

UNIVERSIDAD MIGUEL HERNÁNDEZ DE ELCHE

ESCUELA POLITÉCNICA SUPERIOR DE ELCHE

GRADO EN INGENIERÍA ELECTRÓNICA Y
AUTOMÁTICA INDUSTRIAL



“DETECCIÓN Y CLASIFICACIÓN DE
FRUTAS MEDIANTE LA RED YOLOv8 Y
TÉCNICAS DE VISIÓN POR
COMPUTADOR BAJO CONDICIONES
LUMÍNICAS VARIABLES.”

TRABAJO FIN DE GRADO

Julio -2025

AUTOR: Pablo Poderoso Martínez


DIRECTOR/ES: Mónica Ballesta Galdeano

Judith Vilella Cantos

ÍNDICE

1.INTRODUCCIÓN.....	9
1.1 Antecedentes.....	9
1.1.1 Redes neuronales	9
1.1.2 Inteligencia artificial.....	10
1.2 Robótica móvil en entornos agrícolas	11
1.3 Objetivos.....	12
1.4 Estructura del TFG	13
2.ESTADO DEL ARTE	14
2.1 Redes neuronales convolucionales	14
2.2 Sensores visuales	17
2.3 You Only Look Once (YOLO).....	18
2.4 YOLO aplicado a la robótica.....	21
3.HERRAMIENTAS.....	24
3.1 Software.....	24
3.1.1 Google Colaboratory (Google Colab)	24
3.1.2 Ultralytics	25
3.1.3 Roboflow	26
3.2 YOLOv8	27
3.3 Fruits-360 Dataset	29
4.EXPERIMENTOS Y RESULTADOS.....	32
4.1 Clasificación	32
4.1.1 Estudio de cambio de iluminación en la etapa de clasificación	40
4.2 Detección	44
5.CONCLUSIONES Y TRABAJOS FUTUROS	53
6.BIBLIOGRAFÍA.....	55

7.ANEXO 1: TABLAS DE RESULTADOS DE LAS PREDICCIONES CON IMÁGENES DEL DATASET	60
8.ANEXO 2: TABLAS DE RESULTADOS DE LAS PREDICCIONES CON IMÁGENES EXTERNAS AL DATASET	67
9.ANEXO 3: TABLAS DE RESULTADOS DE LAS PREDICCIONES CON IMÁGENES MODIFICADAS CON CAMBIOS DE ILUMINACIÓN.....	70
10.ANEXO 4: TABLAS DE RESULTADOS DE LAS PREDICCIONES EMPLEANDO LOS MODELOS CON CAMBIOS DE ILUMINACIÓN	77
11.ANEXO 5: RESULTADOS DEL ENTRENAMIENTO DE DETECCIÓN	90
12.ANEXO 6: TABLA DE RESULTADO DE LAS PREDICCIONES DEL PROCESO DE DETECCIÓN CON IMÁGENES DEL DATASET	92
13.ANEXO 7: CÓDIGO DE LA APLICACIÓN.....	93
13.1 Código para el proceso de clasificación	93
13.2 Código para el proceso de detección	95



ÍNDICE DE FIGURAS

Figura 1: Explicación perceptrón original. Fuente: ¿Qué son las redes neuronales artificiales?.....	9
Figura 2: Test de Turing. Fuente: Turing Test: Applications and Limitations.....	10
Figura 3: Funcionamiento red convolucional. Fuente: Redes convolucionales	16
Figura 4: Comparación de tamaño y velocidad entre diferentes modelos de YOLO. Fuente: Ultralytics	27
Figura 5: Arquitectura de YOLOv8. Fuente: Arquitectura de la red YOLOv8	28
Figura 6: Comparación entre los diferentes modelos de YOLOv8. Fuente: YOLOv8: Detección de objetos de última generación en reconocimiento de imágenes (computer vision).....	28
Figura 7: Imágenes de las frutas empleadas del dataset Fruits-360. Fuente: Fruits-360 dataset	31
Figura 8: Imágenes externas al dataset.	38
Figura 9: imágenes del conjunto de predicción sometidas a cambios de iluminación. ...	40
Figura 10: Ejemplo de rejillas generadas.	45
Figura 11: Proceso de anotado automático de Roboflow.	46
Figura 12: Ejemplo de predicción realizado por el modelo de detección.	50
Figura 13: Ejemplo de predicción con imágenes externas al dataset realizado por el modelo de detección.	51
Figura 14: Fragmento de código para conectar el cuaderno de Google Colab a Google Drive e instalar la biblioteca Ultralytics.	93
Figura 15: Fragmento de código para realizar un entrenamiento de clasificación de la red YOLOv8.	93
Figura 16: Fragmento de código para realizar predicciones empleando un modelo de clasificación y generar un archivo con los resultados de las predicciones.....	93
Figura 17: Fragmento de código para generar cambios de iluminación en las imágenes de predicción.	94

Figura 18: Fragmento de código para generar las nuevas imágenes para emplear en el proceso de detección.....	95
Figura 19: Fragmento de código para realizar un entrenamiento de detección de la red YOLOv8.....	96
Figura 20: Fragmento de código para realizar predicciones empleando un modelo de detección y generar un archivo con los resultados de las predicciones.....	96



ÍNDICE DE TABLAS

Tabla 1: Detalles del entrenamiento de clasificación de las manzanas.	33
Tabla 2: Detalles del entrenamiento de clasificación de las peras.	33
Tabla 3: Detalles del entrenamiento de clasificación de las uvas.	33
Tabla 4: Detalles del entrenamiento de clasificación de las cerezas.	34
Tabla 5: Detalles del entrenamiento de clasificación de las frutas conjuntas.	34
Tabla 6: Resultados del entrenamiento de clasificación de las manzanas.	35
Tabla 7: Resultados del entrenamiento de clasificación de las peras.	35
Tabla 8: Resultados del entrenamiento de clasificación de las uvas.	36
Tabla 9: Resultados del entrenamiento de clasificación de las cerezas.	36
Tabla 10: Resultados del entrenamiento de clasificación de las frutas conjuntas.	36
Tabla 11: Resumen de los resultados del proceso de predicción.	38
Tabla 12: Resumen de los resultados del proceso de predicción con imágenes externas al dataset.	39
Tabla 13: Resumen de los resultados del proceso de predicción con imágenes modificadas con cambios de iluminación.	41
Tabla 14: Resultados del entrenamiento de clasificación de las manzanas con cambios de iluminación.	42
Tabla 15: Resultados del entrenamiento de clasificación de las peras con cambios de iluminación.	42
Tabla 16: Resultados del entrenamiento de clasificación de las uvas con cambios de iluminación.	42
Tabla 17: Resultados del entrenamiento de clasificación de las cerezas con cambios de iluminación.	42
Tabla 18: Resultados del entrenamiento de clasificación de las frutas conjuntas con cambios de iluminación.	42

