

# Desarrollo de un Algoritmo de Visión Artificial mediante Redes Neuronales Convolucionales YOLO v8 para la Clasificación de Espárragos según la Yema

**Ryan A. LEÓN LEÓN**

La Libertad – Universidad Privada del Norte  
Trujillo, 13006, Perú

**Janeth C. MORALES SALAZAR**

La Libertad – Universidad Privada del Norte  
Trujillo, 13006, Perú

**Maria B. ALCALDE PORTAL**

La Libertad – Universidad Privada del Norte  
Trujillo, 13006, Perú

**RESUMEN:** El propósito de este estudio es analizar la inspección de control de calidad durante la exportación de espárragos, la misma se realiza de manera visual por operadores experimentados, pero la visión humana no cumple con criterios de selección estandarizados, por lo que se desarrolló el plegado basado en YOLO v8. Sistema de inteligencia artificial basado en redes neuronales; el estado de la punta o de las yemas de los espárragos se puede determinar según el tipo de espárrago. Utilizando un algoritmo Python v3.7 desarrollado en Visual Studio Code, se creó un conjunto de datos que contiene 2300 imágenes de espárragos con una cámara conectada a una computadora. Se cargaron 1610 imágenes para entrenamiento, 460 para prueba y 230 para prueba de la red neuronal. Cuando se probó en un ambiente controlado, logró una precisión del 96% en la clasificación de los botones florales según la matriz de confusión.

**Palabras Claves:** Inteligencia artificial, YOLOv8, Matriz Confusión, Red neuronal, Control de calidad de espárrago.

## *Development of a computer vision algorithm using yolo convolutional neural networks for the classification of asparagus according to the bud*

**ABSTRACT:** *The purpose of this research is to analyze the quality control inspection of the asparagus export process; This is done visually by experienced operators, however human vision does not follow a standardized selection criterion, so an artificial intelligence system was designed with convolutional neural networks based on YOLO v8 that detect the state of the tips or buds of the eyes. the asparagus according to its class, A which is closed tips, and class B which are open or flowered tips. Using an algorithm in Python v3.7 developed in Visual Studio Code, a dataset was created with 2,300 images of asparagus with the camera connected to the computer; of which 1610 images were entered for training, 460 for validation and 230 for testing the neural network, obtaining 96% accuracy according to the confusion matrix in the classification of the bud when testing in a controlled environment.*

**Keywords:** *Artificial Intelligence, YOLOv8, Confusion Matrix, Neural Network, Stud Quality Control.*

## 1. INTRODUCCIÓN

El proceso de producción de espárragos en conserva requiere ciertos requisitos de calidad, como color, forma, longitud y el estado de las yemas. Los recolectores clasifican manualmente las muestras de espárragos verdes cosechadas en nuestros campos antes de enviarlas a la fábrica.

Esta inspección visual implicó tomar una muestra aleatoria de 10 kg de espárragos verdes por bandeja de cada bolsa y clasificarlos en función del aspecto de las yemas. Debe ser cerrado y de color verde claro para ser clasificado como A.

Cuando las yemas tienen una pequeña abertura o floreción, entran en la categoría B. Debido a las limitaciones del ojo humano, existen algunos detalles imperceptibles en la inspección visual, lo que significa que el proceso no puede alcanzar la confiabilidad diurna.

Perú es un gran país agrícola conocido por su variedad de frutas, tubérculos y verduras. Es uno de los países más reconocidos en producción anual de espárragos y ocupa el segundo lugar a nivel mundial, ha superado varios certificados sanitarios y de calidad, y también se exporta a EE.UU. y países más desarrollados del continente europeo [1]. Perú es un importante productor agrícola. El país exporta dos tipos de espárragos, enlatados y frescos, ambos blancos y/o verdes, la conserva se mantuvo y generó 104 millones de dólares, y los espárragos frescos producen \$92.000, se produce en Ica, La Libertad y Lima, el 60% de las cuales tiene más de 5 hectáreas, y se ve favorecida por el clima costero del Perú [2]. Su desarrollo en los años siguientes fue desigual, con una disminución del 5% en 2007, 2012 y 2017, pero las exportaciones generaron 545 millones de dólares, de los cuales Ica representó el 45% y La Libertad el 43%, seguida de Lambayeque, Ancash y Lima, contribuyendo desarrollo sostenible del país [3] [4].

Con base en los resultados de los últimos meses [5], se espera que la producción alcance 140.499 toneladas por un valor de 422 millones de dólares al cierre de 2020, con un aumento de la demanda y el valor del 10%, siendo Perú nuevamente el principal proveedor. en hortalizas y en el segundo lugar entre proveedores globales. La calidad e inocuidad de nuestros productos son factores decisivos en el mercado internacional que nos permiten

exportar espárragos [6]. La gestión y control de calidad de las operaciones de muestreo se realiza manualmente en fábrica identificando aspectos como las puntas tipo A, B y C [7].

