

Development of an Artificial Vision Algorithm for the Classification of Export or Domestic Consumption Strawberries

León León, Ryan Abraham¹ ; Boy Diaz, Carlos Sebastian¹ ; Gonzalez Palacios, José Jesús¹ 

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

²Student, Industrial Engineering Degree, Universidad Privada del Norte, Trujillo, Perú,
n00209835@upn.pe, n00205821@upn.pe

Abstract – This article developed an algorithm using computer vision employing a convolutional neural network with YOLO to classify strawberries for export and domestic consumption. This is crucial as export companies strive daily for the proper collection, sorting, and disposition of strawberries to enhance profitability. The tests were conducted on a Lenovo laptop with an Intel i7 processor and Windows 11. A Logitech c920 camera was used to detect the strawberry's coloration, which was integrated into the programming done in Visual Studio Code. The YOLOv5 network, specifically the YOLOv5x model, was employed, pre-trained with images collected by the research team. The training was done in Google Colab before integrating the neural network into the programming. After conducting various tests, an overall efficiency of 97.14% was achieved for both classifications with a margin of error of 2.86%. This outperforms other works, such as the thesis "Classification of apples using computer vision and neural networks," which attained an efficiency of 92.25%. Our results suggest that the application of this image processing system with neural networks will simplify processes and gradually increase productivity within the production line.

Keywords – YOLO, Convolutional, Neural Networks, Computer Vision.

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 Clasificación de Fresas de Exportación o Consumo Nacional

León León, Ryan Abraham¹ ; Boy Diaz, Carlos Sebastian¹ ; Gonzalez Palacios, José Jesús¹ 

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

²Student, Industrial Engineering Degree, Universidad Privada del Norte, Trujillo, Perú,
n00209835@upn.pe, n00205821@upn.pe

Resumen– El presente artículo desarrolló un algoritmo utilizando visión artificial aplicando una red neuronal convolucional utilizando YOLO para poder clasificar fresas para exportación y consumo nacional. Debido a que las empresas exportadoras se esfuerzan día con día para su correcto acopio, clasificación y disposición en busca de su rentabilidad. Las pruebas fueron realizadas en una laptop Lenovo con un procesador Intel i7 y Windows 11. Se utilizó una cámara Logitech c920 para detectar la coloración de la fresa, la cual fue incluida en la programación realizada en Visual Studio Code. Utilizamos la red YOLOv5 en su modelo YOLOv5x, la cual fue previamente entrenada con imágenes recopiladas por los integrantes de esta investigación, la cual entrenamos en Google Colab para posteriormente introducir nuestra red neuronal en la programación. Tras realizar diferentes pruebas, se obtuvo una eficiencia general en ambas clasificaciones del 97.14% con un margen de error del 2.86%. Logrando estar por encima de otros trabajos como los de la tesis “Clasificación de manzanas utilizando visión artificial y redes neuronales”, la cual obtuvo un 92.25% de eficiencia. Nuestros resultados indican que la aplicación de este sistema de procesamiento de imágenes con redes neuronales ayudará a simplificar procesos y aumentar gradualmente la productividad dentro de la línea de producción.

Palabras clave – YOLO, Convolucional, Redes neuronales, Visión artificial.

1. INTRODUCCIÓN

Las industrias determinan estrategias para alcanzar sus objetivos en el mercado. En el caso de la fresa (Fragaria annanasa), un fruto altamente demandado debido a su delicioso sabor y valor alimenticio, las pequeñas empresas exportadoras se esfuerzan por realizar un acopio, clasificación y disposición final eficientes para lograr una producción rentable. Para ello, se busca utilizar una sistematización adecuada para clasificar la fruta en diferentes etapas de madurez.

Python es una tecnología de codificación versátil que se caracteriza por ser interpretada, compatible con múltiples paradigmas y plataformas. Su aplicación principal se encuentra en campos como el análisis de grandes volúmenes de datos, la inteligencia artificial, Data Science, Testing Frameworks y Desarrollo Web “Referencia [1]”. La visión artificial, dentro del campo de la inteligencia artificial, emplea técnicas de procesamiento de imágenes para identificar patrones y características visuales en entornos diversos. Esta disciplina utiliza algoritmos para analizar imágenes, lo que implica múltiples interacciones en el procesamiento para obtener resultados precisos. Esta área de

