




# Artificial vision algorithm for the detection of Apodemus sylvaticus rodent pests in corn crops (Zea mays L.)

León León, Ryan Abraham<sup>1</sup>; Cortijo Vare, Yariixa Marisol<sup>1</sup>; Vera Alvarado, Karen Celeny<sup>1</sup>

<sup>1</sup>Profesor, Industrial Engineering Degree, Universidad Privada del Norte, Trujillo, Perú,  
ryan.leon@upn.edu.pe

<sup>2</sup>Student, Industrial Engineering Degree, Universidad Privada del Norte, Trujillo, Perú,  
n00221115@upn.pe, n00227180@upn.pe

*Abstract - The purpose of this work is to develop an artificial vision algorithm to detect the presence of Apodemus sylvaticus rodent pests in a Zea mays L. corn crop and implement the necessary hardware to guarantee the functionality of the algorithm in a crop in Laredo, since has seen that these rodents generate considerable economic losses due to contamination and nibbling of the fruit, which in turn cause diseases to people and animals that consume this product. For this research, Python software was used in a Python 3.8.0 programming language in a Visual Studio programming environment, a Yolov5 pre-trained convolutional neural network with 3615 illustrations of different rodents and; libraries such as base64, BytesIO, PIL import Image, time, torch and cv2. For the results, a sample of 225 images of 3 rodents detected in the culture (75 for each rodent) was considered, whose percentages of algorithm detection efficiencies are greater than 90%, that is, 97.33%, 98.67% and 100.00% for rodents 1, 2 and 3 respectively and; a total average efficiency of 98.67% with an error of 1.33%. In conclusion, the application of an artificial vision algorithm managed to detect the presence of Apodemus sylvaticus rodent pests in a Zea mays L corn crop.*

*Keywords—computer vision; rodent; convolutional neural network; algorithm*

**Digital Object Identifier:** (only for full papers, inserted by LACCEI).

**ISSN, ISBN:** (to be inserted by LACCEI).

**DO NOT REMOVE**

# Desarrollo de un algoritmo de visión artificial para la detección de plagas de roedores *Apodemus sylvaticus* en un cultivo de maíz (*Zea mays* L.)

León León, Ryan Abraham<sup>1</sup>; Cortijo Vare, Yarixa Marisol<sup>1</sup>; Vera Alvarado, Karen Celeny<sup>1</sup>

<sup>1</sup>Profesor, Industrial Engineering Degree, Universidad Privada del Norte, Trujillo, Perú,  
ryan.leon@upn.edu.pe

<sup>2</sup>Student, Industrial Engineering Degree, Universidad Privada del Norte, Trujillo, Perú,  
n00221115@upn.pe, n00227180@upn.pe

**Resumen** - El presente trabajo, tiene por objetivo desarrollar un algoritmo de visión artificial que permita detectar la presencia de plagas de roedores *Apodemus sylvaticus* en un cultivo de maíz *Zea mays* L. e implementar el hardware necesario para el buen funcionamiento del algoritmo en un cultivo de Laredo, pues se ha visto que estos roedores generan cuantiosas pérdidas económicas al reducir las cosechas como consecuencia de la contaminación y mordisqueos, que a su vez, provocan enfermedades a las personas y animales que consumen este producto. Para esta investigación se empleó el software Python desarrollado en un lenguaje de programación Python 3.8.0 en un entorno de programación Visual Studio, una red neuronal convolucional pre entrenada Yolov5 con 3615 imágenes de distintos roedores y; librerías como base64, BytesIO, PIL import Image, time, torch y cv2. Para los resultados, se consideraron 225 muestras de 3 roedores detectado en el cultivo (75 para cada roedor), cuyos porcentajes de eficiencias de detección del algoritmo son superiores al 90%, es decir, 97.33%, 98.67% y 100% para los roedores 1, 2 y 3 respectivamente y; una eficiencia promedio total de 98.67% con un error de 1.33%. Como conclusión se obtuvo que la aplicación de un algoritmo de visión artificial logró detectar la presencia de plagas de roedores *Apodemus sylvaticus* en un cultivo de maíz *Zea mays* L.

**Palabras clave**— visión artificial; roedor; red neuronal convolucional; algoritmo

## I. INTRODUCCIÓN

La principal actividad económica de Laredo es la agricultura, siendo el comercio la actividad complementaria de gran riesgo, por lo que, esta producción se destina fundamentalmente al autoconsumo y al mercado local. Los cultivos predominantes son: el maíz amiláceo, palta y caña de azúcar, por eso, es de suma importancia para los productores cerrar todas las temporadas de cultivo con resultados óptimos, sin embargo, este escenario usualmente no sucede, ya que, se presencian plagas que evitan lograr las metas planeadas. Uno de los principales inconvenientes que presenta un cultivo de maíz amiláceo (*Zea mays* L) de esta ciudad, es la presencia de roedores principalmente de *Apodemus sylvaticus* más conocido como “ratón de campo”, su población asciende paulatinamente y, por temporadas, la población de este animal es considerablemente mayor de lo habitual, lo que resulta en pérdidas económicas significativas debido a la reducción considerable en la cantidad de productos que se pueden cosechar. Además, infestan las siembras y contaminan cualquier elemento que entre en contacto con sus orines y excrementos, asimismo, estos se comen todo el producto, llegando a arrasar hasta con el 100% de la cosecha, además de,

destronar las pequeñas plantas impidiendo su maduración. Además, se añade el riesgo de transmitir una amplia variedad de enfermedades a las personas.

