



# FACULTAD DE INGENIERÍA

Carrera de Ingeniería Electrónica

**“Sistema de procesamiento de imágenes  
utilizando un modelo Deep Learning para  
identificar el de grado de madurez satisfactorio del  
arándano como requisito para su exportación según  
la Norma Técnica Peruana 012.501 en 2024”**

**Tesis para optar al título profesional de:**

**Ingeniera Electrónico**

**Autor:**

Eimy Jeanisse Paredes Alfaro

**Asesor:**

Mg. Ing. Edgar Andre Manzano Ramos

**0000-0002-8198-5619**

Lima - Perú

**2024**

## JURADO EVALUADOR

Jurado 1 Presidente(a)	<b>Lizbeth Leslie Hidalgo Tufiño</b>
	Nombre y Apellidos

Jurado 2	<b>Jairo Pinedo Taquia</b>
	Nombre y Apellidos

Jurado 3	<b>Edgar Andre Manzano Ramos</b>
	Nombre y Apellidos

## Informe de Similitud




### 5% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

#### Filtrado desde el informe

- ▶ Bibliografía
- ▶ Texto citado
- ▶ Texto mencionado
- ▶ Coincidencias menores (menos de 10 palabras)

#### Fuentes principales

- 4%  Fuentes de Internet
- 1%  Publicaciones
- 3%  Trabajos entregados (trabajos del estudiante)

#### Marcas de integridad

##### N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.




Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.



Página 3 of 115 - Descripción general de integridad

#### Fuentes principales

- 4%  Fuentes de Internet
- 1%  Publicaciones
- 3%  Trabajos entregados (trabajos del estudiante)

#### Fuentes principales

Las fuentes con el mayor número de coincidencias dentro de la entrega. Las fuentes superpuestas no se mostrarán.

1	Internet	
	repositorio.upn.edu.pe	1%
2	Internet	
	core.ac.uk	1%
3	Publicación	
	Craig B. MacEachern, Travis J. Esau, Arnold W. Schumann, Patrick J. Hennessy, Qa...	0%
4	Internet	
	uu.diva-portal.org	0%

## **Dedicatoria**

A mis padres, quienes con amor incondicional y dedicación me acompañaron en  
cada paso de este camino. Este logro es por y para ustedes.

A mi hermano, que siempre me acompaña y alegra mis días.

### **Agradecimiento**

A Dios, que me da la vida, y con indescriptible amor y misericordia me permitió  
llegar hasta aquí.

A mis padres, quienes con amor, esfuerzo y sacrificio me brindaron acceso a una  
carrera universitaria.

A mi asesor de tesis Mg. Ing. Edgar Manzano por brindarme su conocimiento,  
orientación y paciencia durante este largo proceso.

## ÍNDICE

JURADO EVALUADOR.....	2
Informe de Similitud.....	3
Dedicatoria.....	4
Agradecimiento.....	5
Índice de tablas .....	10
Índice de Figuras.....	13
Resumen .....	15
Palabras Claves .....	16
CAPÍTULO I: INTRODUCCIÓN.....	17
1.1    Realidad problemática .....	17
1.2.    Antecedentes.....	19
1.3.    Precisiones conceptuales .....	23
1.3.1.    Arándano.....	23
1.3.2.    Índice de madurez.....	23
1.3.3.    Estado de maduración del arándano .....	23
1.3.4.    Estándares de Calidad para la exportación .....	24
1.3.5.    Inteligencia Artificial.....	24
1.3.6.    Machine Learning (ML) .....	25
1.3.7.    Deep Learning (DL) .....	25
1.3.8.    Redes Neuronales Convolucionales (CNN) .....	25

1.3.9. YOLO v8 .....	28
1.3.10. Hiperparámetros .....	31
1.3.11. Métricas de rendimiento .....	32
1.4. Formulación del problema .....	35
1.4.1. Pregunta general .....	35
1.4.2. Preguntas específicas .....	35
1.5 Objetivos .....	36
1.5.1. Objetivo general .....	36
1.5.2. Objetivos específicos .....	36
1.6 Hipótesis .....	37
1.6.1. Hipótesis general .....	37
1.6.2. Hipótesis específicas .....	37
<b>CAPÍTULO II: METODOLOGÍA .....</b>	<b>38</b>
2.1. Tipo de investigación .....	38
2.1.1. Enfoque .....	38
2.1.2. Alcance .....	38
2.1.3. Diseño de la investigación .....	38
2.2. Población y Muestra .....	39
2.2.1. Población .....	39
2.2.2. Muestra .....	39
2.3 Métodos e instrumentos .....	40

2.3.1. Métodos .....	40
2.3.2. Instrumentos .....	50
2.4. Procedimiento de recolección de datos.....	51
2.4.1. Construcción del conjunto de datos.....	51
2.4.2. Selección de modelo Deep Learning .....	53
2.5. Tratamiento y análisis de datos.....	58
2.5.1. Tratamiento de datos.....	58
2.5.2. Análisis de datos .....	60
2.6. Aspectos éticos .....	60
CAPÍTULO III: RESULTADOS .....	62
3.1. Resultados del entrenamiento .....	62
3.1.1. Batch .....	63
3.1.2. Tasa de aprendizaje (Learning rate) .....	64
3.1.3. Optimizador .....	71
3.1.4. HSV_H .....	74
3.2. Resultados de validación .....	78
3.3. Resultados del conjunto de prueba .....	80
CAPÍTULO IV: DISCUSIÓN Y CONCLUSIONES.....	87
4.1. Limitaciones .....	87
4.2. Interpretación Comparativa .....	88
4.2.1. Comparación con modelos de MacEachern et.al.....	90

4.2.2. Comparación con modelos de Xiao et.al. ....	91
4.2.3. Comparación con modelos Wenji et.al. ....	94
4.3. Implicancias .....	97
4.4. Conclusiones.....	98
<b>REFERENCIAS.....</b>	<b>100</b>
<b>ANEXOS .....</b>	<b>107</b>

## Índice de tablas

<b>Tabla 1.</b> Características principales de las versiones YOLO versiones 1-8 extraídas del artículo de investigación de Terven et.al (2023). .....	30
<b>Tabla 2.</b> Lista de requerimientos del sistema de procesamiento de imágenes. ....	41
<b>Tabla 3.</b> Clasificación de estados de madurez empleados en trabajos de investigación. ....	42
<b>Tabla 4.</b> Robots orientados a la cosecha de frutas o verduras .....	45
<b>Tabla 5.</b> Áreas de aplicación de redes neuronales convolucionales. ....	47
<b>Tabla 6.</b> Tiempo de ciclo de robots para cosechar verduras o frutas.....	48
<b>Tabla 7.</b> Valores que debe alcanzar el modelo en las métricas de rendimiento. ....	49
<b>Tabla 8.</b> Composición del conjunto de arándanos .....	51
<b>Tabla 9.</b> Cantidad de imágenes descartadas en cada base de datos. ....	52
<b>Tabla 10.</b> Redes Neuronales empleadas en el artículo “Detection of fruit maturity stage and yield estimation in wild blueberry using deep learning convolutional neural networks”.....	54
<b>Tabla 11.</b> Redes Neuronales empleadas en el artículo “Blueberry Ripeness Detection Model Based on Enhanced Detail Feature and Content-Aware Reassembly”.....	54
<b>Tabla 12.</b> Redes Neuronales empleadas en el artículo “A Lightweight Detection Method for Blueberry Fruit Maturity Based on an Improved YOLO v5 Algorithm”....	55
<b>Tabla 13.</b> Métricas de rendimiento de la familia YOLOv8 para detección de objetos. ....	57
<b>Tabla 14.</b> Dimensiones de las imágenes del conjunto de datos. ....	58
<b>Tabla 15.</b> Cantidad de datos en conjuntos de evaluación empleadas en investigaciones afines.....	60

<b>Tabla 16.</b> Condiciones iniciales de hiperparámetros. ....	62
<b>Tabla 17.</b> Pruebas realizadas modificando el batch en la red neuronal YOLO v8.....	63
<b>Tabla 18.</b> Pruebas con mejores resultados asignando el mismo el valor a ambas tasas de aprendizaje.....	65
<b>Tabla 19.</b> Pruebas realizadas asignando valores diferentes a las tasas de aprendizaje inicial y final.....	68
<b>Tabla 20.</b> Pruebas realizadas utilizando el optimizador Adam y SGD.....	72
<b>Tabla 22.</b> Pruebas modificando hiperparámetro hue con 3 clases.....	75
<b>Tabla 23.</b> Hiperparámetros empleados en la red neuronal YOLO v8n. ....	77
<b>Tabla 24.</b> Tiempos de inferencia obtenidos en el set de prueba. ....	82
<b>Tabla 25.</b> Métricas de rendimiento para 3 clases.....	82
<b>Tabla 26.</b> Precisión, sensibilidad y F1 score por cada clase.....	83
<b>Tabla 27.</b> Precisión media y precisión media promedio por clase. ....	84
<b>Tabla 28.</b> Métricas de rendimiento para enfoque de 2 clases.....	85
<b>Tabla 29.</b> Estado de cada requerimiento establecido.....	86
<b>Tabla 30.</b> Comparación de métricas de precisión, sensibilidad y F1 score entre el modelo YOLOv8 n y los modelos entrenados por MacEachern et.al con 2 enfoques... ..	90
<b>Tabla 31.</b> Comparación de métricas P y R entre YOLOv8n y los modelos entrenados por Xiao et.al. ....	92
<b>Tabla 32.</b> Factores que influyeron en el rendimiento de las redes YOLOv8n y YOLOv5.....	93
<b>Tabla 33.</b> Comparación de métricas AP y mAP entre YOLOv8n y modelos entrenados por Wenji et.al. ....	95

**Tabla 34.** Factores que influyeron en el rendimiento de las redes..... 96

## Índice de Figuras

<b>Figura 1.</b> Clasificación de arándanos próximos a la maduración según Quispe (2023). .....	24
<b>Figura 2.</b> Diagrama de la arquitectura YOLOv8. ....	29
<b>Figura 3.</b> Diagrama de flujo para desarrollar el sistema de procesamiento de imágenes. .....	40
<b>Figura 4.</b> Clasificación inicial de los grados de madurez del arándano. ....	44
<b>Figura 5.</b> Tipo de imágenes descartadas del conjunto de datos.....	53
<b>Figura 6.</b> Clasificación final de los distintos grados de madurez. ....	59
<b>Figura 7.</b> Gráficas de la métrica F1-confidence obtenidas de las pruebas modificando el batch.....	64
<b>Figura 8.</b> Gráficas de las curvas de precisión-recall obtenidas de las pruebas III y IV.	66
<b>Figura 9.</b> Gráficas de las curvas precisión- recall obtenidas de las pruebas V, VI y VII. .....	67
<b>Figura 10.</b> Matriz de confusión de la prueba IV con ambas tasas de aprendizaje iguales.....	67
<b>Figura 11.</b> Gráficas de las curvas de precisión-recall obtenidas en las pruebas I y II.	70
<b>Figura 12.</b> Gráficas de las curvas de precisión y recall obtenidas de las pruebas III y IV.....	70
<b>Figura 13.</b> Matriz de confusión de la prueba III con tasas de aprendizajes diferentes.	71
<b>Figura 14.</b> Gráficas de las curvas precisión-recall de las pruebas realizadas con los optimizadores Adam y SGD.....	73
<b>Figura 15.</b> Matriz de confusión obtenida al emplear el optimizador SGD.....	74

<b>Figura 16.</b> Matrices de confusión obtenidas al modificar el hiperparámetro hue. ....	76
<b>Figura 17.</b> Curvas Precisión-Recall para $h=0.012$ y $h=0.015$ . .....	77
<b>Figura 18.</b> Curva F1-confianza generada a partir de los datos de validación.....	78
<b>Figura 19.</b> Curva Precisión-Sensibilidad.....	80
<b>Figura 20.</b> Predicciones realizadas por la red neuronal YOLO v8n.....	80
<b>Figura 21.</b> Predicciones de imágenes similares realizadas por YOLOv8n. ....	88
<b>Figura 22.</b> Niveles de maduración usados por Wenji et.al .....	94

## Resumen

En la presente investigación, se aborda la importancia de mantener la calidad del arándano de exportación. Por ello, el Instituto Nacional de Calidad aprobó la Norma Técnica Peruana 012.501:2019, que establece los requisitos que el arándano debe cumplir para su exportación. Uno de estos requisitos es que el fruto presente un índice de madurez adecuado. Por esta razón, se propone desarrollar un sistema de procesamiento de imágenes para identificar el grado de madurez óptimo del arándano.

Para ello, en primera instancia, se elaboró una lista de requerimientos, que sirvió como guía para establecer los recursos necesarios para desarrollar dicho sistema. Luego, se construyó un conjunto de datos, los cuales fueron preprocesados antes de ser utilizados para entrenar una red neuronal convolucional. Posteriormente, se realizaron distintas pruebas modificando los valores de los hiperparámetros a fin de obtener el mejor rendimiento posible de la red, y, finalmente, se evaluó el rendimiento del sistema empleando métricas, tales como, precisión, sensibilidad, F1 score, precisión promedio (AP) y precisión media promedio (mAP).

Asimismo, para evaluar la eficiencia del sistema propuesto se comparó el rendimiento con el de otros modelos presentados en 3 artículos científicos. A partir de ello, se evidenció que el sistema presentado en esta investigación tiene una alta precisión (97.5%) para identificar el grado de madurez satisfactorio del arándano, valor similar a los obtenidos por otros modelos. Por otra parte, en términos de sensibilidad para la clase de arándano maduro el sistema obtuvo 81.2%, que, a pesar de ser un puntaje alto, fue superado por las demás redes. Por último, en cuanto a AP y mAP el modelo obtuvo resultados superiores al 60%, pero bajos a comparación de los demás.

### **Palabras Claves**

Grado de madurez, arándano, Deep learning, YOLOv8

## **CAPÍTULO I: INTRODUCCIÓN**

### **1.1 Realidad problemática**

Un símbolo de desarrollo económico y social en el Perú son las agroexportaciones (IPE,2022). En la actualidad, según la plataforma digital única del Estado Peruano (2023), Perú se posicionó en 2022 como el principal exportador de arándanos a nivel mundial por cuarta vez consecutiva, y en enero de 2023 se registró un aumento de agroexportaciones del 4% respecto al año pasado. El boom de la agroexportación peruana del denominado oro azul se debe principalmente a las condiciones favorables que posee el país en términos de clima, temperatura y la baja probabilidad de perder cosechas (Ghezzi y Stein, 2021); lo que brinda ventaja respecto a otros países exportadores, pues la producción del arándano puede extenderse durante todo el año. Asimismo, el alto nivel de profesionalismo en cuanto a la producción agrícola, en conjunto con el debido cuidado fitosanitario y la apertura y acceso a mercados internacionales han permitido al Perú pasar de exportar 12,951 toneladas de arándanos frescos en el período 2015-2016 a exportar 286,240 toneladas en la campaña 2022-2023 (Proarándanos, 2024).

El auge tecnológico ha traído consigo variedad de beneficios en diversos ámbitos de la vida, por ejemplo, mejorar la productividad y eficiencia; además de impulsar el crecimiento económico. En esta era moderna, la tecnología ha logrado desempeñar un papel fundamental en la industria agrícola, dando lugar a la aparición de la agricultura de precisión, la cual engloba una serie de tecnologías empleadas en este sector; las cuales son útiles para tomar decisiones eficientes y ejecutarlas de forma idónea. Las técnicas empleadas en la agricultura de precisión se concentran en las actividades que involucran la siembra, crecimiento y explotación de cultivos (Rambauth, 2022). Dos de las tecnologías más importantes de esta época son Machine Learning, el cual es subconjunto

de la inteligencia artificial que brinda a las computadoras la capacidad de aprender mediante datos que le permiten entender la relación entrada-salida empleando algoritmos para predecir, clasificar y generar conocimiento; por otra parte, Deep Learning, que traducido al español significa aprendizaje profundo, es el subconjunto del Machine Learning que emplea redes neuronales y redes neuronales profundas las cuales requieren un conjunto de datos de entrenamiento para aprender (Rozo-García, 2020).

El uso de la IA en la agricultura de precisión ha generado un impacto positivo en la cosecha de frutos, pues sus algoritmos son muy útiles para la detección y clasificación de frutos maduros, ya que se pueden entrenar para reconocer características específicas de maduración, por ejemplo, color y tamaño mediante el uso de bases de datos (Ultralytics, 2024). Esto permite una identificación precisa y eficiente de los frutos listos para la cosecha. Lo que aumenta la eficiencia operativa, además de garantizar una cosecha de calidad.

En el mercado agroindustrial se exige que el productor y exportador trabajen bajo distintas normas y códigos de prácticas que garanticen la inocuidad y calidad de los productos. Dichas normas están referidas a que los productos no sean nocivos para la salud del consumidor, y otras hacen referencia a características de calidad comercial (MIDAGRI, s/f). Por esta razón en el Perú, principal exportador de arándanos a nivel mundial, en 2021 el Instituto Nacional de Calidad aprobó las Normas Técnicas Peruanas: NTP 012.500:2018 Arándano Términos y Definiciones, NTP 012.501:2019 Arándano Fresco Requisitos y la NTP 012:502:2021 ARÁNDANO (Gobierno Regional de Piura, 2022). Para el motivo de este trabajo, nos centraremos en el anexo c de regla NTP 012.501:2019 la cual enuncia los estándares mínimos para que el arándano pueda ser

exportable: fruto firme, fresco, sano y libre de pudrición, fruto de color azul uniforme, fruto con índice de madurez adecuado, no presentar olores y/o sabores extraños, fruto entero y sin daño (Santiesteban, 2024).

Debido a las altas cifras en producción de arándanos en el Perú, y a que estos deben mantener ciertos estándares mínimos para ser exportados, tal y como se menciona líneas arriba, se hace imprescindible emplear tecnologías de Machine Learning y Deep Learning para garantizar el buen estado de los arándanos. Para ello, se propone un algoritmo de detección de objetos que sea capaz de identificar en tiempo real que los arándanos presenten el índice de madurez adecuado.

## **1.2. Antecedentes**

Aguilar-Alvarado y Campoverde-Molina (2020) en “*Clasificación de frutas basadas en redes neuronales convolucionales*” mencionan que para que un identificador de frutas adquiera un buen valor y competitividad en el mercado, este debe ser capaz de reconocer parámetros básicos, tales como forma, tamaño y color de la fruta, con efectividad. Los autores crearon una red convolucional capaz de clasificar 13 tipos de frutas (banana, cereza, frutilla, mandarina, mora, papaya, piña, uva, mango, manzana, naranja, pera, limón). Para ello, emplearon una base de datos con imágenes propias de la fruta e imágenes obtenidas de internet; dicha dataset constó de 13.516 imágenes. Lograron obtener 87% de eficiencia en este trabajo con un tiempo de respuesta que oscila entre los 0,406s y 0,463s. Además, concluyeron que, a mejor resolución de imágenes, mayor eficiencia del modelo neuronal, es decir, la efectividad del aprendizaje y la resolución de imágenes están ligadas.

Aguirre (2021) en “*Detección de enfermedades de la fresa en la agricultura de precisión*” comparó cuatro algoritmos de detección de objetos empleando aprendizaje

profundo con la finalidad de identificar enfermedades muy frecuentes en cultivos de fresa, tales como, Botrytis cinérea, quemadura fomial y mildiú polvoriento. Se enfocó en los dos mejores resultados en términos de precisión media. Los algoritmos efficientDet-D0 y SSDD-Resnet 500 presentaron mejores resultados en términos de precisión promedio media. Las pruebas se realizaron usando un conjunto de prueba de 100 imágenes. El primer algoritmo logró una precisión del 81% y el segundo logró el 77%. Ambos algoritmos identificaron con éxito las 3 enfermedades y los dos tipos de estado de la fresa (sin madurar aún y madura).

