



RESEARCH ARTICLE

Convolutional neural networks ResNet-50 for weevil detection in corn kernels

Redes neuronales convolucionales ResNet-50 para la detección de gorgojo en granos de maíz

Iván Analuisa-Aroca¹, * ; Arnaldo Vergara-Romero¹ ; Iris Betzaida Pérez Almeida¹ 

¹ Universidad ECOTEC, km 13.5 Samborondón, Samborondón, EC092302, Ecuador.

* Corresponding author: ivan.analuisa@utm.edu.ec (I. Analuisa-Aroca).

Received: 13 November 2022. Accepted: 25 July 2023. Published: 18 September 2023.

Abstract

The article explores the use of convolutional neural networks, specifically ResNet-50, to detect weevils in corn kernels. Weevils are a major pest of stored maize and can cause significant yield and quality losses. The study found that the ResNet-50 model was able to distinguish with high precision between weevil-infested corn kernels and healthy kernels, achieving values of 0.9464 for precision, 0.9310 for sensitivity, 0.9630 for specificity, 0.9469 for quality index, 0.9470 for the area under the curve (AUC) and 0.9474 for the F-score. The model was able to recognize nine out of ten weevil-free corn kernels using a minimal number of training samples. These results demonstrate the efficiency of the model in the accurate detection of weevil infestation in maize grains. The model's ability to accurately identify weevil-affected grains is critical to taking rapid action to control the spread of the pest, which can prevent significant economic losses and preserve the quality of stored corn. Research suggests that the use of ResNet-50 offers an efficient and low-cost solution for the early detection of weevil infestation in corn kernels. These models can quickly process large amounts of imaging data and perform accurate analysis, making it easy to identify affected grains.

Keywords: Weevil; corn; convolutional neural networks; Ecuador.

Resumen

El artículo explora el uso de redes neuronales convolucionales, específicamente ResNet-50, para detectar gorgojos en granos de maíz. Los gorgojos son una plaga importante en el maíz almacenado y pueden causar pérdidas significativas en rendimiento y calidad. El estudio encontró que el modelo ResNet-50 fue capaz de distinguir con alta precisión entre granos de maíz infestados por gorgojos y granos sanos, logrando valores de 0.9464 para precisión, 0.9310 para sensibilidad, 0.9630 para especificidad, 0.9469 para el índice de calidad, 0.9470 para el área bajo la curva (AUC) y 0.9474 para el F-score. El modelo fue capaz de reconocer nueve de cada diez granos de maíz libres de gorgojos utilizando un número mínimo de muestras de entrenamiento. Estos resultados demuestran la eficacia del modelo en la detección precisa de la infestación por gorgojos en los granos de maíz. La capacidad del modelo para identificar con precisión los granos afectados por gorgojos es crucial para tomar medidas rápidas y controlar la propagación de la plaga, lo que puede prevenir pérdidas económicas considerables y preservar la calidad del maíz almacenado. La investigación sugiere que el uso de ResNet-50, ofrece una solución eficiente y de bajo costo para la detección temprana de la infestación por gorgojos en los granos de maíz. Estos modelos pueden procesar rápidamente grandes cantidades de datos de imágenes y realizar análisis precisos, lo que facilita la identificación de granos afectados.

Palabras clave: Gorgojo; maíz; redes neuronales convolucionales; Ecuador.

DOI: <https://doi.org/10.17268/sci.agropecu.2023.034>

Cite this article:

Analuisa-Aroca, I., Vergara-Romero, A., & Pérez Almeida, I. B. (2023). Redes neuronales convolucionales ResNet-50 para la detección de gorgojo en granos de maíz. *Scientia Agropecuaria*, 14(3), 385-394.

1. Introducción

Los Objetivos de Desarrollo Sostenible (ODS), específicamente el ODS 1 para erradicar la pobreza y el ODS 2 para acabar con el hambre, requieren un aumento significativo en la producción agrícola a nivel mundial. Según la **FAO (2017)**, para cubrir la demanda en 2050 se estima que la agricultura tendrá que producir casi un 50% más de alimentos,

forraje y biocombustible de los que producía en 2012. Sin embargo, este aumento en la producción se ve desafiado por el crecimiento de la población mundial y el cambio climático.

El cultivo de maíz, siendo uno de los granos más cultivados en el mundo, se ve especialmente afectado por estos desafíos. Para desarrollar variedades de maíz resistentes a las plagas y a las

condiciones de almacenamiento, se requieren nuevas tendencias en la investigación agrícola (Altuntaş et al., 2019). Actualmente, se cultivan alrededor de 183.73 millones de hectáreas de maíz en todo el mundo, siendo un cultivo base para el consumo humano en América y fundamental para la seguridad alimentaria global (Mamoon-Ur-rashid et al., 2021).

El gorgojo del maíz - SZM (*Sitophilus zeamais* Motschulsky, Coleoptera, Curculionidae), **Figura 1**, es una plaga ampliamente distribuida en todo el mundo (Stuhl, 2019). Esta plaga representa una de las principales amenazas para el grano de maíz almacenado y otros cereales (Bohinc et al., 2020), causando pérdidas significativas tanto en calidad como en cantidad del grano. Las pérdidas ocurren durante el cultivo y el almacenamiento, ya que el insecto se encuentra presente en ambas etapas (Rau et al., 2021). Además, la presencia del SZM puede llevar a la contaminación del maíz por hongos del género *Aspergillus*, *Penicillium* y *Fusarium*, lo que resulta en la producción de aflatoxinas, un problema grave para la seguridad alimentaria (de Carvalho et al., 2019). Los pequeños agricultores y vendedores minoristas, que utilizan estructuras de almacenamiento menos adecuadas, son especialmente vulnerables al ataque del SZM (Ileke et al., 2020). Las larvas del gorgojo se desarrollan dentro de los granos, lo que reduce su capacidad de germinación (Ngom et al., 2021). Por lo tanto, la presencia del SZM y sus efectos en el grano de maíz tienen un impacto directo en la seguridad alimentaria y el cumplimiento de las normas sanitarias.



Figura 1: El gorgojo del maíz (*Sitophilus zeamais* Motschulsky, Coleoptera, Curculionidae)-SZM. (Alcheton, 2022).

