

Desarrollo de visión artificial con redes neuronales para identificación de imperfecciones en envases de atún con tres cámaras

Development of artificial vision with neural networks for identification of imperfections in tuna packaging with three cameras

Desenvolvimento de visão computacional com redes neurais para identificação de imperfeições em embalagens de atum utilizando três câmeras

Deza Villafana, Alessandro Del Piero¹

<https://orcid.org/0000-0002-7691-1738>

Farfán Canchis, Crhistian Omar²

<https://orcid.org/0000-0002-7108-1640>

Obando Rubio, Alexandra Iveth³

<https://orcid.org/0000-0002-7599-9619>

Pita Quiliche, Daniel Alberto⁴

<https://orcid.org/0000-0003-3811-3142>

Valderrama Benites, Keysi Alexandra⁵

<https://orcid.org/0000-0003-4797-3224>

Velásquez de la Cruz, Rodolfo⁶

Recibido: 15.12.2023

Aceptado: 30.01.2024

RESUMEN

La presente investigación tiene como objetivo describir el desarrollo de visión artificial con redes neuronales para identificar las imperfecciones presentes en las latas de atún usando tres cámaras. Para el desarrollo del sistema se utilizó Python y bibliotecas especializadas como TensorFlow, OpenCV, NumPy y Keras. Se implementó una red neuronal convolucional (CNN) con imágenes etiquetadas de latas en buen y mal estado. El sistema usa tres cámaras para inspeccionar las latas desde múltiples ángulos y aplica filtros como desenfoque Gaussiano, umbral adaptativo y algoritmo de Canny para mejorar la calidad de las imágenes y la precisión en la detección de bordes. Se logró una precisión del 98.17% en el entrenamiento y del 98.76% en la validación de imágenes. Se recomienda realizar pruebas adicionales con conjuntos de datos más amplios, optimizar el algoritmo de detección de bordes, explorar otras arquitecturas de redes neuronales y considerar la integración con robótica para automatizar el proceso de inspección. Finalmente, se concluye que el sistema desarrollado es una herramienta efectiva para detectar abolladuras en latas de atún, mejorando el control de calidad, reduciendo costos y garantizando la seguridad del producto final en la industria alimentaria.

¹

Universidad Cesar Vallejo. Chimbote. Perú. Bachiller. ddezavi@ucvvirtual.edu.pe

²

Universidad Cesar Vallejo. Chimbote. Perú. Bachiller. cfarfanca@ucvvirtual.edu.pe

³

Universidad Cesar Vallejo. Chimbote. Perú. Bachiller. aobandoru@ucvvirtual.edu.pe

⁴

Universidad Cesar Vallejo. Chimbote. Perú. Bachiller. dpitaqu23@ucvvirtual.edu.pe

⁵

Universidad Cesar Vallejo. Chimbote. Perú. Bachiller kvalderramab@ucvvirtual.edu.pe

⁶

Universidad Cesar Vallejo. Chimbote. Perú. Bachiller. rvelasquezcr@ucvvirtual.edu.pe

Palabras clave: Conservas de atún, Detección de abolladuras, Librería de código libre, Python, Redes Neuronales.

ABSTRACT

The objective of this research is to describe the development of artificial vision with neural networks to identify imperfections in tuna cans using three cameras. Python and specialized libraries such as TensorFlow, OpenCV, NumPy and Keras were used to develop the system. A convolutional neural network (CNN) was implemented with labeled images of cans in good and bad condition. The system uses three cameras to inspect cans from multiple angles and applies filters such as Gaussian blur, adaptive thresholding, and Canny algorithm to improve image quality and edge detection accuracy. An accuracy of 98.17% was achieved in training and 98.76% in image validation. It is recommended to perform additional testing with larger data sets, optimize the edge detection algorithm, explore other neural network architectures, and consider integration with robotics to automate the inspection process. Finally, it is concluded that the developed system is an effective tool to detect dents in tuna cans, improving quality control, reducing costs and guaranteeing the safety of the final product in the food industry.

Keywords: Canned tuna, Dent detection, Open source library, Python, Neural Networks.