Branque (2022) en *“Implementación de un sistema automatizado, mediante el uso de visión artificial para la clasificación del maracuyá, según su color de madurez y el uso de un sistema SCADA para el monitoreo de la productividad”* implementó un sistema automatizado empleando visión artificial para clasificar el maracuyá según su color de madurez, adicionalmente, usó un sistema SCADA para el monitoreo de la productividad. Respecto al sistema de detección de visión artificial, se realizaron tres pruebas para el sistema; el primero con 20 muestras, el segundo con 100 muestras y el tercero con 200 muestras. Siendo el último el más efectivo, pues detectó todas las maracuyás pintonas, maduras y dañadas, es decir, todas las pruebas fueron correctas. Se concluye que, a mayor número de muestras aplicadas al modelo, mejor es precisión de este.

Delgado y Obeso (2019) en *“Solución de machine learning en el reconocimiento de plagas para plántones de arándanos”* crearon una aplicación móvil en Android basada en técnicas de machine learning para detectar plagas que afectan a la planta del arándano, tales como heliothis y argytaenia, con la finalidad de acelerar el proceso de reconocimiento, y agricultores inexpertos reconozcan con facilidad plagas en sus cultivos. Emplearon la red convolucional Inception v3, así como las librerías TensorFlow y Keras

con lenguaje de programación en Python. El entrenamiento se realizó con un total de 539 imágenes, y se obtuvo como resultado en las dimensiones sensibilidad y especificidad una precisión del 89,88% y 82,29% respectivamente. Para este trabajo el promedio de la certeza en el reconocimiento de plagas para plantones de arándano fue 90,14%.

MachEachern et.al. (2023) en *“Detection of fruit maturity stage and yield estimation in wild blueberry using Deep learning convolutional neural networks”* analizaron 6 modelos de redes neuronales artificiales de aprendizaje profundo para detectar el estado de madurez en arándanos silvestres y desarrollar modelos para la estimación del rendimiento. Los modelos utilizados fueron YOLOv3, YOLOv3-Tiny, YOLOv3 SPP, YOLOv4, YOLOv4-Small y YOLO v4-Tiny. Cada una de las redes mencionadas fue entrenada empleando Darknet y una base de datos propia que consta de 17280 imágenes, de las cuales 6766 fueron etiquetadas, 4736 (70%) de estas se usaron para el entrenamiento y 1015 (15%) para la validación; mientras que, el 15% restante se reservó para testear modelos independientes. Los resultados muestran que YOLOv4 obtuvo la precisión promedio más alta con 79.79%, seguida de YOLOv4-Small con 79.53%, YOLOv3-SPP con 77.36% de mAP50, luego continua YOLOv3 (77.07%), YOLOv4-Tiny (74.08%), y finalmente YOLOv3-Tiny (62.34%).

Xiao et.al. (2023) en *“A Lightweight Detection Method for Blueberry Fruit Maturity Based on an Improved YOLOv5 Algorithm”* desarrollaron un método de detección liviano basado en el algoritmo YOLO v5 mejorado para reconocer de forma precisa, rápida y sólida las etapas de madurez de los frutos de arándanos. El algoritmo YOLOv5 mejorado está compuesto por un módulo ShuffleNet, el cual sirve para lograr redes neuronales ligeras y convolucionales profundas, y el módulo de atención de bloques convolucionales (CBAM) también se utiliza para mejorar la capacidad de fusión de

características de redes neuronales convolucionales profundas y livianas. Para esta investigación utilizaron una base de datos de 9935 frutas de arándanos de las cuales 7895 se usaron para el entrenamiento y 2040 para la validación. Cabe destacar que las imágenes se etiquetaron basándose en 3 clases: arándano maduro, arándano medio maduro y arándano inmaduro. Este modelo obtuvo una precisión media (mAP) en un umbral de 0,5 es 91.5%, un recall de 92% y velocidad de detección media de 67,1 fotogramas por segundo. El algoritmo trabajado en esta investigación se comparó con otros, tales como, YOLOv5, SSD y Faster R-CNN. De los mencionados el que obtuvo mayor precisión, recall y precisión media fue YOLOv5.

Wenji et.al. (2023) en “*Blueberry Ripeness Detection Model Based on Enhanced Detail Feature and Content-Aware Reassembly*” desarrollaron un modelo de detección de madurez de arándanos realizando algunas mejoras en la red YOLOv7, a la cual se le añadió un Módulo de funciones de detalle mejorado (EFDM), un módulo RFB más eficiente con menos parámetros y el módulo MP-S rediseñado para eliminar la pérdida de información detallada. Además, se empleó una base de datos propia que paso de tener 600 a 6000 imágenes de arándanos; esto empleando tecnología para aumentar datos. Se clasificaron los arándanos en 5 niveles de madurez: 1-verde,2-volviendose rojos, 3-rojos,4-azul púrpura y 5-demasiado maduros con superficie arrugada. El modelo mejorado de YOLOv7 fue comparado con otros 7 modelos, tales como, YOLOv5, YOLOX, EfficientDet, Faster RCNN, YOLOv7-GhostNet, YOLOv7-MobileNetV3 y YOLOv7. El indicador empleado para la evaluación de los modelos fue la precisión promedio y mAP, en donde el modelo YOLOv7 mejorado obtuvo los mejores resultados 67.3% a 90.6% en cuanto a AP y 80.7 %

### **1.3.Precisiones conceptuales**

A continuación, se abordan las precisiones conceptuales sobre las variables de la presente investigación

#### **1.3.1. Arándano**

Es una baya de forma redondeada cuyo diámetro oscila entre los 7 a 9 mm, de tonalidad azul oscura. Esta fruta del bosque presenta un sabor agrídulce, y es abundante en antioxidantes los cuales regulan los niveles de colesterol y favorecen el sistema cardiovascular, además de mejorar la circulación sanguínea. Debido a sus grandes beneficios se ha convertido en un alimento muy demandado a nivel mundial. Existen diferentes tipos de arándanos tales como, arándano azul, arándano negro y arándano rojo (Gobierno Regional de Piura, 2022).

#### **1.3.2. Índice de madurez**

Romero et.al. (2023) indican que el índice de madurez determina si un producto ha alcanzado la madurez que se busca a nivel comercial. Se emplean características del fruto a fin de obtener estimaciones adecuadas de madurez; para el arándano son muy usados el color, la firmeza, el contenido de sólidos solubles totales y la acidez titulable (pp.20-21).


#### **1.3.3. Estado de maduración del arándano**

Quispe (2023) clasificó en 3 clases los arándanos basándose en el color del fruto que adquieren cuando están próximos a la maduración. A los frutos de tonalidad rosa oscura que ocupan el 50% del área superior del arándano y en la parte inferior tienen una

tonalidad verde clara los denomino “*fruta rosada*”. Por otra parte, a las bayas cuya área superior es de color morada oscura y su base de tono más claro las denomino “*fruta pinta*”, y, por último, a los arándanos cuya superficie total es de color azul oscuro los clasifico como “*fruta madura*” (p.33).

**Figura 1.**

*Clasificación de arándanos próximos a la maduración según Quispe (2023).*



**1.3.4. Estándares de Calidad para la exportación**

INACAL (2019) estableció una Norma Técnica Peruana en la que enuncia que para que los arándanos puedan ser exportados deben cumplir requisitos mínimos, por ejemplo, no tener lesiones y estar enteros, tener consistencia firme, tener aspecto fresco, presentar cera en su superficie, estar suficientemente desarrollados y presentar un grado de madurez satisfactorio de acuerdo con la naturaleza de la variedad, etc. (p.4). En este trabajo nos centraremos en este último requisito mencionado.

**1.3.5. Inteligencia Artificial**

Capacidad de las máquinas para emular la inteligencia del ser humano; para ello, utiliza algoritmos mediante los cuales adquiere la

capacidad de aprender de la información y tomar decisiones (Rouhiainen, 2018, p.17).

### **1.3.6. Machine Learning (ML)**

Describe la capacidad de un sistema para aprender mediante el entrenamiento de datos asociados a un problema específico. Esta tecnología permite automatizar el proceso de construcción de modelos analíticos y resolver tareas asociadas. Actualmente, los algoritmos de ML se han aplicado en distintas áreas de trabajo debido a que su capacidad para extraer patrones y relaciones de base de datos masivas le permite producir decisiones confiables y repetibles (Janiesch et.al, 2021).

### **1.3.7. Deep Learning (DL)**

El aprendizaje profundo está asociado al concepto del aprendizaje automático empleando redes neuronales artificiales. En diversas aplicaciones los modelos de DL superan a los de ML y a los enfoques tradicionales de análisis de datos. Esta tecnología nace a partir de la creación de redes neuronales más complejas y profundas dotadas con capacidades de aprendizaje mejoradas (Janiesch et.al, 2021).

### **1.3.8. Redes Neuronales Convolucionales (CNN)**

Son un subconjunto del ML y se caracterizan por su buen desempeño con entradas de señal de imagen. Su arquitectura consta de 3 capas principales; la capa convolucional, pilar de la CNN, aplica

filtros convolucionales los cuales detectan patrones específicos en la entrada y producen mapas de características; la capa de agrupación se encarga de reducir la dimensionalidad de los mapas de características. Esta capa es fundamental para limitar el riesgo de sobreajuste. Por último, la capa totalmente conectada clasifica en función de las características extraídas de los filtros de las capas anteriores. La capa FC suele estar al final de la red y pueden incluir varias capas de neuronas densamente conectadas (IBM, s/f).

En las siguientes líneas se mencionan algunas arquitecturas de las CNN más utilizadas en la detección de objetos.

#### **1.3.8.1.Faster R-CNN**

Esta red combina la potencia de las CNN con un enfoque eficiente de propuesta de regiones. Su arquitectura se compone de tres partes principales: una red base que actúa como extractor de características, una Red de Propuestas de Región (RPN, por sus siglas en inglés) que genera posibles áreas donde podrían estar los objetos, y finalmente, una etapa de clasificación y refinamiento que utiliza una red totalmente conectada para clasificar cada región propuesta y ajustar con precisión las cajas delimitadoras. Faster R-CNN integra la generación de propuestas de región directamente en la red, eliminando la necesidad de métodos externos como Selective Search, lo que mejora tanto la velocidad como la precisión de detección (Ren et.al, 2015).

### **1.3.8.2.EfficientDet**

Es una arquitectura para la detección de objetos que optimiza tanto la precisión como la eficiencia. Se basa en la red EfficientNet como backbone para la extracción de características. Además, emplea una técnica llamada BiFPN (Bidirectional Feature Pyramid Network), que fusiona las características de diferentes niveles de la red de forma más eficiente, permitiendo una mejor detección de objetos en múltiples escalas. Debido a su diseño optimizado y escalable, EfficientDet logra un buen balance entre velocidad y precisión, utilizando menos parámetros y recursos que otros modelos de detección (Tan et.al, 2020).

### **1.3.8.3.YOLO**

Es una arquitectura de red neuronal diseñada para la detección en tiempo real de objetos. A diferencia de otros enfoques que dividen la tarea en varias etapas, YOLO procesa la imagen completa de una sola vez, dividiéndola en una cuadrícula y prediciendo directamente las cajas delimitadoras y las clases de los objetos en cada celda. Esta simplicidad le permite ser extremadamente rápida, logrando detecciones en tiempo real con alta precisión. YOLO ha evolucionado en varias versiones, mejorando tanto en velocidad como en precisión, y es conocida por su eficiencia en tareas que

requieren procesamiento rápido de imágenes, como vigilancia y conducción autónoma (Redmon et.al, 2016).

### **1.3.9. YOLO v8**

YOLOv8, lanzada por Ultralytics, ofrece cinco versiones escalables: nano (YOLOv8n), pequeña (YOLOv8s), media (YOLOv8m), grande (YOLOv8l) y extragrande (YOLOv8x). Esta red admite múltiples tareas de visión por computadora, como detección de objetos, segmentación, estimación de poses, seguimiento y clasificación.

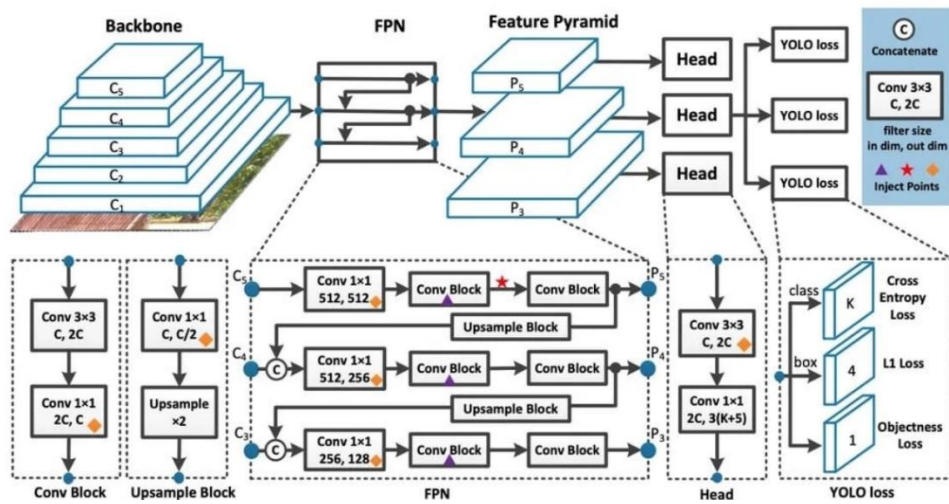
#### **1.3.9.1.Arquitectura**

Según Terven et.al. (2023) YOLOv8 mantiene un backbone similar al de YOLOv5, pero introduce modificaciones en la capa CSPLayer, ahora llamada módulo C2f, que combina características de alto nivel con información contextual para mejorar la precisión en la detección. A diferencia de versiones anteriores, YOLOv8 no utiliza anclas y cuenta con una cabeza desacoplada que procesa independientemente las tareas de objetividad, clasificación y regresión. En su capa de salida, emplea la función sigmoide para la puntuación de objetividad, que refleja la probabilidad de que una caja delimitadora contenga un objeto, y softmax para las probabilidades de clase, que indican la pertenencia de un objeto a cada categoría posible. Además, el modelo utiliza funciones de pérdida como CIoU y DFL para la pérdida de cajas delimitadoras, y la entropía cruzada binaria para la pérdida de clasificación. Estas mejoras en las funciones de

pérdida han optimizado el rendimiento en la detección de objetos, especialmente en los de menor tamaño. En la Figura 2 se observa el diagrama de la arquitectura YOLOv8, y en la Tabla 1, se han recopilado algunas de las características de la familia YOLO hasta la octava versión.

**Figura 2.**

*Diagrama de la arquitectura YOLOv8.*



**Tabla 1.**

*Características principales de las versiones YOLO versiones 1-8  
 extraídas del artículo de investigación de Terven et.al (2023).*

<b>Versión</b>	<b>Características</b>
YOLO	Limitado a detectar 2 objetos por celda de grilla. Aprendizaje de características de objetos gruesas debido a downsampling.
YOLOv2	Clasificador de alta resolución, arquitectura completamente convolucional y predicción directa de ubicación.
YOLOv3	Predicciones multi-escala y extractor de características con 53 capas convolucionales.
YOLOv4	Función de activación Mish y módulo de atención espacial (SAM).
YOLOv5	Usa backbone modificado CSPDarknet53 y diferentes aumentos como Mosaic, MixUp, entre otros.
YOLOv6	Estrategia de auto destilación para tareas de regresión y clasificación.
YOLOv7	Escalado de modelo para arquitecturas basadas en concatenación.
YOLOv8	Uso de backbone modificado CSPDarknet53 y cabeza desacoplada para procesar objetividad, clasificación y regresión de forma independiente.

### 1.3.10. Hiperparámetros

Son una serie de configuraciones que se usan para controlar el comportamiento de un algoritmo de machine learning (Goodfellow et.al, 2016, p.118).

#### 1.3.10.1. Batch

Para Brownlee (2018) el tamaño del batch es un hiperparámetro que define el número de muestras a procesar antes de actualizar los parámetros internos del modelo.

#### 1.3.10.2. Épocas

La cantidad de épocas es un hiperparámetro que define el número de veces que el algoritmo de aprendizaje procesará el completamente la base de datos (Brownlee, 2018).

#### 1.3.10.3. Optimizador

- **Adam:** Método para la optimización estocástica eficiente que solo requiere gradientes de primer orden con un bajo requerimiento de memoria. Adam, cuyo nombre deriva de la estimación de momentos adaptativos, calcula las tasas de aprendizaje adaptativas individuales para diferentes parámetros a partir de estimaciones de los primeros y segundos momentos de los gradientes (Kingma y Ba, 2014).
- **AdamW:** Es un método de optimización estocástica que modifica la implementación típica del decaimiento de pesos en Adam, desacoplando el decaimiento de pesos de la actualización del gradiente (Loshchilov y Hutter, 2019).

- **Stochastic Gradient Descent (SGD):** Es un algoritmo de optimización utilizado para entrenar algoritmos de aprendizaje automático. Tiene como objetivo encontrar un conjunto de parámetros internos que funcionen bien en relación con alguna medida de rendimiento, por ejemplo, la pérdida logarítmica. SGD encuentra valores de los parámetros de una función que minimizan una función de costo (Brownlee, 2018).

#### **1.3.10.4. Tasa de aprendizaje**

La tasa de aprendizaje determina el tamaño de los pasos que el algoritmo de optimización toma para modificar los pesos de la red neuronal, mientras se minimiza la función pérdida (Biswajit et.al, 2021).

#### **1.3.11. Métricas de rendimiento**

Se emplean para realizar mejoras en los modelos de clasificación, ya que, comúnmente hay falsas predicciones, subajustes y sobreajustes. Existen distintas métricas, por ejemplo, precisión, recall, F1 score, entre otras (Zapeta et.al, 2022).

##### **1.3.11.1. Matriz de confusión**

Géron (2019) establece que la matriz de confusión es una métrica que sirve para evaluar el desempeño de un clasificador, en donde cada fila representa la clase actual; mientras que, las columnas, las predicciones de las clases. Para que un clasificador sea considerado perfecto no debe haber falsos positivos (FP) ni

falsos negativos (FN), de esta manera, solo habría valores en la diagonal principal estos serían los verdaderos positivos (TP) y verdaderos negativos (TN) (pp.92-93).

### 1.3.11.2. Precisión

Para Géron (2019) esta medida indica la exactitud de las predicciones positivas realizadas por el modelo, y se obtiene a partir de la cantidad de los verdaderos y falsos positivos (p.93). Esto se representa mediante la siguiente expresión matemática.

**Ecuación 1.** *Fórmula para calcular la precisión.*

$$P = \frac{TP}{TP + FP}$$

*Donde*

*TP: Verdadero positivo , FP: Falso positivo*

### 1.3.11.3. Recall

Esta métrica también denominada sensibilidad es la proporción de instancias positivas que el modelo ha detectado correctamente, y se determina a partir de una ecuación que involucra la cantidad de verdaderos positivos (TP) y falsos negativos (FN) (Géron, 2019, p.94).

**Ecuación 2.** *Fórmula para calcular la sensibilidad.*

$$R = \frac{TP}{TP + FN}$$

*Donde*

*TP: Verdadero positivo , FN: Falso negativo*

#### 1.3.11.4. F1 score

F1 score combina dos métricas: precisión y sensibilidad. Esta medida es la media armónica de P y R. Se obtiene un valor alto de F1 si ambas métricas son altas (Géron, 2019, p.94).