El crecimiento de la población mundial junto al cambio climático generan nuevas tendencias para desarrollar variedades de maíz, resistentes a las plagas y condiciones de almacenamiento (Altuntaş,

Cömert & Kocamaz, 2019). En el cultivo de maíz existen cerca de 183,73 millones de hectáreas cultivadas en todo el mundo (Peschiutta et al., 2019). En América, el maíz es un cultivo base para el consumo humano, siendo uno de los granos más cultivados en el mundo.

El maíz es un cereal de vital importancia en Ecuador, ocupando el tercer lugar después del trigo y el arroz. En los últimos años, la producción de maíz en Ecuador ha experimentado un crecimiento considerable, con un aumento de 1358,63 toneladas (miles) y un rendimiento de 5,57 toneladas por hectárea (Ministerio de Agricultura y Ganadería, 2019). El maíz duro amarillo es cultivado principalmente en la región occidental de Ecuador en pequeñas extensiones. Sin embargo, la producción interna de maíz no es suficiente para satisfacer la demanda, lo que lleva a la importación de grandes cantidades de maíz (67,20 toneladas en miles) con una tendencia decreciente. El almacenamiento del maíz en Ecuador presenta desafíos debido a los procesos de cosecha, secado y almacenamiento, que favorecen la acumulación de impurezas, defectos en el grano y la exposición a plagas de insectos. Estos desafíos son evidentes en todos los estratos de producción y almacenamiento del maíz, y están influenciados por factores regionales, climáticos y económicos (Stathers et al., 2020).

En el sector agrícola, la adopción de técnicas de aprendizaje automático e inteligencia artificial, como el aprendizaje profundo y las redes neuronales convolucionales, ha demostrado ser de gran importancia para mejorar el rendimiento del maíz y abordar problemas como la detección de enfermedades y plagas (Waheed et al., 2020; Yang et al., 2021; Zhang et al., 2020). Estas técnicas permiten el reconocimiento de patrones en imágenes, lo que resulta útil para identificar plagas como el SZM en los granos de maíz (An et al., 2019). Con respecto a las normas sanitarias el sector agrícola está adoptando y retroalimentándose del aprendizaje de máquinas con la inteligencia artificial en todas las áreas incluidas la detección de enfermedades, diagnóstico de plagas entre otras (Waheed et al., 2020; Yang et al., 2021) de gran importancia para incrementar el rendimiento del maíz (Zhang et al., 2020), en la **Figura 2**, se observa la diferencia visual entre un grano afectado por SZM con deformaciones y un grano sano. La inspección es una actividad que requiere tiempo en el dominio de la agroindustria (Ni et al., 2019). El Deep learning es un subconjunto del Machine Learning, simulando un sistema de redes artificiales de neuronas dentro del software para el análisis de datos (Fan et al., 2021), el cual inicia con una idea

de aprendizaje desde el ejemplo, y le enseña al ordenador una serie de reglas para solventar un problema (Sibiya & Sumbwanyambe, 2021). Se anexan un conjunto de ejemplos a evaluar y un grupo de instrucciones para modificar el modelo cuando se produzcan errores, el sistema es capaz de extraer patrones (Ni et al., 2019).

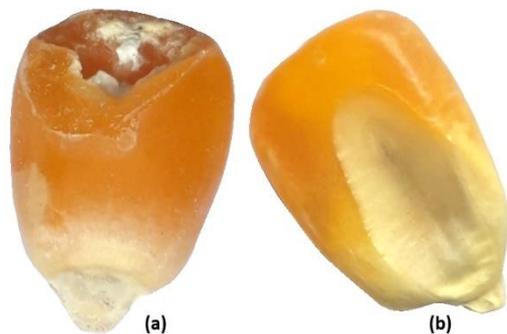


Figura 2. Clasificación visual del grano de maíz: (a) con SZM y (b) sano.

Las redes neuronales convolucionales (Convolutional Neural Network, CNN siglas en inglés) aprenden la detección de características en el plano XY de la característica de entrada (mapas, imágenes) (Srivastava et al., 2014; Xu et al., 2021). En la actualidad se han aplicado métodos de aprendizaje clasificatorio para resolver problemas de agrupación, problemas de calidad, medicina, etcétera. Las CNN, dominan los modelos de aprendizaje computarizado (da Silva et al., 2021). Los modelos predictivos tienen características diferenciales determinados por los datos, elección de modelos de predicción (Zhang et al., 2018; Javanmardi et al., 2021). La principal ventaja de las redes CNN es la de extraer diferentes niveles de características de las imágenes (Abiyev & Ma'aitah, 2018), su arquitectura para redes no entrenadas y pre-entrenadas permiten detectar un objetivo (Basir et al., 2021), a partir de un banco de imágenes, se clasifica y valora según el rendimiento acorde a la exactitud de la clasificación (Muhaisin & Rahman, 2019). El aprendizaje multicapa, entre otras razones ayuda a las redes neuronales tengan éxito (Nurma Yulita et al., 2020). Las CNN alcanzan una gran precisión en el procesamiento de imágenes, en la mayoría de los problemas en los que se ha utilizado (Kamilaris & Prenafeta, 2018; White, 2018).

Según el Ministerio de Agricultura y Ganadería (MAG, 2019), se acepta en el mercado local un 13% de humedad y el 1% con algún nivel de impurezas, defectos en la forma de presentación del grano o semilla del maíz producido. La clasificación de la semilla es de importancia para los agricultores y comerciantes para mantener el rendimiento en el

cultivo, aumentar la producción y las ganancias (Javanmardi et al., 2021). No existe información actualizada en relación de las ventas relacionadas con la calidad del maíz vendido en los mercados locales de Ecuador. En este estudio proporcionamos información sobre la presentación del grano y la calidad fitosanitaria del maíz, basamos el estudio en las imágenes de granos provenientes de locales minoristas del mercado de maíz. El resultado podría integrarse a herramientas para la toma de decisiones especialmente en el almacenamiento. Se plantea la hipótesis desde un enfoque de ayuda a los agricultores para modificar las prácticas de almacenamiento del grano, minimizar los costos y maximizar rendimientos. Así, existe la necesidad de alternativas para superar las dificultades de almacenamiento del grano de maíz, y la detección temprana y preservación de las plagas como el SZM. El objetivo del presente estudio fue usar las redes neuronales convolucionales Resnet-50 para la detección temprana del agente causal de plagas utilizando fotografías de granos de maíz obtenidas de locales comerciales de comerciantes minoristas.

