

Desarrollo de un algoritmo de visión artificial que facilite la selección de paltas para exportación a los agricultores

Development of an artificial vision algorithm to facilitate the selection of avocados for export to growers

Desenvolvimento de um algoritmo de visão mecânica para facilitar a seleção de abacates para exportação pelos produtores

Montano Maldonado, Leslie Katherine¹

<https://orcid.org/0000-0002-8638-808X>

Vásquez Rodríguez, Alexandra Nicol²

<https://orcid.org/0009-0007-4512-3003>

Loor Zambrano, Jenniffer Elizabeth³

<https://orcid.org/0009-0003-3244-7827>

Luzardo Zamora, Jhonatan Alexander⁴

<https://orcid.org/0000-0003-4587-082X>

Castro Curay, José Alberto⁵

<https://orcid.org/0000-0003-0794-2968>

Recibido: 11.09.2023

Aceptado: 29.11.2023

RESUMEN

Este estudio presenta el desarrollo de un algoritmo de visión artificial para la selección de aguacates destinados a la exportación. Se empleó el modelo YOLOv7 utilizando aprendizaje de transferencia para construir el algoritmo, logrando una eficiencia del 96,36% en la identificación de aguacates aptos o no aptos para la exportación. El algoritmo demuestra un potencial significativo para mejorar los procesos de selección agrícola y las operaciones de almacén, ofreciendo una herramienta eficiente y prometedora para mejorar la calidad y la competitividad dentro de la industria agroexportadora.

Palabras claves: Selección de aguacates, calidad de exportación, visión artificial, redes neuronales.

ABSTRACT

This study presents the development of an artificial vision algorithm for avocado selection intended for exportation. The YOLOv7 model was employed using transfer learning to construct the algorithm, achieving an efficiency of 96.36% in identifying avocados suitable or unsuitable for export. The algorithm demonstrates significant potential to enhance agricultural selection processes and warehouse operations, offering an efficient and promising tool to improve quality and competitiveness within the agro-export industry.

Keywords: Avocado selection, export quality, artificial vision, neural networks.

RESUMO

Este estudo apresenta o desenvolvimento de um algoritmo de visão artificial para a seleção de abacates destinados à exportação. O modelo YOLOv7 foi empregado usando a aprendizagem por transferência para construir o algoritmo, alcançando uma eficiência de 96,36% na identificação de abacates adequados ou inadequados para exportação. O algoritmo demonstra um potencial significativo para aprimorar os processos de seleção agrícola e as operações de armazém, oferecendo uma ferramenta eficiente e promissora para melhorar a qualidade e a competitividade no setor de agroexportação.

Palavras Chave: Seleção de abacate, qualidade de exportação, visão artificial, redes neurais.

¹ Universidad Cesar Vallejo. Chimbote. Perú. Bachiller. lesliekmm@gmail.com

² Universidad Cesar Vallejo. Chimbote. Perú. Bachiller. nicolvasquezr21@gmail.com

³ British House Internacional. Lima. Peru. Bachiller. jenniloorz96@gmail.com

⁴ Universidad Cesar Vallejo. Chimbote. Perú. Bachiller. banksgfx3@gmail.com

⁵ Instituto Superior Tecnológico Público de Huarney. Huarney. Perú. Magister. jose.castro@iestphuarney.edu.pe

Introducción

La industria agroexportadora desempeña un papel esencial en la economía peruana, proporcionando productos alimenticios de alta calidad a los mercados internacionales. En este sentido, la selección de productos agrícolas, como las paltas, juega un papel esencial para garantizar la calidad y la competitividad en los mercados internacionales. Este proceso puede llegar a ser una tarea compleja, que tradicionalmente ha dependido de la experiencia y el juicio humano. Sin embargo, en la era actual de la tecnología y la automatización, se requieren herramientas tecnológicas en la selección de paltas que permitan cumplir con los estándares de calidad exigidos por los mercados internacionales con mayor eficiencia.