##### **Ecuación 3.**

*Fórmula para calcular F1 score*

$$F_1 = \frac{2PR}{P + R}$$

*Donde*

*P: Precisión , R: Sensibilidad*

#### 1.3.11.5. Precisión media (AP)

La precisión media para una clase en particular es el área bajo la curva de precisión y sensibilidad (Wang, 2022).

##### **Ecuación 4.**

*Fórmula para calcular AP*

$$AP = \frac{1}{11} \sum P$$

#### 1.3.11.6. Precisión media promedio (mAP)

Se calcula al promediar los valores promedio de las precisiones (AP) obtenida en cada clase (Koirala et.al., 2019).

##### **Ecuación 5.**

*Fórmula para calcular mAP.*

$$mAP = \frac{\sum_1^N AP}{N}$$

## **1.4. Formulación del problema**

### **1.4.1. Pregunta general**

¿Cómo un sistema de procesamiento de imágenes puede identificar el grado de madurez satisfactorio del arándano como requisito mínimo para su exportación según la Norma Técnica Peruana 012.501?

### **1.4.2. Preguntas específicas**

**PE1:** ¿Cuáles son los requerimientos para desarrollar un sistema de procesamiento de imágenes para identificar el grado de madurez satisfactorio del arándano como requisito para su exportación según la Norma Técnica Peruana 012.501?

**PE2:** ¿Qué base de datos y modelo de red neuronal son los más adecuados para el sistema de procesamiento de imágenes utilizando un modelo de Deep Learning para identificar el grado de madurez satisfactorio del arándano?

**PE3:** ¿Qué técnicas de pre-procesamiento serán necesarias para que las imágenes de la base de datos del sistema permitan identificar el grado de madurez satisfactorio del arándano?

**P4:** ¿Cómo se determinará la configuración más adecuada para el modelo de Deep Learning para identificar el grado de madurez satisfactorio del arándano?

**P5:** ¿Cómo se verificará y validará el funcionamiento del sistema de procesamiento de imágenes usando un modelo de Deep Learning para identificar el grado de madurez satisfactorio del arándano?

## **1.5 Objetivos**

### **1.5.1. Objetivo general**

Desarrollar un sistema de procesamiento de imágenes utilizando un modelo de Deep Learning para identificar el grado de madurez satisfactorio del arándano como requisito mínimo para su exportación según la Norma Técnica Peruana 012.501 en 2024.

### **1.5.2. Objetivos específicos**

**OE1:** Elaborar una lista de requerimientos para desarrollar un sistema de procesamiento de imágenes para identificar el grado de madurez satisfactorio del arándano como requisito para su exportación según la Norma Técnica Peruana 012.501.

**OE2:** Establecer la base de datos y modelo de red neuronal adecuados para el sistema de procesamiento de imágenes utilizando un modelo de Deep Learning para identificar el grado de madurez satisfactorio del arándano.

**OE3:** Aplicar la técnica de redimensionamiento para el pre-procesamiento de imágenes de la base de datos, y etiquetar los datos según la clasificación de los grados de madurez del arándano establecidos en la lista de requerimientos.

**OE4:** Realizar diversas pruebas modificando los hiperparámetros del modelo de Deep Learning para identificar el grado de madurez satisfactorio del arándano a fin de determinar la configuración más adecuada para el sistema.

**OE5:** Verificar el funcionamiento del sistema de procesamiento de imágenes usando un modelo de Deep Learning mediante métricas de rendimiento y validarlo de acuerdo con la lista de requerimientos.

## **1.6 Hipótesis**

### **1.6.1. Hipótesis general**

El sistema de procesamiento de imágenes utilizando un modelo Deep Learning permitirá identificar el grado de madurez satisfactorio del arándano como requisito mínimo para su exportación según la Norma Técnica Peruana 012.501.

### **1.6.2. Hipótesis específicas**

**H1:** Mediante una lista de requerimientos se podrá identificar los objetivos del sistema y establecer la clasificación del arándano según el estado de madurez para su exportación según la Norma Técnica Peruana 012.501.

**H2:** La base de datos empleada para el desarrollo del presente sistema debe ser representativa, y el sistema de procesamiento de imágenes utilizando un modelo de Deep Learning debe de cumplir con el requerimiento.

**H3:** Las imágenes de la base de datos se deben redimensionar sin perder su calidad, y se debe realizar el etiquetado de datos según el grado de madurez del arándano para identificar los patrones adecuadamente.

**H4:** La cantidad de pruebas realizadas modificando la configuración del modelo debe ser lo suficientemente grande para explorar y determinar la más adecuada.

**H5:** El sistema de procesamiento de imágenes alcanzará los valores esperados en las métricas de rendimiento y cumplirá con todos los requerimientos enlistados.

## **CAPÍTULO II: METODOLOGÍA**

### **2.1. Tipo de investigación**

#### **2.1.1. Enfoque**

La presente investigación presenta un enfoque cuantitativo, que según Hernández y Mendoza (2018) se encarga de recolectar datos numéricos extraídos de la medición de las variables presentes en la hipótesis, para posteriormente analizarlos mediante métodos estadísticos. Dicho enfoque busca objetividad durante el proceso de la investigación. Esta ruta tiene como principal propósito probar la hipótesis (pág.13-14).

#### **2.1.2. Alcance**

Esta investigación tiene alcance descriptivo puesto que busca especificar las propiedades del sistema de procesamiento de imágenes usando un modelo de Deep Learning en términos de precisión, sensibilidad, puntaje F1, AP y mAP.

(Hernández y Mendoza, 2018) señalan que un estudio con alcance descriptivo tiene como objetivo especificar las características de las variables mediante la recolección de datos (p.108).

#### **2.1.3. Diseño de la investigación**

Para Hernández y Mendoza (2018) en un diseño preexperimental el grado de control es mínimo. Este tipo de diseño alberga dos modelos, uno en donde se aplica una sola medición después del estímulo; mientras que, en el segundo caso se realizan dos mediciones: anterior y posterior al estímulo (p.163).

En el presente trabajo de investigación, se trabajará con el diseño de investigación preexperimental denominado estudio de caso con una sola medición, puesto que la prueba

se tomará posterior a aplicar el estímulo del sistema de procesamiento de imágenes.

**G X M**

Donde:

G: Conjunto de imágenes de arándanos en distintos grados de madurez en arbustos

X: Sistema de procesamiento de imágenes usando un modelo de Deep Learning

M: Medición realizada luego de aplicar el sistema de procesamiento de imágenes.

## **2.2. Población y Muestra**

### **2.2.1. Población**

(Hernández y Mendoza, 2018) definen la población como la totalidad de un conjunto de casos que cumplen con las características establecidas (p. 198-199). Para esta investigación la población está conformada por todas las imágenes de arándanos en arbustos en distintos grados de madurez en internet.

### **2.2.2. Muestra**

Para Hernández y Mendoza (2018) la muestra es una porción de la población, es decir, un subgrupo sobre el cual el investigador está interesado, y a partir de este se extrae la información pertinente. La muestra siempre debe ser representativa de la población para que los resultados obtenidos se puedan generalizar. (p. 196)

La muestra empleada en esta investigación estará conformada por todas las imágenes de arándanos en arbustos en distintos grados de madurez que sean de libre acceso.

Los criterios para seleccionar la muestra se detallan en el procedimiento de recolección de datos.

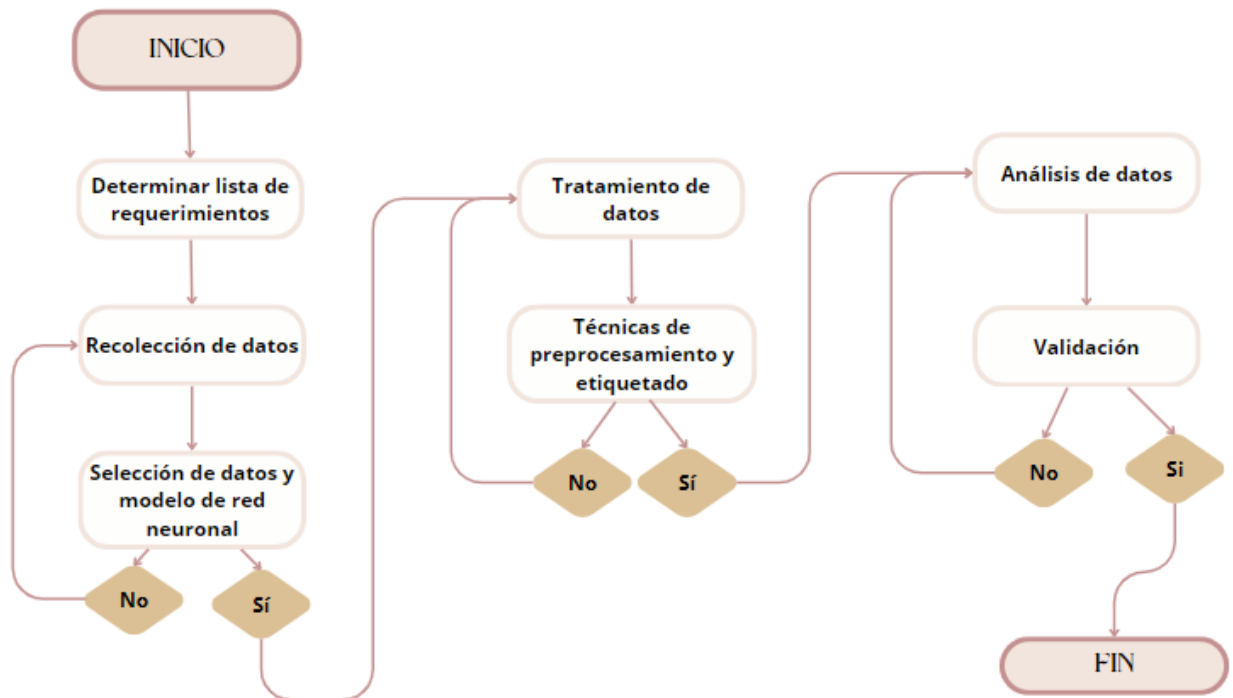
## 2.3 Métodos e instrumentos

### 2.3.1. Métodos

Para desarrollar el sistema de procesamiento de imágenes se llevaron a cabo los procedimientos presentados en la siguiente figura.

**Figura 3.**

*Diagrama de flujo para desarrollar el sistema de procesamiento de imágenes.*



#### 2.3.1.1. Lista de requerimientos

Con el propósito de validar el sistema de procesamiento de imágenes, se establecieron una serie de requerimientos en función a la Norma Técnica Peruana 012.501, investigaciones orientadas a la detección de los grados de madurez del arándano,

tecnologías actuales y métricas de rendimiento. A continuación, se presentan dichos requerimientos en la Tabla 2.

**Tabla 2.**

*Lista de requerimientos del sistema de procesamiento de imágenes.*

<b>Requerimiento</b>	<b>Descripción</b>
Grado de madurez	Sistema debe identificar de 3-4 niveles de madurez.
Tipo de imágenes para la recolección	Las imágenes de la base de datos deben tener arándanos en arbustos en distintos grados de madurez.
Arquitectura del modelo	El sistema debe ser un modelo de Deep Learning basado en arquitectura de CNN.
Tiempo de procesamiento de inferencia	El sistema no debe exceder el orden de los segundos en realizar cada predicción.
Métricas de evaluación	El sistema debe alcanzar los valores de la Tabla 7 en las métricas de rendimiento.

En los siguientes ítems se explica y justifica a detalle el porqué de cada uno de los requerimientos.

**A. Requerimiento: Grados de madurez**

**Descripción**

El sistema debe identificar de 3 a 4 niveles de madurez del arándano, los cuales se deben establecer basándose en trabajos de investigación, y consultando la Norma Técnica Peruana 012.501 para exportación del arándano.

### **Justificación**

Se consultó la Norma Técnica Peruana 012.501, la cual establece los requisitos que el arándano debe cumplir para ser exportado. En dicho documento el ítem O indica que “Los arándanos deben estar suficientemente desarrollados y presentar un grado de madurez satisfactorio según la naturaleza de la variedad”. Por ende, se indagó acerca del índice de madurez, que según Romero et.al. (2023) son un conjunto de variables que establecen el momento óptimo de cosecha, y sirven para determinar si el producto presenta la madurez que se requiere a nivel comercial. Asimismo, los autores también señalan que para el arándano los índices más empleados son el color, la firmeza, el contenido de sólidos solubles totales y la acidez titulable. Para efectos de esta investigación, nos centraremos en el color del fruto. Adicionalmente, en la Tabla 3 se recopiló información de la clasificación de los distintos grados de maduración de los arándanos empleados en distintos trabajos de investigación.

**Tabla 3.**

*Clasificación de estados de madurez empleados en trabajos de investigación.*

Trabajo	Autor	País	Año	Clasificación
Artículo científico	MacEachern, C et.al.	Canadá	2023	Arándanos verdes, rojos, azules
Artículo científico	Xiao, F et.al.	China	2023	Arándanos maduros e inmaduros
Artículo científico	Wenji, Y et.al.	China	2023	Arándano inmaduro, semimaduro y maduro
Artículo científico	Wenji, Y et.al.	China	2023	N.1(inmaduro-verde)
Artículo científico	Wenji, Y et.al.	China	2023	N.2(arándano con manchas rojas)
Artículo científico	Wenji, Y et.al.	China	2023	N.3(arándano semimaduro-rojo)
Artículo científico	Wenji, Y et.al.	China	2023	N.4(arándano maduro)
Artículo científico	Wenji, Y et.al.	China	2023	N.5(arándano pasado)
Trabajo de suficiencia profesional	Quispe, F.	Perú	2023	Fruta rosada
Trabajo de suficiencia profesional	Quispe, F.	Perú	2023	Fruta pinta
Trabajo de suficiencia profesional	Quispe, F.	Perú	2023	Fruta madura

La Tabla 3 revela que el arándano se clasificó de manera similar, a pesar de que los estudios se realizaron en diferentes países. Esto se debe a que las distintas variedades de arándano presentan características similares en términos de color, tamaño y composición (Romero et.al ,2023). En base a la información recolectada, se optó por adoptar la clasificación respecto al color del arándano cerca a la maduración expuesta en el trabajo de

suficiencia profesional elaborado por Quispe (2023) que estableció 3 divisiones: fruta rosada, de tonalidad rosa oscura que cubre el 50% de todo el fruto, y muestra color verde claro, además, su tiempo de maduración varía entre 4 a 6 días; fruta pinta, su tonalidad es morada oscura en el área superior y un tono más claro en la base, su tiempo de maduración oscila entre 2 a 3 días, y madura, tiene área total de tonalidad azul oscuro (p.20). En adición, considerando que el arándano verde o inmaduro está incluida en los 3 artículos científicos presentados en la tabla, se incluyó en la clasificación inicialmente usada para este trabajo, la cual se muestra en la siguiente figura.

#### **Figura 4.**

*Clasificación inicial de los grados de madurez del arándano.*



### **B. Requerimiento: Tipo de imágenes a considerar para recolección**

#### **Descripción**

Las imágenes recolectadas para la construcción de la base de datos deben mostrar a los arándanos en arbustos en distintos grados de madurez. Asimismo, deben ser tomadas bajo diferentes condiciones (iluminación y ángulos).

#### **Justificación**

Se requieren este tipo de imágenes, ya que proporcionan el contexto necesario para que la red neuronal aprenda a identificar no solo el fruto, sino también su posición relativa a las hojas, ramas y otros elementos del arbusto. Esto es importante para que el modelo funcione adecuadamente en condiciones reales de campo. Por otra parte, al entrenar el modelo solo con imágenes de arándanos aislados podría ocasionar un sobreajuste, donde el modelo aprende a reconocer solo esas condiciones específicas provocando que falle en un entorno real. Se plantea ello, puesto que este sistema podría usarse en un futuro para un robot orientado a la cosecha. Zeeshan et.al. (2024) afirma que esta clase de robots son un avance importante en la tecnología agrícola, ya que solucionan desafíos que se presentan al momento de cosechar, por ejemplo, escasez de mano de obra, deficiencia en la recolección, entre otros. Además de solucionar generan beneficios, tales como, mejorar la eficiencia, productividad y rentabilidad en la agricultura. En la Tabla 4, se muestran algunos trabajos de investigación que implementaron robots de cosecha usando tecnología de detección basadas en procesamiento de imágenes.

**Tabla 4.**

*Robots orientados a la cosecha de frutas o verduras*

<b>Autor</b>	<b>Año</b>	<b>Equipo/software usado</b>	<b>Tarea</b>
Onishi et.al	2019	VGG-16 Brazo robótico de 6 grados de libertad	Detectar y recolectar manzanas
Almendral et.al	2018	Brazo robótico de 6 grados de libertad Algoritmo de detección Green	Cosechar naranjas
Zhang et.al	2019	Brazo robótico de 6 grados de libertad Mask R-CNN	Detectar y cosechar frutas y verduras
Arad et.al	2020	Brazo robótico de 6 grados de libertad Python, C++	Cosechar pimiento dulce en invernaderos

**C. Requerimiento: Arquitectura del modelo**

**Descripción**

El sistema para identificar y clasificar el grado de madurez del arándano a partir de un conjunto de imágenes debe ser un modelo de Deep Learning basado en una arquitectura de Red Neuronal Convolutacional (CNN).

**Justificación**

Se debe usar una arquitectura de CNN debido a que es el tipo de red más exitoso para analizar imágenes (Litjens et.al, 2017). Asimismo, las CNN presentan gran capacidad para manejar datos no estructurados, tales como, imágenes texto y audio, pues extraen automáticamente

características relevantes (LeCun et.al, 2015). En la actualidad, los modelos de Deep Learning se han aplicado en una amplia gama de industrias [ver Tabla 5] lo que demuestra su gran adaptabilidad (Litjens et.al, 2017).

**Tabla 5.**

*Áreas de aplicación de redes neuronales convolucionales.*

<b>Título</b>	<b>Autor</b>	<b>Año</b>	<b>Área</b>
Deep learning for medical image analysis: A review	Shen et.al.	2017	Medicina
A review on deep learning applications in precision agriculture	Kamilaris et.al.	2018	Agricultura de precisión
Deep learning for materials science	Behler et.al.	2018	Ciencia de materiales
Convolutional neural networks for galaxy morphology classification	Dieleman et.al.	2015	Astronomía
Deep learning for precipitation nowcasting: A benchmark and comparison	Shi et.al.	2019	Meteorología

**D. Requerimiento: Tiempo de procesamiento de inferencia**

**Descripción**

El sistema desarrollado debe ser capaz de realizar inferencias en un tiempo que no debe exceder el orden de los segundos por imagen utilizando hardware estándar (CPU).

**Justificación**

Un tiempo de inferencia eficiente es crucial para que el sistema pueda ser aplicado en un futuro en un robot orientado a la cosecha de frutas

o verduras para asegurar una experiencia de usuario fluida.

En la Tabla 6, se presenta el tiempo de ciclo de robots, que, según Zhou et.al. (2022) se refiere a la velocidad de cosecha para un solo brazo robótico. De estos datos, se observa que la velocidad de un robot de cosecha está en el orden de los segundos. Por ende, se espera que el sistema de procesamiento de imágenes para identificar el grado de madurez satisfactorio del arándano no supere el orden de los segundos.