Tabla 19: Resumen de los resultados del proceso de predicción empleando los diferentes modelos entrenados con cambios de iluminación.	44
Tabla 20: Fragmento de los resultados del entrenamiento de detección.	49
Tabla 21: Resumen de resultados del proceso de predicción.	49
Tabla 22: Resultados del proceso de predicción con imágenes externas al dataset.	50
Tabla 23: Porcentaje de acierto del proceso de predicción con imágenes externas al dataset.	51
Tabla 24: Resultados de las predicciones del entrenamiento de las manzanas.	61
Tabla 25: Resultados de las predicciones del entrenamiento de las peras.	62
Tabla 26: Resultados de las predicciones del entrenamiento de las uvas.	63
Tabla 27: Resultados de las predicciones del entrenamiento de las cerezas.	64
Tabla 28: Resultados de las predicciones del entrenamiento de las frutas conjuntas. ...	66
Tabla 29: Resultados de las predicciones del entrenamiento de las manzanas con imágenes externas al dataset.	67
Tabla 30: Resultados de las predicciones del entrenamiento de las peras con imágenes externas al dataset.	68
Tabla 31: Resultados de las predicciones del entrenamiento de las uvas con imágenes externas al dataset.	68
Tabla 32: Resultados de las predicciones del entrenamiento de las cerezas con imágenes externas al dataset.	68
Tabla 33: Resultados de las predicciones del entrenamiento de las frutas conjuntas con imágenes externas al dataset.	69
Tabla 34: Resultados de las predicciones del entrenamiento de las manzanas con imágenes modificadas con cambios de iluminación.	71
Tabla 35: Resultados de las predicciones del entrenamiento de las peras con imágenes modificadas con cambios de iluminación.	72
Tabla 36: Resultados de las predicciones del entrenamiento de las uvas con imágenes modificadas con cambios de iluminación.	73

Tabla 37: Resultados de las predicciones del entrenamiento de las cerezas con imágenes modificadas con cambios de iluminación.....	74
Tabla 38: Resultados de las predicciones del entrenamiento de las frutas conjuntas con imágenes modificadas con cambios de iluminación.....	76
Tabla 39: Resultados de las predicciones del entrenamiento de las manzanas con cambios de iluminación.	80
Tabla 40: Resultados de las predicciones del entrenamiento de las peras con cambios de iluminación.	82
Tabla 41: Resultados de las predicciones del entrenamiento de las uvas con cambios de iluminación.	83
Tabla 42: Resultados de las predicciones del entrenamiento de las cerezas con cambios de iluminación.	85
Tabla 43: Resultados de las predicciones del entrenamiento de las frutas conjuntas con cambios de iluminación.	89
Tabla 44: Resultados del entrenamiento de detección.	91
Tabla 45: Resultados de las predicciones del proceso de detección.....	92

1.INTRODUCCIÓN

1.1 Antecedentes

1.1.1 Redes neuronales

Los investigadores Warren McCulloch y Walter Pitts en 1943 crearon la lógica umbral [1], un modelo informático que se inspiró en las redes neuronales del cerebro y se basaba en las matemáticas y los algoritmos. A raíz de esto surgieron dos vías de investigación, una que profundizó en los procesos biológicos del cerebro y otra que se centró en el uso de estas redes para inteligencia artificial.

En 1958, el científico Frank Rosenblatt, influenciado por el trabajo de Warren McCulloch y Walter Pitts, desarrolló el perceptrón [2], la unidad básica de las redes neuronales, sentando así las bases de este campo.

Las redes neuronales están formadas por una capa de entrada, una o más capas ocultas y una capa de salida. Cada capa está formada por perceptrones o unidades más complejas con distintas funciones de activación.

Los perceptrones tienen una cantidad determinada de entradas, a las que se les asignan un peso, que es un número por el que se multiplica cada entrada. Dentro del perceptrón se aplica una función de activación para determinar la salida. Originalmente, el perceptrón utilizaba una función escalón para su salida, es decir 0 o 1. En cambio, en redes neuronales actuales, se utilizan funciones como ReLU o sigmoide para obtener un mejor aprendizaje de la red.




Figura 1: Explicación perceptrón original. Fuente: [¿Qué son las redes neuronales artificiales?](#)

1.1.2 Inteligencia artificial

A raíz de los trabajos de Warren McCulloch y Walter Pitts y con la intención de responder a la pregunta de si las máquinas pueden pensar, el matemático Alan Turing publicó en 1950 “*Computing machinery and intelligence*” [3]. Este artículo proponía un experimento que pasó a conocerse como el Test de Turing. Dicho test tenía como objetivo determinar si una máquina se puede considerar inteligente y si es capaz de llegar a mostrar un comportamiento indistinguible del de un ser humano.

El Test de Turing marcó un punto de inflexión en el desarrollo de la inteligencia artificial, ya que planteó unas condiciones mediante las cuales se podía llegar a evaluar si una máquina era capaz de replicar la inteligencia humana. Esto inspiró años de investigación, con la intención de poder desarrollar sistemas capaces de interactuar con humanos de manera natural.

Desde entonces, el campo de la inteligencia artificial ha evolucionado enormemente, creando tecnologías que, aunque estrictamente no cumplan con los criterios del Test de Turing, sí han revolucionado gran cantidad de sectores.




