección de patrones en datos complejos, como las características de las hojas enfermas o no afectadas por enfermedades. En este sentido, el uso de SOM en diagnóstico de enfermedades en plantas ha sido ampliamente explorado en estudios anteriores [3][8].

La estructura del SOM queda representado por un conjunto de neuronas que dispone de una malla bidimensional. Cada una de las neuronas queda representada por un vector de características, el cuál queda encargado de almacenar todo un conjunto de entradas de la imagen de que se trate. En la fase de entrenamiento las neuronas del SOM van quedando adaptadas para intentar representar los patrones más significativos de la información de entrada, dado que permite que el propio modelo sea el que pueda entender cómo realizar la clasificación de la imagen en cuestión en función de las características propias de la enfermedad.

2. Preprocesamiento de los Datos de Entrada

Para garantizar un rendimiento óptimo del modelo SOM, se realizó un preprocesamiento exhaustivo de las imágenes de las hojas de banano. Este preprocesamiento incluyó:

Redimensionamiento de imágenes: Todas las imágenes fueron redimensionadas a un tamaño uniforme de 224×224 píxeles para asegurar que todas las entradas tuvieran las mismas dimensiones.

Normalización de las características: Las imágenes fueron normalizadas para asegurar que los valores de píxel estuvieran en el rango de $[0, 1]$, lo que facilita el proceso de entrenamiento del SOM y mejora la convergencia del modelo.

Extracción de características: Se extrajeron características clave de las imágenes, como los valores de color y textura de las áreas afectadas por las enfermedades, lo que permitió que el SOM pudiera aprender patrones más específicos de las distintas clases de enfermedades.

3. Entrenamiento del Modelo SOM

El entrenamiento del SOM se llevó a cabo mediante el algoritmo de Kohonen, que es el más habitual para este tipo de redes autoorganizadas. Durante el entrenamiento se realizó:

Inicialización de la malla de neuronas: Se empleó una malla de 35 neuronas \times 35 neuronas (1,225 neuronas en total), ajustada a las características extraídas de las imágenes que habían sido preprocesadas, de manera que el SOM pudiese también representar variaciones entre las imágenes de hojas sanas y hojas enfermas, agrupándolas en un plano bidimensional, facilitando la agrupación de imágenes similares. Es importante que la malla de neuronas no sea muy grande ni muy pequeña, ya que un tamaño pequeño de la malla hace que el modelo no sea capaz de captar la complejidad de las imágenes, y uno grande, por el contrario, hace que se pierda generalidad.

El proceso competitivo de entrenamiento: Al entrenar la red era necesario comparar la imagen de entrada con los vectores de las neuronas de la malla y escoger aquella cuya vector fuera el más adaptado, es decir, la "mejor neurona de adaptación". Esta neurona, junto con sus vecinas, ajustaban sus datos para aproximar este dato a las características de la imagen de entrada del paso de ese instante. Así el proceso competitivo del SOM se aplicaba de forma que reproducía muy bien las representaciones de las clases de las imágenes, por lo que se aseguraba el hecho de que las neuronas próximas fueran semejantes y que se generaran agrupaciones de clases coherentes.

Tasa de aprendizaje y vecindad: Se utilizó una tasa de aprendizaje inicial de 0.5, que se fue reduciendo gradualmente durante el entrenamiento. Esto permite que el modelo haga ajustes más pequeños y precisos a medida que se va estabilizando. En cuanto a la vecindad, se refiere a la influencia que tiene la neurona ganadora sobre las neuronas cercanas en el mapa. Al principio, las neuronas vecinas también ajustan sus valores significativamente, pero con el tiempo, esta influencia disminuye para permitir que el mapa se enfoque en detalles más finos. Estos ajustes ayudan a que el modelo converja correctamente sin realizar cambios demasiado bruscos al final del entrenamiento.