**Tabla 6.**

*Tiempo de ciclo de robots para cosechar verduras o frutas.*

<b>Autor</b>	<b>Año</b>	<b>Tarea</b>	<b>Tiempo de ciclo</b>
Kang et.al.	2020	Cosecha de manzanas con robot	6.5s
HarvestCroo	2019	Cosecha de fresa con robot	2.7s
Zhao	2011	Cosecha de manzanas con robot	15s
Feng	2018	Cosecha de tomates con robot	8s
RootAI	2020	Cosecha de tomates con robot	4s

### **E. Requerimiento: Métricas de evaluación**

#### **Descripción**

El rendimiento del sistema a desarrollar se evaluará mediante las métricas de evaluación más usadas: precisión (P), sensibilidad (R), F1 score, AP y mAP, las cuales cuantificarán la capacidad del modelo para clasificar las distintas instancias. Se espera que el modelo desempeñe un

alto rendimiento, y esto se vea reflejado en resultados mayores o iguales a los valores presentados.

### **Justificación**

Es necesario que el modelo alcance valores altos en dichas métricas para garantizar que la red neuronal es eficaz y confiable en su tarea. Para determinar qué es un valor alto en términos de métricas de rendimiento, se revisarán métricas obtenidas por otros modelos en trabajos anteriores para identificación de los grados de madurez del arándano. Esto se debe a que no existe un valor exacto como tal, ya que puede variar debido al contexto del problema.

Luego de revisar los valores de las distintas métricas obtenidas por los modelos de MacEachern et.al. (2023), Wenji et.al. (2023) y Xiao et.al. (2023). En la Tabla 7, se muestran los valores promedios computados, los cuales el sistema de preprocesamiento de imágenes debe alcanzar.

**Tabla 7.**

*Valores que debe alcanzar el modelo en las métricas de rendimiento.*

<b>Métricas</b>	<b>Valores</b>
Precisión	>0.742
Recall	>0.746
F1 score	>0.743
AP	>70.194
mAP	>70.18

### **2.3.2. Instrumentos**

En la presente investigación, se usaron diferentes instrumentos de software y hardware.

#### **2.3.2.1. Hardware**

Para desarrollar el sistema de procesamiento de imágenes se utilizó el procesador Intel(R) Core (TM) i5-8265U @1.60GHz, 1800MHz.

#### **2.3.2.2. Software**

Para identificar las imágenes duplicadas de la base de datos se ejecutó en Jupyter Notebook un código, el cual se encarga de asignar un código hash, sucesión alfanumérica de longitud fija, a cada imagen a fin eliminar una de las imágenes que presenten el mismo hash. Para esto, se instalaron algunas dependencias, tales como, hashlib para implementar funciones hash criptográficas; MD5 para generar un hash de 128 bits; imageio para leer y mostrar imágenes; matplotlib para crear gráficos y visualizaciones; y numpy para el análisis numérico y de datos.

Para redimensionar las imágenes de la base de datos se utilizó la interfaz Google Colab, en donde mediante las librerías cv2, módulo de OpenCV para procesamiento de imágenes; glob para buscar archivos jpg; y os para crear y renombrar directorios, se ejecutó un código para modificar las dimensiones de las imágenes a 1920 x 1080 píxeles.

Para el etiquetado de los diferentes grados de madurez del arándano se usó la herramienta de anotación de imágenes gráficas Labelimg versión 1.8.6, la cual guarda de manera automática un archivo de texto en formato YOLO. Para cada arándano se dibujó un cuadro delimitador que cubrió toda el área del fruto.

Para modelar la red neuronal convolucional YOLOv8n se utilizó la aplicación web Jupyter Notebook 7.0.8. En este software se ejecutó el código en lenguaje de programación Python 3.11 para entrenar, validar y realizar pruebas con el modelo.

## 2.4. Procedimiento de recolección de datos

### 2.4.1. Construcción del conjunto de datos

En primer lugar, se construyó el conjunto de datos de arándanos, para esto, en internet se buscaron imágenes del fruto presentes en arbustos, tomadas bajo diferentes condiciones de iluminación, y distintos ángulos. Para ello, se llevó a cabo el siguiente procedimiento.

- a) En el motor de búsqueda Google se insertaron las palabras clave: “Blueberry database”.
- b) Se identificaron los sitios web confiables de donde se podían extraer imágenes de arándanos con libre acceso.
- c) Se revisaron las imágenes encontradas en dichas páginas web a fin de asegurar que cumplieran con el requisito para ser recolectadas.

Se recolectaron imágenes de dos bases de datos, las cuales se muestran en la Tabla 8, en total el conjunto de datos se conformó por 1050 imágenes de arándanos en arbustos con sus distintos niveles de maduración.

**Tabla 8.**

*Composición del conjunto de arándanos*

---

<b>Base de datos</b>	<b>Cantidad</b>	<b>Plataforma</b>	<b>Enlace</b>
----------------------	-----------------	-------------------	---------------

---

Deep Blueberry	383	IEEEDataport	<a href="https://iee-dataport.org/documents/deepblueberry-quantification-blueberries-wild-using-instance-segmentation">https://iee-dataport.org/documents/deepblueberry-quantification-blueberries-wild-using-instance-segmentation</a>
Blueberry F image	667	Roboflow	<a href="https://universe.roboflow.com/luis-osses/blueberry-f/dataset/1">https://universe.roboflow.com/luis-osses/blueberry-f/dataset/1</a>

Del conjunto de datos de arándanos obtenidos se observaron imágenes que no generaban un aporte significativo; por ello, se aplicaron criterios de descarte a fin de eliminar aquellas con fondo lleno de vegetación que dificulta el etiquetado de los arándanos; imágenes en donde el arándano se ve tan pequeño que es casi imperceptible; imágenes en donde no hay presencia de arándanos; imágenes aumentadas muy cargadas con gran cantidad de modificaciones que dificulten el etiquetado, imágenes aumentadas en blanco y negro e imágenes con arándanos desenfocados [ver Figura 5]. En la Tabla 9, se muestran las cantidades de imágenes que cumplieron con dichos criterios. Al finalizar este proceso quedaron 550 imágenes.

**Tabla 9.**

*Cantidad de imágenes descartadas en cada base de datos.*

<b>Criterios de descarte</b>	<b>N° Blueberry F image</b>	<b>N° Deep Blueberry</b>
Imágenes en blanco y negro	49	0
Fondo complejo	29	21
Imágenes aumentadas muy cargadas	236	0
Imágenes desenfocadas	22	3

Imágenes sin presencia de arándanos	0	16
Imágenes con arándanos imperceptibles	0	11
Imágenes duplicadas	0	7
Imágenes similares	98	8
<b>Total</b>	<b>434</b>	<b>66</b>

**Figura 5.**

*Tipo de imágenes descartadas del conjunto de datos.*



#### 2.4.2. Selección de modelo Deep Learning

En la actualidad, con el avance de la tecnología las computadoras son capaces de extraer características a partir de datos, a esto se le conoce como Deep Learning, el cual usa modelos compuestos por muchas capas que convierten datos de entrada en salidas. Según Litjens et.al. (2017) el tipo de modelo más exitoso para el análisis de imágenes son las redes neuronales convoluciones.

A partir de ello, se realizó una búsqueda de trabajos investigación asociados a la

detección de grados de madurez del arándano empleando redes neuronales convolucionales. Esto con la finalidad de identificar las redes neuronales más utilizadas en esta área. En dicha búsqueda se encontraron 3 artículos científicos en los cuales comparan distintos modelos Deep Learning. En las siguientes tablas se muestran las redes neuronales usadas en cada trabajo de investigación.

**Tabla 10.**

*Redes Neuronales empleadas en el artículo “Detection of fruit maturity stage and yield estimation in wild blueberry using deep learning convolutional neural networks”.*

<b>Autores</b>	<b>Redes Neuronales usadas</b>	<b>Tamaño de entrada usado (píxeles)</b>	<b>Tamaño de entrada requerido (píxeles)</b>
Mac Eachern, C. et.al	YOLOv3	1280x720	416x416 608x608
	YOLOv3-SPP	1280x720	416x416 - 608x608
	YOLOv3-Tiny	1280x720	416x416
	YOLOv4-Small	1280x720	416x416
	YOLOv4-Tiny	1280x720	416x416

**Tabla 11.**

*Redes Neuronales empleadas en el artículo “Blueberry Ripeness Detection Model Based on Enhanced Detail Feature and Content-Aware Reassembly”.*

<b>Autor</b>	<b>Redes neuronales usadas</b>	<b>Tamaño de entrada usado (píxeles)</b>	<b>Tamaño de entrada requerido (píxeles)</b>
Wenji, Y. et.al	YOLOv5	640x640	640x640

YOLOX	640x640	640x640
EfficientDet	640x640	Variable
Faster R-CNN	640x640	Variable
YOLOv7-GhostNet	640x640	640x640
YOLOv7-MobileNetv3	640x640	640x640
YOLOv7	640x640	640x640

**Tabla 12.**

*Redes Neuronales empleadas en el artículo “A Lightweight Detection Method for Blueberry Fruit Maturity Based on an Improved YOLO v5 Algorithm”.*

<b>Autor</b>	<b>Redes neuronales usadas</b>	<b>Tamaño de entrada usado (píxeles)</b>	<b>Tamaño de entrada requerido (píxeles)</b>
Xiao, F. et.al	YOLOv5	No menciona	640x640
	SSD-VGG	No menciona	300x300
	Faster R-CNN-VGG	No menciona	600x1000

De los datos presentados en las Tablas 10, 11 y 12, se observa que la red neuronal más empleada es YOLO; asimismo, en la Tabla 10, Mac Eachern, C. et.al. emplearon imágenes de entrada de mayor resolución (1280x720 píxeles) a las requeridas (640x640 píxeles). Esto es un factor importante para considerar, pues las imágenes de la base de

datos son de gran tamaño, y al momento de redimensionar a valores muy pequeños, podrían ocasionar pérdidas en la calidad de las imágenes, afectando la precisión del modelo.

Debido a que en los artículos científicos encontrados se utilizaron las versiones 3, 4, 5 y 7 de la familia YOLO, se optó por trabajar con una de las últimas iteraciones: YOLOv8, pues este modelo presenta una arquitectura mejorada sobre las bases de sus predecesores (Ultralytics, s/f.).

La red neuronal YOLOv8 está conformada por diferentes iteraciones: N, S, M, L y X. Por ello, para seleccionar de manera adecuada entre una de ellas se tomaron en consideración factores, tales como, naturaleza del problema y datos, recursos computacionales, velocidad de inferencia y tamaño del modelo. Dentro de los cuales se delinearon requisitos que la versión seleccionada debía cumplir.

**FACTOR: Naturaleza del problema y datos**

- Modelo especializado en tareas de detección

**FACTOR: Recursos Computacionales**

- Tiempo de entrenamiento no debe ser de larga duración a fin de no requerir mayores recursos computacionales.

**FACTOR: Velocidad de inferencia**

- Modelo debe detectar en tiempo real y con gran velocidad.

**FACTOR: Tamaño de modelo**

- Modelo debe ser pequeño a fin de ser de fácil despliegue para otros

dispositivos.

**Tabla 13.**

*Métricas de rendimiento de la familia YOLOv8 para detección de objetos.*

Modelo	Tamaño (píxeles)	$mAP^{val}$ 50-95	Velocidad		
			CPU ONNX (ms)	Parámetros (M)	FLOPs (B)
<b>YOLOv8n</b>	<b>640</b>	<b>37.3</b>	<b>80.4</b>	<b>3.2</b>	<b>8.7</b>
YOLOv8s	640	44.9	128.4	11.2	28.6
YOLOv8m	640	50.2	234.7	25.9	78.9
YOLOv8l	640	52.9	375.2	43.7	165.2
YOLOv8x	640	53.9	479.1	68.2	257.8

*Nota.* Esta tabla fue tomada de *Ultralytics YOLO Docs*.

En la Tabla 13, se observa que el modelo YOLOv8n tiene menor cantidad de parámetros y FLOPs (Floating Point Operations per second) a comparación de las demás versiones; esto cumple con el requisito del tamaño del modelo, pues según Kurkova (2016, como se citó en Hu et.al, 2021) la cantidad de parámetros es una medida usada para el tamaño del modelo, que a su vez es un factor que contribuye a la complejidad de un modelo Deep Learning. Asimismo, encaja con el requisito de la velocidad de inferencia, ya que tiene velocidad en CPU de 80.4 ms, siendo este el menor valor entre las demás versiones. Aunque el mAP 50-95 de la versión N es el menor valor de todos, se optó por este modelo, ya que, cumplió con todos los requisitos previamente establecidos.

## 2.5. Tratamiento y análisis de datos

### 2.5.1. Tratamiento de datos

#### 2.5.1.1. Técnicas de preprocesamiento

Se observó que las imágenes del conjunto de datos presentaban diferentes dimensiones; por esta razón, se optó por redimensionar las imágenes empleando la proporción 16:9, esto con el propósito de normalizar todos los datos. Para redimensionar las imágenes, se tuvo cuidado de no disminuir la calidad; por ello, se trabajó con la dimensión 1920x1080. Todo este proceso se llevó a cabo ejecutando un código elaborado en Google Colab. En la Tabla 14, se muestran las dimensiones originales de los datos, y la nueva dimensión que se asignó.

**Tabla 14.**

*Dimensiones de las imágenes del conjunto de datos.*

Base de datos	Dimensión	Redimensión	Cantidad
	1920x1080	1920x1080	224
Deep Blueberry	3264x2448	1920x1080	73
	2448x2048	1920x1080	21
	2004x1504 - 2448x1832	1920x1080	38
Blueberry F	1920x1440 - 1996x1496	1920x1080	39
	5184x3888	1920x1080	155
<b>Total</b>			<b>550</b>

#### 2.5.1.2. Etiquetado

Para el etiquetado de los diferentes grados de madurez del arándano se usó

herramienta de anotación de imágenes gráficas Labelimg. Para cada arándano se dibujó un cuadro delimitador que cubrió toda el área del fruto. Durante este proceso se observó que la cantidad de arándanos rosados presente en el conjunto de datos era pequeña (aproximadamente 120 etiquetas); lo que perjudicaría el rendimiento del modelo al combinar todas las clases. Por esta razón, se optó eliminar el arándano rosado de la clasificación previamente estipulada, quedando así 3 clases, las cuales se muestran en la siguiente figura.

### **Figura 6.**

*Clasificación final de los distintos grados de madurez.*



*Arándano verde*



*Arándano pinto*



*Arándano maduro*

#### **2.5.1.3. Conjunto de entrenamiento, validación y prueba**

Para evitar el sobreajuste y maximizar la capacidad del modelo, se debe evaluar la base de datos dividiéndola en tres conjuntos: entrenamiento, validación y prueba (Chollet, 2017). A partir de las investigaciones de los autores MacEachern, C. et al., Xiao, F. et al. y Wenji, Y. et.al. se recopiló información acerca del porcentaje de datos usados para cada conjunto de evaluación. En la Tabla 15, se plasmó dicha información, en donde queda en evidencia que cada equipo de investigadores realizó la división de los sets en distintas proporciones. Sin embargo, en líneas generales se observa que el conjunto más grande es el de entrenamiento; mientras que, los sets de validación y prueba se les asignó porcentajes iguales. Para esta investigación, se usó la distribución que sea promedio de

los 3, que redondeando sería 70, 20, 10.

**Tabla 15.**

*Cantidad de datos en conjuntos de evaluación empleadas en investigaciones afines.*

<b>Autor</b>	<b>Cantidad de datos</b>	<b>Entrenamiento</b>	<b>Validación</b>	<b>Prueba</b>
MacEachern, C. et al.	6766	70%	15%	15%
Xiao, F. et al.	680	80%*	20%*	No menciona
Wenji, Y. et al	10000	60%	20%	20%

### 2.5.2. Análisis de datos

Para analizar el comportamiento del sistema de procesamiento de imágenes, se realizaron distintas pruebas modificando los valores de los hiperparámetros de la red neuronal convolucional YOLOv8n. A partir de los resultados obtenidos en el conjunto de validación, YOLOv8n generó gráficos de las métricas de rendimiento (precisión, recall, F1 score, mAP y AP), las cuales se analizan detalladamente en el apartado de resultados.

Respecto al conjunto de prueba, para analizar los datos fue necesario contabilizar los verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos, los cuales se extrajeron a partir de las predicciones realizadas por YOLOv8n. Luego de realizar dicho conteo se calcularon los valores que obtuvo el modelo en las distintas métricas de rendimiento. Estos datos se explican a fondo en el apartado de resultados.

### 2.6. Aspectos éticos

A lo largo de la presente investigación se han citado las fuentes utilizadas con el

propósito de reconocer y dar crédito a las ideas y el trabajo de otros investigadores. De esta manera se mostró la transparencia durante el proceso de investigación. El citado se realizó siguiendo las normas APA 7ma edición lo que garantiza el citado preciso y completo de cada fuente. Asimismo, debido a que la población y la muestra están relacionadas a imágenes de arándanos en sus distintos grados de madurez no hubo perjuicios en seres vivos ni en parte de la naturaleza.

### CAPÍTULO III: RESULTADOS

Debido a que se dividió la base de datos de arándanos en conjuntos de entrenamiento, validación y prueba, se obtuvieron resultados durante estos tres momentos.

#### 3.1. Resultados del entrenamiento

Con la finalidad de mejorar el rendimiento de la red neuronal YOLO v8 versión N para identificar el grado de madurez satisfactorio a partir de los valores iniciales de los hiperparámetros [ver Tabla 16] se realizaron ajustes de estos en distintas pruebas. En primera instancia, para las pruebas se emplearon 4 clases: arándano verde, rosado, pinto y maduro. Además, inicialmente se utilizaron pocas imágenes etiquetadas en el set de entrenamiento y validación; para no consumir mucho tiempo en el proceso de entrenamiento de la red. Posteriormente, se optó por utilizar 3 clases: arándano verde, pinto y maduro, ya que durante el etiquetado se observó que había poca cantidad de arándanos rosados, lo que perjudicaría el rendimiento final de la red neuronal YOLO v8n.

**Tabla 16.**

*Condiciones iniciales de hiperparámetros.*

Hiperparámetros	Valores
Epoch	100
Batch	16
Tasa de aprendizaje inicial	0.001429
Tasa de aprendizaje final	0.01
Hue	0.015
Optimizador	Automático/ AdamW

### 3.1.1. Batch

En la Tabla 17, se presentan 4 pruebas manipulando el hiperparámetro batch a fin de determinar qué valor mejoraba el rendimiento del sistema. Para esto, en primera instancia, solo se tomaron en cuenta los valores F1 score obtenidos a partir de la gráfica F1 confidence-curve generada por la red YOLO v8n en el proceso de validación.