estudio se centra en aplicaciones que van desde la detección de objetos hasta el reconocimiento facial, abarcando una amplia gama de aplicaciones en la vida cotidiana y en diversas industrias “Referencia [2]”. La investigación de León, Castillo y Soto emplea la visión artificial para identificar características específicas de los espárragos destinados a la industria alimentaria, centrándose en el color y el tipo de punta como criterios de clasificación. Se busca alcanzar una precisión óptima en el análisis de cada uno de estos aspectos. Para llevar a cabo esta tarea, se utiliza el lenguaje de programación Python. Los resultados de la investigación revelaron que, para obtener una precisión máxima del 95%, se requerían entre 50 y 200 tomas, destacando que la precisión máxima se alcanza a partir de las 150 tomas “Referencia [3]”. La investigación hecha por León, Bobadilla y Díaz propone un sistema de visión artificial basado en redes neuronales para detectar defectos en las variedades de papa Yungay y Huevo de Indio causados por el Premnotrypes Vorax. El desarrollo del software se realiza utilizando Python como lenguaje de programación y la plataforma TensorFlow. Se ha logrado un alto nivel de eficacia del 96.33% en la detección de defectos en la papa Yungay y del 95.12% en la papa Huevo de Indio “Referencia [4]”. La investigación de Nieto y Rangel crea un sistema utilizando visión artificial para evaluar el nivel de madurez de una fruta y predecir su tiempo de conservación. Este sistema arroja resultados precisos, confirmados mediante la comparación con la vida útil real de los plátanos. De esta manera, se logra estimar de manera efectiva tanto la maduración como el tiempo de conservación de la fruta “Referencia [5]”. La investigación de Alvarado y Molina describe el entrenamiento de una red neuronal convolucional profunda (CNN) del proyecto MobileNet de TensorFlow, diseñada para clasificar 13 categorías de frutas. La validación del modelo se lleva a cabo evaluando los tiempos de respuesta y la precisión de las predicciones. Como resultado, se logra una eficiencia del 87% en la clasificación de las frutas “Referencia [6]”. La investigación de Escobar y Castaño se basa en el procesamiento de imágenes para evaluar la madurez de las paltas. Se enfocaron en el color medio como la característica principal. Utilizaron el algoritmo Support Vector Machine (SVM) con OpenCV en Python y Raspberry Pi como sistema integrado. Desarrollaron un algoritmo que utilizó el procesamiento de imágenes digitales en una pequeña computadora Raspberry Pi 2B y una cámara Picam para

determinar la madurez de un aguacate, aunque con cierto margen de error “Referencia [7]”. La investigación de Escobedo y Cruz desarrolló un algoritmo de detección para identificar peras en su punto óptimo de maduración, destinado a la industria agrícola. Este algoritmo es capaz de reconocer las peras en tiempo real, utilizando tecnología que ajusta el brillo adecuado para una detección precisa. La eficacia del algoritmo se ha demostrado con una tasa de acierto del 98% y un tiempo de detección de tan solo 7.63 milisegundos, gracias a las técnicas avanzadas aplicadas al procesamiento de imágenes “Referencia [8]”. El estudio de Orbes implementó un sistema de detección y clasificación visual para la cosecha de fresas en la parroquia Andrade Marín, Ecuador. Se capturaron imágenes de las fresas cosechadas y se utilizó un conjunto de datos para entrenar una red neuronal basada en "MobileNetV2". El algoritmo resultante mostró una pérdida reducida de 1.7705599, una velocidad de reconocimiento de 0.123 segundos y una precisión del 82.91%, con una sensibilidad del 87% y una especificidad del 79% “Referencia [9]”. La investigación de Ati, Erazo, Ati y Martínez diseñó y desarrolló un prototipo que puede identificar tanto el tipo como el tamaño de las naranjillas y los tomates de árbol. Este sistema se basa en visión artificial por computadora, utilizando redes neuronales. Los algoritmos fueron implementados en Raspbian utilizando Python con las bibliotecas OpenCV y TensorFlow. Los resultados mostraron que el sistema funciona de manera óptima, con una precisión del 95% en la detección del tipo de fruta y del 93% en la identificación del tamaño. El tiempo de respuesta del sistema varía entre 0.3 y 1.3 segundos “Referencia [10]”. En el trabajo de investigación de Sacari, se evaluó la eficacia de la visión artificial en la detección de patrones para catalogar frutas en el sector agrícola. Se utilizó una base de datos de referencia con 50 registros de 6 frutas, considerando 4 atributos y 20 muestras de frutas utilizando un clasificador automático bayesiano. Las técnicas de reconocimiento de patrones lograron una eficiencia superior al 85% “Referencia [11]”. En el método propuesto por Calle para estimar parámetros de masa en racimos de uva, se consideran peso, calibre y apariencia como elementos clave. Se utiliza un algoritmo basado en SVM y ponderación de atributos para clasificar los racimos según su aptitud para exportación basada en su apariencia. El error estimado en calibre y peso fue del 7,7%. Se evaluaron tres variantes: dos utilizando redes neuronales (con errores del 14,6% y 19,8%, respectivamente) y una utilizando regresión lineal múltiple (con un error del 13,3%). En la clasificación del estado del racimo, una red neuronal convolucional con aprendizaje de transferencia alcanzó una precisión del 90,36% en la validación, mientras que SVM logró una precisión del 78,1% en la clasificación de grupos “Referencia [12]”. La investigación de Plata y Araujo ha propuesto un sistema para la clasificación de uchuvas. El desarrollo del software se llevó a cabo en Matlab, donde se implementaron tanto el tratamiento de imágenes como la red neuronal ART para el reconocimiento de las características del fruto. Se utilizó una base de datos de 300 imágenes, con 100 imágenes para cada etapa de maduración, todas con una resolución de 2688x2016 píxeles. Los resultados mostraron que el sistema alcanzó una precisión de hasta el 90.66% en las pruebas finales “Referencia [13]”. El trabajo de Rodríguez consistió en

desarrollar un clasificador de piñas mediante visión artificial basada en color y forma. El objetivo fue encontrar una solución óptima que no dañara ni contaminara las piñas. Se implementó un sistema de transporte de rodillos que capturaba imágenes con una cámara Raspberry Pi y una iluminación controlada. El prototipo logró una eficiencia del 96.99% y redujo el tiempo requerido en un 13.65%. Además, el clasificador realizaba la tarea sin afectar las piñas. Se sugiere utilizar un procesador más rápido para acelerar el tiempo de ejecución “Referencia [14]”. La investigación realizada por Gamonal se centra en el desarrollo de procesamiento digital de imágenes (DIP) para clasificar frutos cítricos. Se capturan imágenes en tiempo real con una cámara web y se realiza el preprocesamiento, segmentación y descripción de los frutos. El objetivo es crear un algoritmo que clasifique los frutos considerando tamaño, forma, color y posibles defectos. Los resultados se presentan de forma numérica y gráfica. El sistema logró una precisión del 93.3% “Referencia [15]”.