El director ejecutivo del Idexcam – CCL, Posada (2023), comparte que, en el último quinquenio, las exportaciones peruanas han mantenido una participación promedio del 25% en el producto Bruto Interno (PBI) del país, demostrando su sólido impacto económico. Asimismo, De la Vega (2023) en el diario El Peruano, refuerza esta idea al afirmar que el Perú exporta 5 000 diferentes productos a los diferentes países con los que trabaja. Llevando títulos como “principal exportador mundial de arándanos y uvas”, u otros de gran orgullo MIDAGRI (2023). Estos indicadores consolidan la presencia de Perú en el mercado internacional, pero no la aseguran, los exportadores deben cumplir múltiples requisitos para que sus productos sean aptos para posicionarse en los mercados del mundo. El MIDAGRI (2021), nos indica que los requisitos básicos para exportar, incluyen: Acceso a información oportuna, una planificación adecuada, la capacidad de competir en mercados extranjeros, y, por supuesto, contar con productos competitivos en precio, valor agregado y calidad. Este último término, “calidad”, no tiene una definición exacta pues depende de percepciones Cadena (2018), sin embargo, es un aspecto que hace progresar el posicionamiento competitivo de una empresa, tanto nacional como internacionalmente, y este posicionamiento determina el éxito empresarial de una marca Rugel y Chacón (2018). Hoy en día, y de manera más marcada, la calidad es la finalidad de cualquier sector comercial Carrión et al. (2020). En un mercado globalizado y con la internalización del comercio, la calidad obliga a las empresas a cumplir las expectativas del usuario e incluso superarlas, pues existe competencia entre las industrias y entre países Díaz y Salazar (2021). Las empresas peruanas deben priorizar estrategias que fomenten su competitividad, es decir, buscar constantemente generar el mejor producto con los recursos que tienen disponibles Medeiros et al. (2019), y de la manera más eficiente, tratando de obtener, conservar e incrementar una ventaja que supere a sus competidores en el mercado global Palomo y Pedroza (2018).

En la actualidad, la automatización representa esta pieza clave para poder competir en la industria productiva Quinteros et al. (2020), pues emplea diversas tecnologías que supervisan y controlan diferentes maquinarias e instrumentos sin la participación de personas; lo que mejora los procesos productivos Zapata et al. (2021). La automatización puede aplicarse para un sinnúmero de procesos, entre los que se encuentra la selección, proceso esencial para garantizar que el producto cumpla con estándares de calidad solicitados por el cliente Sucari et al. (2020). De automatizarse, se librarían así tareas humanas que resultan costosas, a pesar de sus limitaciones y susceptibilidad a cometer errores Romainville (2020), por supuesto, se acelerarían los periodos de tiempo Ferrara y Yupanqui (2018) ofreciéndole a la empresa mayor eficiencia y mayores ganancias. Esto se ha puesto a prueba en diversas investigaciones, entre las que se encuentra la de García, quien concluyó que la eficiencia con la herramienta de visión artificial que desarrolló fue del 91.5% comparado con la eficiencia de un clasificador experto García (2019). En el mismo sentido, encontramos la investigación de Bermeo y Zorrilla (2019) quienes determinaron que, con su sistema, disminuyó la posibilidad de fallo humano de 5.8% a 3.3%. Yamberla (2023) por su parte, evaluó paltas seleccionadas por la vista y experiencia de los inspectores, obteniendo como resultado que su herramienta ofrecía un 96.7% de eficiencia, así Pasuy (2019), comprobó la eficiencia ofrecida por su sistema en el tamaño y calidad de las paltas, obteniendo como resultado: 93.1% para el tamaño y 76.2% para la calidad.

Este proyecto se justifica en la necesidad de una herramienta tecnológica que permita mejorar la competitividad de los productores de paltas en el mercado internacional, asegurando la calidad y el cumplimiento de los estándares requeridos. Busca generar un nuevo aporte a la comunidad científica ofreciendo las líneas de código del proyecto para el uso y mejora por otros investigadores. En respuesta a lo mencionado, el presente estudio se plantea como objetivo general: el desarrollo de un algoritmo de

visión artificial diseñado para facilitar a los agricultores la selección de paltas destinadas a la exportación. Se definen como objetivos específicos: Utilizar de manera correcta la red neuronal convolucional. Identificar y trabajar con un dataset adecuado. Y, evaluar el desempeño del algoritmo de visión artificial desarrollado.