Por lo tanto, utilizando imágenes, las herramientas digitales pueden realizar una identificación automática en un tiempo más corto y son la mejor solución para identificar las características del estado de estos espárragos exportados, ayudando a reducir errores por parte de los expertos en calidad en extensos periodos de muestreo en el hallazgo de las características propuestas [8]. La investigación [9] mencionó que los espárragos exportados deben cumplir varios requisitos, por lo que la solución más eficaz para la clasificación automatizada de los espárragos es la integración de sistemas automatizados.

En las pruebas realizadas, la tasa de éxito de las redes neuronales artificiales en la clasificación de espárragos alcanzó el 96%, lo que demuestra que la implementación de la visión artificial en diversas empresas exportadoras es posible. Por otro lado, el siguiente trabajo de investigación [10] muestra que la implementación de un sistema de visión artificial puede determinar la calidad de los frutos cítricos a partir de una clasificación basada en las siguientes características: tamaño, forma, color y daños y/o defectos externos. El método consiste en determinar el valor de la distancia euclidiana en el espacio RGB para cada píxel de la imagen segmentada respecto de cada centro de gravedad de la clase. Finalmente, a cada píxel se le asigna la clase correspondiente con la distancia euclidiana más pequeña [11].

Un dispositivo que captura imágenes digitales que pueden determinar las características físicas de las frutas se puede definir como una gran herramienta que acerca a las personas al mundo digital, permitiéndoles aprovechar al máximo su entorno [12]. También se utilizan otros métodos invasivos, como penetrómetros para medir la resistencia a la penetración o tendómetros para medir la resistencia al corte de frutos [13]. Además, se pretende desarrollar un sistema portátil para la maduración no destructiva directamente en la plantación. La clasificación de frutas en la agricultura peruana aún se encuentra en un estado muy rudimentario, especialmente cuando se trata de productos de exportación que generan muchos ingresos en divisas, por lo que se estudia trabajar en la clasificación automática del espárrago, integrando sistemas robóticos, procesamiento de imágenes y redes neuronales artificiales [14]. A partir de 210 frutas divididas en tres niveles, con visión artificial, procesamiento de imágenes y descriptores de color (se utilizan descriptores K-Means), se identifican los principales problemas de rechazo de los clientes, se determinan las frutas aceptables y se identifican en un entorno cualitativo [15].

La justificación de este estudio es mejorar la clasificación de los espárragos en función de la calidad, la forma y el color de los brotes utilizando la automatización basada en programación de redes neuronales en lugar de métodos manuales y básicos.

El objetivo general es desarrollar el algoritmo de visión artificial mediante redes neuronales Yolo v8. Por esta razón, la implementación de herramientas Tenemos como objetivo específico crear una galería de imágenes de alta calidad de espárragos verdes maduros con diferentes categorías es decir con las yemas abiertas y cerradas. El objetivo específico es entrenar

la red neuronal Yolo v8 según las imágenes brindadas para que aprenda a identificar la categoría de espárrago que le corresponda.

Finalmente se va a simular en el entorno Python usando una cámara donde se mostrarán imágenes en tiempo real y el programa indicará la categoría el cual pertenece.

## 2. MATERIALES Y METODOS

Para el desarrollo del sistema de descripción fueron necesarias las siguientes herramientas de procesamiento y clasificación de imágenes: dispositivo móvil para capturar imágenes y conjuntos de datos, 2 computadoras estacionarias para trabajar en conjunto: Python y TensorFlow; documentadores e implementadores de código de aplicación.

Los sistemas expertos se definen como "programas informáticos que contienen expertos humanos capacitados en el dominio de la aplicación" [16], es decir, se especializan en realizar procesos especializados en un dominio específico de conocimiento que puede automatizarse. Para que los sistemas expertos puedan realizar las acciones de los expertos humanos, deben poder resolver el problema actual, desarrollar soluciones utilizando información incompleta, reorganizar y adquirir conocimientos. [17].