2. Metodología

2.1. Colección de datos

Se requiere un conjunto de datos adecuados en todos los estadios de la investigación, el reconocimiento clave de objetos, desde la fase inicial del proceso de entrenamiento hasta la fase de evaluación es fundamental el reconocimiento para un mejor rendimiento de los algoritmos (Zhang et al., 2018). Dentro del método de identificación de enfermedades del grano de maíz considero: la toma de datos de la muestra, clasificación del grano, selección de imágenes, establecimiento del modelo y resultados (Zhang et al., 2018). Los expertos clasificaron los núcleos, se separaron manualmente en conjuntos de datos; lo siguiente fue la prueba de análisis visual separando defectuosos y en buen estado (Ni et al., 2019). Además, de las características fenotípicas de bajo nivel (color, morfología, textura) como características de alto nivel (extraídas por CNN) (Javanmardi et al., 2021).

Los datos utilizados, provienen de diferentes localidades de la provincia de Manabí-Ecuador. Un total de 1380 imágenes fueron recolectadas, las mismas fueron filtradas para ubicar la presencia o ausencia del agente causal o agente externo. El muestreo de campo se realizó entre los meses de febrero y marzo del 2022 como se muestra en la **Tabla 1**, las referencias para la toma de muestras.

Tabla 1
Toma de muestras de los principales cantones de Manabí

Cantón de Manabí	Total observaciones	Lugares de ventas	Sector	
			Urbano	Rural
Portoviejo	285	25	14	11
Rocafuerte	185	18	10	8
Sucre	135	16	10	6
24 de Mayo	115	12	6	6
Jipijapa	145	18	11	7
Chone	140	21	15	6
Tosagua	108	18	12	6
Santa Ana	125	19	14	5
Paján	142	17	11	6
Total	1380	164	103	61

El análisis del grado de deformidades se realizó midiendo la densidad de granos con deformaciones y la calidad del grano de maíz de la siguiente manera: 1. Se usó un frasco para recolectar muestras de maíz de la parte superior, media y baja de los contenedores de almacenamiento; 2. Posteriormente, se mezclaron completamente, se guardaron y etiquetaron 500 gramos para su análisis; 3. Las impurezas, granos quebrados o con defectos se separaron y pesaron para determinar un comparable proporcional en relación con el peso de la muestra base (Baoua et al., 2014); 4. Para el cálculo de granos con deformaciones se utilizó la siguiente ecuación:

$$\frac{\text{Contenido de granos con deformaciones} = \text{Peso de los granos con deformaciones}}{\text{Peso total de la muestra}} * 100 \tag{1}$$

Se utilizó un umbral para separar las muestras de campo en dos clases: (1) grano integral de muestras iguales o superiores al promedio; (0) granos contaminados que comprende todas las muestras por debajo del límite (Camardo et al., 2021). Dentro de la diferenciación las características básicas, mejoran la clasificación en tanto las características abstractas contribuyen a la segmentación y optimizan la transformación (Li et al., 2021).

2.2. Redes Neuronales convolucionales CNN

El modelo CNN consiste en una arquitectura de aprendizaje profundo conformado de una sucesión de capas, como agrupamiento, convolución,

abandono y capas interconectadas que tienen diversas tareas en la arquitectura. La capa base en esta arquitectura consiste en capas de convolución que realizan las características discriminativas locales al conectar cada nodo a un subconjunto de neuronas conectadas con los canales de imagen de entrada (Altuntaş et al., 2019). La conexión en la compartición en las redes convolucionales en búsqueda de la característica discriminatoria en cada conjunto de datos explica un núcleo de convolución (Sibiya & Sumbwanyambe, 2019).

Los modelos ResNet50 (“Res” = Residual, “Net” = Network y 50 capas), se implementaron dentro de la biblioteca de los módulos de Google Colab. En el método propuesto de investigación se utilizó la cámara digital de un celular inteligente.

2.3. Validación de la red

Como en Camardo et al. (2021), el conjunto de datos originales se divide en subconjuntos de datos, de forma aleatorio en base a la proporción de muestras contaminadas frente a las no contaminadas. El primer subconjunto de fotografías 70% utilizadas para el entrenamiento, 15% se utilizó para la validación cruzada y 15% para el test. Dentro del primer grupo, el subgrupo en este trabajo representa el 50% del conjunto de datos para una mayor validación del modelo

2.4. Modelos predictivos

2.4.1. Proceso de las redes neuronales convolucionales CNN (Figura 3).

a. Convolución

Es la operación más importante en las CNN, el pronóstico de la imagen bidimensional se asigna la ventana de convolución deslizante continua, consiste en la suma de productos (Michelucci, 2018). Cada mapa de características está compilada por características de entradas múltiples en las gráficas (Goodfellow et al., 2017). La ecuación de convolución se expresa (2):

$$h_{ic} = (W_i^K * f)(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s, t) f(x + s, y + t) \tag{2}$$

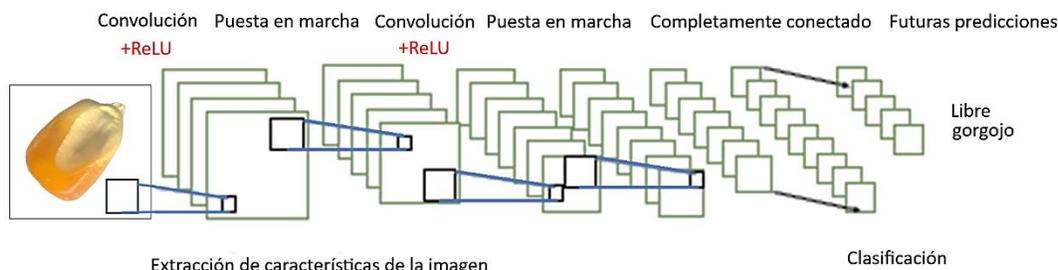


Figura 3. Resumen del Procesamiento de la red neuronal convolucional.