En este sentido, en el ámbito económico, una actividad que ha sobresalido en el mercado debido a su notorio crecimiento es la producción de maíz amiláceo (*Zea mays* L.), un recurso esencial utilizado en la elaboración de alimentos balanceados, especialmente en la industria avícola y en la cría de otros animales [1]. En julio de 2022, la producción de maíz amiláceo alcanzó las 78.285 toneladas, lo que representó un incremento del 25,8% con respecto al año anterior [2]. No obstante, este cultivo es vulnerable a enfermedades y plagas durante su periodo de floración hasta su madurez fisiológica, que abarca un período de 42 a 93 días desde la fase de emergencia [3]. Estas plagas pueden causar pérdidas significativas, estimadas en alrededor del 30% de rendimiento [4]. La existencia de estas plagas en los campos de cultivo se atribuye a factores como las condiciones ambientales, el desarrollo del cultivo y los hábitos de las plagas. Según la FAO, las plagas pueden reducir la productividad agrícola en hasta un 40% [5]. Entre las plagas más destructivas para este cultivo se encuentran los roedores, que afectan negativamente tanto la cantidad como la calidad de los granos, lo que disminuye su valor en el mercado al punto de hacer que la producción sea inútil o incluso resulte en pérdida total [6]. En países como Filipinas y Malasia, los daños causados por los roedores pueden llevar a pérdidas del 80% en la cosecha. Además, al mordisquear los productos, los roedores pueden transmitir enfermedades como el cornezuelo del centeno, la leptospirosis o la tifoidea, lo que hace que los productos sean inadecuados para el consumo tanto de animales como de seres humanos [7]. Ante esta problemática, las industrias relacionadas con este sector están enfocando sus esfuerzos en la detección y el manejo de estas y otras plagas a través de la agricultura 4.0, haciendo uso de la visión artificial y el procesamiento de imágenes [8].

Entonces, en la automatización de procesos industriales, se utiliza el procesamiento de imágenes debido a su capacidad para identificar plagas y analizar la morfología de las plantas, lo que lo convierte en una solución efectiva para gestionar, supervisar y controlar aspectos críticos en la industria agrícola [9]. Mientras que, la visión artificial, es un campo complejo que requiere una variedad de herramientas y lenguajes de programación. Sus fases abarcan desde la captura de

imágenes, su preprocesamiento, segmentación, descripción, clasificación y la interpretación de las imágenes mediante técnicas de procesamiento, análisis y visión por computadora [10]. Y, la inteligencia artificial, engloba un grupo de tecnologías creadas con el propósito de emular la inteligencia humana a través de máquinas y programas informáticos [11]. Asimismo, En el ámbito agrícola, la visión artificial posibilita la obtención de una amplia gama de datos acerca de los terrenos de cultivo, lo que permite mejorar los procedimientos de siembra, el control de las malezas y la cosecha, todo ello mediante el análisis de imágenes capturadas en los cultivos [12].

Se han empleado sistemas de visión artificial para identificar los daños provocados por plagas como la araña roja y el bicho de cesto en un cultivo de palto. Se han empleado utilizando imágenes capturadas por un dron Mavic2 Zoom y el entorno Anaconda-Spyder (Python 3.6 y las bibliotecas: Open CV y Numpy, se concluyó que el algoritmo Random Forest es idóneo para evaluar el nivel de la presencia de plagas en las hojas de aguacate, con una precisión del 100% [13]. De la misma manera, se aplicó la visión artificial para la detección de aves mediante el uso de YOLOv5, que facilita la creación de un algoritmo de aprendizaje automatizado desarrollado en el lenguaje de programación Python utilizando la adquisición de 4952 imágenes de varias especies de aves. Con ello, se logró una precisión de detección del 80% tras probarlo en un ambiente natural durante 15 días [14]. Por último, se empleó la visión artificial para la detectar y clasificar 4 tipos de roedores mediante la red neuronal convolucional pre entrenada VGG-16 con 1411 imágenes, captadas mediante sistemas de cámaras activadas en modo automático. Este proyecto, consistió en 3 etapas que son: pre-procesamiento, red neuronal convolucional CNN o más conocida como VGG-16 y máquina de vectores de soporte SVM, dando como resultado una exactitud y error promedio de 98.1% y 1.9% respectivamente [15].

Basándonos en lo previamente expuesto, se elaboró este artículo de investigación con el propósito de aportar a la comunidad científica en pos de futuras investigaciones vinculadas a este procedimiento. Esto se debe a la relevancia de este método en la detección de plagas de roedores en campos de maíz, un aspecto de suma importancia para el consumo tanto animal como humano, ya que este cultivo se considera un recurso esencial para la población. Por otro lado, el objetivo principal, es desarrollar un algoritmo de visión artificial para la detección de plagas de roedores *Apodemus sylvaticus* en el cultivo de maíz. Asimismo, como objetivos específicos, se implementará el hardware requerido para garantizar el correcto funcionamiento del algoritmo de visión artificial, se utilizará la red neuronal pre-entrenada YOLOv5 y se tomarán pruebas de los roedores en el cultivo de maíz amiláceo. Cabe recalcar que, al introducir el sistema de detección de roedores en el cultivo de maíz, se contribuirá con el aseguramiento de la calidad del fruto que será procesado para los principales consumidores.

## MATERIALES Y METODOS

Este estudio de investigación es de carácter experimental, por lo que, a continuación, se detallan los materiales y métodos empleados durante el desarrollo del algoritmo de visión artificial.

En primer lugar, el cultivo de maíz donde se realizó la investigación está ubicado en la calle Junior Saavedra, perteneciente el centro poblado San Carlos del distrito de Laredo, abarcando un área de 4.34 m<sup>2</sup> (Figura 1). El cual, presenta daños en las plantas de maíz amiláceo a causa de la presencia de roedores (Figura 2).



Fig. 1 Vista del cultivo de maíz amiláceo en C.P. San Carlos



Fig. 2 Daños causados al cultivo

Para la adquisición de imágenes para el proceso de entrenamiento de la red neuronal se utilizó un equipo fotográfico, cuyas principales especificaciones técnicas son, resolución de 2400 x 1080; procesador de ocho núcleos (2 x 2,2 GHz + 6 x 1,8 GHz) y; cuatro cámaras traseras de las cuales, la principal es de 64 MP, gran angular de 12 MP, macro de 5 MP y profundidad de 5 MP. Asimismo, se utilizó una Web Cam Syfinee HP 720P de 12MP para la grabación de video en tiempo real del movimiento de los roedores en el cultivo de maíz; cuyas principales especificaciones técnicas son, Chip DSP Sin conductor; sensor de imagen CMOS; lente de cristal de calidad; alta definición: 12,0 M Píxeles; velocidad de fotogramas 30 fps; interfaz USB 2.0 y; tamaño 8 cm x 3 cm x 11cm/3,15x1,18x 4,33 pulgadas (aprox.) Y, una laptop ASUS VivoBook con las siguientes especificaciones

técnicas, procesador Intel(R) Core (TM) i7-1065G7 CPU @1.30GHz 1.50 GHz, RAV instalada de 12.0 GB y; sistema operativo de 64 bits procesador x64.