Existe cierto interés en la inteligencia artificial para el control del rendimiento y la detección de defectos en el sector agrícola [18]. La afección se puede diagnosticar y tratar utilizando herramientas destinadas al control del rendimiento. Los sistemas expertos con visión por computadora pueden ser analizadores de áreas grandes y pequeñas. El reconocimiento de imágenes ayuda a determinar el estado de los cultivos en grandes áreas y, por lo tanto, genera beneficios económicos al ayudar a la industria agrícola [19]. La implementación de sistemas de visión artificial para detectar defectos en los cultivos tiene sentido porque "se ha demostrado que el tiempo promedio requerido por los agricultores para completar el proceso de identificación disminuye" [20]. La creación de un sistema experto móvil implementado en un dispositivo móvil con una cámara no solo puede lograr un diagnóstico rápido, sino también obtener información sobre plagas, enfermedades, plagas y pesticidas que pueden usarse para el tratamiento. Una red neuronal artificial (RNA) es un sistema informático distribuido basado en el sistema nervioso humano. Las redes neuronales artificiales son, hasta cierto punto, una forma de simular el comportamiento de aprendizaje humano con una red de elementos simples (elementos básicos) conectados masivamente en una organización jerárquica que puede interactuar con objetos del mundo real para interactuar, al igual que las redes neuronales biológicas. esto [21]. Una de las propiedades más importantes de una red neuronal artificial es su capacidad para reconocer y aprender de un conjunto de datos que genera patrones, es decir, formula un modelo de alineación de datos para relacionar dichos patrones con conjuntos de datos similares y diferentes [22]. Entre los tipos de redes neuronales artificiales existe un grupo de redes llamadas redes neuronales convolucionales (CNN), que son redes jerárquicas que constan principalmente de capas convolucionales [23] intercaladas con capas de submuestreo capaces de realizar

muestreos matriciales bidimensionales. CNN contiene varias capas de filtrado 2D [24] (convoluciones). Pueden existir varias capas que se pueden encontrar desde el principio hasta el final de la red: una capa de minería de datos que extrae las características de los datos o imágenes a procesar en la red, que al igual que el procesamiento matricial, realiza operaciones en los datos dimensionales. Una neurona reducida puede realizar acciones como la agrupación máxima si su salida es similar a la categoría especificada por el modelo (Figura 1).

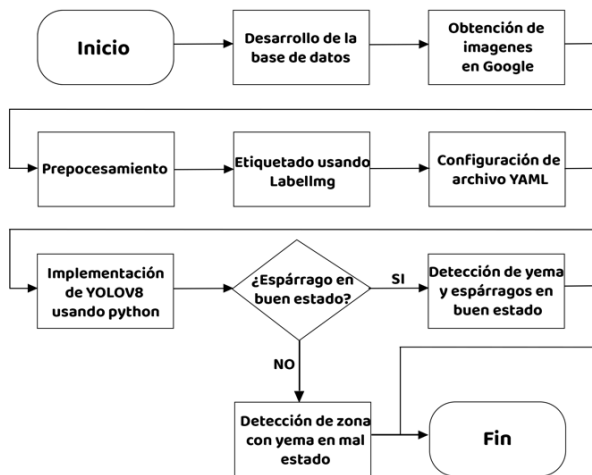


Diagrama de flujo del algoritmo de visión artificial  
Figura 1

Las capas convolucionales extraen características de la entrada que coinciden con la base de datos. Esto corresponde a una serie de operaciones matemáticas donde una convolución toma datos de entrada y un núcleo (una matriz de valores pequeños) que escanea la entrada. Se coloca un núcleo en cada píxel de los datos de entrada y se calcula el producto escalar de los valores superpuestos. El valor resultante está en la salida en una ubicación correspondiente al centro del núcleo. La ecuación matemática que representa el plegado se muestra a continuación.  
Ec. (1)

$$Y = \sum_{-\infty}^{\infty} xk * hk \tag{1}$$

Ecuación 1

Donde: x representa el dato de entrada, h el kernel e Y la salida.

$$LBP(xC,yC) = \sum 2 p s(ip - iC) \tag{2}$$

Ecuación 2

La salida de esta capa corresponde a un mapa de características que contiene información sobre cada imagen, incluidos puntos de esquina y contornos. Los mapas de características se proporcionan a otras capas para que el proceso de extracción de

características pueda continuar con otras imágenes de entrada. Cuando se aplica una operación de convolución a la entrada, la capa de convolución pasa el resultado a la siguiente capa. Ec. (2) Con (xC, yC) como las coordenadas del píxel central con intensidad iC; e ip la intensidad del píxel vecino. De esta manera, el píxel seleccionado se diferencia de los píxeles vecinos mediante funciones entrenadas. La función Step de activación de la red neuronal está determinada por la variable S, es decir, la función Signo definida como: Ec. (3)