Donde \star representa la operación de convolución, W_i es el filtro o kernel, $f(x, y)$ es la región de la imagen donde se realiza la operación de convolución, K es el número de núcleos de convolución de la capa, s el desplazamiento horizontal y t el desplazamiento vertical. Cada Kernel W_i^K , es un M x M x N siendo M el tamaño de la ventana, N el número de canales de entrada (Wang, Sun & Wang, 2017).

b. Función de Activación

Función no lineal no saturada que puede recibir señales simulando neuronas cerebrales (Zhang et al., 2018).

c. Pooling

A medida que se incrementa el número de capas convolucionales, se incrementan los parámetros de forma exponencial. Esta agrupación puede reducir el número de parámetros de la red. En este proceso se calcula las características estadísticas por región para representar la región (average) y todas sus características (Bisong, 2019).

d. Abandono

Srivastava et al. (2014) hace referencia la eliminación o abandono de muestras de entrenamiento en redes neuronales al evitar las sinergias de ciertas características.

2.4.2. Transferencia de aprendizaje y ajuste de la red neuronal convolucional

- Inicia con el aprendizaje de características de la imagen posterior al aplanamiento del volumen (Flatten)
- La red neuronal establece conexiones entre todas las activaciones de las capas previas, usando los filtros. El valor de ReLU devuelve los valores positivos.
- Actualización constante mediante Backpropagation (Mi et al., 2021).
- Los porcentajes probabilísticos generan las predicciones.

De la matriz de confusión para la clasificación binaria se obtiene la forma mostrada en la **Tabla 2**.

Para demostrar de manera efectiva las ventajas del rendimiento del modelo sobre imágenes de grano de maíz, se consideró 6 métricas para ser calculadas: precisión (Acc), sensibilidad (Se), especificidad (Sp), índice de calidad (QI), F1-score y AUC en escalas de 0 a 1. Cuanto mayor sea el valor de precisión, mejor será el rendimiento del modelo. Sin embargo, este valor puede no ser significativo o no confiable, por lo que se usa junto con otras métricas de rendimiento (como puntuación F1), (Xu et al., 2021) (**Tabla 3**).

Tabla 2
Matriz de confusión de la red neuronal

Matriz de Confusión		Predicción		Resultados
		Positivos +R	Negativos -R	
Observación	Positivos +P	Verdaderos Positivos (VP)	Falsos Positivo (FP)	TP+FP
	Negativos -P	Falsos Negativos (FN)	Verdaderos Negativos (VN)	FN+TN
Resultados		TP+FN	FP+TN	N

Donde:

- El verdadero positivo (VP), es el número de casos/imágenes identificadas integras pronosticadas correctamente.
- El falso positivo (FP), es el número de casos/imágenes de grano de maíz pronosticados erróneamente.
- Positivo es el número de casos/imágenes de granos positivos con deformaciones provocadas por el SZM.
- El verdadero negativo (VN), es el número de casos/imágenes de granos de maíz NO-infectados pronosticados correctamente.
- El falso negativo (FN), es el número de casos/imágenes de granos de maíz NO-infectados pronosticados erróneamente.
- Negativo es la cantidad de casos/imágenes de granos de maíz NO-infectados.

Tabla 3
Métricas de rendimiento del modelo CNN

Métricas	Formula	Descripción
Accuracy (Acc)	$\frac{TP + TN}{TP + FP + FN + TN}$	Eficiencia integral del modelo
Sensibilidad (Se)	$\frac{TP}{TP + FN}$	Eficiencia del modelo en las muestras positivas (Pashaei et al., 2020)
Especificidad (Sp)	$\frac{TN}{TN + FP}$	Eficiencia del modelo en las muestras negativas (Kienbaum et al., 2021)
Índice de calidad (QI)	$\sqrt{Se * Sp}$	Media geométrica de Se y Sp
F1-score	$\frac{(2 * TP)}{(2 * TP + FP + FN)}$	F1-score usa una combinación de precisión y sensibilidad para calcular un resultado promedio equilibrado (Wang, Sun & Wang, 2017).
AUC	$\frac{1}{2} \left(\frac{TP}{TP + FN} + \frac{TN}{TN + FP} \right)$	Poder del modelo para evitar errores en la clasificación (Altuntaş et al., 2019)

3. Resultados y discusión

El documento proporciona imágenes de la infestación de SZM en granos almacenados, independientemente de la calidad y sus características visibles en la presentación del grano. Se recolectaron 1380 imágenes de maíz. En la **Figura 4** se muestra una proporción de las imágenes del maíz con y sin presencia de la plaga, de diferentes locales comerciales de minoristas y venta directa en el sector rural. El contenido de granos con deformidades y/o rotos fue de 0,898%. En este estudio, la primera matriz fue para predecir el desarrollo del modelo CNN. Las respuestas incluyen los índices de verdadero positivo (VP), verdadero negativo (VN), falso positivo (FP) y falso negativo (FN) como se observa en la **Tabla 2**. En nuestro caso los valores corresponden a las etiquetas de libre y con SZM, para VN y VP respectivamente, obteniendo los valores de imágenes posibles de libres y con SZM incorrectamente en FN y FP. Como característica de las prácticas de postcosecha en un mínimo porcentaje de los agricultores, el secado posterior

al maíz desgranado, producto de las cosechas se hace en el patio de casa a exposición del sol a suelo desnudo o áreas despejadas, pudiendo variar los tiempos de secado entre 15 a 21 días y las temperaturas según las temporadas.

1.1. Resultados Experimentales

Los experimentos fueron implementados en las librerías de Google Colab, en el entorno GPU. El detalle del tamaño de las muestras de imágenes para entrenamiento, validación y prueba fue de 70%, 15% y 15% respectivamente. Al momento del ciclo de aprendizaje el valor más bajo en tiempo fue de 02:01 en la segunda época, aspecto a considerar como una muestra rápida y eficiente.

El desempeño de la clasificación del grano por las métricas de precisión, sensibilidad, especificidad, índice de calidad, AUC y F-score, **Figura 5**. En el conjunto de entrenamiento, se clasificaron correctamente como grano con SZM (valor predictivo positivo). En el conjunto de validación los valores se incrementan a excepción de la sensibilidad, permaneció igual o similar a 0,9310.