Material y métodos:

Para realizar este proyecto se necesitó la programación correspondiente, así como un entorno controlado para una mejor detección y confiabilidad evitando falsas lecturas. Los componentes a utilizar fueron: un aro de luz led 26 cm, una caja de fondo blanca 30x30x30, una laptop ACER con un GPU NVIDIA GeForce GTX 1650, una cámara y un sujetador para la cámara. El aro de luz permite el ajuste de intensidad y color, escogiéndose el color blanco que permite una mejor detección. La iluminación desde arriba ayudará a identificar los posibles desperfectos de la palta. Además, un lado de la caja será removible para facilitar la colocación de la palta en la posición para la detección correspondiente. Este ambiente controlado ayudará al programa con la detección pues, mejorará la visualización de la palta al hacer contraste y no interferir factores externos, tal como observamos en la figura 1.




Figura 1. Sistema controlado para selección de paltas

Respecto a la programación, para conseguir una inferencia precisa de la detección de paltas, se siguió un proceso integral que abarca la preparación del conjunto de datos, el entrenamiento del modelo y la fase de inferencia. El conjunto de datos o dataset utilizado en este estudio fue preparado mediante la plataforma Roboflow, una herramienta especializada en la organización y etiquetado de imágenes para aplicaciones de visión por computadora. Roboflow facilitó la recopilación, etiquetado y estructuración de las imágenes de frutos de aguacate utilizadas en el proyecto. Además, se le añadió un pequeño conjunto de fotos extras con mayor variedad, para mejorar el entrenamiento. Así, el dataset utilizado en este estudio se compone de cerca de 2000 imágenes de frutos de aguacate, elegidas con base en criterios que reflejan tanto los estándares de exportación como las condiciones que no cumplen con dichos estándares. El grupo de imágenes que representan las paltas óptimas, incluyen imágenes de paltas que cumplen con características de exportación, como el aspecto ovalado, la cáscara gruesa y con irregularidades, además, del color verde que pasa a violeta oscuro cuando madura Armas y Yoshitomi (2021). Por otro lado, el grupo de paltas que representan las paltas no óptimas, incluyen imágenes que muestran paltas que no cumplen con los estándares de exportación debido a diversas condiciones, como daños físicos, suciedad, madurez avanzada, enfermedades o presencia de hongos, que suelen desencadenar la exclusión de los frutos de la categoría de exportación de alta calidad Ucharima (2019). La inclusión de ambos grupos en el conjunto de datos permite al modelo de detección de objetos aprender a identificar no solo las paltas que cumplen con los estándares deseados, sino también aquellas que presentan condiciones no aptas para la exportación.

La segunda etapa del proceso se enfocó en la preparación y entrenamiento del modelo de detección de objetos. Para el entrenamiento se utilizó la técnica de transfer learning, la cual consiste en utilizar un modelo pre-entrenado y re-entrenarlo con un dataset propio. En este caso se utilizó el modelo yolov7

(YOLO Versión 07). Que se optó por utilizar debido a su eficiencia y capacidad probada para detectar objetos en imágenes en tiempo real. El proceso de detección de objetos de YOLOv7 se basa en una arquitectura de red neuronal convolucional (CNN) profunda, que se divide en múltiples capas de convolución y extracción de características. La base del funcionamiento de YOLO radica en su capacidad para predecir simultáneamente múltiples cuadros delimitadores y las probabilidades de clase asociadas con esos cuadros. Este enfoque permite que la red procese la imagen completa y optimice directamente el rendimiento de detección.

En primer lugar, la imagen se divide en una cuadrícula de tamaño $S \times S$, donde cada celda de la cuadrícula es responsable de detectar objetos presentes en esa región específica. Cada celda predice B cuadros delimitadores y sus correspondientes puntuaciones de confianza. La puntuación de confianza refleja tanto la probabilidad de que la celda contenga un objeto como la precisión de esa predicción. La generación de cuadros delimitadores se realiza mediante predictores, que son ternas de cinco neuronas de salida que indican las coordenadas (x,y) del centro del cuadro, sus dimensiones (w,h) , y la confianza asociada a ese cuadro. La confianza se calcula como se observa en la ecuación 1, donde $P(\text{Objeto})$ representa la probabilidad de que haya un objeto en la celda e IOU es el índice de Jaccard estimado entre el cuadro predicho y el cuadro real.

$$P(\text{Objeto}) \times \text{IOU} \dots\dots\dots (1)$$

Además de los predictores, cada celda está equipada con C neuronas clasificadoras que indican la probabilidad de que el objeto detectado pertenezca a una de las C clases determinadas (en este caso, paltas). El entrenamiento de YOLO se realiza mediante una función de pérdida que incluye tres componentes principales: Pérdida de Clasificación (L_{cls}), Pérdida de Localización (L_{loc}) y Pérdida de Confianza (L_{conf}). Finalmente, la pérdida total (L) es la suma ponderada de estas pérdidas. La arquitectura de la red YOLO consta de 24 capas convolucionales y 2 capas completamente conectadas, tal como se observa en la figura 2. Este enfoque permite una detección eficiente de objetos, como paltas, en imágenes y se ajusta específicamente a las necesidades del proyecto para seleccionar paltas óptimas para exportación.