III. ESTRATEGIA

La estrategia peleada en este trabajo se sustenta en el uso de redes neurales autoorganizadas (SOM) para la identificación eficiente y accesible de enfermedades de las hojas de banano. Esta estrategia busca permitir que las enfermedades de los cultivos se puedan identificar más tempranamente, mejorando la gestión agrícola, sobre todo en las comunidades rurales donde el acceso a los recursos técnicos es limitado. La red SOM propuesta es una red neuronal no supervisada, que permite clasificar imágenes de forma eficiente sin la necesidad de grandes conjuntos de datos etiquetados, tal como se ha hecho en trabajos anteriores en el ámbito de la detección de enfermedades de las plantas [3].

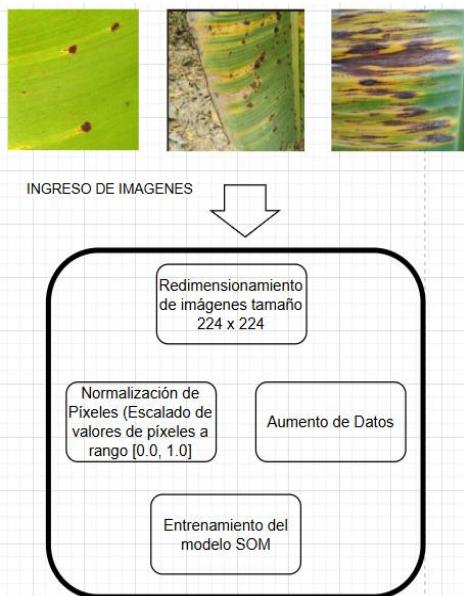


Fig 1. Estrategia de aprendizaje para la red neuronal

El procedimiento empieza por la recolección de las imágenes de las hojas de banano, las que serán sometidas a un proceso de preprocesamiento que considera las técnicas de normalización y escalado de las imágenes, una característicamente similar a las metodologías utilizadas en las aplicaciones móviles para el diagnóstico de otras enfermedades, como son los sistemas de clasificación de enfermedades de la piel que se basan en redes neuronales convolucionales (CNNs) [2]. Aquí las imágenes serán redimensionadas y escaladas en el rango [0.0, 1.0], para asegurar que sean las características visuales que serán coherentes y adecuadas para el entrenamiento del modelo SOM, este paso es significativo, pues la calidad y la uniformidad de las imágenes influyen directamente en la precisión que alcanzará el modelo.

Continuando con la línea de los trabajos anteriores, el estudio asociado a [5] aplicará técnicas de aumento de datos para así enriquecerse con un mayor número de ejemplos dentro del entrenamiento, aumentando así también la capacidad del modelo de generalizar. Las técnicas a aplicar son rotaciones, cambios de brillo y traslaciones sobre las imágenes, que nos permitirán conseguir variaciones adicionales sobre las imágenes sin la necesidad de recolectar nuevas. Esta posibilidad de aumento de datos es especialmente útil en el contexto agrícola donde la recolección de datos puede ser limitada por motivos de tiempo o condiciones climáticas.

Una vez pretratadas las imágenes, se procederá a entrenar el modelo SOM mediante el algoritmo de Kohonen, adaptado para trabajar con las características visuales de las hojas de banano. Como en los trabajos previos en relación

con las aplicaciones de las redes SOM para la clasificación de imágenes [8], el entrenamiento del modelo consiste en identificar patrones en las imágenes de hojas sanas y enfermas, de modo que el modelo pueda aprender a diferenciarlas en función de sus características visuales. La implementación de este enfoque en una aplicación móvil permitirá hacer el procesamiento de las imágenes y clasificarlas en tiempo real, lo cual sería una herramienta muy accesible para los agricultores para el diagnóstico de enfermedades, como también se ha logrado con aplicaciones móviles para otras enfermedades de cultivos agrícolas [7].