Figura 2: Test de Turing. Fuente: [Turing Test: Applications and Limitations](#)

Actualmente la inteligencia artificial (IA) ha llegado al punto de ser capaz de replicar procesos cognitivos del ser humano, como razonar, aprender, percibir y resolver problemas. Para lograr esto, se hace uso de algoritmos avanzados y modelos matemáticos, como las redes neuronales o el aprendizaje automático, y se está usando para tareas como:

- **Análisis de datos masivos (*Big data*):** Las empresas hacen uso de la IA para procesar grandes cantidades de datos y obtener información valiosa de estos, como patrones y tendencias [4].
- **Asistentes virtuales:** Los asistentes virtuales como Alexa, Siri o Google Assistant, emplean procesamiento de lenguaje natural para ser capaces de entender y contestar a la información que les proporciona el usuario [5].
- **Robótica móvil:** Gracias a la IA se ha conseguido que los robots no solo se muevan de manera autónoma, sino que también puedan tomar decisiones basándose en la información del entorno que perciben [6].

1.2 Robótica móvil en entornos agrícolas

La robótica móvil aplicada a la agricultura ha sufrido un gran avance en estos últimos años. Ejemplo de esto es el aumento de la cantidad de robots en el mercado y el aumento de las tareas que son capaces de realizar. Algunas de estas tareas son:

1. **Monitoreo y análisis de cultivos:** esta actividad es de crucial importancia en este ámbito [7]. Gracias a la integración de sensores visuales y algoritmos de visión por computador, los robots son capaces de evaluar el estado de salud vegetal midiendo índices como NDVI [8] o GNDVI, que se correlacionan con el contenido de clorofila y el vigor de la planta. También son capaces de detectar enfermedades y estrés identificando manchas, decoloraciones o patrones de marchitez.
2. **Detección y clasificación de frutos para recolección:** el uso de robots para desempeñar esta actividad ha aumentado significativamente el rendimiento de los campos, ya que permite realizar un trabajo continuo. Para que sean efectivos en esta tarea, es necesario poder detectar correctamente qué vegetales están listos para su recolección [9]. Esto se logra a través de modelos de detección de objetos y de clasificadores basados en redes neuronales.
3. **Conteo y estimación de rendimiento:** mediante algoritmos de detección de objetos los sistemas pueden contar las muestras en cada planta [10], lo que permite estimar el rendimiento antes de la cosecha, incluso permitiendo modelar el crecimiento a través de capturas periódicas, generando curvas de desarrollo y ayudando a predecir picos de producción.

4. Control de calidad tras la cosecha: se realiza emplazando sensores visuales y utilizando modelos de visión por computador para analizar las imágenes de cintas transportadores donde se mueven los frutos, pudiendo detectar imperfecciones, clasificar por calibre y color y rechazar de manera automática frutos que no cumplan con los criterios especificados [11].

1.3 Objetivos

Este TFG se motiva con el objetivo de detectar y clasificar frutas mediante la red YOLOv8 y emplear técnicas de visión por computador para trabajar bajo condiciones lumínicas variables.

Para ello, se plantea como principal objetivo el desarrollo de sistemas capaces de clasificar y detectar frutas en diferentes imágenes, evaluando su rendimiento en distintas condiciones, incluyendo variaciones de iluminación en la tarea de clasificación. A partir de este, se establecen los siguientes subobjetivos:

- Analizar el estado del arte para seleccionar una red neuronal adecuada para llevar a cabo el trabajo y una base de datos con la que realizar los experimentos.
- Entrenar distintos modelos de clasificación utilizando la variante YOLOv8n-cls con frutas extraídas del *dataset* Fruits-360, seleccionando frutas concretas, además de un conjunto con diferentes tipos de frutas.
- Evaluar el rendimiento de los diferentes modelos de clasificación empleando imágenes que han sido extraídas previamente del *dataset* y frente a imágenes externas al mismo, con el fin de valorar la capacidad de generalización de los diferentes modelos.
- Analizar el comportamiento de los modelos de clasificación frente a cambios en las condiciones de iluminación, mediante la modificación del brillo en las imágenes de predicción.
- Utilizar la herramienta Roboflow para generar nuevas imágenes con cambios de iluminación, y entrenar modelos que incluyan tanto las imágenes originales como las modificadas.
- Comparar los resultados obtenidos de los modelos entrenados con y sin cambios de iluminación, con la intención de determinar si añadir cambios de iluminación en el entrenamiento mejoran la robustez de los diferentes modelos.

- Entrenar un modelo de detección con YOLOv8n, generando con Roboflow las anotaciones en imágenes de diferentes tipos de fruta.
- Evaluar el rendimiento del modelo de detección frente a imágenes extraídas previamente del *dataset* y frente a imágenes externas al mismo.

1.4 Estructura del TFG

La memoria del TFG se estructura de la siguiente manera:

En el apartado 2 se presenta la historia y funcionamiento de las redes neuronales, así como los sensores visuales que se están empleando para visión por computador. También se trata el funcionamiento y las diferentes versiones de la familia de algoritmos YOLO, además de sus aplicaciones en robótica.

A continuación, en el apartado 3 se presentan y explican las diferentes herramientas que se han empleado a lo largo de los experimentos y la justificación de su uso.

Tras esto, en el apartado 4 inician las explicaciones de los diferentes experimentos, desarrollando tanto la metodología seguida como los resultados que se han obtenido para cada prueba.

Finalmente, en el apartado 5 se analizan los resultados obtenidos y como estos pueden fomentar futuros trabajos.

2. ESTADO DEL ARTE

2.1 Redes neuronales convolucionales

Las redes neuronales convolucionales (CNN) tienen como origen el neocognitrón, creado por Kunihiko Fukushima en 1980 [12]. El neocognitrón fue el primer modelo que introdujo la idea de usar convoluciones en redes neuronales. Este modelo utilizaba capas jerárquicas para detectar patrones simples y luego combinarlos en otros más complejos. El aprendizaje de este modelo no era supervisado, sino que dependía de reglas predefinidas.

En 1998, Yann LeCun y Leon Bottou incorporaron a la idea de las convoluciones un algoritmo de retropropagación para entrenar redes [13]. Esto fue presentado a través de su red LeNet-5, que combinaba capas convolucionales, de agrupamiento y totalmente conectadas.