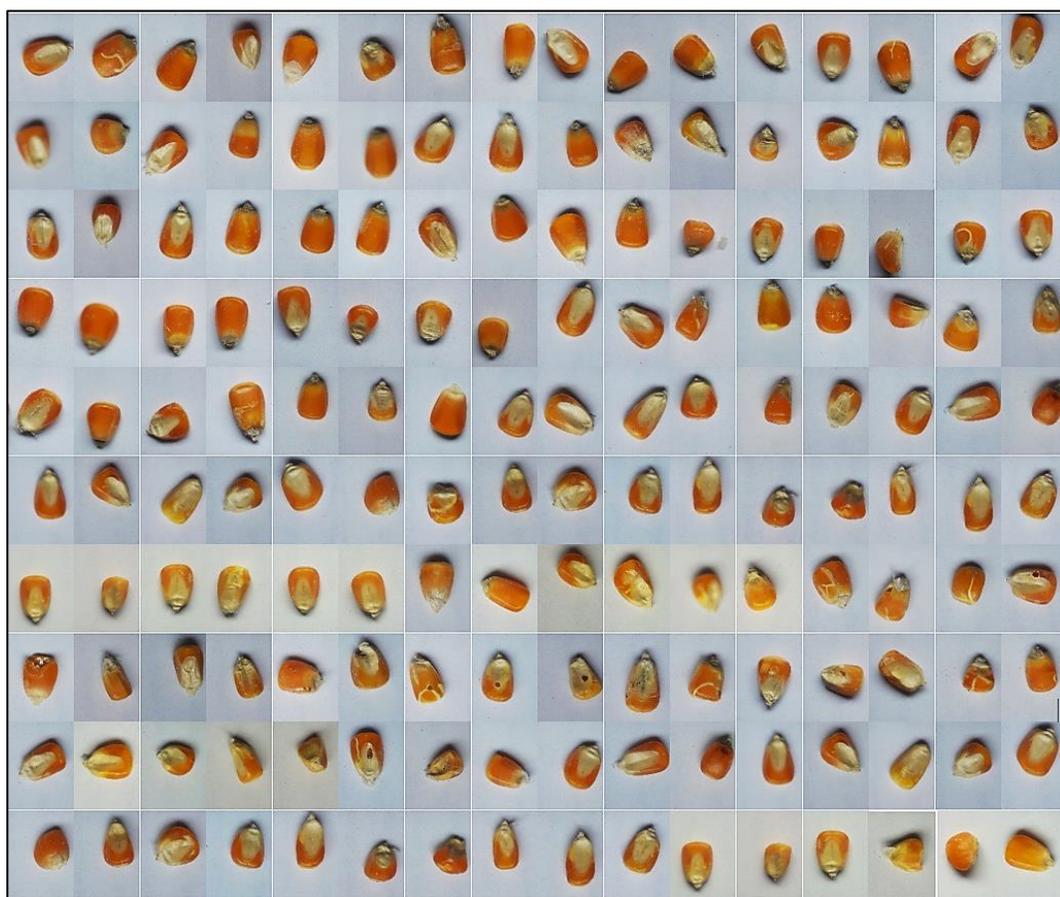


Figura 4. Muestra de imágenes de maíz con y sin SZM.

Los valores mejoran en la validación logrando mayor precisión para la validación, después de conocer la función grano libre que se clasificaron correctamente como no infestados, la AUC y F1-score tienen el mismo peso, lo que permite medir la efectividad del modelo utilizado para la clasificación de granos con SZM.

Los modelos de precisión de detección de SZM en el grano seco de maíz redujeron las iteraciones de convergencia, lo que pudo mejorar la eficiencia del entrenamiento y reconocimiento del modelo. Posterior a los procesos de entrenamiento de los modelos CNN con Resnet-50, se obtuvieron los resultados mostrados en la **Tabla 4**. La variación de los valores comprende desde 0,931 de sensibilidad hasta el valor más alto obtenido en especificidad de 0,9630. Para las señales de tráfico se obtuvieron 28 clases, la matriz de confusión.

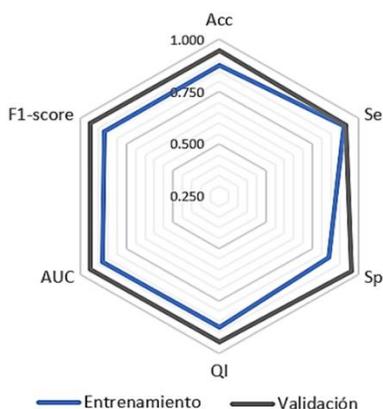


Figura 5. Diagrama de estrella para las métricas del modelo ResNet-50 para la clasificación de imágenes de grano de maíz con SZM y libre.

Comparación del modelo CNN con otros modelos

Al momento de comparar los problemas de clasificación sucede que la precisión no entrega

toda la información de la calidad de la clasificación. En comparación con las máquinas de clasificación automática con dispensador de los granos de maíz en Hebei-China (**Ni et al., 2019**), utilizando varios modelos ResNet, se obtuvo valores de sensibilidad y especificidad superiores de 0,981 y 0,985 respectivamente, con un tiempo computacional de 5,2. Comparado con la base de datos utilizada se logró una alta sensibilidad 0,931 y especificidad de 0,963. También, al probar la eficiencia de ResNet50 para nuestra aplicación, se comparan en el modelo los rendimientos de otros modelos, donde se incluye la precisión de la prueba, número de capas convolucionales en la red para un conjunto de datos de imágenes. Estos valores muestran resultados de precisión con alta significancia estadísticamente, suponiendo una diferencia en el número de capas en la red, tamaño de muestra, condiciones del grano, tipo de imágenes, modelo de hardware utilizado.

El número de capas utilizadas como diseños experimentales es muy variado en los estudios relacionados como se muestra en la **Tabla 5**, la cantidad de datos de los estudios sea fiable. Comparando con los valores obtenidos en otras investigaciones, la cantidad de datos utilizados en este estudio es similar e inferior que la mayoría de los datos utilizados en la literatura. A pesar del estudio riguroso es posible que los granos se hayan etiquetado mal en el conjunto de datos.

Aunque el modelo utilizado demuestra buenos resultados, las muestras mal etiquetadas pueden haber afectado el aprendizaje de las redes. El predominio de los estudios se realiza en China esto posiblemente comparado con las condiciones de desarrollo tecnológico y características de conservación del grano y la constante innovación de sus productos y servicios.