RESUMO

O objetivo geral da pesquisa foi aplicar o planejamento de requisitos de distribuição para reduzir os tempos de distribuição na empresa de preservação de pescado. Materiais e métodos. A metodologia utilizada foi do tipo aplicada, abordagem quantitativa e delineamento pré-experimental. Resultados. Nos resultados foi determinado que os principais que geram má gestão na logística, atraso de pedidos, falta de coordenação, erros contínuos nos registros das atas e falta de treinamento; O tempo de distribuição obtido antes da determinação da aplicação foi de 61,95% do total de pedidos entregues em até 10 dias e após sua aplicação do DRP, impactando positivamente a empresa com 98,73% do total de pedidos entregues em até 10 dias de os 1104 pedidos gerados por três meses, o que representa 100% dos pedidos. Conclusões. Conclui-se que com a aplicação do planejamento de requisitos de distribuição (DRP) foi alcançado um aumento no indicador de tempo de distribuição, de forma que permite uma redução nas entregas, gerando assim maiores benefícios para a empresa e satisfação dos clientes. Ao PNAEQW.

Palavras Chave: plano de requisitos, DRP, logística de distribuição, tempo de distribuição.

Introducción

En la industria alimentaria es fundamental incorporar la calidad en todas las etapas de producción para prevenir errores en los productos finales, especialmente en la industria conservera donde la falta de hermeticidad en latas, como el del pescado (atún) supone un alto riesgo para la salud del consumidor. La detección precisa de fallas, como las “abolladuras” en las latas es un desafío puesto que afecta directamente a la seguridad del producto. Por ello, es importante el desarrollo de algoritmos confiables que puedan identificar estas imperfecciones y, así, incrementar la eficiencia y la calidad en la fabricación de enlatados de atún.

La aplicación de la visión artificial en el proceso de fabricación de conservas de pescado es importante para permitir la detección de abolladuras en las latas de manera rápida y eficaz. Hoy en día, muchas empresas implementan este sistema para mejorar la calidad de sus productos, tal es caso de la investigación de Burgos P. et al (2022) donde se plantea el uso de un algoritmo eficaz para identificar anomalías en los bordes de las latas de aluminio de atún, logrando una efectividad de 90.4% en la detección de imperfecciones. Así mismo, Galdea (2024) usó la visión artificial para implementar un sistema de supervisión y control en la producción de latas de atún que le permitió identificar fallas en el sellado a través de métodos de visión artificial, concluyó que utilizar ese sistema en el control de calidad ofrecía numerosas ventajas como la realización de tareas específicas sin necesidad de la supervisión directa del trabajador. También, la investigación de Icaza (2019) plantea la creación un sistema de visión artificial con el fin de detectar defectos en productos enlatados, concluyeron que la implementación de este sistema mejoró considerablemente la calidad del producto final, reduciendo el

desperdicio y aumentando las ganancias de las empresas manufactureras. En la investigación de Palma (2020) se aplicó la visión artificial para detectar en tiempo real las fallas en el codificado de latas de atún; se desarrolló un modelo de red neuronal convolucional implementado en Python y TensorFlow, que permitió detectar si la lata estaba codificada de forma correcta o no, concluyó que la implementación del sistema ayudó a la empresa a mejorar su eficiencia en un 84% en la línea de codificación de latas de atún. Así mismo, en Pañi (2020) se destaca la creación de un prototipo usando el reconocimiento facial mediante tecnología de visión artificial para gestionar el acceso en áreas restringidas.

Tal como lo manifiesta Poblet (2022) respecto a que al abordar el campo de la inteligencia artificial en el control de calidad de procesos productivos se puede lograr un nivel superior de eficiencia y calidad, también dice que el uso de Python y redes neuronales convolucionales logran automatizar la adquisición de conocimientos, especialmente en el procesamiento de imágenes, lo que complementa la capacidad del escaneo 3D para realizar análisis detallados en diferentes contextos industriales y de salud.

Esta investigación está basada en el uso del lenguaje Python, que según Moreno (2020) es, actualmente, uno de los más usados por ser un lenguaje multiparadigma y orientado a objetos, siendo elegido por la mayoría de ingenieros, desarrolladores y científicos. Asimismo, Giraldo (2020) menciona que las redes neuronales artificiales son sistemas usados en la mayoría de las investigaciones de reconocimiento de objetos usando técnicas de Inteligencia artificial dado su capacidad de filtrar y detectar patrones particulares.

La investigación de Zúñiga (2022) afirma que con la Inteligencia Artificial (IA) es factible llevar a cabo labores concretas, como inspecciones manuales en las industrias. Así mismo, León et al (2022) propuso un sistema de clasificación automatizado, en una empresa conservera, basado en visión artificial, sistema que utiliza una cámara de alta resolución para capturar imágenes de los frascos y un algoritmo de aprendizaje automático para clasificarlos en "buenos" y "malos". Concluyó que un sistema desarrollado desde la visión artificial tiene un mayor alcance que los métodos tradicionales, permitiendo un control del 100% de la producción y la eliminación de la posibilidad de aparición de fallas que afecten tanto la calidad del producto final como la satisfacción del cliente. Ante esto, es importante que las empresas de conservas apliquen métodos eficientes para la "clasificación", por ejemplo, ya que los métodos realizados manualmente son lentos, costosos y propensos a errores.