En 2012 apareció AlexNet [14], una CNN que ganó la competencia ImageNet Large Scale Visual Recognition Challenge (ILSVRC) con un rendimiento muy superior al de los métodos tradicionales, gracias al uso de una GPU para acelerar su entrenamiento. A partir de ese momento, el uso de GPUS para entrenamiento de redes neuronales se volvió algo indispensable.

En 2014, Simonyan y Zisserman propusieron VGGNet [15], que apostó por usar únicamente convoluciones 3×3 repetidas en profundidad para extraer características cada vez más complejas. Las variantes VGG-16 y VGG-19 probaron que la uniformidad de la arquitectura facilitaba el diseño y la experimentación, convirtiéndose en un modelo de referencia para múltiples tareas de visión por computador, a pesar del uso de un elevado número de parámetros.

Ese mismo año se lanzó GoogLeNet (Inception v1) [16]. Esta nueva red introdujo el módulo Inception, un bloque que combina convoluciones 1×1 , 3×3 y 5×5 en paralelo, junto con submuestreo, empleando convoluciones 1×1 para reducir la dimensionalidad antes de las operaciones más costosas. Este enfoque sentó las bases hacia redes más profundas y eficientes.

En 2015, se presentó ResNet [17], la arquitectura que hizo posible entrenar redes superprofundas (hasta 152 capas) gracias a los bloques residuales. Estas conexiones

directas solucionaron el desvanecimiento del gradiente, estableciendo un nuevo estándar en precisión y profundidad de las CNNs.

En 2019, Tan y Le introdujeron EfficientNet [18], una familia de modelos diseñados mediante AutoML que equilibra la profundidad, el ancho y la resolución de entrada. EfficientNet demostró un desempeño superior al de arquitecturas previas con un coste computacional y número de parámetros significativamente menores.

En 2022, salió ConvNeXt [19], una evolución de las CNN clásicas que emplea kernels más grandes, como 7×7 . Reemplaza *BatchNorm* por *LayerNorm* para mayor estabilidad y reorganiza el orden de convoluciones y activaciones para lograr una mayor optimización, obteniendo así un modelo tan eficiente como las redes tradicionales, pero con un rendimiento superior en visión por computador.

Finalmente, en 2024 aparece PeLK [20], la cual es una versión mejorada de las CNN que utiliza filtros de gran tamaño, hasta 101×101 píxeles, sin incrementar en gran medida el número de parámetros. Esto lo consigue agrupando y compartiendo progresivamente la información de sus filtros, de modo que puede ver áreas muy amplias de la imagen y al mismo tiempo seguir siendo ligero y rápido de entrenar, logrando así un alto rendimiento en tareas de visión por computador.

Las CNN son un tipo de red neuronal especial, que destaca en el procesamiento de imágenes. Por esta razón, estas redes están siendo ampliamente utilizadas para visión por computador, pudiendo llegar a realizar tareas como clasificar imágenes, detección de objetos o segmentación. La principal diferencia con respecto a las redes neuronales tradicionales es la inclusión de capas convolucionales, que permiten extraer características de forma autónoma a gran escala.

Las capas convolucionales son el núcleo de las CNNs. Dentro de las capas convolucionales encontramos diferentes tipos de convoluciones. Algunas de estas son: convolución estándar, convolución transpuesta y convolución de Minkowski.

1. Convolución estándar (conv2D o conv3D): en la convolución estándar se aplican los filtros, los cuales se utilizan para detectar una característica concreta de la imagen, como los bordes, texturas o patrones más complejos en capas posteriores. Los filtros son matrices deslizantes de pesos que recorren toda la imagen, y al multiplicarse con las diferentes porciones de esta, generan una imagen resultante

que se conoce como mapa de características. Los pesos que se emplean en los filtros son asignados automáticamente por la red durante su entrenamiento.

2. Convolución transpuesta: la convolución transpuesta invierte el proceso de convolución, es decir, genera una salida mayor que la entrada. Gracias a este proceso se puede conseguir transformar una representación comprimida en una versión de mayor resolución. Una de sus ventajas es su flexibilidad, ya que el *stride* y el *padding* son ajustables.
3. Convolución de Minkowski: este tipo de convolución está diseñada para trabajar con datos esparcidos en espacios discretos, ya que únicamente operan sobre los puntos del espacio que no se encuentran vacíos, lo que agiliza las tareas que involucran datos tridimensionales. Se usan en simulaciones físicas y en análisis de datos biomédicos, pero especialmente en visión artificial 3D.




Figura 3: Funcionamiento red convolucional. Fuente: [Redes convolucionales](#)

Las redes neuronales tienen una alta capacidad para detectar patrones en grandes conjuntos de datos. Por ello, tienen una amplia variedad de aplicaciones en distintos sectores, destacando: predicción y toma de decisiones, procesamiento del lenguaje natural y visión por computador.

- Predicción y toma de decisiones: se basa en el reconocimiento de patrones de datos históricos para anticipar tendencias y optimizar procesos. Se pueden emplear en campos como economía [21] y agricultura [22] entre otros.
- Procesamiento del lenguaje natural: las redes neuronales permiten a las máquinas comprender y generar texto al analizar patrones en el lenguaje. Esto se puede llegar a usar en el comercio electrónico [23] o en traducción [24].
- Visión por computador: permite a las máquinas interpretar imágenes y vídeos, lo que puede desembocar en aplicaciones como reconocimiento facial [25], en determinar el grado de madurez de un fruto [26], etc.

2.2 Sensores visuales

Los sensores visuales son el primer paso para obtener los *inputs* necesarios para alimentar los modelos de aprendizaje profundo. La calidad, tipo y características de las imágenes afectan directamente a la precisión y rendimiento del modelo.