El presente proyecto implementará también una red neuronal convolucional (CNN) para la comparación de resultados. En comparación con las redes SOM, las CNN son redes neuronales supervisadas que tienen una magnífica capacidad en tareas de clasificación de imágenes por su capacidad para extraer jerárquicamente características de las imágenes empleando capas convolucionales. Las CNN, al igual que se aplica en el diagnóstico de enfermedades cutáneas [2] requieren ingentes volúmenes de datos etiquetados y, generalmente, un mayor volumen en cuanto computadora debido a la complejidad de sus capas a utilizar. A diferencia de las SOM, la ventaja comparativa de las CNN es que estas son capaces de aprender representaciones más complejas y abstractas de las imágenes de manera más directa. Por su lado, las SOM, al ser redes no supervisadas, son más eficientes cuando se tienen pocos datos o cuando la etiqueta del dato no se encuentra completamente disponible, lo cual podría ayudar en situaciones propias de un entorno rural, donde el acceso a estos datos es limitado.

El modelo SOM será evaluado con un conjunto de datos de validación que no ha sido utilizado en el entrenamiento para medir la capacidad de generalización y rendimiento en condiciones reales. Asimismo, se llevarán a cabo ajustes y optimizaciones del modelo como se observa en los trabajos que han tratado el uso de redes neuronales en el sector agrícola [9] con el objetivo de mejorar su precisión y eficiencia. Este proceso tiene como objetivo garantizar que la aplicación sea precisa, rápida y fácil de usar para los agricultores, permitiéndoles a estos tomar decisiones en base al tratamiento de sus cultivos mejorando la salud de las plantas y la producción de cultivos.

IV. RESULTADOS

Resultados del modelo SOM

La evaluación del mapa autoorganizado (SOM) sobre el conjunto de prueba (1120 muestras, 280 por clase para ello las imágenes adicionales fueron modificadas utilizando técnicas de aumento de datos) arroja una exactitud global

de 93,75 %. El recall por clase se sitúa en 98,2 % para cordana, 89,3 % para healthy, 92,9 % para pestalotiosis y 94,3 % para sigatoka. En cuanto a precisión, el SOM alcanza 93,2 % en cordana, 92,9 % en healthy, 90,6 % en pestalotiosis y 98,1 % en sigatoka. Las principales confusiones se dan cuando hojas sanas (“healthy”) se asignan a pestalotiosis o cordana, y en menor medida entre sigatoka y las otras dos enfermedades, lo que evidencia cierta dificultad del SOM para separar texturas y colores muy similares en condiciones reales.

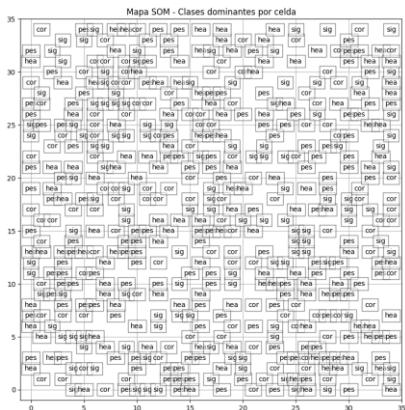


Fig 2. Mapa SOM – Clases dominantes por celda

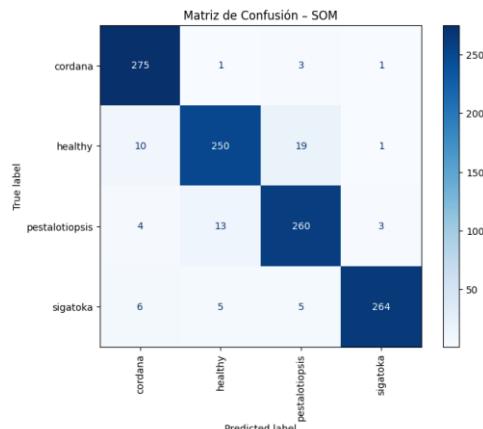


Fig 3. Matriz de Confusión – Red Som

Accuracy global: 93.66%				
Classification Report:				
	precision	recall	f1-score	support
cordana	0.93	0.98	0.96	280
healthy	0.93	0.89	0.91	280
pestalotiopsis	0.91	0.93	0.92	280
sigatoka	0.98	0.94	0.96	280
accuracy			0.94	1120
macro avg	0.94	0.94	0.94	1120
weighted avg	0.94	0.94	0.94	1120