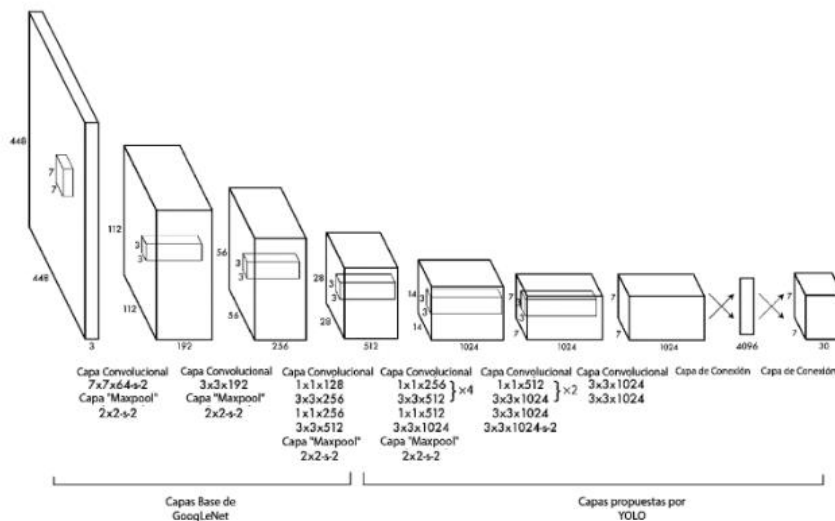


Figura 2. Arquitectura de YOLO

Es importante aclarar que la convolución es una operación fundamental en el aprendizaje profundo que implica el análisis pixel por pixel de las imágenes captadas. A medida que las capas de convolución se apilan en la red, se van extrayendo características de mayor nivel, lo que permite al modelo comprender patrones más complejos en las imágenes. En la Figura 3 podemos observar como la convolución se aplica en la arquitectura del algoritmo planteado.




Figura 3. Arquitectura del algoritmo

La convolución, un tipo de operación lineal, se refiere a la combinación de dos funciones, $x(t)$ y $w(t)$, representada como $(x * w)(t)$ o $s(t)$, como se muestra en la ecuación 2:

$$s(t) = (x * w)(t) = \int x(a)w(t - a)da \dots \dots \dots (2)$$

En el contexto de las CNN, $x(t)$ se refiere a la entrada, $w(t)$ representa el núcleo o kernel, y $s(t)$ es la salida generada por la convolución, conocida como mapa de características. Al discretizar los datos, si t se limita a valores enteros y w está definida exclusivamente en valores enteros, entonces obtendríamos la ecuación 3:

$$s(t) = (x * w)(t) = \sum_{a=-\infty}^{\infty} x(a)w(t - a) \dots \dots \dots (3)$$

Luego de haber implementado el dataset y haber realizado el entrenamiento correspondiente, se procedió a elaborar el algoritmo necesario para la inferencia. Ésta utiliza el modelo entrenado y lo ejecuta en tiempo real. Para lograr utilizar el modelo entrenado, se utilizó la librería PyTorch. Además, se usaron librerías como OpenCV, bastante popular en este tipo de proyectos; Pillow, una librería de manejo de imagen; y numpy, que nos permite trabajar los frames capturados como arrays. El programa se implementó utilizando PyCharm Community Edition 2023.2.1 como editor de código, pues sus diversas funciones facilitan la programación y ejecución de los programas codificados. Asimismo, el lenguaje de programación elegido fue Python. En la tabla 1 se muestran las líneas de código esenciales del algoritmo, junto a una breve descripción de su función.