Los principales sensores visuales son:

- **Cámaras RGB:** capturan imágenes en los tres canales, rojo, verde y azul. Estos sensores son los más utilizados en visión por computador por su reducido coste, disponibilidad y alta resolución. A pesar de sus ventajas, estas cámaras no proporcionan información de profundidad ni otro tipo de datos espectrales. Sus principales aplicaciones son: clasificación de imágenes, detección de objetos en 2D, reconocimiento óptico de caracteres (OCR), entre otras.
- **Cámaras RGB-D:** este tipo de cámaras, al igual que el tipo anterior, capturan una imagen RGB, pero además añaden una imagen de profundidad, que indica la distancia del sensor a cada punta de la escena. Esto permite representar una escena en tres dimensiones, lo que aumenta enormemente la cantidad de información disponible para entrenar redes. Se emplea principalmente en tareas de detección y reconocimiento de objetos en 3D, navegación autónoma en entornos interiores y segmentación semántica con contexto espacial.
- **Cámaras en escala de grises (monocromo):** estas cámaras capturan únicamente la intensidad de luz sin información de color. Son útiles en aplicaciones donde el color no es relevante, como el reconocimiento óptico de caracteres o ciertas imágenes médicas. Su principal ventaja es que ofrecen mayor sensibilidad a la luz y mejor contraste, pero limitan el tipo de información disponible para el modelo.
- **Cámaras LiDAR (*Light Detection and Ranging*):** emiten pulsos de luz y miden el tiempo que tarda en regresar cada pulso, permitiendo así generar mapas en tres dimensiones. Una de sus ventajas es que no se ven afectadas por las condiciones lumínicas en las que operen, por ello se emplean para navegación de vehículos autónomos, robótica avanzada, agricultura de precisión, etc.
- **Cámaras estéreo profesionales:** capturan imágenes desde dos lentes separadas, sin necesidad de luz estructurada o infrarroja, para calcular la profundidad mediante triangulación. Pueden usarse en condiciones difíciles y con objetos a gran distancia. Debido a esto, son idóneas para tareas como SLAM en drones y robots

móviles, medición de objetos en entornos industriales y reconstrucción 3D de escenas o superficies.

2.3 You Only Look Once (YOLO)

YOLO es una familia de algoritmos de detección de objetos en tiempo real que identifican y clasifican objetos con tan solo una pasada sobre la imagen completa, lo que permite lograr una gran velocidad sin tener que sacrificar demasiada precisión. Está basado en una red neuronal convolucional (CNN), un tipo de arquitectura especialmente eficaz para el procesamiento de imágenes, ya que permite extraer características espaciales y patrones visuales de forma automática.

Esta familia de modelos ha ido evolucionando con cada versión, mejorando en aspectos como precisión, eficiencia computacional y añadiendo capacidades adicionales como la segmentación de instancias o la detección a múltiples escalas. Debido a todo esto, YOLO es una de las soluciones más utilizadas en la actualidad para tareas de visión por computador, como la detección de objetos, la clasificación de imágenes y la segmentación semántica.

La evolución de las versiones de YOLO ha sido la siguiente:

- YOLOv1: esta fue la primera versión de YOLO, la cual abandonó los enfoques tradicionales basados en redes neuronales convolucionales como R-CNN y Fast R-CNN. Estos métodos utilizan un proceso en dos pasos: primero predicen las cajas delimitadoras y luego aplican regresión para clasificar los objetos dentro de ellas.

Sin embargo, YOLOv1 propone un proceso en un solo paso donde se divide la imagen en una rejilla, y cada celda es responsable de predecir las cajas delimitadoras y las probabilidades de pertenencia a cada clase de los objetos en su interior. Es decir, realiza en un mismo paso tanto la clasificación como la detección.

Pese a que este enfoque fue revolucionario por reducir los tiempos de procesamiento, presenta limitaciones a la hora de detectar objetos pequeños o múltiples objetos cercanos entre sí.

- YOLOv2: esta versión fue desarrollada un año después de YOLOv1, con la intención de superar las limitaciones que su predecesora presentaba. YOLOv2

introdujo un entrenamiento conjunto que combina datos de detección y clasificación, lo que le permitió mejorar tanto la localización de objetos como la capacidad para reconocer una mayor cantidad de clases.

Para lograr esto, utiliza una jerarquía de clases basada en *WordTree*, lo que le permite realizar clasificación jerárquica y generalizar a objetos que no hayan sido vistos durante el entrenamiento. También incorporó nuevos elementos arquitectónicos como: uso de *batch normalization*, incorporación de *anchor boxes* y el uso de Darknet-19. Todos estos cambios hicieron a YOLOv2 una opción mucho más precisa, rápida y robusta en comparación con YOLOv1.

- YOLOv3: llegó unos años más tarde para mejorar la precisión y velocidad de detección de objetos. Pese a que YOLOv2 era considerada como estado del arte en ese momento, este modelo seguía teniendo limitaciones. Para mejorar este aspecto, uno de los elementos que introdujo YOLOv3 fueron las predicciones a múltiples escalas. Esto significa que ahora las cajas delimitadoras se predicen en tres escalas diferentes, lo que mejora la detección de objetos de diferentes tamaños.

Otro de los aspectos que se introdujeron fue el uso de una columna vertebral CNN mejorada, Darknet-53, formada por 53 capas y siendo un híbrido entre Darknet-19 y Resnets. También se introducen clasificadores logísticos independientes, lo que permite asignar múltiples etiquetas por caja, lo que produjo una mejora en la capacidad para detectar objetos de múltiples clases en una sola caja delimitadora.

- YOLOv4: esta nueva versión de YOLO tiene como cambio más significativo que es una arquitectura dividida en tres partes claves: columna vertebral, cuello y cabeza, manteniéndose como una red de detección de objetos de una sola etapa. Esta división modular trajo mejoras significativas tanto en precisión como en velocidad. La columna vertebral es la encargada de extraer características de la imagen, el cuello se encarga de refinar y combinar las características extraídas anteriormente, y, por último, la cabeza se encarga de hacer las predicciones finales.

Algunas de las técnicas más significativas de optimización que se usaron en este modelo fueron: *Mosaic Data Augmentation*, *Self-Adversarial Training*, *Cross mini-Batch Normalization*, entre otras.