En cuanto al software, se utilizó Python, que es libre y gratuito desarrollado en un lenguaje de programación Python 3.8.0. Este lenguaje facilita la implementación de diversas funciones con una sintaxis accesible, y su compatibilidad abarca todos los sistemas operativos [16]. Asimismo, se empleó al entorno de programación Visual Studio es un editor de código fuente ligero y eficaz que está disponible para Windows, macOS y Linux. Ofrece compatibilidad integrada con JavaScript, TypeScript y Node.js, y dispone de un extenso ecosistema de extensiones para otros lenguajes y entornos de ejecución, como Python [17].

Asimismo, se emplearon las siguientes librerías: import base64, la cual sirve para importar la biblioteca base64, que se usa para realizar codificación y decodificación de la misma [18]; from io import BytesIO, la cual permite importa BytesIO desde la biblioteca io que permite trabajar con datos binarios en memoria [19]; from PIL import Image, usada para importar la imagen desde la biblioteca Python Imaging Library (PIL), que se utiliza para manipular imágenes [20]; import time, la cual como su propio nombre lo dice importa la biblioteca time, utilizada para medir el tiempo [21]; import torch, la cual importa la biblioteca PyTorch, que se utiliza para cargar el modelo YOLOv5 para realizar inferencias [22] e; import cv2 la cual esta importa OpenCV, que se usa para capturar imágenes de la cámara y mostrar las detecciones en tiempo real [23].

Por último, para el entrenamiento del algoritmo, se utilizó la red neuronal pre entrenada Yolov5, un sistema de código abierto diseñada para realizar la detección de objetos en tiempo real. Esta herramienta se caracteriza por emplear exclusivamente una red neuronal convolucional (CNN) para identificar objetos presentes en ilustraciones, a través de la extracción de características, empleando: capas convolucionales para la detección de bordes, formas y texturas a partir de la aplicación de filtros convolucionales a la imagen de entrada; capas de agrupación (pooling) para reducir la resolución espacial de las características, lo cual conlleva a una reducción en la cantidad de datos, al mismo tiempo que se conservan las características más relevantes. Además, se recurre a capas completamente conectadas con el propósito de realizar las predicciones finales [24].

En cuanto a la metodología de este estudio de investigación, se colocó el equipo fotográfico en un punto fijo para registrar la presencia de roedores en el cultivo de maíz mediante la captura de imágenes y videos durante 2 días. Y, luego utilizar las técnicas de inteligencia y visión artificial, y redes neuronales convolucionales.

#### A. Proceso de adquisición de imágenes

Se captura imágenes de roedores en el cultivo de maíz del C.P. San Carlos, a través del equipo fotográfico cuya resolución es de 64MP, así como, se obtienen imágenes de la biblioteca de imágenes COCO de Python.



Fig. 3 Esquema de toma de captura de imagen del roedor

Para este proceso de adquisición de imágenes, se consideró el esquema (Figura 3), es decir, se posicionó la cámara del equipo fotográfico en un trípode de 15 cm de altura sobre el nivel del piso con un ángulo de 60°, ya que permite captar las características morfológicas y el movimiento del roedor necesarias para etapa de procesamiento de las imágenes.

#### B. Tamaño de muestra

Considerando un nivel de confianza del 99%, se utiliza la ecuación 1 para calcular el tamaño de la muestra.

$$N = \frac{N * Z_{\infty}^2 * p * q}{e^2 * (N - 1) + Z_{\infty}^2 * p * q} \quad (1)$$

Donde:

- n = Tamaño de muestra
- N = Tamaño de la población o universo
- Z = Parámetro estadístico que depende el nivel de confianza.
- e = Error de estimación máximo aceptado
- p = Probabilidad de que ocurra el evento estudiado
- q = Probabilidad de que no ocurra el evento estudiado.

Se utilizó la formula del tamaño de muestra para una población finita, donde el número de fotografías tomadas por la cámara es de 3608 durante 1 hora (Considerando que la cámara toma aproximadamente 1 foto por segundo).

$$\frac{3608 * (2.58^2) * 0.9 * 0.1}{(0.05^2) * (3608 - 1) + (2.58^2) * 0.9 * 0.1} = 225 \quad (2)$$

$$\frac{225}{3} = 75 \quad (3)$$

En este sentido, se obtuvo un valor “n” de 225, el cual se dividió por 3 para tomar 75 fotografías de cada roedor durante ese periodo de tiempo y en un ambiente no controlado. Es decir, con presencia de organismos biológicos propios del entorno tales como plantas e insectos, así como también, hojas secas, tierra y piedras. Y, en diferentes condiciones ambientales en cuanto a la iluminación.



### C. Arquitectura de red neuronal

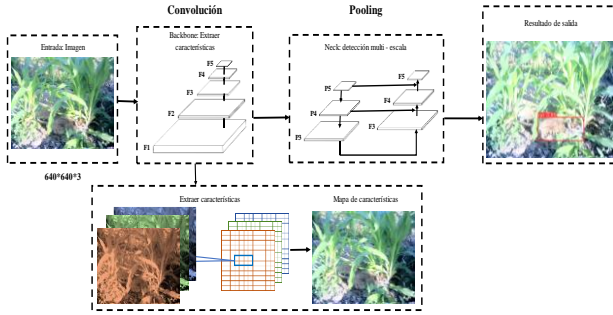


Fig. 4 Arquitectura de red neuronal convolucional pre-entrenada Yolov5

Según la Figura 4, para la detección del roedor en tiempo real, primero, se realiza la división de la imagen de entrada con tamaño de  $60 \times 60 \times 3$ , en una cuadrícula y cada celda predice objetos que se encuentran en su región a través de capas convolucionales que aplican filtros a la imagen de entrada con el fin de detectar y extraer características como bordes, texturas y formas mediante la ecuación 4, donde  $f$  es la ilustración de entrada,  $g$  es el filtro (núcleo de convolución),  $x$  e  $y$  son las coordenadas del píxel en la imagen de salida  $y$ ; a y b representan el alto y ancho de imagen.

$$(f * g)(x, y) = \sum_a \sum_b f(a, b)g(x - a, y - b) \quad (4)$$

Asimismo, mediante las capas de agrupación (pooling) se reduce la resolución espacial de las características, lo que resulta en una disminución en la cantidad de datos mientras se mantienen las características más importantes de la imagen de entrada, aplicando un proceso de supresión de no máximos para eliminar las detecciones redundantes y mantener solo la detección más confiable del roedor mediante la ecuación de solapamiento entre cajas (Ecuación 5) donde IoU es la detección sobre la unión, el área de intersección es el área común entre dos cajas y el área de unión es el área total cubierta por ambas cajas.