Tabla 1.
Explicación de líneas de código

LÍNEAS DE CÓDIGO	FUNCIONALIDAD
import torch import cv2 from PIL import Image import numpy as np	Importación de librerías (PyTorch, OpenCV, Pillow y numpy)
DEVICE = "cuda" if torch.cuda.is_available() else "cpu"	Se define la variable DEVICE que definirá si se usa CPU o GPU
model = torch.hub.load('WongKinYiu/yolov7', 'custom', 'model-avocado-export/model-export.pt',force_reload=False, trust_repo=True)	Se carga un modelo YOLOv7 personalizado. El modelo se carga desde un archivo pre-entrenado llamado 'model-export.pt'.
model.conf = 0.5	Se establece la sensibilidad del modelo en 0.4. Esto controla la confianza requerida para que el modelo detecte un objeto en la imagen.
cam = cv2.VideoCapture(0)	Se inicializa la captura de video desde la cámara web con OpenCV.
ret, frame = cam.read()	Lee un fotograma de la cámara web y lo almacena en la variable frame. ret indica si la lectura fue exitosa.
frame = cv2.flip(frame, 1)	Voltea el fotograma horizontalmente para que no esté invertido.
result = model(frame,size=640)	Realiza la inferencia en el fotograma utilizando el modelo cargado. El resultado se almacena en la variable result.
cv2.imshow('Palta', np.squeeze(result.render()))	Muestra el fotograma resultante con las detecciones en una ventana llamada 'Palta'.

Resultados

Se realizaron 110 pruebas del algoritmo desarrollado, usando paltas que se encontraban en diferentes estados para corroborar si el programa respondía de manera correcta. El algoritmo desarrollado ofrece dos resultados, uno positivo si la palta cumple con las condiciones para ser exportada, en el que figura la etiqueta “Exportable” (Figura 4); y uno negativo si la palta no cumple con las condiciones necesarias, que presenta la etiqueta “Rechazado” (Figura 5). Se capturó pantalla de cada resultado obtenido durante el periodo de pruebas para su posterior registro y análisis, tal como vemos en la Figura 6.

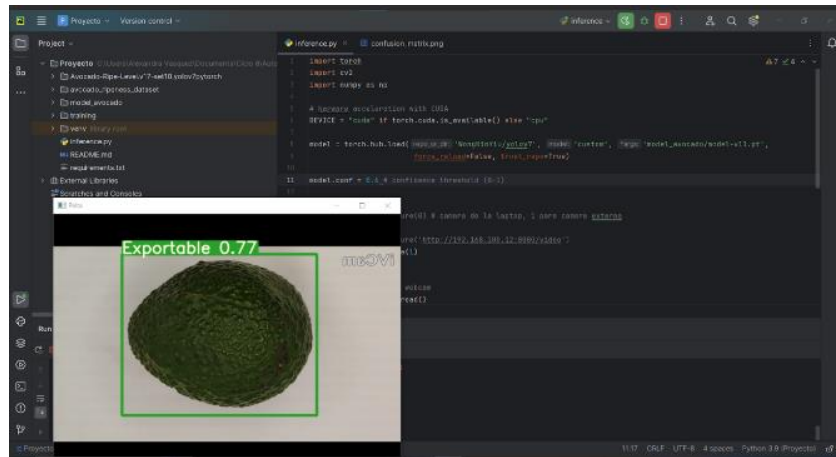


Figura 4. Prueba: Palta Exportable

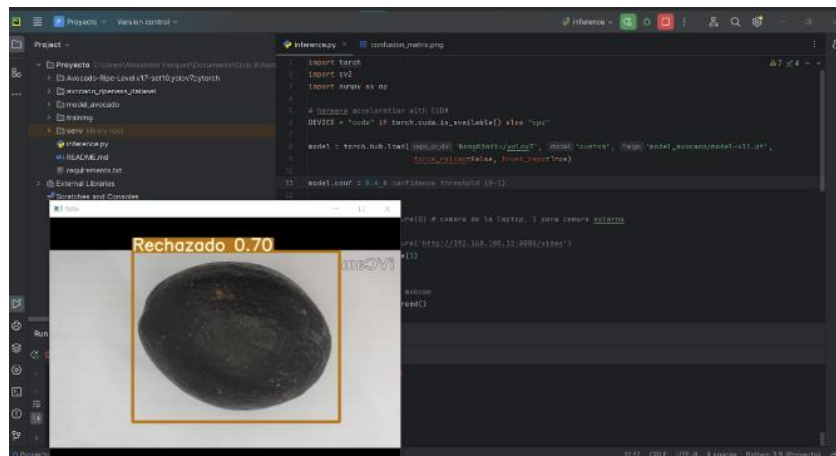


Figura 5. Prueba: Palta Rechazada




Figura 6. Pruebas realizadas

Obteniéndose así los resultados mostrados en la tabla 2, en la que se utilizaron las abreviaciones VP para los verdaderos positivos, VN para los verdaderos negativos y FP para los Falsos positivos.