- YOLOv5: apareció unos pocos meses después del lanzamiento de YOLOv4, aumentando ligeramente su velocidad, pero sin mucha mejora. Sin embargo, esta

versión fue desarrollada para que tuviera una sencilla implementación y una documentación más detallada. Su característica más notoria es que está hecha en Pytorch, volviéndola fácil de usar para desarrolladores. Algunas de sus nuevas características fueron la aparición de diferentes formatos para exportar modelos, un *script* para entrenar modelos usando datos propios, la posibilidad de usar *Test-Time Augmentation*, etc.

- YOLOv6: se enfocó en aplicaciones industriales. Introdujo cambios arquitectónicos relevantes como el *EfficientRep* para la columna vertebral, *Rep-PAN* en el cuello y una *Efficient Decoupled* en la cabeza. También, aplicó técnicas como *Task-Aligned Label Assignment*, *Self-Distillation*. Todos estos cambios fueron para ofrecer una alta precisión con buena eficiencia en hardware real.
- YOLOv7: destacó por su enfoque en refinar el proceso de entrenamiento. Introdujo el concepto de *trainable bag of freebies*, además de otras técnicas como *model re-parameterization*, *dynamic label assignment* y *extended and compound scaling*. Todas estas mejoras lograron aumentar la precisión del proceso sin comprometer la velocidad, convirtiéndose en una opción viable para poder realizar tareas en tiempo real.
- YOLOv8: esta versión, al igual que pasó con YOLOv5, se centró en la facilidad de uso. Incorporó mejoras como una cabeza *anchor-free* y una arquitectura optimizada para lograr un equilibrio entre velocidad y precisión. Además, ofrece diferentes versiones, cada una especializada en una tarea concreta, como son detección, segmentación, clasificación y detección de posturas, siendo todo esto fácilmente accesible gracias a la librería Ultralytics.
- YOLOv9: introdujo un cambio en la arquitectura diferenciándose de sus predecesoras, centrándose en evitar la pérdida de información en redes profundas. El primer gran cambio fue la aparición del concepto *Programmable Gradient Information (PGI)*, que usa una rama auxiliar reversible para mejorar los gradientes, y el segundo gran cambio fue GELAN, una arquitectura liviana diseñada para maximizar el flujo de información y facilitar la adquisición de información relevante para futuras predicciones. Estas innovaciones mejoraron la calidad del aprendizaje.
- YOLOv10: marcó un hito al eliminar la necesidad del proceso de *Non-Maximum Suppression (NMS)* en la inferencia. Utiliza una estrategia de entrenamiento

basada en *dual label assignments* para lograr supervisión rica sin usar NMS. Además, optimiza su arquitectura con componentes como *lightweight heads* y *rank-guided blocks*, logrando velocidades e inferencias nunca vistas.

- YOLOv11: esta última versión de YOLO se centró en mejorar la eficiencia computacional sin perder precisión. Introduce dos bloques nuevos: *C3k2*, que reduce el tiempo de procesamiento al usar convoluciones pequeñas, y *C2PSA*, que incorpora atención espacial para detectar mejor las regiones importantes.

Debido a sus reducidos costes de computación y a la gran versatilidad y especialización de modelos de YOLOv8, va a ser esta la versión con la que se va a trabajar en este proyecto, donde se usarán los modelos YOLOv8n-cls para la tarea de clasificación y YOLOv8n para la de detección.

2.4 YOLO aplicado a la robótica

Los modelos de la familia YOLO han demostrado ser especialmente útiles en el ámbito de la robótica, gracias a su capacidad para detectar objetos en tiempo real. Algunas de las aplicaciones que se han beneficiado del uso de esta familia han sido la navegación, manipulación y clasificación de objetos y la agricultura entre otras.

Un ejemplo del uso de YOLO en navegación es “*Mobile Robot Navigation Using an Object Recognition Software with RGBD Images and the YOLO Algorithm*” [27]. En este artículo se pretende integrar una cámara RGBD junto con YOLOv2 para poder localizar y clasificar las imágenes que proporciona el sensor visual. También se pretende determinar la distancia entre el robot y el objeto, para que así se pueda emplear en un algoritmo de control.

El sistema se entrenó con la intención de detectar objetos como sillas, mesas y cajas, alcanzando niveles de fiabilidad superiores al 60% en todas las clases, incluso se llegó a implementar un control reactivo, capaz de esquivar obstáculos en escenarios predefinidos.

El robot móvil logró evitar todos los obstáculos conocidos durante las pruebas experimentales, confirmando la eficacia del sistema propuesto para tareas de navegación autónoma en interiores.

En cuanto a la manipulación y clasificación de objetos encontramos estudios como “*Deep Learning Framework for Controlling Work Sequence in Collaborative Human–Robot Assembly Processes*” [28]. En este se presenta el problema de los trabajos colaborativos

entre humanos y máquinas donde no llegan a ser realmente eficientes, ya que el humano necesita realizar una serie de gestos para operar el robot, lo que aumenta el tiempo requerido para llevar a cabo cualquier tarea.

Para solventar esto, se han realizado pruebas con diferentes redes neuronales: ResNet-50, ResNet-101, YOLOv2 y YOLOv3, siendo entrenadas con la intención de que el robot sea capaz, mediante el uso de una cámara RGB, de detectar herramientas y objetos durante procesos de ensamblaje, permitiendo así determinar la etapa del proceso en la que se encuentra y actuar en consecuencia.

De todas las redes entrenadas, la que ofreció mejores resultados fue YOLOv3 con un 72,6% de rendimiento medio, siendo capaz de completar todas las tareas de ensamblado en una ventana de tiempo deseable.

Por último, en agricultura, YOLO se está empleando para tareas como las que se presentan en “*A Real-Time Apple Targets Detection Method for Picking Robot Based on Improved YOLOv5*” [29]. Este artículo se centra en la problemática de que los robots recolectores no distingan si la fruta realmente se puede agarrar o no. Esto puede suponer que el robot, al ser incapaz de distinguir esto, acabe por dañarse al intentar alcanzar fruta que no se puede recolectar. Para solventar este problema han trabajado con un modelo de YOLOv5s mejorado.