En el caso de empresas desarrolladoras de soluciones con IA, Nevitec Vision Technologies (2022), explica que el desarrollo de su solución de visión artificial denominado "Rigel" fue diseñado específicamente para inspeccionar latas y botes de vidrio en una línea de producción, ya sean abiertos o cerrados; este consiste en un sistema avanzado basado en algoritmos de Deep Learning e inteligencia artificial. Tinajero J. et al (2020) indica que la visión artificial permite capturar, almacenar, procesar e interpretar imágenes, lo que facilita controles de calidad e inspecciones sin necesidad de contacto físico. Y, Caicedo (2021) menciona que, en los métodos de visión artificial, las cámaras tienen la tarea de registrar la imagen que llega al sensor y luego transmitirla a un sistema electrónico para su procesamiento.

Esta investigación está basada en el desarrollo de un sistema de visión artificial para detectar abolladuras en latas de atún, buscando mejorar la eficiencia y la calidad en las empresas conserveras al reducir el rechazo de productos dañados, además resulta rentable pues no requiere mucho trabajo, capital e inversión por hora- hombre logrando la reducción de costos de producción. Asimismo, se busca reemplazar el ojo humano por visión artificial, pues con el uso de cámaras se pretende identificar y apreciar las abolladuras en las latas de atún. Para ello, se establece el objetivo principal de desarrollar una visión artificial con redes neuronales para identificar las abolladuras en cualquier tipo de latas de atún. Asimismo, los objetivos específicos son: Detectar imperfecciones desde múltiples direcciones a través de 3 cámaras, integrar una inspección automatizada y continua de los envases, supervisar el proceso de inspección y visualizar los resultados para tomar acciones correctivas si es necesario.

Material y métodos:

El estudio presenta un enfoque de desarrollo de software con Python, utilizando módulos independientes para facilitar una implementación gradual y mejorar la capacidad de mantenimiento.

Se desarrolla en una laptop con tarjeta gráfica Intel Iris Xe y emplea MobileNetV2 junto a bibliotecas especializadas como TensorFlow, OpenCV, NumPy y Keras. El proyecto incluye una estructura triangular para controlar la iluminación y estabilidad de las cámaras, iluminación LED de 9v que emite 800 lúmenes, y tres cámaras conectadas mediante dirección IP, todos estos componentes permiten una percepción de luz adecuada y una captura eficiente de imágenes desde diferentes ángulos.

Para entrenar la red neuronal que detecta abolladuras en latas de atún, se utilizaron imágenes etiquetadas de latas en buen y mal estado, capturadas en un entorno controlado con estabilidad de cámaras e iluminación LED.

Como se visualiza en la Figura 1, se diseñó un ambiente controlado de forma triangular y se utilizó iluminación LED para generar la combinación de 2 tipos de iluminación de visión artificial, estas son iluminación frontal directa e iluminación difusa, las cuales permiten reducir sombras y mejorar la visibilidad de las características superficiales de las latas desde diferentes ángulos.




Figura 1. Imagen de la estructura con iluminación frontal directo e iluminación difusa.

Para desarrollar el software, se utilizó el entorno Spyder (Python 3.11.9) que facilita la escritura, prueba y depuración de código Python, es popular para la ciencia de datos y análisis numérico (Rolon-Mérette, 2020 y Tomas y Timbers, 2022). MobileNetV2 fue la base para entrenar la CNN, pues es una arquitectura diseñada para dispositivos móviles y sistemas embebidos con limitaciones computacionales (Sandler et al (2018). Keras, es una API de alto nivel para la creación de redes neuronales, simplifica el desarrollo de modelos de deep learning y es compatible con múltiples backends como TensorFlow (Grattarola y Alippi, 2021). TensorFlow es una herramienta poderosa y versátil para el aprendizaje automático y deep learning (Tensor Flow, 2024). Además, se utilizaron varias bibliotecas para el procesamiento de imágenes, entrenamiento del modelo y la interacción con el sistema operativo (morenos, 2020). OpenCV ofrece herramientas para la adquisición, preprocesamiento y análisis de imágenes (Chuquimarca, Pinzón y Rosales, 2021). NumPy permite manejar estructuras de datos complejas y realizar operaciones matemáticas avanzadas (Numpy, s.f.). La detección de bordes de Canny es un método preciso para identificar bordes en imágenes, implica cuatro etapas: suavizado con un filtro Gaussiano, cálculo de gradientes de intensidad, supresión de puntos no máximos y aplicación de umbrales con histéresis (Barreda et al, 2021).