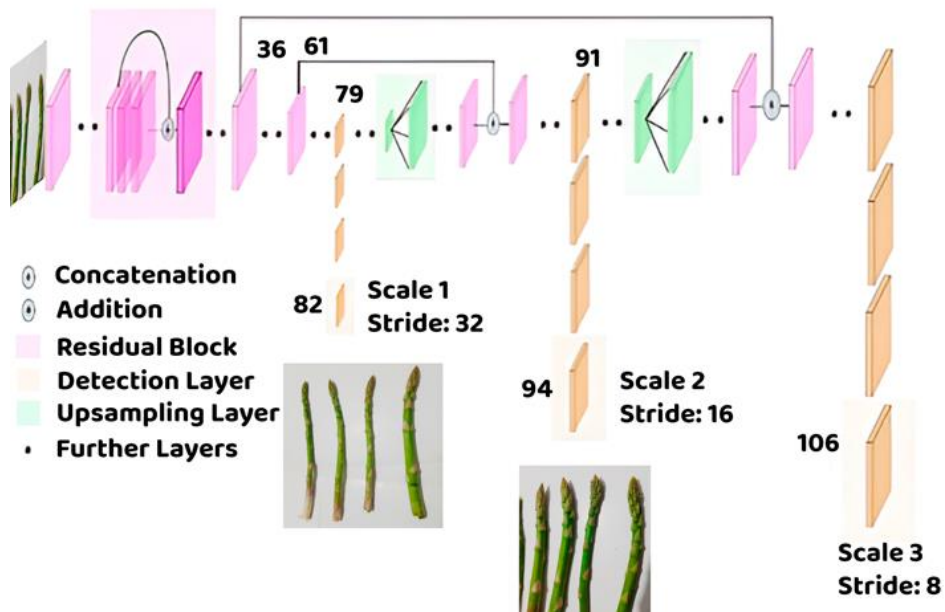
$$\text{Step}(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{e. o. c.} \end{cases} \tag{3}$$

Ecuación 3

Esta ecuación nos indica que, al elevarse el valor de x, sobrepasa un umbral mayor a cero lo que se declara en estado activado. De esta forma, se inicia la segmentación de las características basándonos en el entrenamiento previo, al resaltar los píxeles que están dentro del rango de detección y a opacar los píxeles que están fuera del valor. Los píxeles resaltados están encuadrados. Después de eso, el redimensionador de imágenes lee la imagen y la cambia de tamaño (640\*640 píxeles) para que se pueda programar la función de reconocimiento.

Implementación de Yolo v8: La detección se realiza utilizando kernels de tamaño 1\*1\*(Bx(5+C)), donde B representa las cajas delimitadoras, “5” denota los atributos de la caja y la confianza del objeto, y C es el número de clases. En Yolo v8 entrenado en coco, se usa B=3 y C=0, resultando en un kernel de tamaño 1 \* 1 \* 255. Estos kernels se aplican en mapas de características de tres tamaños diferentes en tres puntos específicos de la red, permitiendo una detección precisa y exhaustiva. La arquitectura del sistema en Yolo v8 se muestra en la (Figura 2), donde se ingresa la imagen de un espárrago en un ambiente controlado con fondo blanco, clasificada según la abertura de las yemas, lo cual es evidente cuando están maduras o sobremaduras. La imagen se prepara asignando un kernel de 3 y una concatenación de 5. Luego, se aplica la convolución a cada píxel, generando diferentes capas que se superponen y muestran una región predominante, la cual se encierra en la imagen binarizada. Esta imagen binarizada se muestra en Python y se le asigna una clase basada en el estado de las yemas, clasificándolas en calidad tipo A o B.

Creación de una galería de imágenes válidas:  
Consulta con un agrónomo experto: Se consulta al experto en espárragos para identificar las afecciones más comunes y establecer categorías específicas para las puntas de los espárragos. Obtención de fotografías: Se buscan fotografías de espárragos sanos en internet o se toman en campo, basándose en la clasificación proporcionada por el agrónomo.  
Validación de datos: Las fotografías se evalúan con el agrónomo experto para garantizar su fiabilidad y usabilidad.  
Elaboración del conjunto de datos: Las imágenes validadas se reúnen en una carpeta en ordenadores, etiquetando cada una de estas con la enfermedad que padecen (si la llegaron a tener) y su severidad.



Arquitectura de la red neuronal Yolo v8

Figura 2

Implementación de Yolo v8: La detección se realiza utilizando kernels de tamaño  $1 \times 1 \times (B \times (5 + C))$ , donde B representa las cajas delimitadoras, "5" denota los atributos de la caja y la confianza del objeto, y C es el número de clases. En Yolo v8 entrenado en coco, se usa B=3 y C=0, resultando en un kernel de tamaño  $1 \times 1 \times 255$ . Estos kernels se aplican en mapas de características de tres tamaños diferentes en tres puntos específicos de la red, permitiendo una detección precisa y exhaustiva. La arquitectura del sistema en Yolo v8 se muestra en la Figura 2, donde se ingresa la imagen de un espárrago en un ambiente controlado con fondo blanco, clasificada según la apertura de las yemas, lo cual es evidente cuando están maduras o sobremaduras. La imagen se prepara asignando un kernel de 3 y una concatenación de 5.