Dicho esto, el proyecto en cuestión resuelve la problemática de la selección manual de fresas mediante un sistema de selección basado en cámara de vídeo. La selección manual presenta problemas como la fatiga visual de los operarios. Por tanto, el objetivo principal es desarrollar un algoritmo de visión artificial para clasificar fresas destinadas a la exportación o consumo nacional, con el fin de realizar esta tarea de manera más eficiente. Como objetivos específicos tenemos: usar adecuadamente las librerías para realizar una red neuronal eficiente en YOLOv5 (OpenCV, NumPy, etc.). Teniendo también como proceso el tomar fotografías y vídeos durante las diferentes etapas de la madurez de la fresa.

2. METODOLOGÍA

2.1. Descripción de materiales

Python, siendo un lenguaje de programación versátil, se emplea en diversos ámbitos como la industria, la ciencia y la academia. Su amplia documentación y su capacidad para resolver problemas tanto teóricos como prácticos pueden estimular el aprendizaje autodidacta y la creatividad de los estudiantes. Además, su adopción en múltiples universidades demuestra su idoneidad para la enseñanza, sirviendo como un medio para integrar la teoría con la práctica de manera efectiva. En resumen, Python ofrece una plataforma propicia para el desarrollo de habilidades y la innovación en diversos campos, promoviendo así un aprendizaje más activo y significativo “Referencia [16]”. Además, Python, junto con todas las herramientas necesarias, está disponible en múltiples plataformas, lo que elimina restricciones de exclusividad en sistemas operativos. En nuestro proyecto, se utiliza OpenCV, que ofrece más de 2500 algoritmos implementados para diferentes aplicaciones.

También se empleó Google Colab, una plataforma de código abierto en la nube que admite escribir y ejecutar código en Python. Proporciona acceso libre a activos computacionales, como CPU y GPU, facilitando el desarrollo de iniciativas de aprendizaje automático y procesamiento de datos. También permite la colaboración en tiempo real, lo que lo convierte en una herramienta ideal para trabajar en equipo en proyectos de programación y

ciencia de datos “Referencia [17]”. Siendo YOLO un algoritmo de detección de objetos en imágenes y vídeos conocido por su velocidad y eficiencia. A diferencia de otros enfoques, YOLO realiza la detección y clasificación de objetos en una sola pasada, dividiendo la imagen en una cuadrícula y asignando cajas delimitadoras a las regiones con objetos. Utiliza un algoritmo de aprendizaje profundo para asignar etiquetas, estimar posiciones y tamaños. Esto permite una detección en tiempo real sin necesidad de múltiples etapas de procesamiento “Referencia [18]” Dentro de este, se utilizó el YOLOv5x, una versión avanzada del algoritmo YOLO que combina mayor precisión y velocidad en la detección de objetos. Gracias a su arquitectura de red neuronal profunda y su entrenamiento con amplios conjuntos de datos, el YOLOv5x puede realizar detecciones en tiempo real en diversas aplicaciones, como seguridad y conducción autónoma. Su enfoque eficiente y mejorado lo convierte en una poderosa herramienta para lograr una detección precisa y rápida de objetos en imágenes y vídeos “Referencia [19]”. Finalizando con la herramienta COCO.yaml, que es un archivo de configuración esencial en el conjunto de datos COCO (Common Objects in Context) utilizado para definir las clases de objetos y sus identificadores correspondientes. Este archivo proporciona las etiquetas y metadatos necesarios para anotar y entrenar modelos de detección de objetos. COCO.yaml contiene información sobre las categorías de objetos presentes en el conjunto de datos, como personas, automóviles, animales, y asigna un identificador único a cada categoría. Este archivo garantiza la consistencia y comprensión en el etiquetado y entrenamiento de modelos en el contexto de COCO “Referencia [20]”. Cabe mencionar dos puntos clave en esta investigación: Nos apoyamos del repositorio subido por Ultralytics, específicamente en YOLOv5, en su página de GitHub, el cual fue fundamental, ya que nos mostró cómo entrenar una red neuronal desde cero. Además, nos ayudó a importar las librerías y requerimientos necesarios para realizar un correcto entrenamiento a nuestra red neuronal, como se puede observar en la figura.

En esta investigación solo se utilizaron fresas en buen estado. Para la realización del proyecto, se utilizará un entorno controlado con una estructura cerrada y estable para garantizar la estabilidad y evitar cambios de iluminación que afecten los resultados. La estructura incluirá una base de análisis de imágenes y una iluminación artificial para estandarizar los resultados. Se empleará una cámara Logitech modelo C920s, conocida por su calidad de imagen excepcional. Esta cámara cuenta con dos micrófonos frontales, opciones de montaje versátiles y conectividad USB, lo que la hace perfecta para aplicaciones de procesamiento de imágenes inteligentes. La C920s tiene una lente de cristal de alta definición que proporciona vídeos Full HD, un amplio campo visual y corrección automática de iluminación HD para imágenes claras y detalladas en conferencias y demostraciones. La tapa del obturador protege la lente y garantiza la privacidad. La cámara tiene enfoque automático preciso y captura sonido estéreo nítido con sus dos micrófonos. La aplicación Capture facilita la creación, grabación y personalización de transmisiones, permitiendo ajustar la configuración de la cámara web. Gracias a la tecnología RightLight™ 2, la cámara se adapta a las condiciones de iluminación, produciendo imágenes

claras y bien contrastadas incluso en entornos oscuros. La lente de cristal de cinco elementos y el enfoque automático premium garantizan una alta definición constante durante las conferencias. Para la iluminación, se utilizará la linterna de un celular inteligente modelo Samsung S20 FE con una intensidad de nivel 1 para un reconocimiento preciso de las fresas.