Figura 2. Arquitectura del modelo base y las capas añadidas

En la Figura 2 se muestra la arquitectura de red neuronal basada en MobileNetV2, la misma que se caracteriza por su eficiencia y capacidad para ejecutarse en entornos con recursos limitados, utilizando operaciones de convolución separable que la dividen en dos pasos: una convolución profunda seguida de una convolución punto a punto. Al utilizar MobileNetV2 como base, se aprovecharon las características preentrenadas, lo que proporcionó una base sólida para construir la red personalizada. Algunas capas de MobileNetV2 se mantienen congeladas durante el entrenamiento de la nueva red, permitiendo el beneficio de las características aprendidas sin alterarlas, mientras que las capas posteriores se adaptan a nuestra tarea específica. Se agregaron capas personalizadas denominadas como capas completamente conectadas, de agrupación y de normalización, diseñadas específicamente para clasificar "0 = lata en mal estado" y "1 = lata en buen estado", capturando características relevantes para la tarea. Además, se entrenó la red completa en un conjunto de datos que contiene imágenes de latas en diferentes condiciones, ajustando los pesos de las capas personalizadas para minimizar la pérdida, mientras las capas congeladas permanecen estables. Además, se evaluó la red en un conjunto de prueba para medir su precisión en la clasificación de latas. En resumen, esta arquitectura combina la eficiencia de MobileNetV2 con la adaptabilidad de capas personalizadas para clasificar latas en buen estado y mal estado de manera eficiente y precisa.




Figura 3. Grafo computacional extraído de TensorBoard

La Figura 3 señala la gráfica del flujo de datos y operaciones en el grafo computacional de TensorBoard. Los nodos 'IteratorG' y 'IteratorGetNext' gestionaron la alimentación de datos al modelo. Los nodos 'StatefulPartition', 'NoOp' y 'Identity' organizaron y transformaron los datos sin alterarlos. El nodo 'inference_one' representó la fase de inferencia para las predicciones. Aunque la gráfica no mostró la arquitectura del modelo en términos de capas de red neuronal, proporcionó una visión detallada de cómo se procesaron los datos a través del grafo, crucial para la depuración y optimización del modelo en TensorFlow.

Tabla 1.

Arquitectura de las capas

Capa	Tipo	Detalle
Input Layer	Input	Tamaño: 128x128x3
MobileNetV2	Pretrained ConvNet	Base preentrenada en ImageNet
Flatten Layer	Flatten	Aplana la salida de MobileNetV2
Dense Layer	Dense	Neuronas: 256, Activación: ReLU
Dropout Layer	Dropout	Ratio: 0.5
Dense Layer	Dense	Neuronas: 1, Activación: Sigmoid

La Tabla 1 presenta las diferentes capas diseñadas para procesar y clasificar imágenes. Inicia con una Capa de Entrada que acepta imágenes de tamaño 128x128x3, seguida por MobileNetV2, una red convolucional preentrenada en ImageNet, lo que indica la utilización de técnicas de transferencia de aprendizaje. Posteriormente, se incluye una Capa de Aplanamiento que logra convertir las características multidimensionales en un vector unidimensional. La red continúa con una Capa Densa de 256 neuronal con una ReLU, seguida de una Capa de Abandono con ratio de 0.5 para mitigar el sobreajuste. Finalmente, se culmina con otra Capa Densa de una sola neurona con activación Sigmoid adecuada para tareas de clasificación binaria. Esta configuración es típica en aplicaciones de visión por computadora y sugiere un modelo capaz de realizar tareas complejas de reconocimiento de imágenes con alta precisión, tal y como se observa en la Figura 4.




Figura 4. Activación Sigmoid y ReLU

La Figura 4 muestra las funciones de activación Sigmoid, que transforma cualquier valor real en un valor entre 0 y 1, y es útil en la última capa para clasificación binaria debido a su salida probabilística en forma de S. Por otro lado, la función ReLU (Rectified Linear Unit), mantiene los valores positivos y convierte los negativos en 0, siendo altamente eficiente y popular en las capas ocultas de redes neuronales profundas gracias a su simplicidad y capacidad para mitigar el problema del desvanecimiento del gradiente.