Por consiguiente, para predecir las coordenadas de una caja delimitadora en la imagen de salida, se utilizan las ecuaciones de regresión 6 y 7, donde se ajustan los valores predichos a los valores reales. Donde,  $\sigma$  es la función sigmoide;  $t_x$  y  $t_y$  son las salidas de la red que representan el desplazamiento y el tamaño de la caja;  $c_x$  y  $c_y$  son las coordenadas del centro de la caja en relación con la cuadrícula de la celda;  $\hat{x}$  (ancho de imagen) e  $\hat{y}$  (alto de imagen), son las dimensiones de la imagen.

$$IoU = \frac{\text{Área de intersección}}{\text{Área de unión}} \quad (5)$$

$$\hat{x} = (\sigma(t_x) + c_x) ; \text{ ancho imagen} \quad (6)$$

$$\hat{y} = (\sigma(t_y) + c_y) ; \text{ alto imagen} \quad (7)$$

Finalmente, con las capas completamente conectadas se logra realizar las predicciones finales, es decir, se obtiene una lista de objetos detectados junto con sus coordenadas y etiquetas de clase (Figura 4). En este sentido, cada celda de la cuadrícula emite varias cajas delimitadoras (bounding boxes) y confianza en la presencia de un roedor en esas cajas, lo cual, implica calcular las probabilidades de que el objeto captado pertenezca a la clase 1 (roedor). Esto se hace típicamente utilizando una función softmax (Ecuación 8) para normalizar las salidas de la red y calcular las probabilidades condicionales, donde  $salida_i$  es la salida de la red correspondiente a la clase  $i$ .

$$P(\text{clase} = i | \text{imagen}) = \frac{\exp(salida_i)}{\sum_j \exp(salida_j)} \quad (8)$$

### C. Funcionamiento del Algoritmo

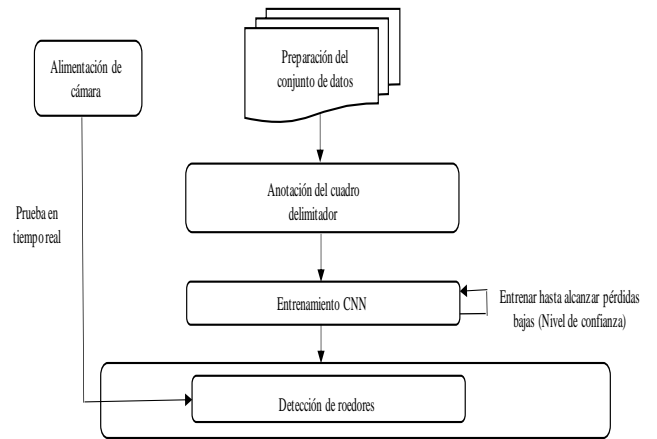


Fig. 5 Diagrama de flujo de la programación y funcionamiento del algoritmo

Según la Figura 5, para la detección y seguimiento de roedores en tiempo real es indispensable contar con un Dataset de 3615 imágenes de roedores, las cuales sirven para alimentar a la red neuronal convolucional Yolov5. Por otro lado, se establece un umbral de confianza para las detecciones del modelo en 0.5 (Figura 6), lo que significa que solo se mostrarán las detecciones con una confianza igual o superior al 50%. Asimismo, mediante la función `cap = cv2.VideoCapture(0)` se inicializa la captura de video en tiempo real desde la cámara predeterminada, a partir de lo cual, se genera el bucle infinito, que con la función `ret, frame = cap.read()`, captura fotografías de la cámara y lo almacena en `frame`, los cuales, serán procesados con la función `img =`

cv2.cvtColor(frame, cv2.COLOR\_BGR2RGB) que convierte el fotograma a formato RGB (Figura 7), que es el formato de imagen que YOLOv5 espera como entrada. Posteriormente, se realiza un bucle a través de las predicciones (pred) y se cuenta el número de roedores detectados y se almacenan las confianzas en una lista. Luego, mediante la función results.render()[0] se dibujan las detecciones en el fotograma original y empleando las funciones cv2.imshow('Detección en Vivo' y cv2.cvtColor(img\_with\_boxes, cv2.COLOR\_RGB2BGR)) se muestra el fotograma con las detecciones en una ventana de visualización en tiempo real.



Fig. 6 Umbral de confianza

```
img = cv2.cvtColor(frame, cv2.COLOR_BGR2RGB) # Convierte el fotograma a formato RGB
results = model(img)
```

Fig. 7 Conversión de fotogramas

## II. RESULTADOS

Para evaluar la eficiencia del algoritmo de detección de roedores *Apodemus sylvaticus* en un cultivo de maíz amiláceo, se utilizaron 3615 imágenes para el entrenamiento de la red neuronal convolucional Yolov5, 165 para prueba y 225 imágenes para la validación del funcionamiento del algoritmo de visión artificial (Tabla 1).

TABLA I  
CONJUNTO DE DATOS DE IMÁGENES DE ROEDORES PARA EL ENTRENAMIENTO, PRUEBA Y VALIDACIÓN

Nombre de la especie de roedor	Nº de imágenes total	Nº de imágenes de entrenamiento	Nº de imágenes de prueba	Nº de imágenes de validación
<i>Apodemus sylvaticus</i>	4005	3615	165	225

Para la fase de validación, se tomaron 75 muestras a tres roedores de diferente tamaño en distintos horarios y con diferente iluminación en el cultivo de maíz, para reflejar la variabilidad que se presenta en las situaciones del mundo real, asegurando así una evaluación precisa y equilibrada de la eficiencia del algoritmo para detectar al roedor o roedores presentes en el área de evaluación tal como se observa en las Tablas II, III y IV. También, cabe recalcar que, durante esta fase, se realizaron pruebas eventuales enfocando a otras especies de animales que habitan en el cultivo tales como gusanos y pájaros, los cuales no fueron detectados como roedores, esto, con el propósito de reducir los falsos positivos.