**Tabla 17.**

*Pruebas realizadas modificando el batch en la red neuronal YOLO v8.*

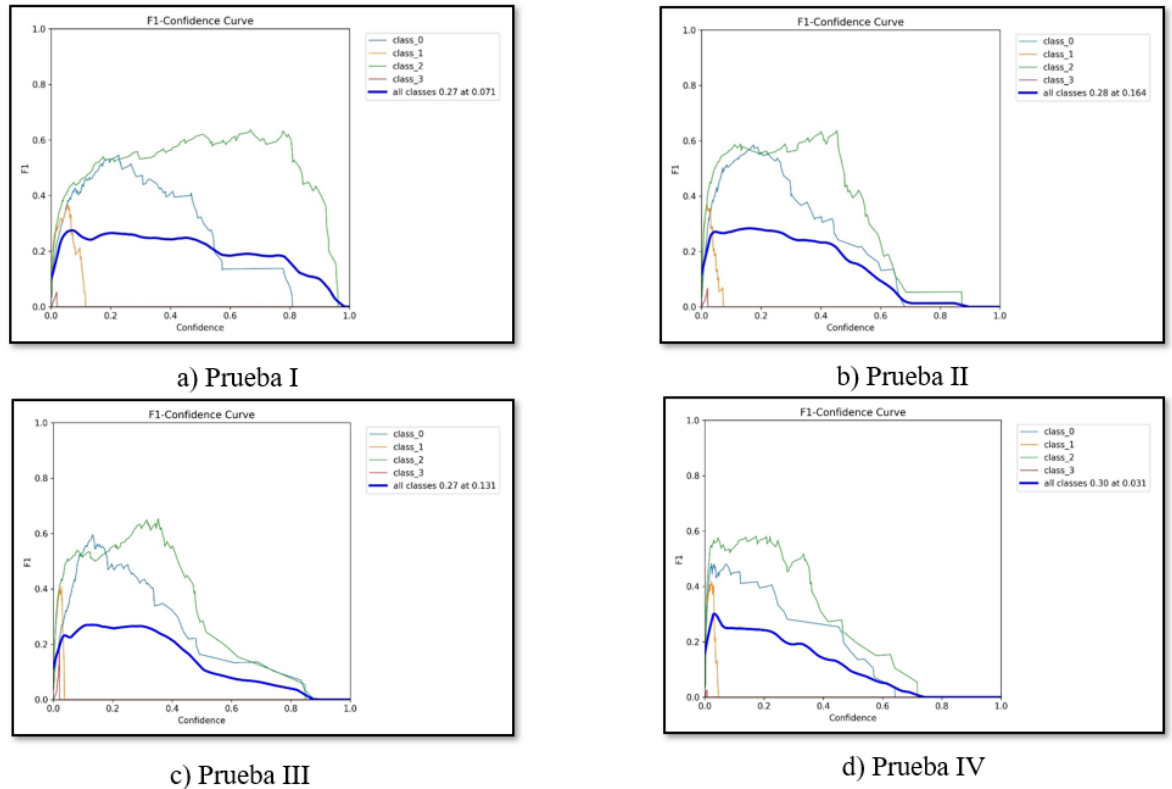
Pruebas (4 clases)		Prueba I	Prueba II	Prueba III	Prueba IV
Imágenes	Train	187	187	187	187
	Val	20	20	20	20
	Test	10	10	10	10
Hiperparámetro	Batch	5	7	9	14
	Duración	0.648h	0.691h	0.792h	0.879h
Resultados	F1 confidence	27%	28%	27%	30%

Debido a que los resultados de la Tabla 17 muestran puntajes F1 similares. Se optó por analizar cada curva F1 confidence de las 4 pruebas. A pesar de que el valor F1 de la prueba I, registrada en la tabla, es el valor más bajo, en la Figura 7, se revela que la curva F1-confidence para la clase 2, que es la clase de interés ya que representa a los arándanos maduros, donde el batch toma el valor de 5, alcanzó 0.6 en puntaje F1 en un amplio rango de confianza; mientras que, en las demás pruebas la curva de la clase 2 presenta caídas significativas a medida que aumenta la confianza. Por esta razón, se optó por asignarle el

valor de 5 a dicho hiperparámetro, a pesar de que las demás pruebas mostraron mejores puntuaciones F1.

**Figura 7.**

*Gráficas de la métrica F1-confidence obtenidas de las pruebas modificando el batch.*



### 3.1.2. Tasa de aprendizaje (Learning rate)

En segunda instancia, se modificaron los valores de la tasa de aprendizaje inicial  $lr_0$  y final  $lr$ . En total se realizaron 14 pruebas, la cuales se dividen en dos grupos, en el primero ambas tasas toman el mismo valor, y en el segundo las tasas toman valores diferentes. Cabe destacar que para todas las pruebas se empleó el optimizador Adam W y se aginaron 20 épocas con la finalidad de acortar la duración del entrenamiento.

#### 3.1.2.1. Tasas de aprendizaje iguales

Se realizaron 9 pruebas asignando el mismo valor a ambas tasas de

aprendizaje, de las cuales 5 presentaron valores de F1 altos a comparación del resto. En la Tabla 18 se observa que, cuando  $lr_0 = 0.003$  y  $lr = 0.003$  se obtuvo el mayor valor de F1 (46%). Para visualizar cómo cambio el rendimiento del modelo a medida que se fueron modificando las tasas de aprendizaje se analizaron las gráficas de las curvas precisión y recall de cada una de las pruebas presentes en la tabla.

**Tabla 18.**

*Pruebas con mejores resultados asignando el mismo el valor a ambas tasas de aprendizaje.*

Pruebas (4 clases)		Prueba	Prueba	Prueba	Prueba	Prueba
		III	IV	V	VI	VII
Imágenes	Train	240	240	240	240	240
	Val	89	89	89	89	89
	Test	20	20	20	20	20
	Batch	5	5	5	5	5
	Epoch	20	20	20	20	20
Hiperparámetros	Inicial learning rate	0.005	0.00377	0.003	0.0027	0.00197
	Final learning rate	0.005	0.00377	0.003	0.0027	0.00197
	Duración	1.201h	1.234h	1.927h	1.224h	1.269h
Resultados	F1 confidence	43%	45%	46%	45%	44%

En la Figura 8 y Figura 9, en las gráficas de las curvas se muestran las precisiones promedio (AP) de cada clase y la precisión media promedio

(mAP) obtenida en cada prueba. Para esto clase 0, clase 1, clase 2 y clase 3 representan el arándano verde, pinto, maduro y rosado respectivamente.

Para determinar con qué valores de inicial learning rate ( $lr_0$ ) y final learning rate ( $lf$ ) se obtienen mejores resultados, nos centramos en los valores de AP de la clase 2, que representan a los arándanos maduros. En la Figura 8, en la tercera y cuarta prueba, se obtuvo un AP de 72.7% y 75.6% respectivamente para los arándanos maduros. Por otra parte, en la Figura 9, en la quinta, sexta y séptima prueba, se obtuvo un AP de 70.1%, 72.8% y 69.5% para los arándanos maduros. A partir de estos datos, se concluye que en la cuarta prueba cuando  $lr_0 = lf = 0.00377$ , a pesar de que en la Tabla 18 se muestra que en la quinta prueba se obtuvo mejor puntaje F1.

Sin embargo, al observar la matriz de confusión obtenida en la prueba IV presentada en la Figura 10, se puede afirmar que la red neuronal YOLO v8n es capaz de detectar la clase 2 (arándano maduro), pero aún se observan confusiones con las demás clases. Por ello, se optó por realizar más ajustes, pero con  $lr_0$  y  $lf$  diferentes.

**Figura 8.**

Gráficas de las curvas de precisión-recall obtenidas de las pruebas III y IV.




Figura 9.

Gráficas de las curvas precisión- recall obtenidas de las pruebas V, VI y VII.

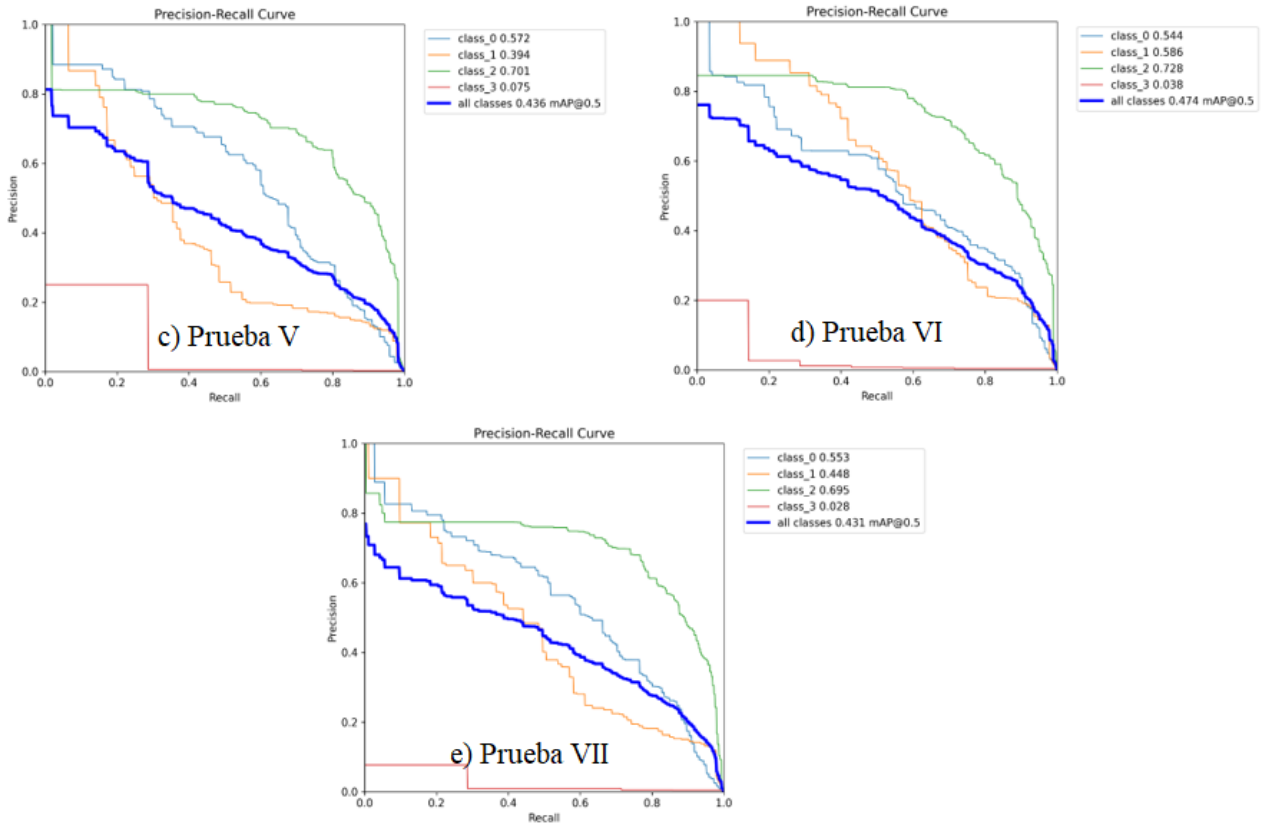



Figura 10.

*Matriz de confusión de la prueba IV con ambas tasas de aprendizaje iguales.*



### 3.1.2.2. Tasas de aprendizaje diferentes

Se realizaron 4 pruebas asignando diferentes valores a las tasas de aprendizaje inicial y final. Los resultados de estas pruebas se plasmaron en la Tabla 19, en donde se muestran valores F1 similares a los obtenidos cuando ambas tasas de aprendizaje eran iguales. Así que para visualizar si cambió el rendimiento del modelo se compararon las gráficas de las curvas de precisión-recall obtenidas.

**Tabla 19.**

*Pruebas realizadas asignando valores diferentes a las tasas de aprendizaje inicial y final.*

Pruebas (4 clases)		Prueba I	Prueba II	Prueba III	Prueba IV
Imágenes	Train	240	240	240	240
	Val	89	89	89	89
	Test	20	20	20	20

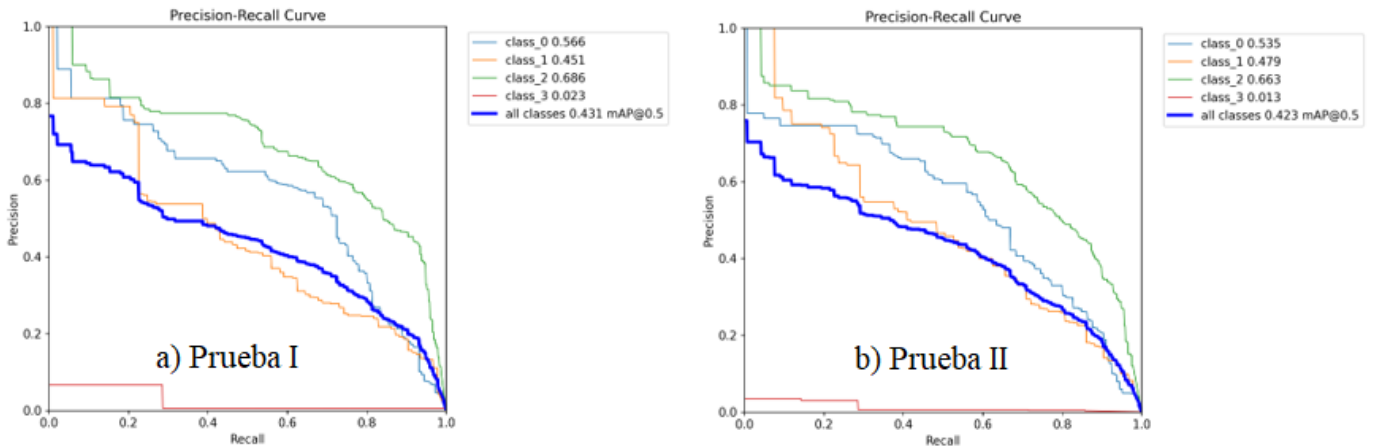
	Batch	5	5	5	5
	Epoch	20	20	20	20
Hiperparámetros	Initial learning rate	0.01	0.01	0.01	0.003
	Final learning rate	0.003	0.00197	0.00125	0.001
	Duración	1.249h	1.354h	1.191h	1.338h
Resultados	F1 confidence	44%	42%	50%	46%

En la Figura 11, se muestran las gráficas de las curvas PR obtenidas en la primera y segunda prueba en donde se visualizan el AP de cada clase, siendo estos arándanos verdes, pintos, maduros y rosados. Debido a que la investigación se centra en el grado de madurez satisfactorio, se realizó especial énfasis en obtener el mejor valor de AP de la clase de arándanos maduros. A partir de esta figura se observa que en la prueba I y prueba II se obtuvo un AP de 68.6% y 66.3% respectivamente para los arándanos maduros. Por otra parte, en la Figura 12, se observó que el AP para las pruebas III y IV fue de 79.6% y 71.2% respectivamente para los arándanos maduros.

De los datos obtenidos en la Tabla 19, en la prueba III se obtuvo un puntaje F1 de 50%, siendo este el mayor a comparación de las demás pruebas. Asimismo, la gráfica de la curva PR de dicha prueba alcanzó el AP más alto para arándanos maduros.

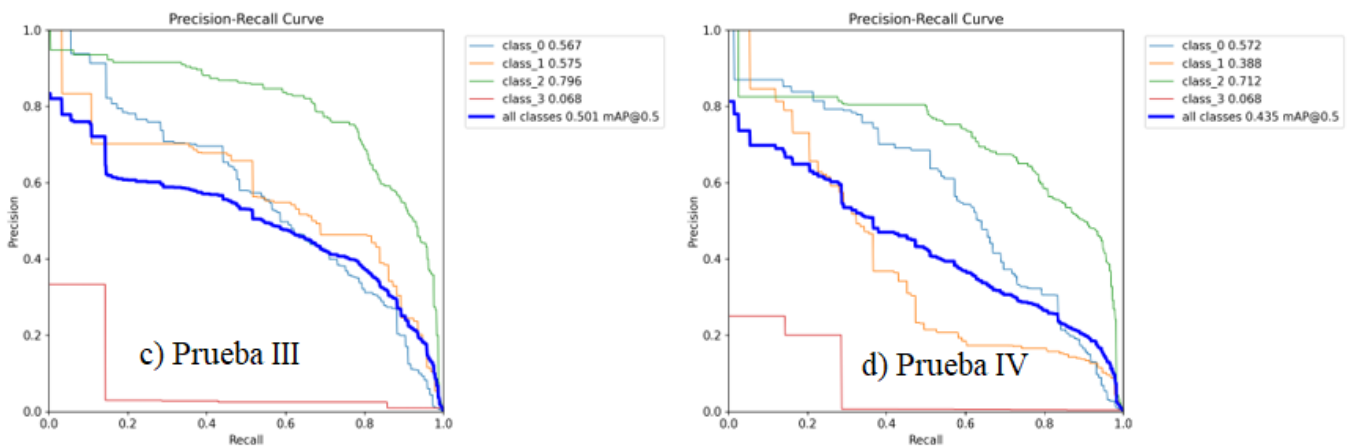
**Figura 11.**

*Gráficas de las curvas de precisión-recall obtenidas en las pruebas I y II.*



**Figura 12.**

*Gráficas de las curvas de precisión y recall obtenidas de las pruebas III y IV.*




Por otra parte, en la Figura 13 se analiza la matriz de confusión de la prueba III, que fue con la que se tuvo mejores resultados, la cual demuestra que el modelo detecta con mayor precisión 3 de las clases, entre ellas, la clase de interés. Sin embargo, aún existe confusión con otras clases y el fondo. En síntesis, de las 13 pruebas realizadas modificando las

tasas de aprendizaje el mejor resultado se alcanzó cuando  $lr_0 = 0.01$  y  $lr = 0.00125$  aunque el rendimiento del modelo general podría aún mejorar.

**Figura 13.**

*Matriz de confusión de la prueba III con tasas de aprendizajes diferentes.*



### 3.1.3. Optimizador

Se realizaron pruebas empleando diferentes optimizadores, como lo son Adam y Stochastic Gradient Descent (SGD), ya que en las pruebas realizadas anteriormente se utilizó Adam W por defecto. Para las pruebas realizadas se emplearon los learning rate ( $lr_0 = 0.01$  y  $lr = 0.00125$ ) con los que se obtuvo el mejor resultado [ver Tabla 20].

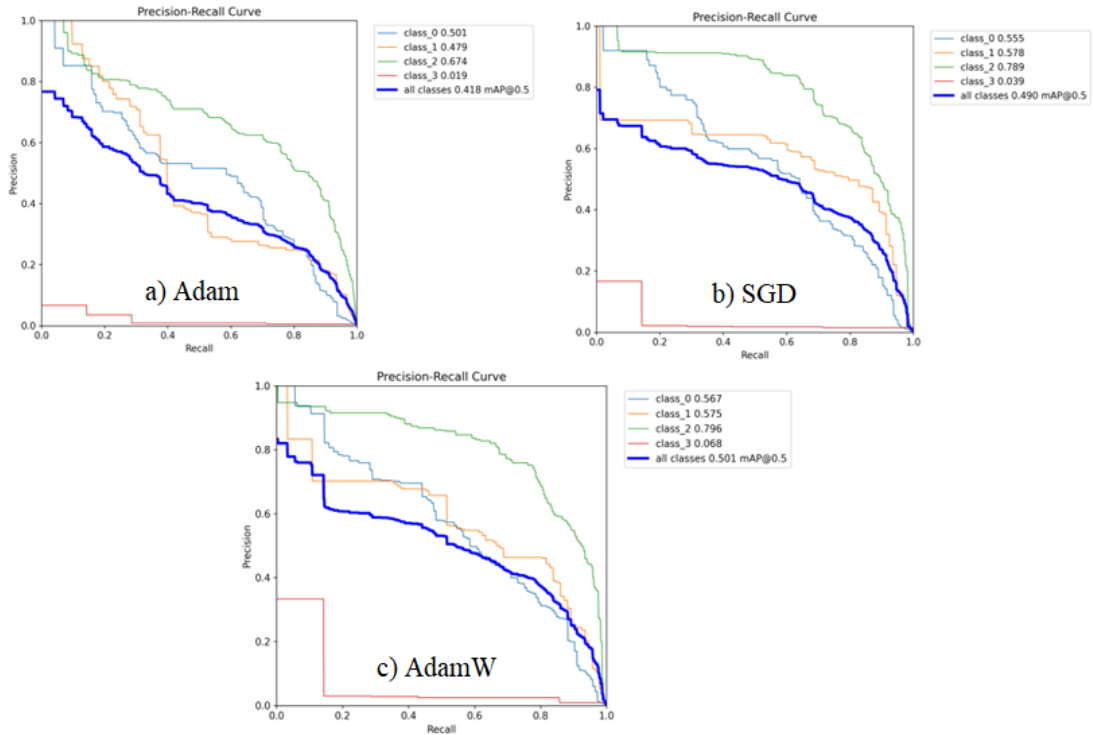
**Tabla 20.**
*Pruebas realizadas utilizando el optimizador Adam y SGD.*

Pruebas (4 clases)		Adam	SGD	AdamW (auto)
Imágenes	Train	240	240	240
	Val	89	89	89
	Test	20	20	20
	Batch	5	5	5
	Epoch	20	20	20
Hiperparámetros	Inicial learning rate	0.01	0.01	0.01
	Final learning rate	0.00125	0.00125	0.00125
	Duración	1.230h	1.97h	1.191h
Resultados	F1-confidence	42%	47%	50%

En la Figura 14, mediante las gráficas de las curvas PR se observó que cuando  $lr_0 = 0.01$  y  $lr = 0.00125$  se obtuvieron mejores resultados al entrenar el modelo con el optimizador AdamW (auto), pues alcanzó el 79.6% en AP para la clase 2 (arándano maduro); sin embargo, se optó por seleccionar SGD, que obtuvo 78.9%, ya que este optimizador obtiene altos niveles de precisión en tareas como la clasificación; asimismo, emplea menos memoria (Hassan et.al, 2022).