2.2. Clasificación de acuerdo con el nivel de madurez

La evaluación del fruto se determina de acuerdo con unos parámetros de madurez, como a continuación se detalla: Primero, cuando aproximadamente 3/4 de la superficie del fruto presenta un tono rosado y un fondo blanquecino, es un indicativo de que está en su punto óptimo de madurez para ser comercializado en mercados lejanos. Otro es cuando el fruto exhibe un color rojo a rojo oscuro, ha alcanzado su nivel ideal de madurez para ser consumido fresco de inmediato o para ser utilizado en la industria de procesamiento “Referencia [21]”. Como se observa en la figura 1.



Figura 1. Clasificación de las fresas

2.3. Técnica utilizada

Siendo la técnica de redes neuronales convolucionales una arquitectura especializada para el procesamiento de imágenes y reconocimiento visual. Utilizando capas de convolución y de pooling, las CNN aprenden características y patrones relevantes, lo que las hace eficientes en clasificación, detección de objetos y segmentación. Su capacidad para capturar información espacial y compartir parámetros las hace populares en visión por computadora y tratamiento de imágenes “Referencia [22]”.

2.4. Algoritmo para entrenamiento de CNN

En la Figura 2 mostramos el proceso de entrenamiento de las CNN para el análisis de imágenes de fresas. Es fundamental seguir una serie de pasos meticulosos para garantizar el buen funcionamiento del modelo. Una vez que hemos recolectado imágenes referenciales de nuestras fresas y las hemos etiquetado utilizando herramientas como Make Sense, el siguiente paso es organizar y procesar los datos.

En Google Colab, después de cargar el archivo zip con las imágenes etiquetadas en nuestro Google Drive, procedemos a descomprimirlo. Luego, realizamos el preprocesamiento de las imágenes para preparar los datos de entrenamiento y validación.

Una vez completado el preprocesamiento, estamos listos para construir y entrenar nuestra red neuronal convolucional. Utilizamos una arquitectura de red que se ajuste a las características de nuestras imágenes de fresas. Es esencial definir capas convolucionales, capas de pooling y capas completamente conectadas de manera adecuada.

Después de finalizar el entrenamiento, descargamos la red neuronal y la incorporamos en nuestro programa local. Es crucial realizar pruebas exhaustivas para asegurarnos de que el modelo generalice bien en nuevas imágenes.

Evaluamos la precisión y la eficacia del modelo utilizando métricas como la matriz de confusión y la precisión.

Finalmente, al ejecutar el programa con nuevas imágenes de fresas, analizamos los resultados e interpretamos los datos que obtenemos.