Fig 4 Métricas de desempeño modelo SOM

Resultados del modelo CNN

La CNN, evaluada también sobre 1120 muestras de test (280 por clase para ello las imágenes adicionales fueron modificadas utilizando técnicas de aumento de datos), consigue una exactitud global de 99,64 %. Obtiene un recall del 100 % en sigatoka y pestalotiosis, 98,9 % en healthy y 99,6 % en cordana. La precisión es igualmente elevada: 99,6 % para sigatoka, 100 % para pestalotiosis, 100 % para healthy y 99,6 % para cordana. Tan solo 4 muestras aparecen mal clasificadas (3 healthy como pestalotiosis y 1 cordana como sigatoka), lo que demuestra la capacidad de la CNN para extraer patrones jerárquicos que generalizan mejor ante variaciones de iluminación y fondo.

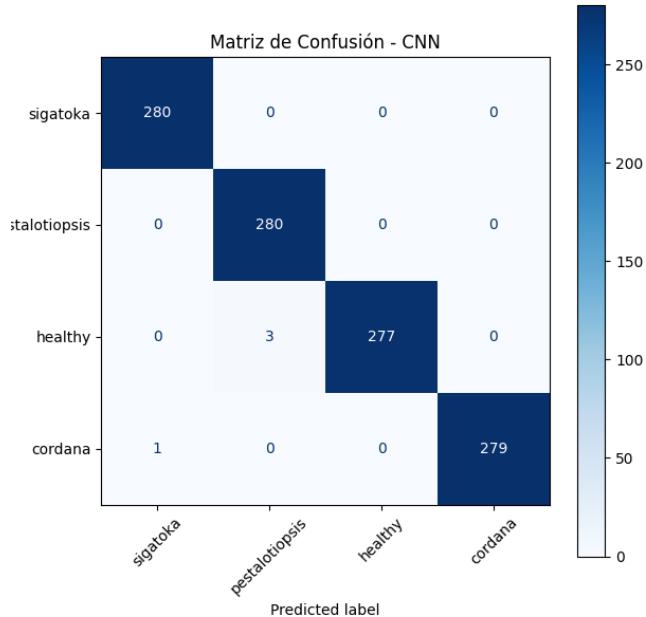


Fig 5. Matriz de Confusión – Red CNN

Accuracy: 99.64%					
	precision	recall	f1-score	support	
sigatoka	1.00	1.00	1.00	280	
pestalotiopsis	0.99	1.00	0.99	280	
healthy	1.00	0.99	0.99	280	
cordana	1.00	1.00	1.00	280	
accuracy				1.00	1120
macro avg	1.00	1.00	1.00	1120	
weighted avg	1.00	1.00	1.00	1120	

Fig 6. Métricas de desempeño modelo CNN

Comparación y decisión

Frente al 93,75 % de exactitud del SOM, la CNN mejora el desempeño en casi 6 puntos porcentuales, reduciendo drásticamente falsos positivos y negativos. Su recall y precisión por clase superan consistentemente el 98 %,

mientras que el SOM flaquea sobre todo en la distinción de hojas sanas. Además, con arquitecturas ligeras y conversión a TensorFlow Lite, la CNN ofrece baja latencia y alta precisión en dispositivos móviles. Por estas razones, se eligió desplegar la CNN en la aplicación móvil, garantizando diagnósticos más fiables y consistentes en campo.