Para el entrenamiento se han empleado 1214 imágenes obtenidas a través de una cámara RGB. De estas imágenes, 200 han sido seleccionadas como conjunto de prueba, teniendo en cuenta que 100 fueran soleadas y las otras 100 nubladas. El resto de las imágenes han sido empleadas como conjunto de entrenamiento, al que se le aplicó compresión de un quinto con respecto a la imagen original para aumentar la eficiencia del entrenamiento. También se aumentaron los datos de entrenamiento aplicando modificaciones a las imágenes para volver más robusto el modelo.

El modelo mejorado alcanzó una precisión del 83,83%, un recall del 91,58%, un mAP del 91,48% y un F1 del 87,49%, además de una velocidad de 0,015s por imagen. En comparación con el modelo original hubo un aumento del 5,05% en el valor mAP. También se comparó con otros modelos, donde el modelo mejorado de YOLOv5s obtuvo resultados superiores en la métrica mAP de 14,95%, 4,74% y 6,75% en comparación con los modelos YOLOv3, YOLOv4 y EfficientDET-D0 respectivamente.

Gracias a las mejoras introducidas, el modelo ofrece detección fiable de manzanas que se pueden agarrar y que no en entornos reales, a la vez que mantiene un modelo compacto de alta velocidad, cumpliendo los requisitos de seguridad y eficiencia de un robot recolector.

En conclusión, podemos apreciar como la familia YOLO, gracias a su versatilidad y gran cantidad de modelos, ofrece resultados prometedores en diferentes áreas gracias a su capacidad para adaptarse a cada una. También como el uso de técnicas, como el aumento de datos y el reescalado de imágenes, juegan un papel crucial a la hora de entrenar modelos de manera eficiente logrando que sean más robustos.



3.HERRAMIENTAS

En este capítulo se van a desarrollar las herramientas de software utilizadas en los experimentos, prestando especial atención a la base de datos y al software empleado para procesar esta información.

3.1 Software

3.1.1 Google Colaboratory (Google Colab)

Google Colab [30] es una herramienta proporcionada por Google que permite programar en Python directamente desde el navegador web. Se basa en la tecnología de los Jupyter Notebooks, que combinan código ejecutable con texto formateado, ecuaciones, gráficas y otros elementos, lo que facilita tanto la documentación como la experimentación con código.

Uno de los aspectos más destacados de Google Colab es que permite ejecutar sus notebooks desde cualquier dispositivo con conexión a internet, sin necesidad de instalar nada en el dispositivo. Además, integra completamente la herramienta de Google Drive, lo que permite trabajar por completo en la nube y compartir los resultados con facilidad.

Otra ventaja de Google Colab es que ofrece acceso a aceleradores de hardware como GPU y TPU. Esto lo convierte en una opción muy útil para entrenar modelos de aprendizaje automático y redes neuronales sin necesidad de contar con un equipo potente. No obstante, el acceso a estos recursos tiene ciertas limitaciones en cuanto a tiempo y disponibilidad ya que se comparten entre todos los usuarios, lo que puede resultar en la necesidad de hacerse con un plan superior al gratuito para asegurarse el acceso a estos recursos durante una mayor cantidad de tiempo.

Colab también permite la colaboración en tiempo real, al igual que ocurre con Google Docs. Esto es excelente para poder realizar trabajos colaborativos, ya que varias personas pueden editar y ejecutar el mismo notebook simultáneamente.

Pese a todas sus ventajas Google Colab también presenta algunas desventajas. Por ejemplo, las sesiones de trabajo tienen una duración limitada sujeta al plan de suscripción del que dispongas, los recursos del hardware pueden llegar a ser insuficiente en tareas muy exigentes, y no se tiene el mismo control sobre el entorno como se tendría en una instalación local.

Se ha decidió usar esta herramienta, ya que permite realizar entrenamientos con YOLO con bastante facilidad, además de no ser necesario contar con un equipo potente que pueda llevar a cabo la tarea. Además, ofrece la posibilidad de tener descargado el *dataset* en Google Drive, pudiendo acceder a los resultados desde cualquier lugar y siendo de gran sencillez compartir los resultados con otros usuarios. Pese a que cuenta con algunas desventajas como la dificultad para acceder a los recursos de aceleración de hardware o las sesiones con tiempos limitados, no llegan a ser un gran inconveniente, ya que los entrenamientos no son tan extensos, y las ventajas superan con creces estos problemas.

3.1.2 Ultralytics

Ultralytics [31] es una biblioteca de código abierto desarrollada en Python que permite una sencilla implementación de los modelos de detección de objetos de la familia YOLO. Esta herramienta ha sido creada y es mantenida por la empresa del mismo nombre. Gracias a la sencillez de uso, al alto rendimiento y a la compatibilidad con entornos de entrenamiento personalizados, esta herramienta se ha consolidado como una de las soluciones más utilizadas para tareas de visión por computador.

A través de esta biblioteca, es posible realizar tareas como detección de objetos, segmentación de instancias, clasificación de imágenes y estimación de poses.

Esta biblioteca ofrece soporte nativo para YOLOv5 y YOLOv8, cada una con distintas variantes escaladas por tamaño, encontrando las versiones *nano* (n), *small* (s), *medium* (m), *large* (l) y *extra large* (x). Pese a que todas las versiones comparten la misma arquitectura, se diferencian en que las versiones más pequeñas tienen menos capas por bloques, menos canales por capa y menor cantidad de parámetros y operaciones. Esto se traduce en un menor tamaño del modelo, mayor velocidad de inferencia y reducción en la precisión.

La instalación de la biblioteca es directa a través del gestor de paquetes pip, y su uso básico consiste en cargar un modelo, pudiendo desde ese momento usarlo para realizar inferencias sobre imágenes o vídeos y, en caso necesario, entrenar un modelo desde cero utilizando un conjunto de datos personalizado.

Por todas las ventajas expresadas anteriormente, se ha decidido trabajar con la biblioteca de Ultralytics, más concretamente con la versión YOLOv8. Se ha elegido esta por ser la versión más reciente y avanzada de la biblioteca, que introduce una arquitectura

completamente nueva desarrollada por el equipo de Ultralytics, mejorando la precisión, la velocidad de inferencia y la versatilidad en comparación con versiones anteriores.