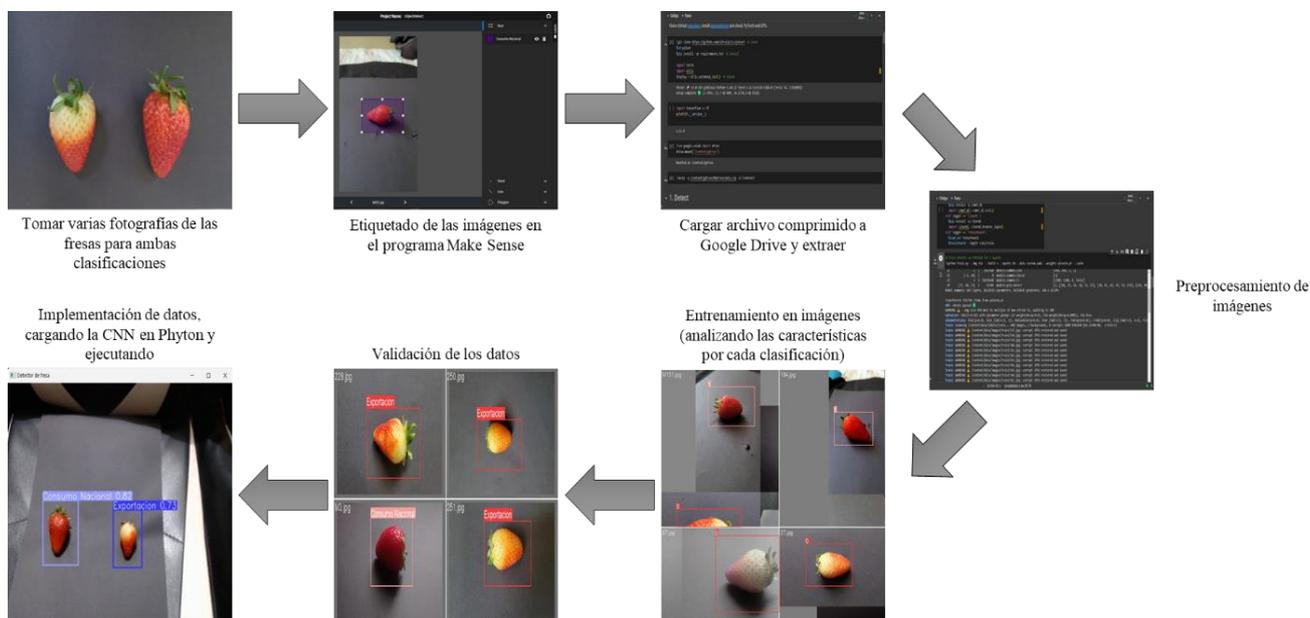


Figura 1. Algoritmo del Proyecto

Para poder realizar nuestro entrenamiento, primero importamos nuestras librerías que utilizaremos. En este caso, nos apoyaremos del repositorio de Ultralytics, el cual nos enseña cómo entrenar nuestra neurona paso a paso. Para hacer esta importación y clonación, utilizamos el siguiente código que podemos visualizar en la Figura 3:

```
!git clone https://github.com/ultralytics/yolov5 #
clonacion
%cd yolov5
!pip install -qr requirements.txt # instalacion
import torch
import utils
display = utils.notebook_init()
```

Figura 3. Preparación e importación para entrenamiento

Podemos observar que también instalamos los requerimientos que necesitamos para realizar nuestro proyecto. Ejecutamos y nos creará una carpeta llamada "yolov5" en la cual editaremos previamente el archivo COCO para colocar nuestras variables, las cuales son Exportación y Consumo Nacional. Guardamos y subimos el archivo, en este caso le colocamos el nombre Custom.yaml.

Posteriormente a esto, subimos nuestro archivo zip a un Google Drive, lo importamos en Google Colab y lo descomprimos, colocando la dirección a donde queremos que se dirija dicho archivo con los siguientes comandos mostrados en la Figura 4:

```
from google.colab import drive
drive.mount('/content/gdrive')
!unzip -q /content/gdrive/MyDrive/data.zip -d /content/
```

Figura 4. Importación del archivo de Google Drive

Mediante el siguiente comando, mostrado en la Figura 5, empezamos a entrenar y validar nuestro archivo. Colocamos como principal fuente la cantidad de imágenes que contamos en el archivo, entrenamos con nuestro archivo Custom y seleccionamos la clase yolov5x, la cual utilizamos en este proyecto.

```
!python train.py --img 914 --batch 4 --epochs 100 --data
custom.yaml --weights yolov5x.pt --cache
```

Figura 5. Código de entrenamiento de CNN

Extraemos el archivo y lo colocamos en nuestra programación para correr nuestra red neuronal, la cual se muestra en la siguiente Figura 6:

```
model = torch.hub.load('ultralytics/yolov5', 'custom',
path='C:/Users/joseg/OneDrive/Escritorio/AUTOMATIZACION
INDUSTRIAL/video/model/fresa.pt')
cap = cv2.VideoCapture(1)
while True:
ret, frame = cap.read()
detect = model(frame)
info = detect.pandas().xyxy[0]
print(info)
cv2.imshow('Detector de fresa', np.squeeze(detect.render()))
```

Figura 6. Código para ejecución de CNN

Podemos observar a detalle en la Figura 6 que importamos diferentes librerías e importamos el modelo junto con la ubicación de nuestra red neuronal, la cual tiene como nombre "fresa.pt". Detectamos las coordenadas y ejecutamos nuestro programa asignando en "cv2.VideoCapture(1)" el número uno, ya que utilizamos una cámara externa a la predeterminada. Esto se debe a que necesitamos una mayor resolución para una detección más precisa.

2.5. Arquitectura del Proyecto

Para poder entender cómo funciona una Red Neuronal Convolutiva, analizamos nuestra arquitectura (Figura 7). Empezamos con nuestra imagen, la cual separamos en los colores RGB y la transformamos en un escalado de grises. Posteriormente, asignamos cada píxel de la imagen a una capa; esto consideramos nuestras entradas. Es decir, el número de capas depende de cuántas neuronas tengamos; estas se dividen de acuerdo con la cantidad de píxeles que contenga la imagen. Comenzamos con nuestras convoluciones, las cuales extraen las características de nuestro objeto al momento de entrenar nuestra CNN; estas son llamadas neuronas simples. Seguidamente, procedemos al período de agrupación, el cual se basa en formar neuronas complejas que agrupan las neuronas simples extraídas de la convolución. Finalmente, pasamos a la etapa de las capas ocultas, las cuales clasifican el objeto, en este caso, ya sea para Exportación o Consumo Nacional, dándonos como resultado una salida clara que detecta nuestra fresa de manera precisa.

Se presenta la teoría con respecto a nuestra arquitectura y lo que sucede en ella.

Kernel gaussiano:

Sea la muestra x_i , el diccionario $D = \{s_j\}_{j=1:m}$ y el ancho de kernel σ .