Luego, se aplica la convolución a cada píxel, generando diferentes capas que se superponen y muestran una región predominante, la cual se encierra en la imagen binarizada. Esta imagen binarizada se muestra en Python y se le asigna una clase basada en el estado de las yemas, clasificándolas en calidad tipo A o B. Creación de una galería de imágenes válidas: Consulta con un agrónomo experto: Se consulta al experto en espárragos para identificar las afecciones más comunes y establecer categorías específicas para las puntas de los espárragos. Obtención de fotografías: Se buscan fotografías de espárragos sanos en internet o se toman en campo, basándose en la clasificación proporcionada por el agrónomo. Validación de datos: Las fotografías se evalúan con el agrónomo experto para garantizar su fiabilidad y usabilidad. Elaboración del conjunto de datos: Las imágenes validadas se reúnen en una carpeta en ordenadores, etiquetando cada imagen con la enfermedad que padecen (si la tienen) y su severidad.

### Implementar la red neuronal Yolo v8

Clasificación del conjunto de datos: La clasificación se realiza en

una reunión con un agrónomo experto. Utilizando documentación confiable, las imágenes del conjunto de datos se distribuyen en subcarpetas para segmentar claramente los datos según las plagas y enfermedades identificadas en las imágenes.

Construcción del modelo de entrenamiento: Con los datos segmentados, se implementa un sistema de clasificación mediante redes neuronales utilizando software.

Generación del archivo de entrenamiento: Se crea un archivo de entrenamiento que se activa al leer el modelo de la red neuronal. Este archivo se genera entrenando la red neuronal con el conjunto de datos proporcionado al modelo de entrenamiento.

Implementación del sistema experto: El sistema experto se implementa en el ordenador, facilitando las pruebas de entradas y salidas.

Pruebas del sistema: Se realizan pruebas ingresando un conjunto de imágenes de las plantas, especificando la clasificación de las puntas del cultivo como parámetro de entrada. Se espera como salida una etiqueta de clase que indique si la yema está abierta o cerrada (Figura 3).

Pruebas: Es esencial realizar una descripción detallada de las entradas y salidas del sistema experto, asegurando la correcta interpretación de los datos en cada fase de prueba. Se deben establecer criterios claros para evaluar la validez y consistencia de los datos obtenidos en las muestras. Las conclusiones derivadas de las pruebas deben documentarse minuciosamente en el informe correspondiente.

Recolección de entregables: La documentación del diseño del sistema experto, junto con las pruebas realizadas y su implementación del sistema en código Python, junto con su respectiva documentación técnica, debe ser alojada en un repositorio gestionado adecuadamente. Este repositorio servirá no solo como un archivo de los entregables, sino también como una

base para futuras actualizaciones y mejoras del sistema.



(a)



(b)

**Puntas de espárragos categoría A (a). Punta de espárragos categoría B (b)**  
**Figura 3**

En la tabla se presenta la verificación de una imagen utilizando Python en Visual Studio Code. El comando ejecutado incluye dos parámetros de confianza de 0.5: el primero define la referencia del modelo entrenado, asegurando que solo se consideren predicciones con un nivel de confianza adecuado, y el segundo especifica la imagen a reconocer, denominada "annotated\_frame," para su posterior visualización. Además de

estos parámetros, se configura el entorno para facilitar la depuración y análisis de resultados, permitiendo realizar ajustes rápidos en caso de ser necesario. Esta configuración asegura que el proceso de verificación sea tanto preciso como eficiente.


**Tabla - Comandos de activación para la detección de puntas de espárrago con la cámara en python.**

Descripción	Código para ver la cámara conectada
OpenCV abre la cámara conectada al ordenador	<code>cap = cv.VideoCapture(1)</code>
Descripción	Código para determinar el alto y ancho de la imagen
Establece la imagen a 800 píxeles de ancho en el dataset	<code>cap.set(cv.CAP_PROP_FRAME_WIDTH, 800)</code>
Descripción	Código para activar red neuronal y mostrar los resultados con confianza: 0.5
Función que activa la cámara y muestra la imagen detectada	<code>results = model(frame, conf=0.5)</code>
Descripción	Código para mostrar clase de Espárrago
Visualización de la imagen con línea contorneada	<code>cv.imshow("espárrago",frame)</code>