Durante el entrenamiento, se aplican aumentos de datos en tiempo real mediante generadores, que incluyen rotaciones, desplazamientos, zooms y volteos para enriquecer el conjunto de datos de entrenamiento. El modelo se entrena a lo largo de múltiples épocas utilizando los generadores de datos de entrenamiento y validación, optimizado con el algoritmo Adam y evaluando con métricas de precisión. Como se pueden apreciar en las figuras 5, 6 y 7.



Figura 5. Imágenes generadas a partir de la Data

En la Figura 5 se muestra las imágenes generadas mediante el comando ImageDataGenerator el cual genera un aumento de datos.




Figura 6. Optimización

con Adam

La Figura 6 fue extraída de TensorBoard donde nos muestra la gráfica de optimización mediante el comando Adam donde se evalúa las épocas de entrenamiento en relación a la pérdida de datos.




Figura 7. Métricas de precisión 'accuracy'

La Figura 7 fue extraída después del entrenamiento de la red neuronal donde se muestran las métricas de precisión obtenidas a través del comando 'accuracy' y se comparan las predicciones hechas por el modelo con los resultados observados reales.

Verdaderos Positivos (VP): Predicciones correctas de la clase positiva.

Falsos Positivos (FP): Predicciones incorrectas como clase positiva.

Verdaderos Negativos (VN): Predicciones correctas de la clase negativa. Falsos

Negativos (FN): Predicciones incorrectas como clase negativa.

Así mismo, para hacer uso de esta red neuronal se diseñó un código en Python de captura de imágenes en tiempo real usando la librería OpenCv como base ya que es la que permitió implementar las tres cámaras haciendo uso de direcciones IP con los siguientes comandos que se muestran en la Tabla 2.

Tabla 2.

Comandos para adaptar las 3 cámaras

```
# Cargar el modelo de la CNN
ModeloCNN2 =
'C:/Users/farfa/Desktop/4/ClasificacioncCNN.h5' CNN2
= tf.keras.models.load_model(ModeloCNN2)
# Función para capturar frames de 3 cámaras
def capturar_frames(camara_url, cola): global
running
cap = cv2.VideoCapture(camara_url)
# Crear hilos para las tres cámaras hilo1 =
threading.Thread(target=capturar_frames,
args=('https://192.168.18.39:8080/video', cola1)) hilo2 =
threading.Thread(target=capturar_frames,
args=('http://192.168.18.41:4747/video', cola2)) hilo3 =
threading.Thread(target=capturar_frames,
args=('http://192.168.18.43:4747/video', cola3))
```

Además, como se visualiza en la Figura 8, en esta implementación, se utilizaron filtros que permiten afinar las imágenes para que sean más lisas y presenten menos ruido. Estos filtros incluyen el desenfoque Gaussiano, el filtro umbral adaptativo tipo Gaussiano y el algoritmo de Canny. Los dos primeros filtros sirven como base para optimizar el rendimiento del algoritmo de Canny. El desenfoque Gaussiano suaviza la imagen para reducir el ruido, preparando el terreno para el procesamiento posterior. A continuación, el filtro umbral adaptativo tipo Gaussiano ajusta dinámicamente los umbrales en diferentes áreas de la imagen para segmentarla eficazmente, especialmente en condiciones de iluminación variable. El algoritmo de Canny, que detecta los bordes en la imagen, se aplica después de estos pasos. Primero, la imagen se convierte a escala de grises, luego se suaviza con el filtro Gaussiano. Después, se calculan los gradientes de la imagen para identificar las áreas de transición rápida de intensidad, indicando posibles bordes. Estos gradientes se afinan para resaltar los bordes más prominentes. Finalmente, se aplican umbrales dobles con seguimiento por histéresis para definir con precisión los bordes eliminando los falsos positivos y garantizando la detección robusta de los contornos reales. Este proceso combinado, mejora significativamente la calidad y precisión de la detección de bordes en las imágenes, proporcionando resultados más nítidos y detallados para el análisis posterior.



Figura 8. Pasos cruciales de la aplicación del algoritmo de Canny

Resultados

El sistema desarrollado utiliza una matriz de confusión en el que se coloca aproximadamente 1541 capturas fotográficas, de las cuales 428 son de latas en buen estado y 1113 de latas en mal estado. El modelo de clasificación fue evaluado utilizando varias métricas clave. Para la clase 0, la precisión fue del 99%, lo que indicó que el 99% de las instancias predichas como clase 0 fueron realmente de esa clase. La recuperación fue del 98%, demostrando que el modelo logró identificar correctamente el 98% de las instancias verdaderas de clase 0. El f1-score para esta clase fue 0.98, reflejando un equilibrio alto entre precisión y recuperación. En cuanto a la clase 1, la precisión también fue del 99%, con una recuperación perfecta del 100%, lo que significó que todas las instancias verdaderas de clase 1 fueron correctamente identificadas. El f1-score para la clase 1 fue 0.99. El soporte total incluyó 428 instancias para la clase 0 y 1113 para la clase 1. Globalmente, el modelo alcanzó una exactitud del 99%, con

promedios macro y ponderados de precisión, recuperación y f1-score también del 99%, indicando un rendimiento consistentemente alto en todas las métricas evaluadas, como se puede evidenciar en la Figura 9.