Tabla 2.
Resultados de pruebas realizadas

N°	Resultado	N°	Resultado
1	Exportable (VP)	56	Exportable (VP)
2	Exportable (FP)	57	Exportable (VP)
3	Exportable (VP)	58	Exportable (VP)
4	Rechazado (VN)	59	Exportable (VP)
5	Exportable (VP)	60	Exportable (VP)
6	Exportable (VP)	61	Exportable (VP)
7	Rechazado (VN)	62	Exportable (VP)
8	Exportable (VP)	63	Exportable (VP)
9	Exportable (VP)	64	Rechazado (VN)
10	Exportable (VP)	65	Exportable (VP)
11	Exportable (VP)	66	Exportable (VP)
12	Rechazado (VN)	67	Exportable (VP)
13	Exportable (VP)	68	Exportable (VP)
14	Rechazado (VN)	69	Exportable (VP)
15	Rechazado (VN)	70	Rechazado (VN)
16	Exportable (VP)	71	Exportable (VP)
17	Rechazado (VN)	72	Exportable (VP)
18	Exportable (VP)	73	Exportable (VP)
19	Exportable (VP)	74	Exportable (VP)
20	Exportable (VP)	75	Exportable (VP)
21	Exportable (VP)	76	Exportable (VP)
22	Exportable (VP)	77	Exportable (VP)
23	Exportable (FP)	78	Exportable (VP)
24	Exportable (VP)	79	Rechazado (VN)
25	Exportable (VP)	80	Exportable (VP)
26	Exportable (VP)	81	Exportable (VP)
27	Exportable (FP)	82	Exportable (VP)
28	Exportable (VP)	83	Exportable (VP)
29	Exportable (VP)	84	Exportable (VP)
30	Rechazado (VN)	85	Rechazado (VN)
31	Exportable (VP)	86	Exportable (VP)
32	Rechazado (VN)	87	Exportable (VP)
33	Exportable (VP)	88	Exportable (VP)
34	Exportable (VP)	89	Exportable (VP)
35	Exportable (FP)	90	Exportable (VP)
36	Exportable (VP)	91	Exportable (VP)
37	Rechazado (VN)	92	Exportable (VP)
38	Exportable (VP)	93	Exportable (VP)
39	Exportable (VP)	94	Exportable (VP)
40	Exportable (VP)	95	Exportable (VP)
41	Exportable (VP)	96	Exportable (VP)
42	Exportable (VP)	97	Exportable (VP)
43	Exportable (VP)	98	Exportable (VP)
44	Rechazado (VN)	99	Rechazado (VN)
45	Exportable (VP)	100	Exportable (VP)
46	Exportable (VP)	101	Exportable (VP)
47	Exportable (VP)	102	Exportable (VP)
48	Exportable (VP)	103	Exportable (VP)
49	Rechazado (VN)	104	Exportable (VP)
50	Exportable (VP)	105	Exportable (VP)
51	Exportable (VP)	106	Exportable (VP)
52	Exportable (VP)	107	Exportable (VP)
53	Exportable (VP)	108	Exportable (VP)
54	Exportable (VP)	109	Rechazado (VN)
55	Exportable (VP)	110	Exportable (VP)

Con los resultados obtenidos, se realizó la matriz de confusión. La Figura 7 representa el esquema de matriz de confusión que se empleará, y en la Figura 8, la matriz de confusión con el resumen de los resultados obtenidos en las pruebas.