### 3. RESULTADOS

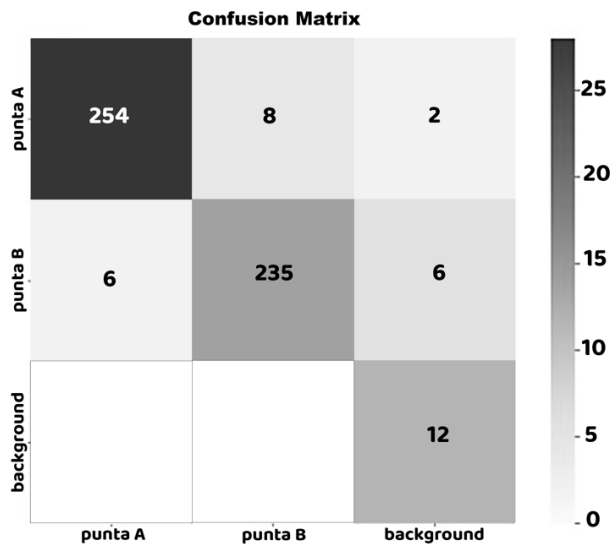
Se muestran los resultados del proceso de visión artificial utilizando YoloV8 con imágenes reales de espárragos en un formato de 640 píxeles, capturadas con una cámara y un fondo blanco. Al aplicar los algoritmos del programa, se pueden observar los recuadros que detectan las puntas en buen estado, en mal estado y en estado intermedio (Figura 4).





*Detección de yemas de espárragos en ambiente controlado*  
**Figura 4**

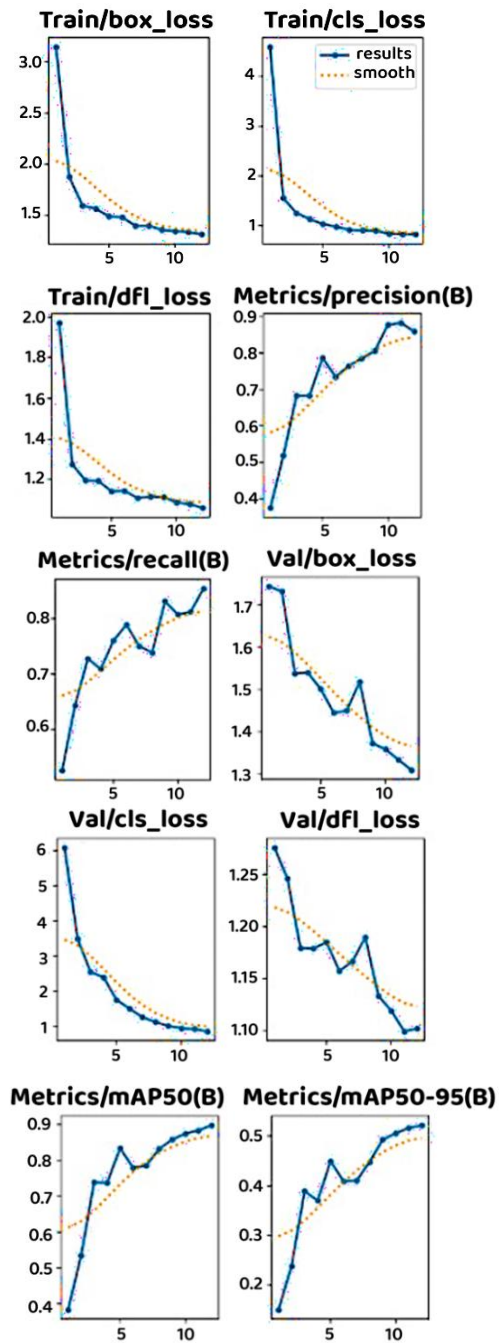
En la (Figura 5), los resultados del entrenamiento de la red neuronal se presentan a través de una matriz de confusión, la cual revela que la precisión promedio en la detección de la calidad de la yema de los espárragos es del 96%. Esta alta precisión indica que el modelo es capaz de clasificar correctamente la calidad de las yemas en la mayoría de los casos, minimizando los errores de clasificación.



*Matriz de confusión para las yemas del espárrago*  
**Figura 5**

Para ejecutar la red neuronal, se utilizó Python 3.7. Durante el entrenamiento del modelo, se emplearon 1,610 imágenes de yemas de espárragos, seleccionadas para representar una variedad de condiciones de calidad. Para la validación del modelo, se utilizaron 460 imágenes adicionales, mientras que 230 imágenes se destinaron a la fase de pruebas, asegurando así una evaluación completa del rendimiento del modelo en diferentes etapas. Una vez seleccionado el modelo, su desempeño fue validado utilizando las métricas estándar de evaluación proporcionadas por YOLO. Estas métricas incluyen la Curva F1-Confidence, la curva

Precision-Recall y las gráficas de pérdida, que ayudan a visualizar la convergencia del modelo durante el entrenamiento. Además, las métricas de rendimiento fueron evaluadas a lo largo de 30 épocas de procesamiento (Figura 6).