	precision	recall	f1-score	support
0	0.99	0.98	0.98	428
1	0.99	1.00	0.99	1113
accuracy			0.99	1541
macro avg	0.99	0.99	0.99	1541
weighted avg	0.99	0.99	0.99	1541

Figura 9: Matriz de confusión



Figura 10. Resultados de Tensorboard del rendimiento de la red neuronal

En la Figura 10 se muestra un gráfico obtenido de TensorBoard en el cual se aprecia el rendimiento de la red neuronal durante su entrenamiento, se observan dos líneas que representan la precisión de entrenamiento y validación a lo largo de varias épocas, ambas superando el 93%, lo cual es indicativo de un modelo altamente efectivo. La precisión durante el entrenamiento alcanza un valor de 0.9831, mientras que la precisión de validación es ligeramente superior con un valor de 0.987, lo que sugiere que el modelo no solo ha aprendido bien los datos con los que fue entrenado, sino que también es capaz de generalizar y realizar predicciones precisas con nuevos datos. La tabla de datos debajo del gráfico proporciona una vista detallada de estos resultados, mostrando los valores exactos de precisión obtenidos en la última época registrada.

La Figura 11 muestra la detección exitosa del sistema de visión artificial con tres cámaras para una lata de atún en mal estado.



Figura 11. Detección exitosa de latas en mal estado

La Figura 12 muestra la detección exitosa del sistema de visión artificial con tres cámaras para una lata de atún en buen estado.




Figura 12. Detección exitosa de latas en buen estado

La Figura 13 muestra la detección exitosa del sistema de visión artificial de cada una de las cámaras de manera independiente.




Figura 13. Detección exitosa de cada una de las cámaras

Discusión

El sistema de visión artificial desarrollado en este estudio demostró ser efectivo en la identificación de abolladuras en latas de atún, alcanzando una precisión del 98.17% en el entrenamiento y del 98.76% en la validación. Esta precisión se logró usando una red neuronal convolucional (CNN) entrenada con un conjunto de imágenes de latas en buen y mal estado. La CNN, compuesta por capas convolucionales, de normalización por lotes y de agrupamiento máximo logró la extracción de características relevantes de las imágenes y realizar la clasificación con éxito.

La implementación de tres cámaras permitió inspeccionar las latas desde múltiples ángulos, lo que aumentó la probabilidad de detectar abolladuras que podrían pasar desapercibidas en una sola perspectiva. Este enfoque multi-cámara, junto con el uso de filtros como el de desenfoque Gaussiano, el umbral adaptativo tipo gaussiano y el algoritmo de Canny, mejoraron la calidad de las imágenes así como la precisión de la detección de bordes.

Sin embargo, es importante destacar que el sistema se desarrolló en un entorno controlado, con iluminación y estabilidad de las cámaras cuidadosamente controladas. En un entorno real de producción, la variabilidad de la iluminación, la velocidad de la línea de producción y la presencia de otros objetos podrían afectar el rendimiento del sistema. Como se menciona en el trabajo de investigación de León (2019) los métodos de clasificación manual son lentos, costosos y propensos a errores, por lo que la implementación de un sistema automatizado basado en visión artificial, como el desarrollado en este estudio, ofrece una alternativa eficiente y precisa. Asimismo, en la investigación de Burgos (2022) también se destaca la importancia de la visión artificial en la industria alimentaria, ya que permite la detección rápida y eficaz de imperfecciones en los productos. En este caso, el sistema desarrollado logró identificar abolladuras en las latas de atún, lo que contribuyó a la mejora de la calidad y seguridad del producto final.

Conclusiones

El desarrollo de visión artificial, haciendo uso de redes neuronales y tres cámaras, revelan su eficacia como herramienta en la detección de abolladuras en latas de atún. Así mismo su aplicación en la industria alimentaria promete mejoras significativas en el control de calidad, la reducción de costos y la garantía de la seguridad del producto final.