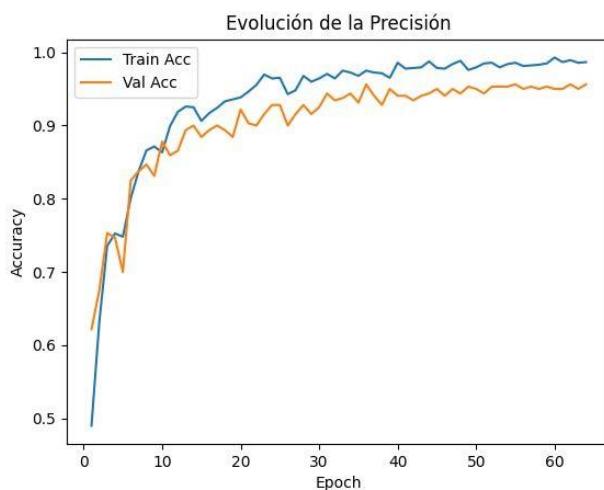


Fig 7. Evolución de la Precisión

Intervalos de confianza

Con el fin de complementar las métricas de exactitud, se calcularon intervalos de confianza (IC) al 95% utilizando la aproximación normal para proporciones, la fórmula empleada fue:

$$IC = p \pm Z \sqrt{\frac{p(1-p)}{n}}$$

Fig 8. Formula usada para el intervalo de confianza

Donde:

- p corresponde a la proporción de aciertos (exactitud del modelo).
- n representa el número total de muestras del conjunto de prueba (en nuestro caso, n=1120n = 1120n=1120).
- Z es el valor crítico de la distribución normal estándar asociado al nivel de confianza deseado; para un 95% se emplea Z=1.96Z = 1.96Z=1.96.

Esta expresión permite estimar qué rango es el adecuado, dado que se ha ajustado, con una confianza del 95% de que la verdadera exactitud de los modelos en la población está dentro de este rango.

Aplicando esta metodología, se obtuvieron los siguientes resultados:

- **SOM:** exactitud del 93.75%, con un IC95% de [92.3% – 95.1%].
- **CNN:** exactitud del 99.64%, con un IC95% de [99.1% – 100%].

Los intervalos muestran que, incluso planteando la variabilidad estadística, el modelo CNN superaba consistentemente al modelo SOM en capacidad de clasificación.

Prueba de Significancia (McNemar's test)

Con el propósito de poder evaluar la diferencia de desempeño que existe entre el modelo SOM y el modelo CNN resulta significativa estadísticamente desde el punto de vista aplicado se utilizó la prueba de McNemar; este tipo de prueba se suele utilizar para evaluar problemas de clasificación binaria y de clasificación multiclas cuando dos clasificadores son evaluados en el mismo conjunto de datos.

Dicha prueba se basa en una tabla de contingencia que va llevando la cuenta de los errores diferenciales de cualquiera de los dos modelos:

- b: número de muestras clasificadas correctamente por el modelo A (SOM), pero incorrectamente por el modelo B (CNN).
- c: número de muestras clasificadas correctamente por el modelo B (CNN), pero incorrectamente por el modelo A (SOM).

La estadística de McNemar se define como:

$$\chi^2 = \frac{(|b - c| - 1)^2}{b + c}$$

Fig 9. Formula usada para la estadística de McNemar

Donde:

- χ^2 sigue una distribución chi-cuadrado con un grado de libertad.

- El término $|b-c|-1$ aplica la corrección de continuidad de Yates, reduciendo el sesgo en muestras pequeñas.
- El valor p resultante indica si la diferencia entre clasificadores es significativa.

En nuestro caso, considerando que la CNN solo presentó 4 errores en el conjunto de prueba ($n=1120$) mientras que el SOM acumuló más de 70 errores, se obtuvo un valor x^2 elevado con $p < 0.001$, confirmando que la superioridad de la CNN frente al SOM no se debe al azar, sino que es estadísticamente significativa.