**Figura 14.**


*Gráficas de las curvas precisión-recall de las pruebas realizadas con los optimizadores Adam y SGD.*



Por otra parte, en la Figura15 se observa la matriz obtenida con el optimizador SGD, la cual indica que el modelo presenta confusión para diferenciar la clase 0 (arándano verde) con el fondo; esto puede deberse a que este último es la vegetación. Por esta razón, a fin de obtener mejores resultados respecto a esta clase se plantea modificar el hiperparámetro HSV\_H.

**Figura 15.**

*Matriz de confusión obtenida al emplear el optimizador SGD.*



### 3.1.4. HSV\_H

En vista a que se notó que el modelo presentó inconvenientes para diferenciar entre la clase 0 (arándano verde) y el fondo. Se optó por modificar el valor de uno de los componentes del modelo de color HSV, que significa, tono, saturación y brillo. El componente por ajustar fue hue, el cual modela el tipo de color; con esto se pretendía reducir la confusión antes mencionada.

En la Tabla 22, se observa que la prueba I y prueba IV con valores de hue de 0.015 y 0.012 respectivamente son las que alcanzaron mayores valores de F1 score (62%) a comparación de las demás pruebas realizadas.

Para determinar cuál es el valor más adecuado se analizarán las matrices de confusión y la curva Precisión – Recall. En esta etapa, se emplearon solo 3 clases, puesto que la clase de arándano rosado fue eliminada debido a que la cantidad de datos de esta instancia era pequeña (120 datos aproximadamente), lo que perjudicaba el rendimiento general del modelo.

**Tabla 21.**

*Pruebas modificando hiperparámetro hue con 3 clases.*

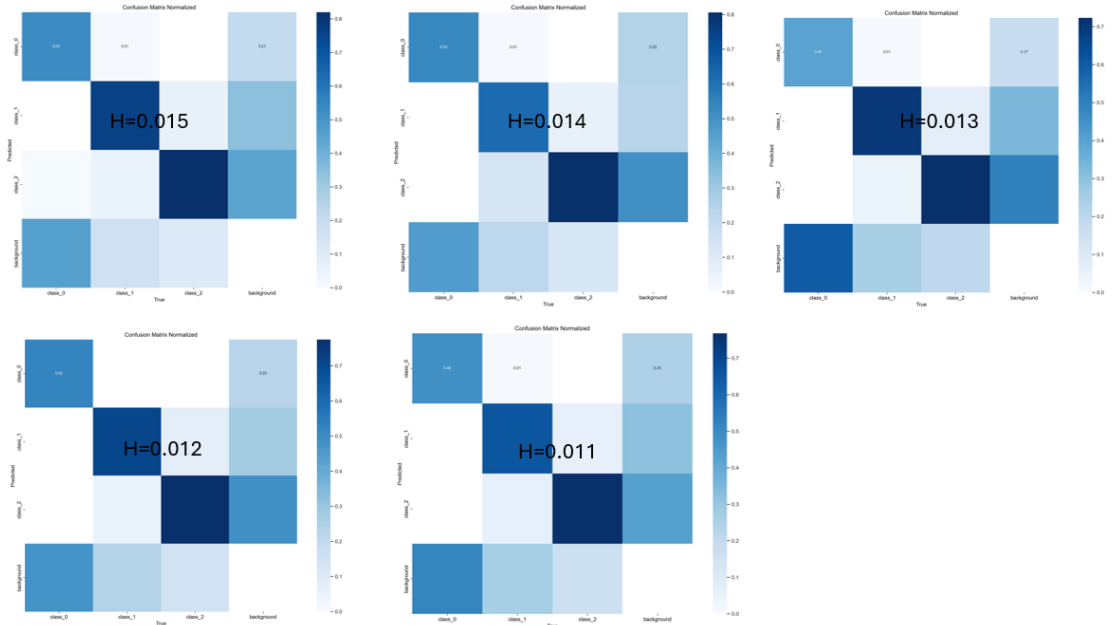
Pruebas (3 clases)		Prueba	Prueba	Prueba	Prueba	Prueba
		I	II	III	IV	V
Imágenes	Train	240	240	240	240	240
	Val	89	89	89	89	89
	Test	20	20	20	20	20
	Batch	5	5	5	5	5
	Epoch	20	20	20	20	20
Hiperparámetros	lr0	0.01	0.01	0.01	0.01	0.01
	lr	0.00125	0.00125	0.00125	0.00125	0.00125
	Hue	0.015*	0.014	0.013	0.012	0.11
	Duración	1.253h	1.213h	1.212h	1.292h	1.290h
Resultados	F1- confidence	62%	61%	60%	62%	60%

En la Figura 16, se presentan las matrices de confusión de cada una de las pruebas realizadas, de las cuales las gráficas correspondientes a  $h=0.015$  y  $h=0.012$  son las que reflejan un mejor rendimiento. En ambas se observa que el modelo es capaz de realizar predicciones correctas de las

tres clases de arándanos; sin embargo, aún hay confusiones entre clases.

**Figura 16.**


*Matrices de confusión obtenidas al modificar el hiperparámetro hue.*



En la Figura 17, cuando  $h=0.012$  la gráfica indica que el modelo detecta la clase 0 (arándanos verdes) con un AP de 0.578; la clase 1 (arándanos pintos) con 0.538 y la clase 2 (arándanos maduros) con 0.799. Por otra parte, cuando  $h=0.015$  la clase 0 es detectada con un AP del 0.593; la clase 1 con 0.544 y la clase de arándanos maduros con 0.802. Basándonos en estos datos, se optó por establecer el valor predeterminado 0.015 para hue.

**Figura 17.**

*Curvas Precisión-Recall para  $h=0.012$  y  $h=0.015$ .*



Una vez establecidos los hiperparámetros se entrenó, validó y testeó la red neuronal YOLO v8n con la cantidad de imágenes establecida para dichos sets, siendo estas 364 imágenes para entrenamiento, 104 para validación y 55 para el conjunto de prueba. En la siguiente tabla se muestran los valores que tomaron los hiperparámetros.

**Tabla 22.**

*Hiperparámetros empleados en la red neuronal YOLO v8n.*

Hiperparámetros	Valores
Batch	5
Épocas	20
Tasa de aprendizaje inicial	0.01
Tasa de aprendizaje final	0.00125
Optimizador	SGD

### 3.2. Resultados de validación


Las gráficas generadas por la red neuronal durante el set de validación reflejan el rendimiento del modelo. En primera instancia, se analiza la curva F1-confidence [ver Figura 18], el cual muestra la curva de confianza F1 para las clases 0, 1 y 2 que representan arándanos verdes, pintos y maduros respectivamente. En la gráfica, el eje x representa el nivel de confianza del modelo en sus predicciones con valores del 0 al 1; mientras que, el eje y muestra la puntuación F1 que también oscila entre 0 y 1.

La curva de la clase 0, que representa a los arándanos verdes, inicialmente, alcanza su pico, pero va disminuyendo a medida que aumenta la confianza. Por otra parte, la curva de los arándanos pintos (clase 1), presenta comportamiento similar a la curva de arándanos verdes, pues también tiene tendencia descendente mientras el nivel de confianza aumenta. En cuanto a la clase 2, que representan los arándanos maduros, se observa que tiene la mejor puntuación F1, ya que alcanza el 0.8, y además se mantiene alta durante un rango amplio de niveles de confianza.

La curva para todas las clases representa el rendimiento general del modelo para las clases combinadas. Se obtuvo una puntuación F1 score de 0.62 cuando la confianza es 0.081.

**Figura 18.**


*Curva F1-confianza generada a partir de los datos de validación.*



Para la Figura 19, el eje x representa la sensibilidad y toma valores de 0 a 1, mientras que el eje y muestra la precisión, que también oscila entre estos valores. La curva de los arándanos verdes (clase 0) muestra una precisión baja, que disminuye a medida que R aumenta; el AP de esta clase es 0.457. Por otra parte, la curva de los arándanos pintos (clase 1) también disminuye en precisión al aumentar R, con un AP de 0.682. La clase de los arándanos maduros (clase 2) es la que tiene mejor precisión y sensibilidad, con un AP de 0.840. En general, el modelo combinando todas las clases, tiene una medida promedio de precisión (mAP) de 65.9% para un umbral de 0.5.

**Figura 19.**

*Curva Precisión-Sensibilidad*




### 3.3. Resultados del conjunto de prueba

De las imágenes del set de prueba, se contabilizaron en total 379 arándanos, de los cuales 196 pertenecían a la clase maduro; 26 arándanos de clase pinto y 157 a la clase verde. A partir de las predicciones obtenidas de dicho set, se obtuvieron los verdaderos positivos (TP), verdaderos negativos (TN), falsos positivos (FP) y falsos negativos (FN) necesarios para determinar la precisión, sensibilidad y F1 score de la red.

En la Figura 20, se muestran algunas de las predicciones que realizó el sistema de procesamiento usando la red YOLOv8n.

**Figura 20.**

*Predicciones realizadas por la red neuronal YOLO v8n.*



Se recolectaron los valores de los tiempos de inferencia de las imágenes ingresadas en el procesamiento de prueba, y a partir de dichos datos se realizó la Tabla 24, que muestra el valor más alto, más bajo y promedio del tiempo en el que el modelo demoró en identificar los distintos grados de madurez de los arándanos presentes en cada imagen. De ello se puede concluir que el modelo es veloz para realizar predicciones pues el tiempo de inferencia no excede el orden de los segundos.

**Tabla 23.**

*Tiempos de inferencia obtenidos en el set de prueba.*

Descripción	Tiempo de inferencia (ms)
Valor más alto	209.4
Valor más bajo	124.7
Valor promedio	140.79

### Métricas obtenidas con el modelo de 3 clases

Se calculó la precisión, sensibilidad y puntaje F1 cuando el modelo YOLOv8n trabajó con 3 clases. Dichos valores se muestran en la siguiente tabla.

**Tabla 24.**

*Métricas de rendimiento para 3 clases.*

Clase	P	R	F1 score
Todas las clases	0.984	0.684	0.807

A partir de los valores presentados en la Tabla 25 se puede aseverar que el modelo ha identificado correctamente el 98% de los casos en los que predijo una determinada clase, es decir, el sistema presenta alta exactitud al clasificar las instancias positivas de las clases. Por otra parte, el modelo ha identificado correctamente el 68% de todos los casos reales de una clase determinada; mientras que, el 32% restante fueron pasadas por alto o no reconocidas (falsos negativos). Además, se obtuvo un valor de F1 score de 0.807, lo que indica que la red neuronal entrenada presenta un buen equilibrio entre precisión y

sensibilidad, es decir identifica correctamente las instancias de una clase y encuentra la mayoría de las instancias verdaderas de la clase.

Con la finalidad de realizar un análisis más profundo del rendimiento de la red también se computaron las métricas de rendimiento para cada clase.

**Tabla 25.**

*Precisión, sensibilidad y F1 score por cada clase.*

<b>Clase</b>	<b>P</b>	<b>R</b>	<b>F1 score</b>
Arándano maduro	0.975	0.812	0.886
Arándano pinto	1	0.615	0.761
Arándano verde	1	0.535	0.697

Para determinar que clase detecta mejor la red neuronal YOLO v8n, se optó por analizar los resultados de la métrica F1 score, ya que combina precisión y sensibilidad. En la Tabla 26, se observan los puntajes F1 obtenidos a partir de los cuales se puede afirmar que el modelo predijo correctamente la mayoría de las instancias de la clase arándano maduro, y no omitió muchas instancias verdaderas; mientras que en el caso de la clase arándano pinto el modelo cometió más errores en forma de falsos negativos, ya que pasó por alto algunos arándanos pintos. Por último, el menor puntaje F1 se obtuvo en la clase arándanos verdes, esto indicó que el modelo no presenta un buen equilibrio en la detección de esta clase.

En la Tabla 27, se observa que la clase arándano maduro obtuvo un valor de 0.818 de AP, lo que indica que el modelo presenta un 81.8% de precisión en la detección y

clasificación correcta de los elementos pertenecientes a esta clase sin confundirlas con otras clases. Por otra parte, la clase arándano pinto alcanzó un valor de 0.636, el cual es el mismo valor que el de arándanos verdes. En resumen, el modelo obtuvo un mejor rendimiento para identificar y clasificar los elementos pertenecientes a la clase de arándanos maduros. Asimismo, el valor de la métrica mAP demuestra que el modelo tiene, en promedio, un desempeño medianamente bueno en las tres clases que se evaluaron.

**Tabla 26.**

*Precisión media y precisión media promedio por clase.*

Clase	AP	mAP
Arándano maduro	0.818	
Arándano pinto	0.636	0.694
Arándano verde	0.636	

Por otra parte, también se tomó en cuenta un segundo enfoque en el cual se trabajaron con dos clases: maduros e inmaduros. Esto debido a que la clase de interés son los arándanos con un grado de madurez satisfactorio.

En la Tabla 28, al aplicar el enfoque para 2 clases, a partir de los valores de AP se puede aseverar que el modelo obtuvo un alto equilibrio entre precisión y sensibilidad tanto para la clase arándanos inmaduros como para la clase de arándanos maduros, destacando ligeramente entre ambas la instancia de arándanos inmaduros. Esto se debe a que el modelo fue capaz de predecir correctamente todas las que dijo que eran positivas

respecto a la clase de arándanos inmaduros, por otra parte, aunque el AP para los arándanos maduros (81.8%) es menor debido a que el modelo se equivocó en realizar algunas predicciones para dicha clase. En líneas generales, la precisión media promedio (mAP) alcanzo un valor mayor (0.859) al del otro enfoque (0.694), lo que indica que el modelo obtuvo un mejor rendimiento cuando se trabajó bajo 2 enfoques.

**Tabla 27.**

*Métricas de rendimiento para enfoque de 2 clases.*

Clases	P	R	F1 score	AP	mAP
Arándano maduro	0.975	0.812	0.886	0.818	0.859
Arándano inmaduro	1	0.551	0.710	0.901	

### Validación de la hipótesis

Para evaluar la hipótesis se tomo como criterio de éxito que el sistema debía alcanzar ciertos valores en las métricas de rendimiento, los cuales fueron establecidos en la lista de requerimientos [ver Tabla 7]. Por lo tanto, si la precisión (P) es mayor a 0.742, recall (R) mayor a 0.746, F1 score mayor a 0.743, y AP mayor a 0.7194 para la clase de arándanos maduros, que es el grado satisfactorio del fruto, entonces la hipótesis es válida.

En base a ello, se puede afirmar que la hipótesis es válida, pues el sistema logró alcanzar para la clase de arándanos maduros valores superiores en las métricas P, R, F1 score y AP siendo estos 0.975, 0.812, 0.886 y 0.818 respectivamente.

## Cumplimiento de requerimientos

Por último, se verifico que se hayan cumplido los requerimientos establecidos previamente, para esto se elaboró una tabla en donde se muestra el estado de cada requerimiento.

De la Tabla 29, se concluye que se cumplieron todos los requerimientos establecidos inicialmente, a excepción del último: métricas de evaluación, que se cumplió parcialmente, ya que solo se lograron alcanzar todos los valores esperados en la clase arándanos maduros; mientras que, en el caso de los arándanos verdes y pintos no se consiguieron los valores establecidos para ciertas métricas como lo son la sensibilidad (R), y la precisión media (AP). Por otra en términos de mAP se alcanzó el valor esperado al trabajar con el enfoque de 2 clases.

### Tabla 28.

*Estado de cada requerimiento establecido*

Requerimiento	Descripción	Evidencia	Resultado
Grado de madurez	Sistema debe identificar de 3-4 niveles de madurez	Figura 6	El sistema identifica arándanos verdes, pintos y maduros
Tipo de imágenes para la recolección	Las imágenes de la base de datos deben tener arándanos en arbustos en distintos grados de madurez	Tabla 8 Tabla 9	Se recolectaron 550 imágenes con arándanos en arbustos en distintos grados de madurez
Arquitectura del modelo	El sistema debe ser un modelo de Deep Learning basado en arquitectura de CNN	Tabla 13	El sistema utilizó la red neuronal convolucional YOLOv8n.

Tiempo de procesamiento de inferencia	El sistema no debe exceder el orden de los segundos en realizar cada predicción	Tabla 24	El sistema logró un tiempo de inferencia promedio de 140.79 ms
Métricas de evaluación	El sistema debe alcanzar los valores de la Tabla 7 en las métricas de rendimiento.	Tabla 26	P= 0.984
		Tabla 27	R=0.684
		Tabla 28	F1=0.807
			AP=63.6% – 90.1%
			mAP= 69.4% - 85.9%

## CAPÍTULO IV: DISCUSIÓN Y CONCLUSIONES

### 4.1. Limitaciones

Para la construcción de la base de datos no se encontraron gran cantidad de imágenes de arándanos bajo las condiciones requeridas, lo que pudo ayudar a mejorar la generalización y aumentar la robustez del modelo.