La capacidad del sistema para identificar abolladuras desde múltiples ángulos, su integración con una inspección automatizada y continua, y la posibilidad de tomar acciones correctivas en tiempo real, lo convierten en una solución innovadora y prometedora para la industria conservera.

Para asegurar la eficacia y generalización del sistema, se recomienda llevar a cabo pruebas adicionales con conjuntos de datos más amplios y diversos. La inclusión de diferentes tipos de latas, variaciones en la iluminación y la incorporación de diferentes defectos, como abolladuras de diversas formas y tamaños, permitiría mejorar la precisión y robustez del modelo.

En cuanto a futuras investigaciones, se sugiere enfocarse en la optimización del algoritmo de detección de bordes, explorar otras arquitecturas de redes neuronales y considerar la integración del sistema con tecnologías como la robótica para automatizar aún más el proceso de inspección y clasificación de las latas. Estos enfoques podrían potenciar la eficiencia, precisión y versatilidad del sistema, consolidando su relevancia en el ámbito industrial y su contribución a la mejora continua de los procesos de control de calidad en la industria alimentaria.

Referencias

- Barreda, S., Mamani, L., Mendoza, J. y Castillo, O. (2021). Una aplicación del algoritmo de detección de bordes Canny en procesos alimentarios. *Revista Científica Investigación Andina*, 20(2), 1-8. <https://mail.revistas.uancv.edu.pe/index.php/RCIA/article/view/865>
- Burgos Zavaleta, P., Ulloa, J., Aguilar, J., Robles, A., & Julián, C. (2022). Desarrollo de un sistema de visión artificial para detección de abolladuras en latas de atún. *INGnosis*, 8(2), 59–68. <https://revistas.ucv.edu.pe/index.php/ingnosis/article/view/2828/2212>
- Deza, A.; Farfán, C.; Obando, A.; Pita, D.; Valderrama, K.; Velásquez, R. (2024). Desarrollo de visión artificial con redes neuronales para identificación de imperfecciones en envases de atún con tres cámaras. *Ingnosis* 10 (1), 72-83

- Caicedo Duque, A. (2021). Sistema de detección y conteo de manos en un racimo de bananos mediante visión artificial [Tesis de pregrado, Universidad EIA]. <https://repository.eia.edu.co/server/api/core/bitstreams/d55b308e-b8ae-41e9-bcf3-27bb3467de5b/content>.
- Chuquimarca Jiménez, L., Pinzón Tituana, S. y Rosales Pincay, A. (2021). Detección de mascarilla para COVID-19 a través de Aprendizaje Profundo usando OpenCV y Cascade Trainer GUI. *Revista Científica y Tecnológica UPSE*, 8(1), 68-73. <https://incyt.upse.edu.ec/ciencia/revistas/index.php/rctu/article/view/572/496>
- Galdea Gonzáles, W. (2024). *Diseño y simulación de sistema automatizado para el control de calidad en la producción de enlatado de atún mediante visión artificial* [Tesis de pregrado, Universidad Estatal Península de Santa Elena]. Repositorio UPSE. <https://repositorio.upse.edu.ec/handle/46000/10620>
- Giraldo Loaiza, W. (2020). *Reconocimiento de Objetos usando técnicas de Inteligencia Artificial* [Universidad Tecnológica de Pereira]. <https://repositorio.utp.edu.co/server/api/core/bitstreams/9e71ddea-7292-473a-b828-3471b0484727/content>.
- Grattarola, D. y Alippi, C. (2021). Graph Neural Networks in TensorFlow and Keras with Spektral. *IEEE Computational Intelligence Magazine*, 16(1), 99-106. <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9321429>
- Icaza Paredes, W. (2019). *Desarrollo de sistema de visión artificial con labview que permita detectar imperfecciones en las latas de atún*. Universidad Estatal de Milagro. <http://repositorio.unemi.edu.ec/xmlui/handle/123456789/4921>.
- León León, R. A, Beltrán Lara, B., Cruz Saavedra, R., Terrones Julcamoro, K., Torres Verastegui, A. y Aponte de la Cruz, M. (2019). Desarrollo de sistema de visión artificial para control de calidad de botellas en la empresa Cartavio Rum Company. *Revista Ingeniería, Investigación y Desarrollo*, 19(1), 17-25. <https://dialnet.unirioja.es/descarga/articulo/8276722.pdf>.
- León León, R. A, Guevara Jiménez, N. Briceño Cabrera, S., Espinoza Llano, Á., Gamboa Nolasco, L., Marín Alzamora, A. y Paz Rodríguez, P. (5-7 de diciembre del 2022). *Simulación de un sistema de clasificación de frascos de conservas mediante visión artificial en las empresas usando Python*. 2nd LACCEI International Multiconference on Entrepreneurship, Innovation and Regional Development - LEIRD [virtual edition], <https://laccei.org/LEIRD2022-VirtualEdition/full-papers/FP181.pdf>.
- Moreno Fernández, S. (2020). *Herramienta de reconocimiento de imágenes en Python* [Tesis de pregrado, Universidad de Sevilla]. <https://biblus.us.es/bibing/proyectos/abreproy/92877/fichero/TFG-2877+MORENO+FERN%C3%81NDEZ%2C+SAMUEL.pdf>.
- NEVITEC VISION TECHNOLOGIES by CLAUDIA, (25 de agosto de 2022). *Inspección de alta calidad de latas y botes de vidrio con la solución de visión artificial Rigel*. <https://nevitecvision.com/blog/inspeccion-de-alta-calidad-de-latas-y-botes-de-vidrio-con-lasolucion-de-vision-artificial-rigel/>.
- NumPy. (s.f.). *Case study: Cricket analytics, the game changer!* <https://numpy.org/casestudies/cricket-analytics/>
- Palma Santacruz, W. (2020). *Implementación de un sistema de visión artificial en líneas de producción de atún, para la detección de fallas de codificado en la empresa Puertomar S.A. Provincia de Manabí*. [Tesis de Maestría, Escuela Superior Politécnica de Chimborazo]. <http://dspace.espacec.edu.ec/bitstream/123456789/14101/1/20T01339.pdf>.
- Deza, A.; Farfán, C.; Obando, A.; Pita, D.; Valderrama, K.; Velásquez, R. (2024). Desarrollo de visión artificial con redes neuronales para identificación de imperfecciones en envases de atún con tres cámaras. *INGnosis* 10 (1), 72-83