Se define el kernel Gaussiano:

$$\kappa(x_i, s_j) = \exp\left(-\frac{(x_i - s_j)^2}{\sigma^2}\right) \quad (1)$$

Ecuación de kernel gaussiano

Como podemos verificar en la ecuación 1, las cualidades del kernel Gaussiano, la Función de Base Radial (RBF) permite calcular la distancia desde un centro específico, lo que la convierte en una medida de similitud entre muestras al evaluar la magnitud de la distancia que las separa. La dimensionalidad del espacio de propiedades se refiere a la expansión de la serie de Taylor de la función exponencial, generando un soporte infinito. Esto implica que utilizar el kernel exponencial es equivalente a trabajar

con una transformación de espacio de atributos con un soporte infinito. La interpretación de límites revela que el valor del kernel está en el rango de 0 a 1, donde 0 indica muestras idénticas y 1 muestra completamente diferentes. El ancho del kernel, representado por " σ ", controla la relación espacial de olvido entre muestras, es decir, cómo las muestras distantes afectan el resultado del cálculo del kernel. Cuando " σ " tiende a infinito, se obtiene una función rectangular que pondera todas las muestras por igual, mientras que cuando " σ " tiende a cero, se colocan funciones δ de Dirac enfocadas en cada elemento del diccionario, implicando que no se considere similitud alguna entre las muestras "Referencia [23]".

Capa Convolutiva:

$$S(i, j) = (K * I)(i, j) = \sum_m \sum_n I(m, n) K(i - m, j - n) \quad (2)$$

Ecuación de Convolución

En la ecuación 2, podemos observar que la convolución se refiere a un proceso en el cual un kernel se desliza sobre una imagen de entrada para extraer características. Cada posición en la imagen de salida, representada por $C(i, j)$, se calcula mediante la suma de productos entre los elementos del kernel, $K(m, n)$, y los correspondientes píxeles de la imagen de entrada, $I(i+m, j+n)$. Este proceso se repite para todas las posiciones (i, j) en la imagen de salida. La convolución es una operación clave en las CNN para extraer características de las imágenes. Los kernels son matrices pequeñas que se utilizan para realizar operaciones locales en la imagen de entrada. Al deslizar el kernel por toda la imagen, se generan mapas de características que capturan patrones importantes (bordes, texturas o formas). Es importante destacar que, en una CNN, la convolución puede involucrar múltiples canales de entrada y salida, lo que agrega una dimensión adicional a la fórmula. Sin embargo, la esencia de la operación de convolución en una CNN se resume en la fórmula básica mencionada anteriormente.

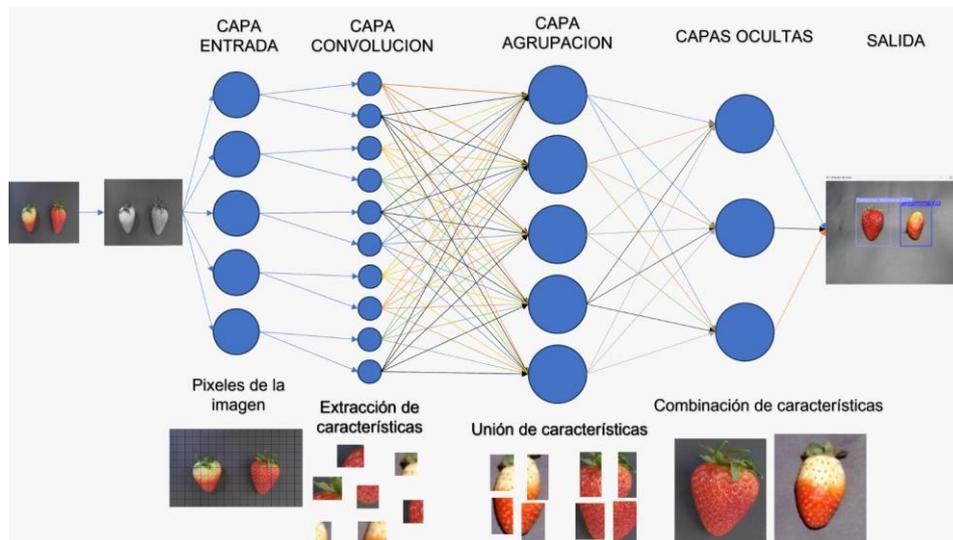


Figura 7. Arquitectura del Proyecto

3. RESULTADOS

Tabla 1. Datos obtenidos de acuerdo con las fresas examinadas (Día N° 1).

N° de fresas	Fresas de consumo nacional		Fresas de exportación	
	DETECTA	NO DETECTA	DETECTA	NO DETECTA
1	X		X	
2	X		X	
3	X		X	
4	X		X	
5	X		X	
6	X		X	
7	X		X	
8	X		X	
9	X		X	
10	X		X	
11	X		X	
12	X		X	

En la tabla 1 se observa que de las 24 pruebas que se realizaron, el programa no detectó 1 fresa de exportación y 1 fresa de consumo nacional.

Tabla 2. Porcentaje de eficiencia Día N° 1.

	DÍA 1
TOTAL DETECTO	22
TOTAL NO DETECTO	2
TOTAL	24
EFICIENCIA DÍA 1	92%

En la tabla 2 se observa que la eficiencia en el día N° 1 fue del 92% de fresas examinadas.

Tabla 3. Porcentaje total y promedio de eficiencias.

N° DIAS	EFICIENCIA
1	92%
2	96%
3	96%
4	96%
5	100%
6	100%
7	100%
Promedio	97.14%

En la tabla 3 se observa el promedio total de eficiencia durante los 7 días de prueba.