*Métricas de precisión y pérdidas durante el entrenamiento para 30 épocas*  
**Figura 6**

**4. DISCUSIÓN**

La simulación demostró la efectividad de clasificar espárragos según su color y la apertura de la punta de la yema. Se observó

que, al aplicar diferentes muestras, el proyecto mantuvo un porcentaje de precisión del 96%, sin variaciones significativas, incluso con nuevas muestras. En comparación con la investigación [15], que aplicó visión artificial en tres niveles con 210 imágenes de frutas y obtuvo un máximo de 92.5%, nuestra red neuronal mostró mejores resultados, permitiendo la automatización y reducción de errores en las áreas de calidad. Además, [9] señala que la implementación de inteligencia artificial en las pruebas logró un 97.5% de precisión en la clasificación de espárragos mediante una red neuronal artificial. Combinado con nuestro sistema, que tiene un 96% de precisión en la detección de yemas, se beneficia la producción, demostrando la viabilidad de implementar visión artificial en diversas empresas exportadoras.

## 5. CONCLUSIÓN

La red neuronal artificial logró un 96% de precisión, lo que demuestra que la segmentación de espárragos mediante inteligencia artificial es una solución eficaz frente a la clasificación manual. Esta tecnología ofrece una alternativa viable para las empresas agroexportadoras de espárragos, ayudándolas a aumentar su productividad.

En la implementación de Yolo v8, se utilizaron diversas técnicas para clasificar las yemas de espárragos según el tipo de punta, un proceso importante para la exportación. Los algoritmos empleados permiten detectar el estado de las yemas, identificando si están en buen o mal estado. Los resultados de las pruebas fueron satisfactorios.

La tecnificación en la clasificación de espárragos no solo mejora el tiempo de procesamiento, sino también la calidad del mismo. Las simulaciones realizadas, con un total de 523 tomas, mostraron una precisión promedio del 96%.

## 6. REFERENCIAS

- [1] Salas Blas, Edwin. (2013). Diseños pre experimentales en psicología y educación: una revisión conceptual. *Liberabit*, 19(1), 133-141. Recuperado en 13 de noviembre de 2022, de [http://www.scielo.org.pe/scielo.php?script=sci\\_arttext&pid=S1729-48272013000100013&lng=es&tlng=es](http://www.scielo.org.pe/scielo.php?script=sci_arttext&pid=S1729-48272013000100013&lng=es&tlng=es).
- [2] Báez Rojas, J. J, & Alonso Pérez, M.A. (2018). Uso del sistema HSI para asignar falso color a objetos en imágenes digitales. *Revista mexicana de física E*, 54(2), 186-192. Recuperado en 14 de noviembre de 2022, de [http://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S1870-35422008000200011&lng=es&tlng=es](http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1870-35422008000200011&lng=es&tlng=es).
- [3] Barea, R, Boquete, L, Bergasa, L. M, & Mazo, M. (2018). Un Programa Interactivo para la Enseñanza de Algoritmos de Procesamiento Digital de Imágenes. *Formación universitaria*, 1(5), 21-28. Recuperado de <https://dx.doi.org/10.4067/S0718-50062008000500004>
- [4] Sanchis Cases, F. J. (2015). Programación de Aplicaciones OpenCV sobre Sistemas Heterogéneos SoC-FPGA. Recuperado de <http://rua.ua.es/dspace/handle/10045/49507>
- [5] Harris, CR, Millman, KJ, Van Der Walt, SJ, Gommers, R., Virtanen, P., Cournapeau, D. y Oliphant, TE (2020). Programación de matrices con NumPy. *Naturaleza*, 585 (7825), 357-362. Recuperado de <https://www.nature.com/articles/s41586-020-2649-2>
- [6] Virtanen, P., Gommers, R., Oliphant, TE, Haberland, M., Reddy, T., Cournapeau, D., & Van Mulbregt, P. (2020). SciPy 1.0: algoritmos fundamentales para la computación científica en Python. *Métodos de la naturaleza*, 17 (3), 261-272. Recuperado de <https://pubmed.ncbi.nlm.nih.gov/32015543/>
- [7] Challenger-Pérez, I., Díaz-Ricardo, Y., & Becerra-García, RA (2014). El lenguaje de programación Python. *Ciencias Holguín*, 20 (2), 1-13. Recuperado de <https://www.redalyc.org/pdf/1815/181531232001.pdf>
- [8] Orduz Rodriguez, J. J., & Lozano Mantilla, G. A. (2015). Diseño de un orq sistema de visión artificial para la revisión del nivel de llenado de bebidas embotelladas. Recuperado de <http://repositorio.uac.edu.co/jspui/handle/11619/1371>
- [9] Gamonal Chanco, A. E. (2020). Diseño de un sistema por visión artificial para determinar la calidad de mandarinas. Recuperado de <https://repositorio.utp.edu.pe/handle/20.500.12867/3986>
- [10] Heredia, E., & Palomino, L. (2020). Análisis del comportamiento de las exportaciones de espárragos frescos en el mercado internacional y su impacto en el PBI agropecuario peruano durante 2007-2019. Recuperado de <https://repositorio.usil.edu.pe/items/f0e826f8-123d-422b-ae3c-6d6959fa313c/full>
- [11] Solem, J. (2013). Programming computer vision with python. *Unite states of America: O'Reilly me- dian, inc..* Recuperado de <https://acortar.link/9IqD95>
- [12] Juanazo Paucar, F. A. (2019). Desarrollo de una herramienta informática basada en visión artificial para el reconocimiento del banano para la exportación aplicando procesamiento de imágenes digitales y su simulación en Matlab mediante redes neuronales (Bachelor's thesis, Universidad de Guayaquil Facultad de Ciencias Matemáticas y Físicas Carrera de Ingeniería en Sistemas Computacionales). Recuperado de <http://repositorio.ug.edu.ec/bitstream/redug/39877/1/B->