		PREDICCIONES	
		Exportable	Rechazado
REALES	Exportable	Verdadero Positivo	Falso Negativo
	Rechazado	Falso Positivo	Verdadero Negativo

Fig 7. Matriz de Confusión

		PREDICCIONES	
		Exportable	Rechazado
REALES	Exportable	89	0
	Rechazado	4	17

Figura 8. Matriz de confusión del proyecto

Asimismo, con los resultados obtenidos, se calcularon diversos indicadores que se mostrarán a continuación:

La eficiencia, que representa la fracción de predicciones que el programa identificó correctamente respecto al total de muestras. La eficiencia del proyecto se calculó como se puede ver en la ecuación 4.

$$\frac{\text{Predicciones Correctas}}{\text{Total de predicciones}} = \frac{89 + 17}{110} = 0.9636 \dots \dots \dots (4)$$

La precisión, que es empleada para conocer que paltas de todas las pruebas realizadas que se clasificaron como positivos son positivos realmente. La precisión del proyecto se calcula en la ecuación 5.

$$\frac{\text{Verdadero Positivos}}{\text{Verdadero Positivos} + \text{Falsos Positivos}} = \frac{89}{89 + 4} = 0.96 \dots \dots \dots (5)$$

El recall, que es una métrica de evaluación que se emplea para conocer cuáles de los positivos reales son identificados correctamente. El recall del presente proyecto se calculó en la ecuación 6.

$$\frac{\text{Verdadero Positivos}}{\text{Verdadero Positivos} + \text{Falsos Negativos}} = \frac{89}{89 + 0} = 1 \dots \dots \dots (6)$$

La métrica de evaluación F1 score que combina las medidas de precisión y recall en solo una puntuación. Si esta medida es más cercana a 1, significa que el programa cumple con su propósito. La métrica F1 score del proyecto se calcula en la ecuación 7.

$$F_1 \text{ score} = \frac{2}{\frac{1}{\text{presicion}} + \frac{1}{\text{recall}}} = \frac{2}{\frac{1}{0.96} + 1} = 0.98 \dots \dots \dots (7)$$

Discusión

Al observar los resultados obtenidos, encontramos que la eficiencia obtenida con el algoritmo que usa redes neuronales para la selección de paltas para exportación (96.36%), resulta mayor que la eficiencia que obtuvo una investigación que utilizó la visión por computadora para la clasificación por categorías

de calidad de paltas García (2019). Ésta analizó una muestra de 702 paltas agrupadas en dos pruebas, obteniendo una eficiencia de 91.5%. Del mismo modo, el presente proyecto presenta una eficiencia mayor a la obtenida en un trabajo que busca ofrecer un algoritmo que permite clasificar paltas mediante la adquisición y procesamiento de imágenes Pasuy (2019), en la que se analizó una muestra de 231 paltas de diferente tamaño y calidad, y se obtuvo una eficiencia de 76.19% respecto a la clasificación de la calidad. Sin embargo, la eficiencia que consigue el presente proyecto, resulta menor a la de una investigación que utiliza hardware y software unidos en la implementación de un sistema automático de selección de paltas según sus índices de calidad Yamberla (2023), que obtuvo una eficiencia de 96.7%

Conclusiones

El objetivo principal de este proyecto consistió en crear un algoritmo de visión artificial a base de redes neuronales para identificar paltas aptas para exportación, cumpliendo satisfactoriamente con esta meta. El sistema desarrollado permitió la identificación y clasificación de paltas óptimas y no óptimas para exportación, mostrando una eficiencia del 96.36% en esta selección.

La implementación de este software de visión artificial se muestra como una oportunidad significativa para mejorar los procesos agrícolas. Su aplicación en la clasificación de paltas no solo potenciaría la eficiencia en la selección para agricultores, sino que también reduciría el tiempo de clasificación en centros de acopio, asegurando una precisión constante y evitando el agotamiento asociado con la labor humana.

A pesar de la eficiencia del sistema, se sugiere que los aspectos técnicos sean objeto de mejoras futuras para aumentar aún más la eficiencia del algoritmo.

Referencias

Posada U., Carlos (2023). Conozca la importancia de los TLC para la economía peruana. <https://lacamara.pe/conozca-la-importancia-de-los-tlc-para-la-economia-peruana/>. [Accessed enero 20, 2023].

De la Vega P., Miguel (2023). El Perú exporta 5,000 diferentes productos al mundo. <https://www.elperuano.pe/noticia/204582-el-peru-exporta-5000-diferentes-productos-al-mundo>. [Accessed enero. 20, 2023].

Ministerio de Desarrollo Agrario y Riego, (2023). MIDAGRI: La meta es lograr que las agroexportaciones peruanas superen los US\$ 11 mil millones en este año. <https://www.gob.pe/institucion/midagri/noticias/735754-midagri-la-meta-es-lograr-que-las-agroexportaciones-peruanas-superen-los-us-11-mil-millones-en-este-ano>. [Accessed marzo 30, 2023].