Tabla 4
Reporte de clasificación

ACC	Sensibilidad (Se)	Especificidad (Sp)	Quality Index (QI)	AUC	F1-score
0,9464	0,9310	0,9630	0,9469	0,9470	0,9474

Tabla 5
Comparación entre diferentes métodos en de maíz revisar

Método	Modelo de clasificación	Precisión de la prueba	País
Deep CNN	ResNet (Ni et al., 2019)	0.982	China
	ResNet50 (An et al., 2019)	0.981	China
	Resnet-18 (Altuntaş et al., 2019)	0.924	Turquía
	Resnet 50 (Xu et al., 2021)	0.905	China
	Mobile NetV2 (da Silva et al., 2021)	0.893	Brasil
	ResNet 101-FPN (Li et al., 2021)	0.887	China
	Resnet 50 (Wang, Sun and Wang, 2017)	0.793	China

Con relación a otros modelos como el VGG-16, utilizado para la predicción de la roya común en el maíz en sur África se obtuvo un valor del modelo similar al obtenido en el estudio con 0,956 (Sibiya & Sumbwanyambe, 2021), pero inferiores al modelo CNN de redes neuronales convolucionales utilizado por los mismos autores, para el reconocimiento de enfermedades de las hojas del maíz con un valor de 0,928 (Sibiya & Sumbwanyambe, 2019). Además, se reporta valores de 0.900 para el modelo de SVM, en la aplicación de imágenes espacio-temporales de sitios de siembra específicos de maíz (Nyéki et al., 2021).

Entre otras propuestas de análisis como el Deep learning, permiten combinar características abstractas de alto nivel en los insectos, facilitando el análisis del perceptrón oculto, consintiendo al algoritmo el reconocimiento de características propias de los insectos y características morfológicas (Xia et al., 2018; Aladhadh et al., 2022). Rimal, Shah & Jha (2023) obtuvieron valores diferenciados superiores al 0,96 en training accuracy y 0,95 validation accuracy con plagas de insectos presentes en el arroz (rodillo, barrenador asiático y amarillo del arroz, gorgojo) y similares a los encontrados por Coulibaly et al. (2022) para varios métodos supervisados en insectos en contornos relevantes de los insectos.

4. Conclusiones

El estudio de la calidad de grano ha lleva a un mayor conocimiento de la cadena de valor del maíz, específicamente: 1) El grano de maíz para la venta en los mercados cercanos especialmente de la sierra ecuatoriana locales generalmente tiene niveles bajos niveles de humedad valores que oscilan entre los 11% a 14% de humedad y menos de 1% de impurezas presentes. 2) la proporción de muestras de grano de maíz infectado o con grano integral se observó entre los comerciantes minoristas,

En este estudio propusimos un modelo para la segmentación de granos de maíz, con base de imágenes de muestras representativas. Hemos diseñado una arquitectura CNN, para la detección de SZM en el maíz y la transferencia de imágenes. Todos los hallazgos indican una predicción de riesgo en el rendimiento del grano de maíz, en las escalas libre y con SZM. El modelo de defectos del maíz causado por el SZM, en los locales de venta minoristas en la red neuronal convolucional tiene una alta significancia en rendimiento de predicción y credibilidad, lo que conduce al control de las plagas por insectos en el grano de maíz. Aunque los datos son limitados, es una desventaja, pues con

una data set no se conoce su tamaño adecuado, resolución, tipo de equipo con el que se capturo las imágenes. Este trabajo demuestra el potencial en las técnicas estadísticas y datos para el manejo diferenciado del grano del maíz. Una vez entendido la propuesta de valor para la calibración de monitores de rendimiento granular, recopilar y almacenar datos, es posibles incorporar modelos de rendimiento electrónico para asesorar a los pequeños productores. El alto grado de conocimiento científico y la importancia práctica para respaldar estrategias científicas de almacenamiento del grano, prevención y mitigación de pérdidas económicas y nutritivas permiten garantizar la seguridad alimentaria y la conservación de granos.

En nuestro enfoque se pudo reconocer nueve de cada diez granos de maíz libres de SZM utilizando modelos Resnet50, enfatizando el aprendizaje y la capacidad de dominio para reconocer con un mínimo de muestras de entrenamiento. El modelo brinda la capacidad de distinguir granos libres y granos infectados de SZM de manera rápida y a bajo costo. El modelo asegura resultados significativos para esta tarea en particular. Las métricas ACC, Se, Sp, QI, AUC y F-score alcanzaron valores de 0.9464; 0.9310; 0.9630; 0.9469; 0.9470; 0.9474 respectivamente. Se introduce un conjunto de datos de granos de maíz disponible públicamente que consta de 1380 imágenes de granos. Los resultados demuestran que el uso del modelo CNN, y su variación Resnet-50, en el reconocimiento de granos infectado y libres es una solución posible para la detección temprana de la presencia del SZM en el maíz.

Es importante realizar buenas prácticas de manejo postcosecha para reducir la propagación de plagas por insectos, la utilización de tecnología acorde a las necesidades de almacenamiento del grano. Por lo tanto, el resolver problemas integrales de datos intermedios y faltantes podría ser una tarea a futuro, cuando los investigadores fomenten a los actores sociales cumplir un papel importante en el desempeño de la recolección de datos y el valor agregado de los modelos de predicción en el manejo de plagas y/o agentes externos. El intercambio de conocimientos en los integrantes de la cadena de valor del maíz podría mejorar el enfoque del modelado, los problemas emergentes relacionados con agentes externos.