- Pañi Pizarro, C. (2020). *Diseño de un prototipo de sistema inmótico basado en reconocimiento facial usando visión artificial, para controlar el acceso en áreas restringidas* [Tesis de pregrado, Escuela Superior Politécnica de Chimborazo]. <http://dspace.espoch.edu.ec/handle/123456789/18053>.
- Poblet García, P. (2022). *Detección de defectos en latas de refrescos mediante redes neuronales y visión artificial* [Tesis de pregrado, Escuela Superior de Ingeniería Industrial de Barcelona]. <https://upcommons.upc.edu/bitstream/handle/2117/371689/detecci-n-de-defectos-en-latas-derefrescos-mediante-deep-learning..pdf?sequence=1&isAllowed=y>
- Rolon-Mérette, D., Ross, Matt, Rolon-Mérette, T. and Church, K. (2020). Introduction to Anaconda and Python: Installation and setup. *The Quantitative Methods for Psychology*, 16(5), S3-S11. https://www.tqmp.org/SpecialIssues/v_ol16-5/S003/S003.pdf
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. and Chen, L. C. (21 de marzo del 2019). *MobileNetV2: Inverted residual and linear bottlenecks*. The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 4510-4520. <https://arxiv.org/abs/1801.04381>
- TEKVISA (23 de mayo de 2022). Deep Learning en la Visión Artificial. <https://tekvisa.com/deep-learning-en-la-vision-artificial/>.
- Tensor Flow (19 de noviembre de 2024). MLSysBook.AI: Principles and practices of Machine Learning systems Engineering. https://blog.tensorflow.org/2024/11/mlsysbookai-principlesand-practices-of-machine-learning-systems-engineering.html?hl=es-419&gl=1*1oyr9zo*_ga*NTg2MDMyNTUuMTczMjEyMDQzMA..*_ga_W0YLR4190T*MTczMjEyMDQyOS4xLjAuMTczMjEyMDQyOS4wLjAuMA..
- Tinajero, J., Acosta, L., Chango, E. y Moyon, J. (2020). Sistema de visión artificial para clasificación de latas de pintura por color considerando el espacio de color RGB. *Revista Espacios*, 41(8), 18. https://www.revistaespacios.com/a20_v41n08/a20v41n08p18.pdf.
- Tomas, B. y Timbers, T. (2022). Python Packages. Florida, USA: CRC Press. https://books.google.com.pe/books?id=_J5IEAAQBAJ&newbks=0&pg=PP1&hl=es&pg=PP1#v=onepage&q&f=false
- Zúñiga Segura, L. (2022). Inteligencia Artificial en las organizaciones. *Investiga. TEC*, 15(45), 21-24. https://revistas.tec.ac.cr/index.php/investiga_tec/issue/view/629