Ministerio de Desarrollo Agrario y Riego (2021). Cuáles son los Requisitos Básicos para Exportar. <https://www.midagri.gob.pe/portal/comercio-exterior/icom-exportar/introduccion62/670-cuales-son-los-requisitos-basicos-para-exportar>. [Accessed Sept. 23, 2022].

Cadena, O. (2018). Gestión de la calidad y productividad. *Universidad de las Fuerzas Armadas ESPE*.

Rugel Kamarova, S., & Chacón Cantos, J. (2018). Teorías, modelos y sistemas de gestión de calidad. Artículo de revisión. <http://biblioteca.udgvirtual.udg.mx/jspui/handle/123456789/3469>

Carrión G., A.; Jabaloyes V., J. M., & Carot Sierra, J. M. (2020). Introducción a la gestión de la calidad. *Colección Académica*. <https://riunet.upv.es/handle/10251/152213>

Díaz M., G. A., & Salazar D., D. A. (2021). La calidad como herramienta estratégica para la gestión empresarial. *Podium*, (39), 19-36. <https://doi.org/10.31095/podium.2021.39.2>

Medeiros, V.; Godoi, L. G. & Teixeira, E. C. (2019). La competitividad y sus factores determinantes: un análisis sistémico para países en desarrollo. <https://hdl.handle.net/11362/45005>

Palomo González, M. Á., & Pedroza Zapata, Á. R. (2018). La competitividad empresarial: el desarrollo tecnológico. <http://editorialuniversitaria.uanl.mx/>

Quinteros, P. R. A., Zurita, M. C., Zambrano, N. C., & Manchay, E. L. (2020). Automatización de los procesos industriales. *Journal of business and entrepreneurial studies: JBES*, 4(2), 123-131. [Automatización de los procesos industriales - Dialnet](#)

Zapata, M., Topón-Visarrea, L., & Tipán, É. (2021). Fundamentos de automatización y redes industriales. <https://repositorio.uti.edu.ec/handle/123456789/2226>.

Sucari, L. R., Durán, Y. A., Yapo, E. Q., León, A. S., Quina, L. D. Q., & Torres, F. A. H. (2020). Visión artificial en reconocimiento de patrones para clasificación de frutas en agronegocios. *Puriq*, 2(2). <https://shs.hal.science/halshs-02554550/>.

Romainville I., Miriam (2020). Del campo al packing: las claves del manejo de frío para garantizar la calidad de la uva de mesa. <https://redagricola.com/del-campo-al-packing-las-claves-del-manejo-de-frio-para-garantizar-la-calidad-de-la-uva-de-mesa/>. [Accessed enero 23, 2023].

Ferrara De Fina, A., & Yupanqui Rodríguez, R. R. (2018). Oferta exportable de palta hass de la asociación Pro Palto para el mercado Español, Chao-La Libertad 2018. <https://hdl.handle.net/20.500.12692/26815>

García Vigil, M. E. (2019). Aplicación de visión por computadora en la clasificación según categorías de calidad de palta (persea americana mill) variedad hass. <https://hdl.handle.net/20.500.12759/5572>

Bermeo Vargas, E. I., & Zorrilla Pascual, D. A. (2019). Desarrollo de un sistema automático de selección de paltas Hass por sus índices de calidad para la empresa Agroindustrias Verdeflor SAC. <http://hdl.handle.net/10757/629958>

Yamberla D., S.S. (2023). Algoritmo para la clasificación de aguacates tipo fuerte según el estado de madurez mediante visión artificial, thesis, Universidad Técnica del Norte. <http://repositorio.utn.edu.ec/handle/123456789/14336>.

Pasuy Q., P. (2019). Clasificación de aguacates basado en visión por Computador, thesis, Universidad Técnica del Norte. <http://repositorio.utn.edu.ec/handle/123456789/9364>.

Armas H., M. E., & Yoshitomi E., D. X. (2021). Factores determinantes en la evolución de la exportación de palta Hass con partida arancelaria 0804400000 a países bajos en el marco del TLC Perú-UE durante los años 2012-2019. <https://repositorioacademico.upc.edu.pe/handle/10757/653440>.

Ucharima P., M.T. (2019). Procesamiento de palta para la exportación”, thesis, Universidad Nacional San Luis Gonzaga, Pisco. <https://hdl.handle.net/20.500.13028/3905>