ORCID

I. Analuisa-Aroca  <https://orcid.org/0000-0002-3798-3122>

A. Vergara-Romero  <https://orcid.org/0000-0001-8503-3685>

I. B. Pérez Almeida  <http://orcid.org/0000-0001-5929-892X>

Referencias bibliográficas

- Abiyev, R. H., & Maaitah, M. K. S. (2018). Deep Convolutional Neural Networks for Chest Diseases Detection. *Journal of Healthcare Engineering*, 2018. doi:10.1155/2018/4168538.
- Aladhadh, S., Habib, S., Islam, M., Aloraini, M., Aladhadh, M., & Al-Rawashdeh, H. S. (2022). An Efficient Pest Detection Framework with a Medium-Scale Benchmark to Increase the Agricultural Productivity. *Sensors*, 22(24), 9749. doi:10.3390/s22249749.
- Alcheton (2022). *Maize weevil*. <https://alcheton.com/Maize-weevil>.
- Altuntaş, Y., Cömert, Z., & Kocamaz, A. F. (2019). Identification of haploid and diploid maize seeds using convolutional neural networks and a transfer learning approach. *Computers and Electronics in Agriculture*, 163, 104874. doi:10.1016/j.compag.2019.104874.
- An, J., Li, W., Li, M., Cui, S., & Yue, H. (2019). Identification and classification of maize drought stress using deep convolutional neural network. *Symmetry*, 11(2), 256. doi:10.3390/sym11020256.
- Baoua, I. B., Amadou, L., Ousmane, B., Baributsa, D., & Murdock, L. L. (2014). PICS bags for post-harvest storage of maize grain in West Africa. *Journal of Stored Products Research*, 58, 20–28. doi:10.1016/j.jspr.2014.03.001.
- Basir, M. S., Chowdhury, M., Islam, M. D., & Ashik-E-Rabbani, M. (2021). Artificial neural network model in predicting yield of mechanically transplanted rice from transplanting parameters in Bangladesh. *Journal of Agriculture and Food Research*, 5, 100186. doi:10.1016/j.jafr.2021.100186.
- Bisong, E. (2019). *Building Machine Learning and Deep Learning Models on Google Cloud Platform*. 1st edn, *Building Machine Learning and Deep Learning Models on Google Cloud Platform*. 1st edn. Ottawa: Apress. doi:10.1007/978-1-4842-4470-8.
- Bohinc, T., Horvat, A., Andrić, G., Pražić Golić, M., Kljajić, P., & Trdan, S. (2020). Natural versus synthetic zeolites for controlling the maize weevil (*Sitophilus zeamais*)-like *Messi* versus *Ronaldo*? *Journal of Stored Products Research*, 88, 101639.
- Camardo, M., Mazzoni, M., & Battilani, P. (2021). Machine Learning for Predicting Mycotoxin Occurrence in Maize. *Frontiers in Microbiology*, 12, 1–10. doi:10.3389/fmicb.2021.661132.
- Coulibaly, S., Kamsu-Foguem, B., Kamissoko, D., Traore, D. (2022). Explainable deep convolutional neural networks for insect pest recognition. *Journal of Cleaner Production*, 371, 133638. doi:10.1016/j.jclepro.2022.133638.
- da Silva, C. B., Silva, A. A. N., Barroso, G., Yamamoto, P. T., Arthur, V., Toledo, C. F. M., & Mastrangelo, T. de A. (2021). Convolutional neural networks using enhanced radiographs for real-time detection of *Sitophilus zeamais* in maize grain. *Foods*, 10(4), 879. doi:10.3390/foods10040879.
- de Carvalho, M. L., Rezende Leite, E., Carvalho, G. A., França-Silva, F., Bernardes de Andrade, D., & Marques, E. R. (2019). The Compared Efficiency of the Traditional Method, Radiography without Contrast and Radiography with Contrast in the Determination of Infestation by Weevil (*Sitophilus zeamais*) in Maize Seeds. *Insects*, 10(6), 156.
- FAO (2017). El futuro de la alimentación y la agricultura: Tendencias y desafíos. Organización de las Naciones Unidas para la Alimentación y la Agricultura. <https://www.fao.org/3/i6881s/i6881s.pdf>
- Fan, J., Zheng, J., Wu, L., & Zhang, F. (2021). Estimation of daily maize transpiration using support vector machines, extreme gradient boosting, artificial and deep neural networks models. *Agricultural Water Management*, 245, 106547. doi:10.1016/j.agwat.2020.106547.
- Goodfellow, I., Bengio, Y., & Courville, A. (2017) *Deep Learning, The MIT Press*. Londres: MIT Press. doi:10.1017/CBO9781107415324.004.
- Ileke, K. D., Idoko, J. E., Ojo, D. O., & Adesina, B. C. (2020). Evaluation of botanical powders and extracts from Nigerian plants as protectants of maize grains against maize weevil, *Sitophilus zeamais* (Motschulsky) [Coleoptera: Curculionidae]. *Biocatal. Agric. Biotechnol.*, 27, 101702.
- Javanmardi, S., Miraei Ashtiani, S.-H., Verbeek, F. J., & Martynenko, A. (2021). Computer-vision classification of corn seed varieties using deep convolutional neural network', *Journal of Stored Products Research*, 92, 101800. doi:10.1016/j.jspr.2021.101800.
- Kamilaris, A., & Prenafeta, F. X. (2018). A review of the use of convolutional neural networks in agriculture. *Journal of Agricultural Science*, 156(3), 312–322. doi:10.1017/S0021859618000436.
- Kienbaum, L., Correa Abondano, M., Blas, R., & Schmid, K. (2021). DeepCob: precise and high-throughput analysis of maize cob geometry using deep learning with an application in genebank phenomics. *Plant Methods*, 17, 91. doi:10.1186/s13007-021-00787-6.
- Li, L., Lv, Ch., Yuan, Y., & Zhao, B. (2021). Maize residue segmentation using Siamese domain transfer network. *Computers and Electronics in Agriculture*, 187, 106261. doi:10.1016/j.compag.2021.106261.
- Mamoon-ur-Rashid, M., Riaz-ud-din, Tariq, M., Khan, A. A., Latif, A., Naeem, M., & Khan, I. (2021). Bioactivity of hexane plant extracts against maize weevil (*Sitophilus zeamais* Motschulsky) (Coleoptera: Curculionidae) on stored maize. *Intl J Agric Biol*, 26, 617–624.
- Mi, C., Zhao, Ch., Deng, Q., & Deng, X. (2021). Prediction of chilling damage risk in maize growth period based on probabilistic neural network approach. *International Journal of Agricultural and Biological Engineering*, 14(2), 120–125. doi:10.25165/J.IJABE.20211402.5732.
- Michelucci, U. (2018). *Applied Deep Learning: A Case-Based Approach to Understanding Deep Neural Networks*. Dübendorf, Switzerland. doi:<https://doi.org/10.1007/978-1-4842-3790-8>.
- Ministerio de Agricultura y Ganadería, (MAG) (2019). Ficha del cultivo de Maíz duro seco (*Zea mays* L.). Quito-Ecuador, p. 1. <http://sjpa.agricultura.gob.ec/index.php/cifras-agroproductivas>.
- Muhaisin, M. M., & Rahman, T. (2019). *Application of Game Theory for Big Data Analytics, Data Analytics*. doi:10.1201/9780429446177-8.
- Ni, C., Wang, D., Vinson, R., Holmes, M., & Tao, Y. (2019). Automatic inspection machine for maize kernels based on deep convolutional neural networks. *Biosystems Engineering*, 178, 131–144. doi:10.1016/j.biosystemseng.2018.11.010.
- Ngom, D., Fauconnier, M. L., Malumba, P., Thiaw, C., Brévault, T., & Sembène, M. (2021). Morphophysical and biochemical traits involved in maize grain varietal susceptibility to the maize weevil, *Sitophilus zeamais* (Coleoptera, Curculionidae). *Biotechnologie, Agronomie, Société et Environnement*, 25(1), 45–56.
- Nurma Yulita, I., Hidayat, A., Setiawan Abdullah, A., & Paulus, E. (2020). Combining Fuzzy Clustering and Hidden Markov Models for Sundanese Speech Recognition. *Journal of Physics: Conference Series*, 1028, 012239.
- Nyékí, A., Kerepesi, C., Daróczy, B., Benczúr, A., Milics, G., Nagy, J., Harsányi, E., Kovács, A. J., & Neményi, M. (2021). Application of spatio-temporal data in site-specific maize yield prediction with machine learning methods. *Precision Agriculture*, 22(5), 1397–1415. doi:10.1007/s11119-021-09833-8.
- Pashaie, M., Kamangir, H., Starek, M. J., & Tissot, P. (2020). Review and evaluation of deep learning architectures for efficient land cover mapping with UAS hyper-spatial imagery: A case study over a wetland. *Remote Sensing*, 12(6), 959. doi:10.3390/rs12060959.