TABLA II  
MUESTRAS DEL ROEDOR 1

Nº Muestra	Horario	Detección	Precisión
1	10:00 a. m.	Detectó	92%
2	10:00 a. m.	Detectó	88%
3	10:00 a. m.	Detectó	93%
4	10:00 a. m.	Detectó	84%
5	10:00 a. m.	Detectó	85%
6	10:00 a. m.	Detectó	71%
7	10:00 a. m.	Detectó	84%
8	10:00 a. m.	Detectó	85%
9	10:00 a. m.	Detectó	83%
10	10:00 a. m.	Detectó	87%
11	10:00 a. m.	No detectó	
12	10:00 a. m.	Detectó	87%
13	10:00 a. m.	Detectó	81%
14	10:00 a. m.	Detectó	78%
15	10:00 a. m.	Detectó	77%
16	2:00 p. m.	Detectó	76%
17	2:00 p. m.	No detectó	
18	2:00 p. m.	Detectó	74%
19	2:00 p. m.	Detectó	87%
20	2:00 p. m.	Detectó	88%
21	2:00 p. m.	Detectó	88%
22	2:00 p. m.	Detectó	73%
23	2:00 p. m.	Detectó	85%
24	2:00 p. m.	Detectó	71%
25	2:00 p. m.	Detectó	69%
26	5:00 p. m.	Detectó	68%
27	5:00 p. m.	Detectó	84%
28	5:00 p. m.	Detectó	85%
29	5:00 p. m.	Detectó	78%
30	5:00 p. m.	Detectó	61%
31	5:00 p. m.	Detectó	66%
32	5:00 p. m.	Detectó	67%
33	5:00 p. m.	Detectó	68%
34	5:00 p. m.	Detectó	71%
35	5:00 p. m.	Detectó	73%
36	2:00 p. m.	Detectó	70%
37	2:00 p. m.	Detectó	50%
38	2:00 p. m.	Detectó	78%
39	2:00 p. m.	Detectó	72%
40	2:00 p. m.	Detectó	55%
41	2:00 p. m.	Detectó	82%
42	2:00 p. m.	Detectó	84%
43	2:00 p. m.	Detectó	69%
44	2:00 p. m.	Detectó	61%
45	2:00 p. m.	Detectó	86%
46	2:00 p. m.	Detectó	87%
47	2:00 p. m.	Detectó	89%
48	2:00 p. m.	Detectó	88%
49	2:00 p. m.	Detectó	79%
50	5:00 p. m.	Detectó	87%
51	5:00 p. m.	Detectó	80%
52	5:00 p. m.	Detectó	89%
53	5:00 p. m.	Detectó	86%
54	5:00 p. m.	Detectó	89%
55	5:00 p. m.	Detectó	79%
56	5:00 p. m.	Detectó	72%
57	5:00 p. m.	Detectó	90%
58	5:00 p. m.	Detectó	89%
59	5:00 p. m.	Detectó	91%
60	5:00 p. m.	Detectó	85%
61	5:00 p. m.	Detectó	60%
62	5:00 p. m.	Detectó	86%
63	5:00 p. m.	Detectó	54%
64	5:00 p. m.	Detectó	71%
65	5:00 p. m.	Detectó	70%
66	5:00 p. m.	Detectó	80%
67	5:00 p. m.	Detectó	58%
68	5:00 p. m.	Detectó	82%
69	5:00 p. m.	Detectó	72%
70	5:00 p. m.	Detectó	76%
71	5:00 p. m.	Detectó	83%
72	5:00 p. m.	Detectó	57%
73	5:00 p. m.	Detectó	82%
74	5:00 p. m.	Detectó	54%
75	5:00 p. m.	Detectó	82%

En la Tabla 2, se puede observar que de las 75 muestras realizadas al roedor 1, el número de muestras sin detección fueron 2 en los horarios de 10:00 am y 2:00 pm y; se alcanzó

una precisión máxima (Figura 6) de detección de 93% (Tabla 5).

TABLA III  
MUESTRAS DEL ROEDOR 2

N° Muestra	Horario	Detección	Precisión
1	11:00 a. m.	Detectó	85%
2	11:00 a. m.	Detectó	91%
3	11:00 a. m.	No detectó	
4	11:00 a. m.	Detectó	77%
5	11:00 a. m.	Detectó	75%
6	11:00 a. m.	Detectó	79%
7	11:00 a. m.	Detectó	84%
8	11:00 a. m.	Detectó	84%
9	11:00 a. m.	Detectó	73%
10	11:00 a. m.	Detectó	75%
11	11:00 a. m.	Detectó	91%
12	11:00 a. m.	Detectó	75%
13	11:00 a. m.	Detectó	78%
14	11:00 a. m.	Detectó	77%
15	11:00 a. m.	Detectó	91%
16	3:00 p. m.	Detectó	78%
17	3:00 p. m.	Detectó	79%
18	3:00 p. m.	Detectó	71%
19	3:00 p. m.	Detectó	79%
20	3:00 p. m.	Detectó	73%
21	3:00 p. m.	Detectó	86%
22	3:00 p. m.	Detectó	86%
23	3:00 p. m.	Detectó	81%
24	3:00 p. m.	Detectó	71%
25	3:00 p. m.	Detectó	83%
26	6:00 p. m.	Detectó	85%
27	6:00 p. m.	Detectó	73%
28	6:00 p. m.	Detectó	91%
29	6:00 p. m.	Detectó	73%
30	6:00 p. m.	Detectó	72%
31	6:00 p. m.	Detectó	85%
32	6:00 p. m.	Detectó	72%
33	6:00 p. m.	Detectó	64%
34	6:00 p. m.	Detectó	80%
35	6:00 p. m.	Detectó	68%
36	6:00 p. m.	Detectó	86%
37	6:00 p. m.	Detectó	89%
38	6:00 p. m.	Detectó	60%
39	6:00 p. m.	Detectó	87%
40	6:00 p. m.	Detectó	69%
41	6:00 p. m.	Detectó	79%
42	6:00 p. m.	Detectó	70%
43	6:00 p. m.	Detectó	84%
44	6:00 p. m.	Detectó	84%
45	6:00 p. m.	Detectó	85%
46	6:00 p. m.	Detectó	74%
47	6:00 p. m.	Detectó	86%
48	6:00 p. m.	Detectó	80%
49	6:00 p. m.	Detectó	87%
50	6:00 p. m.	Detectó	88%
51	6:00 p. m.	Detectó	76%
52	6:00 p. m.	Detectó	83%
53	6:00 p. m.	Detectó	83%
54	6:00 p. m.	Detectó	87%
55	6:00 p. m.	Detectó	73%
56	6:00 p. m.	Detectó	68%
57	6:00 p. m.	Detectó	78%
58	6:00 p. m.	Detectó	87%
59	6:00 p. m.	Detectó	82%
60	6:00 p. m.	Detectó	83%
61	6:00 p. m.	Detectó	91%
62	6:00 p. m.	Detectó	83%
63	6:00 p. m.	Detectó	92%
64	6:00 p. m.	Detectó	73%
65	6:00 p. m.	Detectó	84%
66	6:00 p. m.	Detectó	88%
67	6:00 p. m.	Detectó	80%
68	6:00 p. m.	Detectó	91%
69	6:00 p. m.	Detectó	84%
70	6:00 p. m.	Detectó	91%
71	6:00 p. m.	Detectó	87%
72	6:00 p. m.	Detectó	83%
73	6:00 p. m.	Detectó	92%
74	6:00 p. m.	Detectó	88%
75	6:00 p. m.	Detectó	91%