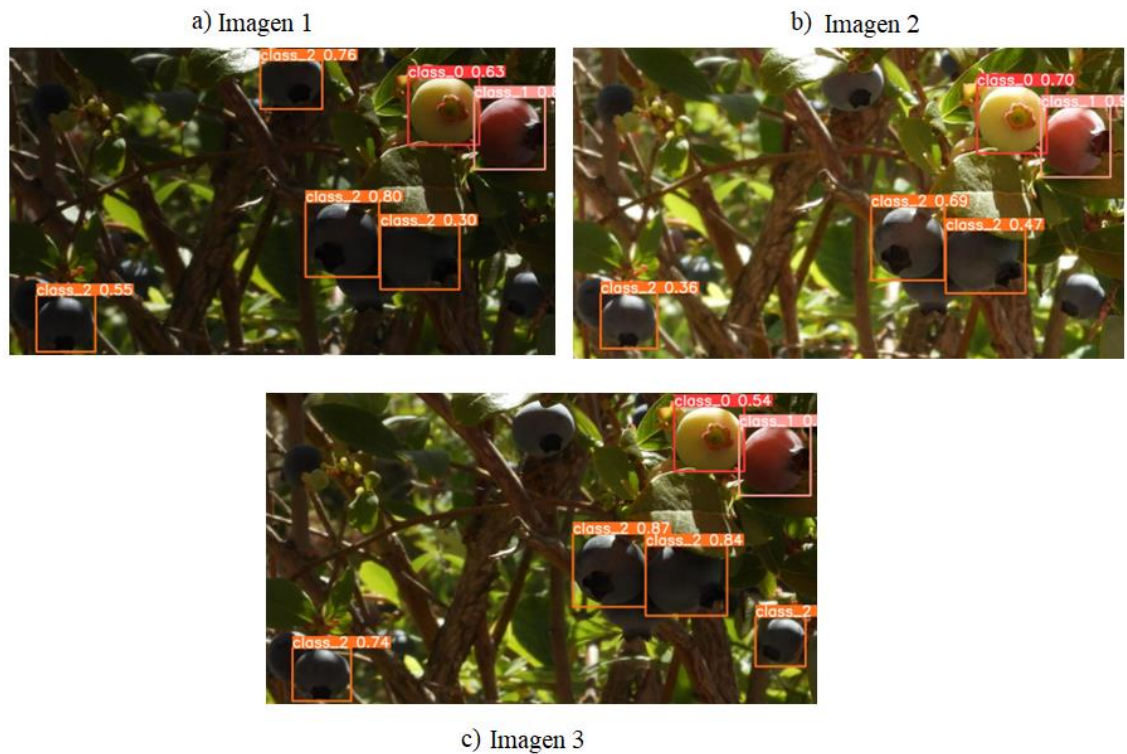
Es así como se observa que el modelo del rendimiento utilizado en este trabajo no alcanzó el valor deseado por la cantidad de imágenes y parámetros. Cabe señalar que esta limitación se debe principalmente a que los trabajos usados para esta comparación construyeron su propia dataset desde cero bajo las condiciones que ellos requerían consiguiendo gran cantidad de imágenes. Esta construcción minuciosa del dataset no era un objetivo principal de esta investigación, puesto que esto podría exceder el límite de tiempo y recursos considerados para la investigación.

## 4.2. Interpretación Comparativa

En el conjunto de prueba, se ingresaron 3 imágenes similares con la misma escena y contenido, aunque con variaciones en la iluminación y ángulo, a la red YOLOv8n, la cual realizó predicciones muy similares en cuanto a cantidad de arándanos verdes, pintos y maduros detectados; sin embargo, dichas predicciones tuvieron distintos niveles de confianza, esto se muestra en la Figura 21.

**Figura 21.**

*Predicciones de imágenes similares realizadas por YOLOv8n.*



A partir de la Figura 21, se puede afirmar que el modelo fue capaz de realizar las 5 mismas predicciones en las tres imágenes, aunque estas varíen en iluminación y ángulo, lo que da indicios de que la red YOLOv8n aprendió características generales que le permiten identificar los distintos grados de madurez independientemente de las condiciones específicas de la imagen. Por otra parte, debido a que las predicciones se obtuvieron bajo distintos niveles de confianza se puede aseverar que la red es sensible a variaciones pequeñas en las imágenes; por ejemplo, bajo las condiciones de iluminación presentes en la imagen 3 se obtuvieron predicciones con altos niveles de confianza para los arándanos maduros; sin embargo, para la imagen 2 (más iluminación), se detecta el arándano verde con alto nivel de confianza a comparación de las demás imágenes.

Asimismo, para evaluar la efectividad del modelo propuesto para identificar el

grado de madurez satisfactorio del arándano se compararon los resultados con otros modelos YOLO entrenados para la misma tarea.

#### 4.2.1. Comparación con modelos de MacEachern et.al. (2023)

En primer lugar, se compararon los valores de las métricas de YOLOv8n, modelo empleado en la presente investigación, con el rendimiento de 6 modelos orientados a detectar el estado de madurez del arándano silvestre extraídos del artículo científico elaborado por MacEachern et.al. Para ello, se utilizó la tabla que se muestra a continuación.

**Tabla 29.**

*Comparación de métricas de precisión, sensibilidad y F1 score entre el modelo YOLOv8 n y los modelos entrenados por MacEachern et.al (2023) con 2 enfoques.*

Modelo	Enfoque - 3 clases			Enfoque – 2 clases		
	P	R	F1	P	R	F1
<b>YOLOv8n</b>	<b>0.984</b>	<b>0.6840</b>	<b>0.807</b>	<b>0.975</b>	<b>0.812</b>	<b>0.710</b>
YOLOv3	0.79	0.77	0.78	0.83	0.82	0.82
YOLOv3-SPP	0.77	0.79	0.79	0.84	0.81	0.82
YOLOv3-Tiny	0.72	0.60	0.66	0.80	0.69	0.74
YOLOv4	0.70	0.82	0.75	0.79	0.86	0.82
YOLOv4-Small	0.73	0.80	0.76	0.78	0.83	0.81
YOLOv4-Tiny	0.74	0.70	0.72	0.80	0.76	0.78

### **a) Enfoque – 3 clases**

A partir de los datos de la Tabla 30 se concluye que la red neuronal YOLO v8n, al trabajar con 3 clases, presentó mejor rendimiento en términos de precisión, alcanzando el valor de 98.4%. Esto significa que, cuando el modelo predice una clase como positiva, es muy probable que acierte, a diferencia de las demás redes YOLO; sin embargo, los modelos YOLOv4 y YOLO v3, junto con sus iteraciones, a excepción de YOLOv3-Tiny, demostraron mayor desempeño para identificar correctamente los casos positivos del conjunto de datos, esto se refleja en los valores de recall. A pesar de estas diferencias, el modelo YOLOv8n, trabajado en la presente investigación, logró el mejor equilibrio entre precisión y recall, con un puntaje de 0.807, destacándose como el modelo más equilibrado en términos de rendimiento global.

### **b) Enfoque – 2 clases**

Según la Tabla 30 al trabajar con 2 clases: “maduro” e “inmaduro” el modelo YOLO v8n nuevamente destacó en términos de precisión, con un valor de 0.975, pero fue superado en sensibilidad por la red YOLO v4, que obtuvo el valor de 0.86. Lo mismo sucedió en la medida F1 score donde lideraron las redes YOLOv3, YOLOv3-SPP y YOLO v4. En general, al centrarnos en la métrica F1, que combina precisión y recall, YOLOv8n mostró un mejor rendimiento al trabajar con 3 clases; sin embargo, fue superada por la familia YOLOv3 e iteración SPP cuando se emplearon 2 clases.

#### **4.2.2. Comparación con modelos de Xiao et.al. (2023)**

También se utilizó el estudio de Xiao et.al, en donde diseñaron un método de detección ligero basado en un algoritmo mejorado de YOLOv5 con el objetivo de lograr un reconocimiento preciso de los estados de madurez de los arándanos, y luego

compararon su rendimiento con 3 modelos. En su investigación, trabajaron con tres clases: maduro, semimaduro e inmaduro.

**Tabla 30.**

*Comparación de métricas P y R entre YOLOv8n y los modelos entrenados por Xiao et.al.(2023)*

Métricas/Modelo	YOLOv8n	YOLOv5 mejorada	YOLOv5	SSD-vgg	Faster R- CNN-vgg	
P (%)	Maduro	<b>97.5</b>	97.8	98.7	96.0	93.1
	Semimaduro	<b>100</b>	96.3	95.5	92.7	87.1
	Inmaduro	<b>100</b>	94.9	97.0	96.2	85.6
	Promedio	<b>99.1</b>	96.3	97.1	95.0	88.6
R (%)	Maduro	<b>81.2</b>	92.9	93.5	96.0	95.8
	Semimaduro	<b>61.5</b>	90.1	91.3	89.0	90.1
	Inmaduro	<b>53.5</b>	93.0	93.4	93.9	93.0
	Promedio	<b>65.4</b>	92.0	92.7	93.0	93.0

A partir de los datos de la Tabla 31, se observa que YOLOv8n presenta una alta precisión en la detección de arándanos maduros, semimaduros e inmaduros, con resultados comparables a los demás modelos. Sin embargo, en términos de sensibilidad, aunque alcanzó un 81.2% para la clase maduro, registró valores más bajos en las demás

clases. En general, YOLOv8n fue superado por el resto de las redes neuronales convolucionales en cuanto a sensibilidad. Esto comprueba que el modelo no capturó todos los estados de madurez del arándano, es decir, hubo gran cantidad de falsos negativos, pero porque no los detectó. Por otra parte, SSD-vgg y Faster R-CNN-vgg son modelos más equilibrados, esto se refleja en el buen rendimiento en términos de precisión y sensibilidad, convirtiéndolos en redes más robustas.

Por tal motivo, en la Tabla 32, se compararon la cantidad de imágenes y parámetros de la red YOLOv8n y los demás modelos de Xiao et.al (2023), en donde se evidencia que las demás redes son más complejas por el número de parámetros, lo que les permite un mejor rendimiento. Por otra parte, la red YOLOv5 mejorada por los investigadores tiene menor cantidad de parámetros que YOLOv8n, y aun así logró obtener mejores resultados. A esto se suma que usaron más imágenes para entrenar sus redes.

**Tabla 31.**

*Factores que influyeron en el rendimiento de las redes YOLOv8n y YOLOv5.*

<b>Modelo</b>	<b>Nº imágenes</b>	<b>Nº parámetros</b>
<b><i>YOLOv8n</i></b>	<b><i>550</i></b>	<b><i>3.2M</i></b>
YOLOv5 mejorada	680	2.85 M
YOLOv5	680	7.2 M
SSD-vgg	680	23.6M
Faster R-CNN-vgg	680	136.7 M

### 4.2.3. Comparación con modelos Wenji et.al. (2023)

Por último, también se comparó el artículo de Wenji et.al (2023), en el cual diseñaron un modelo mejorado para extraer características óptimas del arándano y detectar su madurez de manera precisa, y contrastaron su rendimiento con otros 7 modelos entrenados bajo las mismas condiciones. En su estudio evaluaron cinco niveles de maduración como se muestra en la siguiente figura.

#### Figura 22.

*Niveles de maduración usados por Wenji et.al (2023)*



En este caso, solo se extrajeron los resultados de la precisión media de los niveles 1, 3 y 4, ya que son las mismas clasificaciones usadas en la presente investigación. Por otra parte, en la Tabla 33, se muestran las mAP de las CNN entrenadas por Wenji et.al. (2023) y su modelo mejorado, las cuales calcularon solo considerando los tres niveles ya mencionados.

**Tabla 32.**

*Comparación de métricas AP y mAP entre YOLOv8n y modelos entrenados por Wenji et.al (2023).*

Modelo	Arándano verde	Arándano pinto	Arándano maduro	mAP (%)
	AP (%)	AP (%)	AP (%)	
<b>YOLOv8n</b>	<b>63.6</b>	<b>63.6</b>	<b>81.8</b>	<b>69.4</b>
YOLOv5	83.2	76.2	83.5	80.96*
YOLOX	83.0	75.2	85.1	81.1*
EfficientDet	79.0	74.7	78.7	77.46*
Faster RCNN	53.8	60.4	66.8	60.3*
YOLOv7-GhostNet	84.7	81.3	87.9	84.63*
YOLOv7-MobileNetV3	85.3	80.7	87.8	84.6*
YOLOv7	88.5	81.2	89.9	86.53*
Modelo mejorado	89.1	82.3	90.6	87.3*

*Nota.* \* significa que los datos se computaron a partir de las tres clases.

En la Tabla 33 se observa que el modelo YOLOv8n alcanzó el mayor valor de precisión promedio para el arándano maduro, mientras que las clases verde y pinto obtuvieron 63.6%. Comparado con los modelos configurados por Wenji et al., YOLOv8n mostró un mejor rendimiento que la red Faster RCNN; sin embargo, fue superado por el

resto de los modelos en todas las categorías.

Por ello, se revisaron las posibles razones por las que los modelos de Wenji et.al. (2023) obtuvieron mejores resultados. En la Tabla 34, se compararon las redes YOLOv8n y las entrenadas por Wenij et.al. (2023) en términos de cantidad de imágenes usadas y número de parámetros. En primera instancia, se observa que los modelos que presentan mayor cantidad de parámetros a excepción de YOLOv8n, esto indica que las redes son más completas, y con mayor capacidad para capturar información. Otro factor que influyó en el rendimiento fue la cantidad de imágenes usadas, pues el modelo YOLOv8n utilizó casi la mitad de las imágenes que los demás modelos, lo que puede implicar un menor rendimiento en una variedad de escenarios.

**Tabla 33.**

*Factores que influyeron en el rendimiento de las redes.*

Modelo	Nº imágenes	Nº parámetros
<i>YOLOv8n</i>	<i>550</i>	<i>3.2M</i>
YOLOv5	10 000	2.6 – 155.4 M
YOLOX	10 000	9.0 M
EfficientDet	10 000	3.9M
Faster RCNN	10 000	42 M
YOLOv7	10 000	36.9 M
YOLOv7-GhostNet	10 000	5 M
YOLOv7-MobileNetV3	10 000	7.2 M

### 4.3. Implicancias

El desarrollo del sistema de procesamiento de imágenes implicó la búsqueda de los distintos grados de madurez del arándano en trabajos de investigación y, principalmente, la Norma Técnica Peruana 012.501, la cual define el grado de madurez satisfactorio de este fruto. De esta manera, finalmente, se determinaron 3 estados de madurez del arándano, los que se pueden emplear en una investigación donde se busque identificar también los defectos que pueda presentar el arándano, y así dar lugar a un sistema más robusto y confiable que identifique a grandes rasgos la calidad del arándano.

Para desarrollar el sistema de procesamiento de imágenes se empleó una metodología que se basa en cumplir una lista de requerimientos, la cual se podría emplear en futuros trabajos que estén orientados a la identificación de los distintos grados de madurez de otras frutas o verduras.

El sistema de procesamiento de imágenes orientado a la identificación de los distintos grados de madurez del arándano sienta las bases para futuras investigaciones en la cosecha de arándanos empleando robots, debido a que el sistema trabaja con un tiempo de inferencia en el orden de los milisegundos, siendo el valor más alto y más bajo 209.4ms y 124.7ms respectivamente, lo que lo posiciona como un sistema adecuado para un robot de cosecha, ya que estos trabajan en un tiempo de ciclo en el orden de los segundos [ver Tabla 24].

Dado que el sistema de procesamiento de imágenes logró clasificar 3 niveles de maduración del arándano: verde, pinto y maduro, este podría integrarse a sensores multiespectrales que identifiquen los grados de madurez del arándano basándose en sus compuestos internos.

#### 4.4. Conclusiones

Se desarrolló un sistema de procesamiento de imágenes utilizando la red neuronal YOLOv8n para identificar el grado de madurez satisfactorio; para ello, se construyó una base de datos de arándanos con imágenes extraídas de internet, las cuales posteriormente fueron redimensionadas. Además, se optó por seleccionar un modelo Deep Learning, puesto que actualmente es una tecnología muy empleada para la detección de objetos. Luego, se etiquetaron los arándanos del dataset según la clasificación establecida, y se dividieron los datos en conjuntos para el entrenamiento, validación y prueba del modelo YOLOv8n.

Se elaboró una lista de requerimientos con el objetivo revisar la información pertinente, y establecer los recursos necesarios para el desarrollo del sistema, así como también fijar criterios de evaluación del funcionamiento del sistema de procesamiento de imágenes. Por esta razón, se definieron cinco requerimientos, los cuales son grado de madurez, tipo de imágenes, arquitectura del modelo, tiempo de inferencia y validación del sistema.

Se construyó una base de datos con imágenes de arándanos en distintos grados de madurez en arbustos, la cual proporcionó al sistema datos extraídos en condiciones reales, para que el modelo pueda tener un buen desempeño cuando se utilice a futuro en entornos con gran variedad de vegetación.

El sistema de procesamiento de imágenes utilizó una red neuronal convolucional simple como lo es YOLOv8n, para que, de esta manera, el sistema pueda procesar imágenes más rápido, y además sea de fácil despliegue en distintas plataformas, por ejemplo, microcontroladores. Asimismo, se evidenció que la red neuronal convolucional

YOLOv8n es capaz de aceptar imágenes de entrada con resolución de 1920x1080 píxeles.

Realizar diversas pruebas modificando los valores de los hiperparámetros permitió observar el comportamiento de la red con cada ajuste realizado, y así seleccionar los valores de hiperparámetros con los cuales se obtuvo el mejor rendimiento del modelo.

El sistema alcanzó un nivel de precisión, sensibilidad y puntuación F1 alto, siendo este 97.5%, 81.2% y 88.6% respectivamente, para detectar la instancia arándano maduro, que es la clase de interés. Lo que evidencia que el sistema presenta un buen rendimiento para detectar el grado satisfactorio del arándano.

Se comparó el rendimiento del sistema desarrollado basado en la red neuronal convolucional YOLOv8n con modelos de trabajos actuales, los cuales también emplean redes Deep learning, y de ello se concluyó que nuestro sistema a pesar de ser entrenado con pocas imágenes, a diferencia de dichas investigaciones, tuvo un rendimiento aceptable, aunque no superó, en algunos casos, a los modelos desarrollados por Wenji et.al. y Xiao et.al.

## REFERENCIAS

Aguilar-Alvarado, J. y Campoverde-Molina, M. (2020). Clasificación de frutas basadas en redes neuronales convolucionales. *Polo del Conocimiento: Revista científico-profesional*, 5(1), 3-22.

Aguirre, D. (2021). *Detección de enfermedades de la fresa en agricultura de precisión* [Tesis de grado para optar el título de Ingeniería mecatrónica, Universidad Nueva Militar de Granada].

<https://repository.unimilitar.edu.co/server/api/core/bitstreams/3de2c0d2-0c26-4471-91f1-9ecdcae07171/content>

Biswajit, J. , Saxena, S. , Nayak, G. , Saba, L. , Sharma, N. & Suri, J. (2021). Artificial intelligence-based hybrid deep learning models for image classification: The first narative review. *Computers in Biology and Medicine*, 137.

<https://www.sciencedirect.com/science/article/abs/pii/S0010482521005977>

Branque, N. (2022). *Implementación de un sistema automatizado, mediante el uso de visión artificial para la clasificación del maracuyá, según su color de madurez y el uso de un sistema SCADA para el monitoreo de la productividad*. [Trabajo de Tesis, Universidad Estatal Península de Santa Elena].

<https://repositorio.upse.edu.ec/bitstream/46000/8467/1/UPSE-TEA-2022-0005.pdf>

Brownlee, J. (2018). What is the Difference Between a Batch and an Epoch in a Neural Network. *Machine learning mastery*, 20, 1-5.

<https://deeplearning.lipinyang.org/wp-content/uploads/2018/07/What-is-the->

[Difference-Between-a-Batch-and-an-Epoch-in-a-Neural-Network\\_.pdf](#)

Carrasco, L. y Montalvo, L. (2020). *Factores de crecimiento en la exportación del arándano producido en la Libertad, Perú, a los países del medio oriente (Arabia Saudita y Emiratos Árabes Unidos) en el año 2019*. [Trabajo de Tesis, Universidad San Martín de Porres].

[https://repositorio.usmp.edu.pe/bitstream/handle/20.500.12727/7371/carrasco\\_mlj-montalvo\\_gla.pdf?sequence=1&isAllowed=y](https://repositorio.usmp.edu.pe/bitstream/handle/20.500.12727/7371/carrasco_mlj-montalvo_gla.pdf?sequence=1&isAllowed=y)

Challenger, I., Díaz, Y. y Becerra, R. (2014). El lenguaje de programación Python. *Ciencias Holguín*, 20(2), 1-13.