- Peschiutta, M. L., Brito, V. D., Achimón, F., Zunino, M. P., Usseglio, V. L., & Zygadlo, J. A. (2019). New insecticide delivery method for the control of *Sitophilus zeamais* in stored maize. *Journal of Stored Products Research*, *83*, 185-190.
- Rau, T. S., Bern, C. J., Brumm, T. J., Barnes, R. B., Bbosa, D., & Maier, D. E. (2021). Evaluation of stirring to suppress weevils in stored maize. *Journal of Stored Products Research*, *93*, 101849.
- Rimal, K., Shah, K. B., & Jha, A. K. (2023). Advanced multi-class deep learning convolution neural network approach for insect pest classification using TensorFlow. *International Journal of Environmental Science and Technology*, *20*(4), 4003–4016. doi:10.1007/s13762-022-04277-7.
- Sibiya, M., & Sumbwanyambe, M. (2019). A Computational Procedure for the Recognition and Classification of Maize Leaf Diseases Out of Healthy Leaves Using Convolutional Neural Networks. *AgriEngineering*, *1*(1), 119–131. doi:10.3390/agriengineering1010009.
- Sibiya, M., & Sumbwanyambe, M. (2021). Automatic fuzzy logic-based maize common rust disease severity predictions with thresholding and deep learning. *Pathogens*, *10*(2), 131. doi:10.3390/pathogens10020131.
- Stathers, T. E., Arnold, S. E. J., Rumney, C. J., & Hopson, C., (2020). Measuring the nutritional cost of insect infestation of stored maize and cowpea, *Food Security: The Science, Sociology and Economics of Food Production and Access to Food*, *12*(2), 285-308.
- Stuhl, Ch. J. (2019). Does prior feeding behavior by previous generations of the maize weevil (Coleoptera: Curculionidae) determine future descendants feeding preference and ovipositional suitability? *Florida Entomologist*, *102*(2), 366-372.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, *15*, 1929-1958.
- Waheed, A., Goyal, M., Gupta, D., Khanna, A., Ella Hassanien, A., & Mohan Pandey, H. (2020). An optimized dense convolutional neural network model for disease recognition and classification in corn leaf. *Computers and Electronics in Agriculture*, *175*, 105456. doi:10.1016/j.compag.2020.105456.
- Wang, G., Sun, Y., & Wang, J. (2017). Automatic Image-Based Plant Disease Severity Estimation Using Deep Learning. *Computational Intelligence and Neuroscience*, 2917536. doi:10.1155/2017/2917536.
- White, T. (2018) *Hadoop. The definitive guide. Storage and analysis at internet scale*. 4th Editio. Edited by Oreilly. Sebastopol-USA. <http://oreilly.com/catalog/errata.csp?isbn=9781491901632>.
- Xia, D., Chen, P., Wang, B., Zhang, J., & Xie, Ch. (2018). Insect detection and classification based on an improved convolutional neural network. *Sensors (Switzerland)*, *18*(12), 4169. doi:10.3390/s18124169.
- Xu, Y., Zhao, B., Zhai, Y., Chen, Q., & Zhou, Y. (2021). Maize Diseases Identification Method Based on Multi-Scale Convolutional Global Pooling Neural Network. *IEEE Access*, *9*, 27959–27970. doi:10.1109/ACCESS.2021.3058267.
- Yang, W., Nigon, T., Hao, Z., Dias Paiao, G., Fernández, F. G., Mulla, D., & Yang, C. (2021). Estimation of corn yield based on hyperspectral imagery and convolutional neural network. *Computers and Electronics in Agriculture*, *184*, 106092. doi:10.1016/j.compag.2021.106092.
- Zhang, J., Ma, Q., Cui, X., Guo, H., Wang, K., & Zhu, D. (2020). High-throughput corn ear screening method based on two-pathway convolutional neural network. *Computers and Electronics in Agriculture*, *175*, 105525. doi:10.1016/j.compag.2020.105525.
- Zhang, X., Qiao, Y., Meng, F., Fan, C., & Zhang, M. (2018). Identification of maize leaf diseases using improved deep convolutional neural networks. *IEEE Access*, *6*, 30370–30377. doi:10.1109/ACCESS.2018.2844405.