En la Tabla 3, se observa que de las 75 muestras realizadas al roedor 2, el número de muestras sin detección fue 1 en el

horario de 11:00 am y; se alcanzó una precisión máxima (Figura 6) de detección de 92% (Tabla 5).

TABLA IV  
MUESTRAS DEL ROEDOR 3

N° Muestra	Horario	Detección	Precisión
1	10:30 a. m.	Detectó	87%
2	10:30 a. m.	Detectó	85%
3	10:30 a. m.	Detectó	80%
4	10:30 a. m.	Detectó	77%
5	10:30 a. m.	Detectó	76%
6	10:30 a. m.	Detectó	85%
7	10:30 a. m.	Detectó	87%
8	10:30 a. m.	Detectó	93%
9	10:30 a. m.	Detectó	63%
10	10:30 a. m.	Detectó	86%
11	10:30 a. m.	Detectó	80%
12	10:30 a. m.	Detectó	89%
13	10:30 a. m.	Detectó	79%
14	10:30 a. m.	Detectó	74%
15	10:30 a. m.	Detectó	91%
16	10:30 a. m.	Detectó	80%
17	10:30 a. m.	Detectó	90%
18	10:30 a. m.	Detectó	62%
19	10:30 a. m.	Detectó	90%
20	10:30 a. m.	Detectó	82%
21	10:30 a. m.	Detectó	74%
22	10:30 a. m.	Detectó	83%
23	10:30 a. m.	Detectó	79%
24	10:30 a. m.	Detectó	83%
25	2:30 p. m.	Detectó	87%
26	2:30 p. m.	Detectó	87%
27	2:30 p. m.	Detectó	85%
28	2:30 p. m.	Detectó	92%
29	2:30 p. m.	Detectó	86%
30	2:30 p. m.	Detectó	89%
31	2:30 p. m.	Detectó	86%
32	2:30 p. m.	Detectó	88%
33	2:30 p. m.	Detectó	83%
34	2:30 p. m.	Detectó	87%
35	2:30 p. m.	Detectó	86%
36	2:30 p. m.	Detectó	65%
37	2:30 p. m.	Detectó	74%
38	2:30 p. m.	Detectó	61%
39	2:30 p. m.	Detectó	81%
40	2:30 p. m.	Detectó	69%
41	2:30 p. m.	Detectó	70%
42	2:30 p. m.	Detectó	90%
43	2:30 p. m.	Detectó	81%
44	2:30 p. m.	Detectó	87%
45	2:30 p. m.	Detectó	71%
46	2:30 p. m.	Detectó	68%
47	2:30 p. m.	Detectó	81%
48	2:30 p. m.	Detectó	79%
49	2:30 p. m.	Detectó	55%
50	5:30 p. m.	Detectó	84%
51	5:30 p. m.	Detectó	89%
52	5:30 p. m.	Detectó	85%
53	5:30 p. m.	Detectó	68%
54	5:30 p. m.	Detectó	89%
55	5:30 p. m.	Detectó	76%
56	5:30 p. m.	Detectó	62%
57	5:30 p. m.	Detectó	84%
58	5:30 p. m.	Detectó	78%
59	5:30 p. m.	Detectó	75%
60	5:30 p. m.	Detectó	76%
61	5:30 p. m.	Detectó	74%
62	5:30 p. m.	Detectó	83%
63	5:30 p. m.	Detectó	79%
64	5:30 p. m.	Detectó	90%
65	5:30 p. m.	Detectó	78%
66	5:30 p. m.	Detectó	72%
67	5:30 p. m.	Detectó	80%
68	5:30 p. m.	Detectó	66%
69	5:30 p. m.	Detectó	89%
70	5:30 p. m.	Detectó	85%
71	5:30 p. m.	Detectó	87%
72	5:30 p. m.	Detectó	81%
73	5:30 p. m.	Detectó	56%
74	5:30 p. m.	Detectó	89%
75	5:30 p. m.	Detectó	59%

En la Tabla 4, se puede observar se detectó al roedor 3 en las 75 muestras realizadas, alcanzando una precisión máxima (Figura 6) de detección de 93% (Tabla 5).

TABLA V  
PRECISIÓN DE DETECCIÓN DEL ALGORITMO

Roedor	Nº de muestras	Precisión máxima de detección
1	75	93 %
2	75	92 %
3	75	93 %

TABLA VI  
EFICIENCIA DE DETECCIÓN DEL ALGORITMO

Roedor	Nº de muestras	Coincidencias	Fallos	Eficiencia de detección	Error
1	75	73	2	97.33 %	2.67 %
2	75	74	1	98.67 %	1.33 %
3	75	75	0	100.00 %	- %

En la Tabla 6, se puede observar que, de las 75 muestras realizadas a cada roedor, el número de muestras sin detección fue de 2, 1 y 0 para el Roedor 1, Roedor 2 y Roedor 3 respectivamente. Asimismo, el porcentaje de eficiencia de detección del algoritmo para los 3 roedores fue de 97.33%, 98.67% y 100% respectivamente con errores de 2.67%, 1.33% y 0%, teniendo como base el número total de coincidencias, fallos y totalidad de muestras. Esto, representa un alto grado de confiabilidad, es decir, detecta la presencia de los roedores en un cultivo de maíz amiláceo.