<https://www.redalyc.org/pdf/1815/181531232001.pdf>

Delgado, R. y Obeso, G. (2019). *Solución de machine learning en el reconocimiento de las plagas para plantones de arándano*. [Trabajo de Tesis, Universidad Privada del Norte].

<https://repositorio.upn.edu.pe/bitstream/handle/11537/22493/Delgado%20Pajares%20Renzo%20Manuel%20%20Obeso%20Li%20Gloria%20Isabella.pdf?bitstreamId=430f99d4-f04b-4de2-ab49-40d37fb98585&locale-attribute=es>

Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow*. O'Reilly.

Girshick, R. (2015). Fast R-CNN. *In Proceedings of the IEEE international conference on computer vision 1440-1448*.

[https://openaccess.thecvf.com/content\\_iccv\\_2015/papers/Girshick\\_Fast\\_R-CNN\\_ICCV\\_2015\\_paper.pdf](https://openaccess.thecvf.com/content_iccv_2015/papers/Girshick_Fast_R-CNN_ICCV_2015_paper.pdf)

- Gobierno Regional de Piura. (2022). *Arándanos, un nuevo impulso a la agroexportación en el Perú y en la región Piura*. [Archivo PDF].  
<https://cdn.www.gob.pe/uploads/document/file/3814675/Direcci%C3%B3n%20de%20Industria%20271022Arandanos.pdf.pdf>
- Ghezzi, P & Stein, E. (2021). *Los arándanos en el Perú*. [Archivo PDF].  
<https://cdn.www.gob.pe/uploads/document/file/3814675/Direcci%C3%B3n%20de%20Industria%20271022Arandanos.pdf.pdf>
- Goodfellow, I., Bengio, Y. & Courville, A. (2016). *Deep Learning*. MIT Press.  
<https://www.deeplearningbook.org/contents/ml.html>
- Hassan, E., Shams, M., Hikal, N. & Elmougy, S. (2022). The effect of choosing optimizer algorithms to improve computer vision tasks: a comparative study. *Multimedia Tools and Applications* (82), 16591-16633.  
<https://link.springer.com/content/pdf/10.1007/s11042-022-13820-0.pdf>
- Hernández, R. y Mendoza, C. (2018). *Metodología de la investigación las rutas cuantitativa, cualitativa y mixta*. Mc Graw Hill Education.
- Hu, X., Chu, L., Pei, J., Liu, W. & Bian, J. (2021). *Model Complexity of Deep Learning: A Survey*. <https://arxiv.org/pdf/2103.05127>
- IBM. (s/f). *¿Qué son las redes neuronales convoluciones?* <https://www.ibm.com/mx-es/topics/convolutional-neural-networks>
- IEEEDataPort. (1 de febrero de 2020). DEEPBLUEBERRY: QUANTIFICATION OF BLUEBERRIES IN THE WILD USING INSTANCE SEGMENTATION.

<https://iee-dataport.org/documents/deepblueberry-quantification-blueberries-wild-using-instance-segmentation>

Instituto Nacional de Calidad. (2019). *NTP 012.501.2019*. [Archivo PDF].

<https://es.scribd.com/document/651139215/NTP-Arandano-Fresco>

Instituto Peruano de Economía. (21 noviembre del 2022). *Las agroexportaciones, un caso de desarrollo económico y social*. [https://www.ipe.org.pe/portal/las-](https://www.ipe.org.pe/portal/las-agroexportaciones-un-caso-de-desarrollo-economico-y-social/#:~:text=El%20sector%20agroexportador%20es%20uno,intensivo%20en%20mano%20de%20obra)

[agroexportaciones-un-caso-de-desarrollo-economico-y](https://www.ipe.org.pe/portal/las-agroexportaciones-un-caso-de-desarrollo-economico-y-social/#:~:text=El%20sector%20agroexportador%20es%20uno,intensivo%20en%20mano%20de%20obra)

[social/#:~:text=El%20sector%20agroexportador%20es%20uno,intensivo%20en%20mano%20de%20obra](https://www.ipe.org.pe/portal/las-agroexportaciones-un-caso-de-desarrollo-economico-y-social/#:~:text=El%20sector%20agroexportador%20es%20uno,intensivo%20en%20mano%20de%20obra).

Janiech, C., Zschech, P. & Heinrich, K. (2021). Machine Learning and deep learning.

*Electronic Markets* 31, 685-695.

<https://link.springer.com/article/10.1007/s12525-021-00475-2>

Kingma, P. & Ba, J. (2014). Adam: A method for stochastic optimization.

<https://arxiv.org/pdf/1412.6980>

Koirala, A., Walsh, K., Wang, Z. & McCarthy, C. (2019). Deep Learning- Method

overview and review of use for fruit detection and yield estimation. *Computers and Electronics in Agriculture*, 162, 219-234.

<https://www.sciencedirect.com/topics/computer-science/mean-average-precision>

MacEachern, C. B., Esau, T. J., Schumann, A. W., Hennessy, P. J., & Zaman, Q. U.

(2023). Detection of fruit maturity stage and yield estimation in wild blueberry using deep learning convolutional neural networks. *Smart Agricultural*

*Technology*, 3, 100099.

<https://www.sciencedirect.com/science/article/pii/S2772375522000648>

Plataforma digital única del Estado Peruano. (4 de abril del 2023). *Perú, por cuarto año consecutivo, vuelve a ser el primer exportador mundial de arándanos.*

<https://www.gob.pe/institucion/embajada-del-peru-en-espana/noticias/737763-peru-por-cuarto-ano-consecutivo-vuelve-a-ser-el-primer-exportador-mundial-de-arandanos>

Proarándanos. (s/f.). *Evolución en el Perú.* <https://proarandanos.org.pe/exportaciones/> m

Quispe, F. (2023). *Criterios a considerar en la cosecha y postcosecha de fruto de arándano (Vaccinium corymbosum L.) CV. Biloxi en Villacurí, Ica.* [Trabajo de suficiencia profesional, Universidad Nacional Agraria La Molina].

<https://repositorio.lamolina.edu.pe/bitstream/handle/20.500.12996/6071/quispe-romero-fabiola-karel.pdf?sequence=1&isAllowed=y>

Rambauth-Ibarra, G. (2022). Agricultura de Precisión: La integración de las TIC en la producción Agrícola. *Computer and Electronic Sciences: Theory and Applications*, 3(1), 34-38.

Ren, S. , He, K. , Girshick, R. & Sun, J.(2015). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks.

<https://arxiv.org/pdf/1506.01497>

Rouhiainen, L. (2018). *Inteligencia Artificial 101 cosas que debes saber hoy sobre nuestro futuro.* Editorial Alienta.

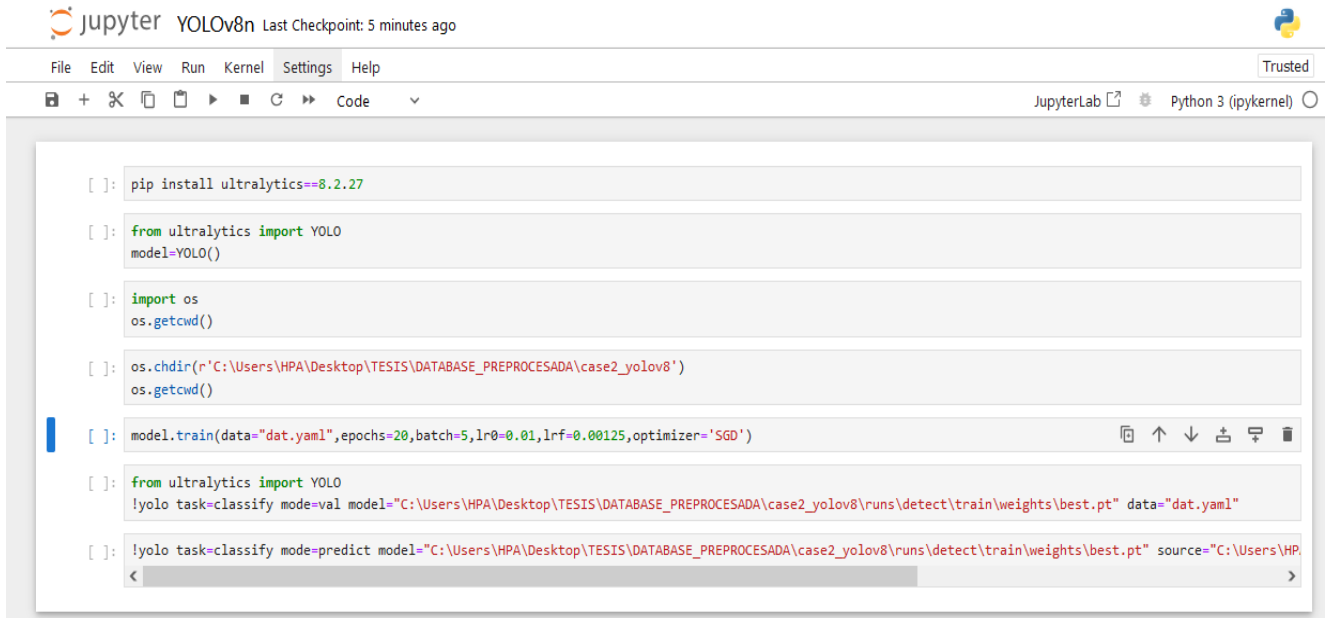
[https://static0planetadelibroscom.cdnstatics.com/libros\\_contenido\\_extra/40/393\\_08\\_Inteligencia\\_artificial.pdf](https://static0planetadelibroscom.cdnstatics.com/libros_contenido_extra/40/393_08_Inteligencia_artificial.pdf)

- Rozo-García, F. (2020). Revisión de las tecnologías presentes en la industria 4.0.  
*Revista UIS Ingenierías*. 19(2), 177-192.  
<https://www.redalyc.org/journal/5537/553768132019/553768132019.pdf>
- Tan, M. , Pang, R. & Le, Q. (2020). EfficientDet: Scalable and Efficient Object  
Detection.  
[https://openaccess.thecvf.com/content\\_CVPR\\_2020/papers/Tan\\_EfficientDet\\_Scalable\\_and\\_Efficient\\_Object\\_Detection\\_CVPR\\_2020\\_paper.pdf](https://openaccess.thecvf.com/content_CVPR_2020/papers/Tan_EfficientDet_Scalable_and_Efficient_Object_Detection_CVPR_2020_paper.pdf)
- Terven, J., Córdova, D. & Romero, J. (2023). A Comprehensive Review of YOLO  
Architecture in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS.  
*Mach Learn Know*, 5(4), 1680-1716. <https://www.mdpi.com/2504-4990/5/4/83>
- Ultralytics. (s/f). *YOLOv8*. <https://docs.ultralytics.com/models/yolov8/>
- Ultralytics. (11 de julio de 2024). *De la Granja a la Mesa: Cómo la IA impulsa la  
innovación en la agricultura*. <https://www.ultralytics.com/es/blog/from-farm-to-table-how-ai-drives-innovation-in-agriculture>
- Wang, B. (2022). A parallel implementation of computing mean average  
precision. <https://arxiv.org/pdf/2206.09504>.
- Wenji, Y., Xixin, M. & Hang, A. (2023). Blueberry Ripeness Detection Model Based  
on Enhanced Detail Feature and Content-Aware Reassembly. *Agronomy*,  
13,1613. <https://www.mdpi.com/2073-4395/13/6/1613>
- Xiao, F., Wang, H., Xu, Y., & Shi, Z. (2023). A Lightweight Detection Method for  
Blueberry Fruit Maturity Based on an Improved YOLOv5 Algorithm.

*Agriculture*, 14(1), 36. <https://www.mdpi.com/2077-0472/14/1/36>

## ANEXOS

### ANEXO N°1. Líneas de código para la configuración inicial de la red YOLOv8n.



The screenshot shows a JupyterLab environment with the following code in a cell:

```
[ ]: pip install ultralytics==8.2.27

[ ]: from ultralytics import YOLO
model=YOLO()

[ ]: import os
os.getcwd()


[ ]: os.chdir(r'C:\Users\HPA\Desktop\TESIS\DATABASE_PREPROCESADA\case2_yolov8')
os.getcwd()

[ ]: model.train(data="dat.yaml", epochs=20, batch=5, lr0=0.01, lrf=0.00125, optimizer='SGD')

[ ]: from ultralytics import YOLO
!yolo task=classify mode=val model="C:\Users\HPA\Desktop\TESIS\DATABASE_PREPROCESADA\case2_yolov8\runs\detect\train\weights\best.pt" data="dat.yaml"

[ ]: !yolo task=classify mode=predict model="C:\Users\HPA\Desktop\TESIS\DATABASE_PREPROCESADA\case2_yolov8\runs\detect\train\weights\best.pt" source="C:\Users\HPA\Desktop\TESIS\DATABASE_PREPROCESADA\case2_yolov8\runs\detect\train\images\test\img001.jpg"
```

ANEXO N° 2. Predicciones realizadas por la red YOLOv8n.



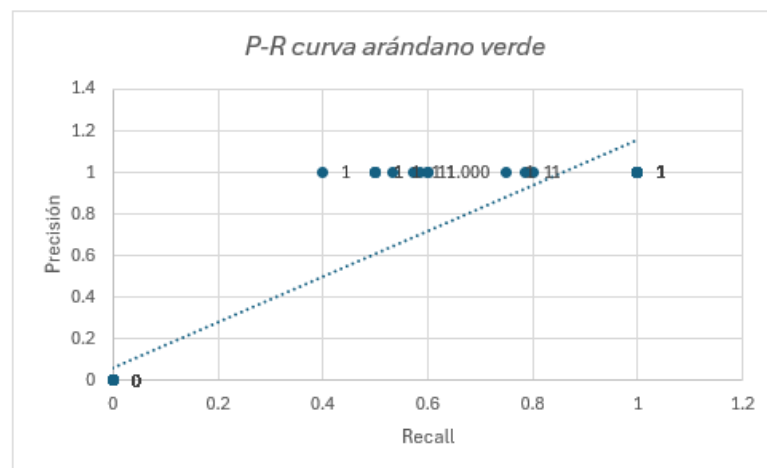
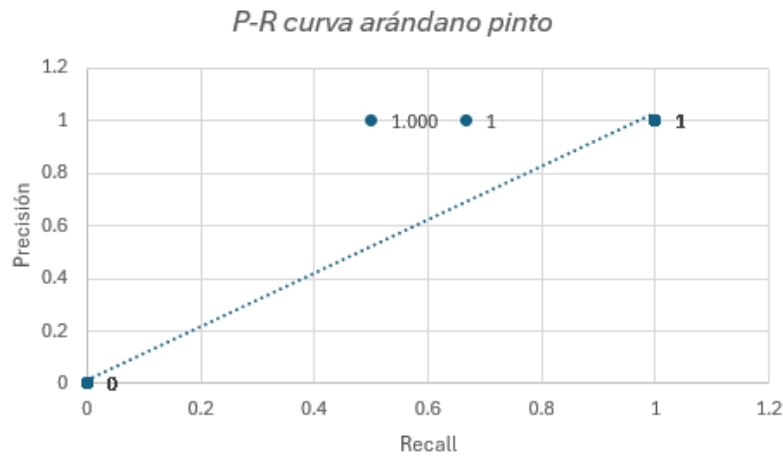

ANEXO N°3. Tabla de datos empleada para calcular el AP para la clase arándano maduro.

Se realizó una tabla en excel con los datos obtenidos de las imágenes del conjunto de prueba en donde se contabilizaron los TP, FP, TN y FN, esto para determinar la precisión y recall obtenida en cada imagen, y de esta manera graficar la curva AP para los arándanos maduros. En esta imagen solo se muestran los datos de las 4 primeras imágenes.

Imágenes	Real	Predicción	Confianza	TP	FP	TN	FN	ATP	AFP	AFN	P	R
dimage53	v	v	0.55	0	0	1	0	0	0	0	1	1
	v	v	0.68	0	0	1	0	0	0	0		
	v	v	0.36	0	0	1	0	0	0	0		
	m	m	0.6	1	0	0	0	1	0	0		
	m	m	0.96	1	0	0	0	2	0	0		
dimage106	v	v	0.56	0	0	1	0	0	0	0	1	1.000
	v	v	0.88	0	0	1	0	0	0	0		
	v			0	0	1	0	0	0	0		
	v			0	0	1	0	0	0	0		
	v			0	0	1	0	0	0	0		
	p	p	0.86	0	0	1	0	0	0	0		
	m	m	0.96	1	0	0	0	1	0	0		
dimage 108	v	v	0.83	0	0	1	0	0	0	0	1	1
	v	v	0.33	0	0	1	0	0	0	0		
	v	v	0.82	0	0	1	0	0	0	0		
	m	m	0.96	1	0	0	0	1	0	0		
	m	m	0.81	1	0	0	0	2	0	0		
	m	m	0.95	1	0	0	0	3	0	0		
dimage265	v	v	0.69	0	0	1	0	0	0	0	#,DIV/0!	#,DIV/0!
	v	v	0.81	0	0	1	0	0	0	0		
	v	v	0.61	0	0	1	0	0	0	0		
	v	v	0.83	0	0	1	0	0	0	0		
	v	v	0.77	0	0	1	0	0	0	0		
	v	v	0.78	0	0	1	0	0	0	0		
	v	v	0.28	0	0	1	0	0	0	0		
	v	v		0	0	1	0	0	0	0		
	v	v		0	0	1	0	0	0	0		
	v			0	0	1	0	0	0	0		
	v			0	0	1	0	0	0	0		
	v			0	0	1	0	0	0	0		
	v			0	0	1	0	0	0	0		

ANEXO N° 4. Curvas PR para la clase de arándanos verdes, pintos y maduros.

Al computarse todos datos en términos de precisión y recall para cada imagen del conjunto de datos, se pudieron graficar las curvas PR para cada clase.



ANEXO N°5. Matriz de operacionalización

VARIABLES	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL	DIMENSIONES	INDICADORES	FÓRMULAS
<i>Variable independiente</i>	Según Romero et.al. (2023) el índice de madurez determina si un producto tiene la madurez que se busca a nivel comercial. Se emplean características del fruto a fin de obtener estimaciones adecuadas de madurez. Para el arándano son muy usados el color, la firmeza, el contenido de sólidos solubles totales y la acidez titulable. (pp.20-21)	El grado madurez satisfactorio de acuerdo a la NTP 012.501 se medirá con el color de la piel del arándano.	Grado de madurez de una base de datos de imágenes de arándano clasificados en términos de madurez satisfactoria según la clasificación elaborada por Quispe (2023).	Arándano verde	/
Grado de madurez satisfactorio del arándano de acuerdo con NTP 012.501				Arándano pinto	
		Arándano maduro			
<i>Variable dependiente</i>	Cuando un modelo se desempeña bien, es decir, logra realizar predicciones precisas, con datos que nunca ha visto significa que la red neuronal ha logrado su principal propósito: generalizar (Chollet, 2017).	El rendimiento del modelo para identificar el grado de madurez satisfactorio se medirá mediante métricas	Se emplean métricas de rendimiento para realizar mejoras en los modelos de clasificación, ya que, comúnmente hay falsas predicciones, subajustes y sobreajustes. Existen distintas métricas, por ejemplo, precisión, recall, F1 score, entre otras (Zapeta et.al, 2022).	Precisión	$P = \frac{TP}{TP + FP}$
Rendimiento del sistema de procesamiento de imágenes usando un modelo Deep Learning en la identificación del grado de madurez satisfactorio				Recall	$R = \frac{TP}{TP + FN}$
				Average Precision	$AP = \frac{1}{11} \sum AP$
				Mean Average Precision	$mAP = \frac{\sum AP}{N}$
				F1 score	$F_1 = \frac{2PR}{P + R}$