	DIA 1		DIA 2		DIA 3		DIA 4		DIA 5		DIA 6	
	DETECTA	NO DETECTA										
Fresas consumo nacional	11	1	12	0	12	0	12	0	12	0	12	0
Fresas exportación	11	1	11	1	11	1	11	1	12	0	12	

Figura 8. Resumen en porcentaje por tipo de fresa

N° de fresas	Fresas de consumo nacional		Fresas de exportación		DIA 1		DIA 2		DIA 3		DIA 4		DIA 5		DIA 6		DIA 7		TOTAL DE FRESAS ESTUDIADAS	EFICIENCIA
	DETECTA	NO DETECTA	DETECTA	NO DETECTA	DETECTA	NO DETECTA	DETECTA	NO DETECTA	DETECTA	NO DETECTA	DETECTA	NO DETECTA	DETECTA	NO DETECTA	DETECTA	NO DETECTA				
6	X		X																84	99%
7	X		X																	
8	X		X		11	X	1	12	0	12	0	12	0	12	0	12	0	12	84	99%
9	X		X																84	95%
10	X		X																	
11	X		X		11	X	1	11	1	11	1	12	0	12	0	12	0	12	84	95%
12	X		X																	

Figura 9. Resumen en porcentaje por tipo de fresa

En la Figura 8 y 9 se presenta el promedio de las pruebas llevadas a cabo a lo largo de cinco días. Durante este período, se mantuvo un control del ambiente para garantizar la calidad de las imágenes utilizadas. Además, se realizaron ajustes en el algoritmo. En cuanto a los resultados de las pruebas, se observó que el programa logró detectar con éxito el 99% de las fresas destinadas al consumo nacional y el 95% de las fresas destinadas a la exportación.

4. DISCUSIÓN

En la investigación "Clasificación de manzanas utilizando visión artificial y redes neuronales", se desarrolló un sistema automatizado diseñado para contabilizar y categorizar eficientemente las manzanas. Se obtuvo un 92.25% de eficiencia con respecto al estudio de campo, con un porcentaje de error del 7.75%. Este sistema se creó aprovechando librerías de código abierto como OpenCV, TensorFlow y Keras "Referencia [25]". En comparación con nuestra investigación, que tiene un porcentaje de eficiencia del 97.14% con un margen de error del 2.86%, en este artículo se utilizaron más librerías para el entrenamiento de la CNN. Esto nos indica que el sistema es mejorable mediante la ejecución de redes neuronales en YOLOv5x. Dicho esto, con un entrenamiento constante de nuestra CNN, el porcentaje de error disminuirá.

5. CONCLUSIONES

Se concluye que el algoritmo desarrollado clasifica de manera precisa las fresas, dejándolas listas para la exportación o el mercado nacional. Esta investigación demuestra ser eficiente y sugiere que el algoritmo de visión artificial puede mejorarse con más imágenes y entrenamientos adicionales, siempre que se utilicen correctamente las librerías.

En este trabajo se logra diferenciar entre fresas de exportación y fresas de consumo nacional gracias al

algoritmo. Aunque las nuevas tecnologías están simplificando procesos en las líneas de producción, aún requieren supervisión humana.

Hemos mejorado la eficiencia del algoritmo para su aplicación en empresas del sector alimentario. Además, hemos optimizado el proceso, dado que la clasificación actual se realiza de manera manual. Con la implementación de nuestro Sistema, se garantiza una mayor precisión en la clasificación.

En resumen, esta investigación es viable y confiable, ya que alcanzó una eficiencia del 97.14%. Además, se documentó todo el proceso de maduración con una serie de fotos y videos.