CISC-PTG-

1652%20Juanazo%20Paucar%20Freddy%20Alex.pdf

- [13] Martín, M. (2013). Procesamiento Digital de Imágenes. Puebla-México. Recuperado de <https://repositorio.utp.edu.co/server/api/core/bitstreams/3224ba15-ea01-4b21-98f4-e100bc16788d/content>
- [14] Montoya, P. (2018). Diseño de un sistema robótico para la clasificación automatizada de espárragos empleando visión artificial por imágenes. Recuperado de <https://hdl.handle.net/20.500.12867/2532>
- [15] Quiroz, A. (2021). Aplicación de técnicas de visión por computador en la selección de palta hass de calidad. Recuperado de <https://repositorio.uss.edu.pe/handle/20.500.12802/8392>
- [16] Ciresan, D. C., Meier, U., Masci, J., Gambardella, L. M., & Schmidhuber, J. (2011, June). Flexible, high performance convolutional neural networks for image classification. In Twenty-second international joint conference on artificial intelligence. Recuperado de <https://people.idsia.ch/~juergen/ijcai2011.pdf>
- [17] Cisneros, F. L. M. (2011). Sistema experto para diagnóstico de puntas de espárrago (*Zea mays* L.) en Centro América. *Agronomía Mesoamericana*, 80-88. Recuperado de <https://repositorio.catie.ac.cr/bitstream/handle/11554/10471/A0789e0203.pdf>
- [18] Díez, R. P., Gómez, A. G., & de Abajo Martínez, N. (2001). Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva. Universidad de Oviedo. Recuperado de [https://books.google.com.pe/books/about/Introducci%C3%B3n\\_a\\_la\\_inteligencia\\_artifici.html?id=RKqLMCw3IUkC&redir\\_esc=y](https://books.google.com.pe/books/about/Introducci%C3%B3n_a_la_inteligencia_artifici.html?id=RKqLMCw3IUkC&redir_esc=y)
- [19] Ferreñan, P., & Enrique, J. (2019). Sistema de visión artificial para apoyar en la identificación de enfermedades del cultivo de espárrago en el distrito de Ferreñafe. Recuperado de <https://core.ac.uk/reader/395733790>
- [20] Flórez, C. A. C., Hurtado, D. A., & Sandoval, O. L. R. (2015). Procesamiento de imágenes para reconocimiento de daños causados por plagas en el cultivo de *Begonia semperflorens* (flor de azúcar). *Acta Agronómica*, 64(3), 273-279. Recuperado de [http://www.scielo.org.co/scielo.php?pid=S0120-28122015000300011&script=sci\\_arttext](http://www.scielo.org.co/scielo.php?pid=S0120-28122015000300011&script=sci_arttext)
- [21] Marco, V. (2011). Modelización de la tasa de desarrollo de espárrago en función de la temperatura. Aplicación al manejo integrado mediante el método de grados-día. *Bol. SEA*, 28, 147-150. Recuperado de [http://sea-entomologia.org/PDF/BOLETIN\\_28/B28-038-147.pdf](http://sea-entomologia.org/PDF/BOLETIN_28/B28-038-147.pdf)
- [22] Matich, D. J. (2021). Redes Neuronales: Conceptos básicos y aplicaciones. Universidad Tecnológica Nacional, México. Recuperado de [https://gc.scalahed.com/recursos/files/r161r/w25199w/s5\\_redesneuronales.pdf](https://gc.scalahed.com/recursos/files/r161r/w25199w/s5_redesneuronales.pdf)
- [23] Pacheco, M. A. (2017). Identificación de sistemas no lineales con redes neuronales convolucionales. Recuperado de <https://www.ctrl.cinvestav.mx/~yuw/pdf/MaTesMLP.pdf>
- [24] Salas, R. (2004). Redes neuronales artificiales. Universidad de Valparaíso. Departamento de Computación. Recuperado de <https://www.studocu.com/latam/document/universidad-central-de-venezuela/anatomia-normal/redes-neuronales-artificiales/66100094>