TABLA VII  
EFICIENCIA PROMEDIO DE DETECCIÓN

Roedor	Eficiencia de detección
1	97.33 %
2	98.67 %
3	100.00 %
Promedio	98.67 %







Fig. 8 Eficiencia total por roedor

A partir de la Tabla 7 y Figura 8, se puede observar que, según las pruebas realizadas en la fase de validación, mediante el cálculo del promedio de la eficiencia del algoritmo, se obtuvo que este tiene una eficiencia promedio total de 98.67%, para detectar la presencia de roedores *Apodemus sylvaticus* en el cultivo de maíz amiláceo en tiempo real.

Por otro lado, en la Tabla 8, se presentan 3 imágenes de las 225 muestras realizadas en la fase de validación del algoritmo de visión artificial para la detección de roedores en el cultivo de maíz amiláceo; donde logra detectar a los roedores pese a la alta y poca iluminación natural, obstaculización de objetos y distancia de detección.

TABLA VIII  
PRUEBAS REALIZADAS

Roedor	Fotografía	Descripción
1		El algoritmo detectó la presencia del roedor con una precisión de 85%. A pesar de estar bien camuflado en el ambiente y con una gran luminosidad natural, arroja resultados positivos.
2		El algoritmo detectó la presencia del roedor con una precisión de 81% en un ambiente con poca luminosidad y presencia de objetos que obstaculizan partes del sujeto.
3		El algoritmo detectó la presencia del roedor con una precisión de 85% a pesar de encontrarse a una distancia considerable de la cámara.

Finalmente, para justipreciar el rendimiento del algoritmo de visión artificial, se utilizó la matriz de confusión, la cual, muestra la representación de las detecciones que realizó el modelo a la hora de validar. En este sentido, los elementos en la diagonal principal de una matriz binaria representan las predicciones correctas que se han realizado según el umbral de confianza, mientras que la diagonal opuesta indica las predicciones erróneas.






Figura 9. Matriz de confusión de la fase de entrenamiento

```

Matriz de Confusión:
[[23  0]
 [ 0 62]]
Reporte de Clasificación:
      precision    recall  f1-score   support

 background      1.00      1.00      1.00      23
      rat         1.00      1.00      1.00      62

 accuracy              1.00      85
 macro avg             1.00      85
 weighted avg          1.00      85
  
```

Figura 10. Métricas de la matriz de confusión de la fase de entrenamiento




Figura 11. Matriz de confusión de la fase de prueba

```

Matriz de Confusión:
[[ 40  0]
 [  0 119]]
Reporte de Clasificación:
      precision    recall  f1-score   support

 background      1.00      1.00      1.00      40
      rat         1.00      1.00      1.00     119

 accuracy              1.00     159
 macro avg             1.00     159
 weighted avg          1.00     159
  
```

Figura 12. Métricas de la matriz de confusión de la fase de prueba




Figura 13. Matriz de confusión de la fase de validación

```

Matriz de Confusión:
[[ 37  0]
 [  0 253]]
Reporte de Clasificación:
      precision    recall  f1-score   support

 background      1.00      1.00      1.00      37
      rat         1.00      1.00      1.00     253

 accuracy              1.00     290
 macro avg             1.00     290
 weighted avg          1.00     290
  
```

Figura 14. Métricas de la matriz de confusión de la fase de validación

Según la Figura 9, durante la fase de entrenamiento, se detectó 62 “Verdaderos Positivos” y 23 “Verdaderos Negativos”. Asimismo, en la Figura 11, durante la fase de prueba, se detectó 119 “Verdaderos Positivos” y 40 “Verdaderos Negativos”. Por último, en la Figura 13, durante la fase de validación, se detectó 253 “Verdaderos Positivos” y 37 “Verdaderos Negativos”, todo ello indica que, las predicciones son correctas pues no hay “Falsos Positivos” ni “Falsos Negativos”.

De la misma manera, en cuanto a las métricas de las matrices de confusión de las fases de entrenamiento, prueba y validación (Figura 10, 12 y 14) se concluye que el clasificador es “perfecto”, por arrojar valores de 1 para la precisión, recall, f1-score y accuracy. Por lo tanto, el modelo detecta la clase roedor muy bien y de manera confiable.

### III. DISCUSIÓN

Silva y Cobos en su investigación titulada “Sistema de detección de aves mediante análisis de imágenes”, utilizó el modelo de entrenamiento de YOLOv5 con un data set de 4952 imágenes y logró una precisión de detección del 80% tras probarlo en un ambiente natural [14]. A comparación con nuestro trabajo que alcanzó una mayor nivel de eficiencia de 98.67 % y un error de 1.33 % con una precisión máxima de detección de 93% en un ambiente no controlado e incluso detectando a los roedores en lugares con poca y mucha iluminación y presencia de objetos a pesar de emplear un data set menor al de Silva y Cobos. Esto se logró gracias al mayor número de librerías empleadas, tales como: Open CV, Base64, IO, PIL, Time y Pytorch.

Por otro lado, Seijas, Montilla y Frassato en su investigación titulada “Identificación de especies de roedores usando aprendizaje profundo” para la detección y clasificación de roedores emplearon la visión artificial mediante la red neuronal convolucional VGG-16 con un data set de 1411 imágenes, dando como resultado un error promedio de 1.9% y eficiencia promedio de 98.1% [15]. A comparación de nuestro trabajo que tiene una eficiencia mayor de 98.67 % y un error de 1.33%, debido al uso de una red neuronal convolucional más actualizada y pre entrenada Yolov5 con un data set de 3615 imágenes, lo cual permitió obtener detecciones más precisas.

#### IV. CONCLUSION

En el presente proyecto de investigación se logró desarrollar un algoritmo de visión artificial para la detección de plagas de roedores *Apodemus sylvaticus* en el cultivo de maíz para lo cual se trabajó con la red neuronal convolucional pre entrenada Yolov5.

Los resultados fueron positivos, mediante 75 muestras de validación realizadas a 3 roedores en un ambiente no controlado, es decir, en el cultivo de maíz, en diferentes horarios e iluminación, se obtuvo una eficiencia promedio de 98.67 % con un error de 1.33%.

En tal sentido, se rescata la importancia de realizar este proyecto, ya que permite asegurar la calidad del maíz amiláceo del cultivo, un insumo fundamental para las industrias de alimentos balanceados para aves y consumo humano.