REFERENCIAS

- [1] E. Mendoza, "Implementación de herramientas Python en el proceso de producción de cultivos agrícolas del fundo San Juan de Buenavista," Tesis de Pregrado. Perú, 2021. https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/59522/Mendoza_VEA-SD.pdf?sequence=1&isAllowed=y
- [2] J. C. S. M. Pinedo, C. A. R. López, C. R. Grández y C. W. G. Estrella, "Reconocimiento de patrones de imágenes a través de un sistema de visión artificial en MATLAB," Revista Científica De Sistemas E Informática, vol. 1, no. 2, pp. 15–26, Jul. 2021. [Doi: 10.51252/resi.v1i2.131](https://doi.org/10.51252/resi.v1i2.131).
- [3] R. A. L. León, N. D. C. Alva y X. a. S. Lozada, "Sistema de Visualización Artificial de Clasificación de Espárragos en una Empresa Procesadora y Exportadora de Espárragos Frescos," Memorias, Mar. 2023. [Doi: 10.54808/cicic2023.01.192](https://doi.org/10.54808/cicic2023.01.192)
- [4] R. A. L. León, M. O.B. Valderrama y A. X. D. Alfaro, "Sistema de Visión Artificial Basado en Redes Neuronales para Identificar Defectos en la Papa Yungay y Huevo de indio Provocado por el Premnotyphes Vorax," LACCEI International Multi-Conference for Engineering, 2023. <https://dx.doi.org/10.18687/LACCEI2023.1.1.1057>
- [5] B. O. Nieto y J. C. Rangel, "Sistema de visión artificial para gestión de calidad del Banano Cavendish en etapa de postcosecha," Revista de Iniciación Científica, vol.8, no. 2, 2022. <https://doi.org/10.33412/rev-ric.v8.2.3670>
- [6] J. V. A. Alvarado y M. A. C. Molina, "Clasificación de frutas basadas en redes neuronales convolucionales," Polo del Conocimiento, vol. 5, no. 9. 2020. [Doi: 10.23857/pc.v5i01.1210](https://doi.org/10.23857/pc.v5i01.1210)
- [7] M. Escobar, J. Castaño, "Determinación del estado de madurez del aguacate mediante procesamiento de imágenes con la Raspberry PI," Tesis de Pregrado. Colombia, 2018. <https://repositorio.utp.edu.co/server/api/core/bitstreams/ee52d870-3ddb-47a1-ab1a-3b7790c0652a/content>
- [8] J. E. Gómez y B. E. C. Díaz, "Desarrollo de un algoritmo de visión artificial para el reconocimiento de la pera de agua en fase optima en su recolección aplicado en industria," Ingnofis, vol. 8, no. 1, 2022. <https://revistas.ucv.edu.pe/index.php/ingnosis/article/view/2826>
- [9] D. Orbes, "Implementación de un sistema de detección por visión artificial en la etapa de recolección del cultivo de fresas," Tesis de Maestría. Ecuador, 2022. <http://repositorio.utn.edu.ec/bitstream/123456789/12524/2/PG%201121%20TRABAJO%20DE%20GRADO.pdf>
- [10] V. M. A. Andaluz, C. A. E. Peñafiel, D. C. A. Andaluz y O. G. Martínez, "Dispositivo que permite la identificación por tipo y tamaño de la naranjilla y del tomate de árbol mediante visión artificial para mejorarla producción en," Alfa Publicaciones, vol. 4, no. 3.1, pp. 127-147, 2022. <https://doi.org/10.33262/ap.v4i3.1.242>
- [11] Sucari et al., "Visión artificial en reconocimiento de patrones para clasificación de frutas en agronegocios," Revista Científica. vol. 2, no. 2, 2020. <https://www.revistas.unah.edu.pe/index.php/puriq/article/view/76/185>
- [12] Calle et al., "Implementación de algoritmos de aprendizaje automático para la medición de parámetros de calidad de uva," Tesis de Bachiller. Perú, 2021. https://pirhua.udep.edu.pe/bitstream/handle/11042/4995/T_IME_2107.pdf?sequence=1&isAllowed=y
- [13] A. B. Plata y S. I. Araujo, "SISTEMA de visión artificial para la clasificación de uchuva basado en forma y color," Revista Interdisciplinar de Estudios en Ciencias Básicas e Ingenierías, vol. 6, no. 1, pp. 27-35, 2019. <https://dialnet.unirioja.es/servlet/articulo?codigo=8742501>
- [14] J. Rodríguez y J. Salazar, "Diseño, construcción y automatización de un prototipo de máquina clasificadora de piñas de acuerdo al color y forma por medio de visión artificial," Tesis de Pregrado. Ecuador, 2020. <http://dspace.espoeh.edu.ec/bitstream/123456789/15044/1/15T00743.pdf>
- [15] A. Gamonal, "Diseño de un sistema por visión artificial para determinar la calidad de mandarinas," Tesis de Pregrado. Perú, 2020. <https://repositorio.utp.edu.pe/handle/20.500.12867/3986>
- [16] E. S. Gómez, "Python en Ingeniería en Ciencias Informáticas," Dialnet, 2021. <https://dialnet.unirioja.es/servlet/articulo?codigo=8590581>
- [17] M. Kuroki, "Uso de Python y Google Colab para enseñar teoría microeconómica de pregrado," Revista Internacional de Educación Económica. EE. UU, 2021. <https://doi.org/10.1016/j.iree.2021.100225>
- [18] Jiang et al., "Una revisión de los desarrollos del algoritmo Yolo," Procedia Computer Science, vol. 199, pp. 1066-1073, 2022. [Doi: 10.1016/j.procs.2022.01.135](https://doi.org/10.1016/j.procs.2022.01.135)
- [19] G. Guo y Z. Zhang, "Algoritmo de detección de daños en la carretera para YOLOv5 mejorado," 2022. [doi:10.1038/s41598-022-19674-8](https://doi.org/10.1038/s41598-022-19674-8)
- [20] G. Jocher, S. Wamann, "COCO – Ultralíticos YOLOv8 Docs." 2023. <https://docs.ultralytics.com/datasets/detect/coco/#citations-and-acknowledgments>
- [21] Agrolibertad, "Ficha Técnica para el Cultivo de la Fresa (Fragaria x annanasa)." 2018. https://agrolibertad.gob.pe/wp-content/uploads/informacion-tecnica/fichas-tecnicas/agricola/Ficha%20T%20%92cnica%20para%20el%20Cultivo%20de%20la%20Fresa_0.pdf
- [22] N. Peleato, "Aplicación de redes neuronales convolucionales para la predicción de subproductos de desinfección." 2022. <https://www.nature.com/articles/s41598-021-03881-w>
- [23] Castro, I., "Predicción no lineal en línea de series de tiempo mediante el uso y mejora de algoritmos de filtros adaptivos de Kernel." Santiago de Chile, 2018. <https://repositorio.uchile.cl/bitstream/handle/2250/159306/Predicci%e3%b3n-no-lineal-en-l%e3%adnea-de-series-de-tiempo-mediante-el-uso-y-mejora-de-algoritmos-de-filtros-adaptivos-de-Kernel.pdf?sequence=1&isAllowed=y>
- [24] Introducción al Aprendizaje Automático, (2021). "Redes Neuronales Convoluciones." https://dcain.etsin.upm.es/~carlos/bookAA/05.7_RRNN_Convoluciones_CIFAR_10_INFORMATIVO.html
- [25] C. Mota, C. Juárez, J. Olguin, "Clasificación de manzanas utilizando visión artificial y redes neuronales artificiales." Revistas Científicas Editorial USCO. vol. 20, 2018. [doi: 10.25054/22161325.1917](https://doi.org/10.25054/22161325.1917)