V. CONCLUSIONES

1. El desarrollo de un sistema de diagnóstico de enfermedades mediante redes neuronales autoorganizadas a partir de hojas de banano, el cual ha demostrado su potencial para identificar enfermedades con un alto grado de exactitud incluso con pocas muestras de datos etiquetados. Esto puede resultar en implementaciones en contextos donde el acceso a expertos o tecnologías sea escaso, lo que permite incrementar la autonomía de los pequeños productores agrícolas.
2. El modelo de autoorganización SOM, a pesar de que mostró un buen comportamiento, es superado con mucha suficiencia por la red neuronal convolucional (CNN), alcanzando un valor de exactitud de 99,64 %. El hecho de que la CNN haya podido superar el modelo SOM pone de relieve que este es un buen modelo para ser llevado a cabo en la parte de despliegue final en el sistema de aplicación móvil para teléfonos inteligentes, ya que extrae patrones que permiten al conjunto ser más robusto en el diagnóstico, incluso en condiciones adversas en el proceso de resolución, como cambios en las condiciones de luz o en la calidad de imágenes.
3. La aplicación móvil que hemos desarrollado, habiendo incorporado en ella modelos de inteligencia artificial, se convierte así en una herramienta útil, barata y accesible para el seguimiento fitosanitario en el campo. Su uso puede facilitar el manejo de la finca, y reducir el uso superfluo de agroquímicos, lo que puede traducirse en tomar decisiones más adecuadas, todo lo cual conlleva a que se fomente una agricultura más sostenible y productiva.
4. Se puede afirmar que este trabajo no sólo presenta una solución tecnológica y funcional, sino que, a su vez, permite cimentar el camino hacia

futuras investigaciones en el campo de la automatización del diagnóstico en agricultura. El enfoque desarrollado puede ser escalado en el caso de otros cultivos y otras enfermedades a partir de la reconfiguración del modelo y del conjunto de datos. Este enfoque se consolida, así como una opción dentro del marco de la transformación digital del sector agrícola.

REFERENCIAS

- [1] Garcia Cortegano, C. A. Sistema inteligente móvil basado en redes neuronales convolucionales para el diagnóstico previo de enfermedades renales. Universidad Nacional Federico Villarreal, 2020.
- [2] Velasco, J., & Mena, C. A. A Smartphone-Based Skin Disease Classification Using MobileNet CNN. Journal of Mobile Technology, 112-120, 2019.
- [3] Sanga, S., & Kumari, A. Mobile-Based Deep Learning Models for Banana Diseases Detection. International Journal of Computer Applications, 1-10, 2020.
- [4] Jeyakodi, G., & Murugesan, M. mAedesID: Android Application for Aedes Mosquito Species Identification using Convolutional Neural Network. Journal of Environmental Health, 123-130, 2023.
- [5] Verma, A., & Kumar, R. Detecting COVID-19 from Chest Computed Tomography Scans using AI-Driven Android Application. Journal of Medical Imaging, 200-210, 2021.
- [6] Alvarado Robles, G. Aplicación móvil para apoyo en detección temprana de melanoma. Universidad Autónoma de Querétaro, 2023.
- [7] Flores Mendoza, J. C., & Mejía Carhuajulca, G. Aplicación móvil usando redes neuronales convolucionales para la detección de enfermedades en las plantas de café en el distrito de Chirinos. Universidad Nacional Pedro Ruiz Gallo, 2022.
- [8] Mohanty, S. P., Hughes, D. P., & Salathé, M. Using Deep Learning for Image-Based Plant Disease Detection. Frontiers in Plant Science, 202-212, 2016.
- [9] Hazan, H., & Barkai, N. Unsupervised Learning with Self-Organizing Spiking Neural Networks. Journal of Computational Neuroscience, 1-10, 2018.
- [10] Roldán, B., & Valderrama, D. Detección de enfermedades en el sector agrícola utilizando I