#### REFERENCIAS

- [1] La cámara. El comportamiento del precio del maíz amarillo y sus efectos en el Perú. Disponible: <https://lacamara.pe/el-comportamiento-del-precio-del-maiz-amarillo-y-sus-efectos-en-el-peru/>
- [2] Instituto Nacional de estadística e informática. Producción de maíz amiláceo creció 25.8% y totalizó 78 mil 285 toneladas durante julio del 2022. <https://www.gob.pe/institucion/inei/noticias/653619-produccion-de-maiz-amilaceo-crecio-25-8-y-totalizo-78-mil-285-toneladas-durante-julio-del-2022>
- [3] Hernández N., & Soto F. (2012). Influencia de tres fechas de siembra sobre el crecimiento y rendimiento de especies de cereales cultivadas en condiciones tropicales. Parte I. Cultivo del maíz (ZEA MAYS L.). *Cultivos Tropicales*, 33 (2), 44-49. <http://scielo.sld.cu/pdf/ctr/v33n2/ctr06212.pdf>
- [4] Hernández A., Estrada B., Rodríguez R., García J., Patiño S., & Osorio E. (2019). Importancia del control biológico de plagas en maíz (Zea mays L.). *Revista mexicana de ciencias agrícolas*, 10(4), 803-813. Epub 22 de mayo de 2020. <https://doi.org/10.29312/remexca.v10i4.1665>
- [5] ONU (2021). El cambio climático y medio ambiente. <https://news.un.org/es/story/2021/06/1492762>
- [6] Sánchez V., Gutierrez G., Rodríguez Á. & Flores J. (2022). Roedores y riesgo agrícola. El modelado del nicho ecológico como herramienta de predicción. [https://www.researchgate.net/publication/360859414\\_Roedores\\_y\\_riesgo\\_agricola\\_El\\_modelado\\_del\\_nicho\\_ecologico\\_como\\_herramienta\\_de\\_prediccion](https://www.researchgate.net/publication/360859414_Roedores_y_riesgo_agricola_El_modelado_del_nicho_ecologico_como_herramienta_de_prediccion)
- [7] Belmain S. (2017). Ratas: Un enfoque ecológico para manejar un problema global. *Leisa*, 23(4), 24-27. <https://www.leisa-al.org/web/index.php/volumen-23-numero-4/1839-ratas-un-enfoque-ecologico-para-manejar-un-problema-global>
- [8] Ojeda A. (2022). "Plataformas tecnológicas en la Agricultura 4.0: Una mirada al desarrollo en Colombia", *J. Comput. Electron. Sci.: Theory Appl.*, 3(1), pp. 9–18, 2022. <https://doi.org/10.17981/cesta.03.01.2022.02>
- [9] Flórez C., Hurtado D. & Sandoval O. (2015). Procesamiento de imágenes para reconocimiento de daños causados por plagas en el cultivo de Begonia semperflorens (flor de azúcar). *Acta Agronómica*, 64(3): 273-279. <https://www.redalyc.org/articulo.oa?id=169940048012>
- [10] Atencio R. & Cruz E. (2022). Situación actual de la aplicación y potenciales usos de la visión artificial en la entomología agrícola en Panamá. *I+D Tecnológico*. 18. 124-135. <https://revistas.utp.ac.pa/index.php/id-tecnologico/article/view/3741/4313>
- [11] CEPLAN. (2021). Inteligencia Artificial: Desafíos y Oportunidades para el Perú. Disponible: <https://www.gob.pe/institucion/ceplan/informes-publicaciones/2296616-inteligencia-artificial-desafios-y-oportunidades-para-el-peru>
- [12] Sotomayor J., Gómez A. & Cela A. (2014) "Sistema de Visión Artificial para el Análisis de imágenes de Cultivo basado en Texturas Orientadas", *Revista Politécnica*, 33(1), 2014. [Online]. Disponible: [https://revistapolitecnica.epn.edu.ec/ojs2/index.php/revista\\_politecnica2/article/view/104/pdf](https://revistapolitecnica.epn.edu.ec/ojs2/index.php/revista_politecnica2/article/view/104/pdf)
- [13] León R., Díaz M. & Rodríguez, L. (2020). Gestión de un sistema de visión artificial para la detección de los daños causados por plagas en el cultivo de palto utilizando un dron. *Revista CIENCIA Y TECNOLOGÍA*, 16(4), 145-151. <https://revistas.unitru.edu.pe/index.php/PGM/article/view/3151/3874>
- [14] Silva, L., & Cobos, J. (2021). Sistema de detección de aves mediante análisis de imágenes. *Dom. Cien.* 7(6). 1464-1484. <https://dialnet.unirioja.es/descarga/articulo/8383787.pdf>
- [15] Seijas, C., Montilla, G., y Frassato, L. (2019). Identificación de especies de roedores usando aprendizaje profundo. *Computación y sistemas*, 23(1). <https://doi.org/10.13053/cys-23-1-2906>
- [16] Python Software Foundation (2023). Python. <https://docs.python.org/es/3.8/tutorial/index.html>
- [17] Microsoft (2023). GitHub Copilot y Visual Studio 2022. <https://visualstudio.microsoft.com/es/>
- [18] Python Software Foundation (2023). base64 — Codificaciones de datos Base16, Base32, Base64, y Base85. <https://docs.python.org/es/3/library/base64.html>
- [19] Python. (2023). io - Herramientas principales para trabajar con transmisiones. <https://docs.python.org/3/library/io.html>
- [20] Geeksforgeeks. (s.f). Pitón PIL | Método Imagen. Open() <https://www.geeksforgeeks.org/python-pil-image-open-method/>
- [21] Python. (2023). time— Acceso de tiempo y conversiones. <https://docs.python.org/3/library/time.html>
- [22] Microsoft. (2023). Preparación de datos de PyTorch. <https://learn.microsoft.com/es-es/windows/ai/windows-ml/tutorials/pytorch-data>
- [23] OpenCV. (2023). OpenCV-Python en Windows. [https://docs.opencv.org/4.x/d5/de5/tutorial\\_py\\_setup\\_in\\_windows.html](https://docs.opencv.org/4.x/d5/de5/tutorial_py_setup_in_windows.html)
- [24] Python. (s.f). Descripción del modelo. [https://pytorch.org/hub/ultralytics\\_yolov5/](https://pytorch.org/hub/ultralytics_yolov5/)