De entre las versiones de este modelo se ha empleado el modelo nano, ya que la tarea de clasificar y detectar diferentes frutas no requiere de usar versiones más grandes, sino que con esta versión se logra obtener buenos resultados en cuanto a la precisión. Gracias a usar la versión más pequeña se consigue reducir en gran medida los tiempos de entrenamiento e inferencia, característica muy deseada al realizar estas tareas en entornos de ejecución alojados en la nube.

3.1.3 Roboflow

Otra de las herramientas que se ha utilizado es Roboflow, que es una plataforma de anotación y gestión de *datasets* especialmente diseñada para proyectos de visión por computador. Su principal objetivo es facilitar la creación, preparación y anotación de imágenes para entrenar modelos de *machine learning*, optimizando el tiempo y los recursos necesarios en la fase de preparación de datos.

Una de las características más utilizadas de esta herramienta es su interfaz de anotación de imágenes, que permite etiquetar objetos de forma rápida y precisa. A través de su plataforma web, los usuarios pueden cargar imágenes y asignarles etiquetas correspondientes a los objetos presentes en cada una de ellas. También incluye la posibilidad de usar modelos preentrenados para realizar anotaciones automáticas en nuevas imágenes. Esto es especialmente útil cuando son imágenes que contienen objetos fácilmente identificables por modelos ya entrenados.

Otra de las funciones que ofrece Roboflow es la generación de *datasets*. Una vez anotadas las imágenes, Roboflow genera de manera automática un *dataset* organizado que puede ser exportado a diferentes formatos. Algunos de los formatos que se encuentran disponibles son COCO, YOLO o VOC, lo que facilita que los *datasets* generados puedan ser empleados por diferentes bibliotecas de *deep learning*.

Roboflow también cuenta con la posibilidad de aumentar los datos para mejorar la robustez del modelo. Esto lo realiza a través de técnicas como rotaciones, cambios de escala y ajustes de brillo. Estas modificaciones ayudan a que el modelo sea más resistente a variaciones en los datos reales, mejorando su capacidad para detectar objetos en condiciones diversas.

Debido a su excelente integración con YOLOv8, Roboflow ha sido utilizado en este proyecto para aumentar los datos del *dataset* Fruits-360, aplicando modificaciones en el brillo de las imágenes. También se ha utilizado la herramienta de anotación con la que cuenta Roboflow para emplear una selección de frutas del *dataset* anterior en la tarea de detección.

3.2 YOLOv8

YOLOv8 es la versión de 2023 desarrollada por Ultralytics. Esta se basa en versiones anteriores de YOLO incorporando nuevas mejoras de rendimiento, flexibilidad y eficiencia, y ofrece soporte integrado para un amplio conjunto de tareas de visión por computador tales como detección, segmentación de instancias, detección de posturas, detección orientada y clasificación. Esto se realiza a través de variantes específicas para cada una de estas tareas, pudiendo operar en diferentes modos operativos, siendo estos inferencia, validación, formación y exportación.




Figura 4: Comparación de tamaño y velocidad entre diferentes modelos de YOLO. Fuente: [Ultralytics](#)

Esta versión de YOLO emplea arquitecturas avanzadas de columna vertebral y cuello, lo que mejora la extracción de características y el rendimiento de la detección de objetos. También elimina la necesidad de definir *anchor boxes*, lo que contribuye a una mayor precisión y a un proceso de detección más eficaz frente a los enfoques tradicionales basados en anclajes.

Además, YOLOv8 emplea durante el entrenamiento la mejora de datos con mosaico, que consiste en combinar cuatro imágenes distintas en una sola para ampliar la diversidad de contextos y fondos, mientras que al mismo tiempo reemplaza las antiguas convoluciones de 6×6 por núcleos de 3×3 . Esto no solo mejora la capacidad del modelo para detectar objetos en escenarios variados, sino que también permite extraer características más complejas de la imagen.

La arquitectura de YOLOv8 incorpora un esquema de procesamiento en múltiples escalas, que mejora notablemente su capacidad para detectar objetos de tamaños muy dispares en la misma imagen. De este modo, el modelo mantiene alta sensibilidad tanto frente a objetos pequeños, como frente a objetos grandes sin sacrificar la velocidad de inferencia.




Figura 5: Arquitectura de YOLOv8. Fuente: [Arquitectura de la red YOLOv8](#)

YOLOv8 ofrece una gran cantidad de variantes ya entrenadas, lo que permite elegir el modelo más adecuado según las necesidades particulares de cada proyecto y de sus requisitos de rendimiento.

Atributo / Modelo	YOLOv8n (Nano)	YOLOv8s (Pequeño)	YOLOv8m (Mediano)	YOLOv8l (Grande)	YOLOv8x (Extra Grande)
Tamaño	Muy Pequeño	Pequeño	Mediano	Grande	Muy Grande
Velocidad	Muy Rápido	Rápido	Moderado	Lento	Muy Lento
Precisión	Menor	Moderada	Alta	Muy Alta	La Más Alta
mAP (COCO)	~30%	~40%	~50%	~60%	~70%
Resolución	320×320	640×640	640×640	640×640	640×640

Figura 6: Comparación entre los diferentes modelos de YOLOv8. Fuente: [YOLOv8: Detección de objetos de última generación en reconocimiento de imágenes \(computer vision\)](#)

3.3 Fruits-360 Dataset

El *dataset* Fruit-360 [32] es un conjunto de datos de imágenes diseñado específicamente para tareas de clasificación de frutas, verduras, frutos secos y semillas. Este *dataset* es muy utilizado en proyectos de visión por computador y aprendizaje automático debido a su calidad, variedad y facilidad de uso [33] [34] [35].

En cuanto a la toma de imágenes del *dataset*, las frutas y verduras fueron montadas en el eje de un motor de baja velocidad que giraba a 3 revoluciones por minuto (rpm). Durante aproximadamente 20 segundos, mientras que se grababa un vídeo de cada objeto en rotación. Para la grabación se utilizó una cámara Logitech C920, usando como fondo de la grabación una hoja de papel blanca detrás de cada fruta o verdura para facilitar la futura segmentación del objeto.

Debido a que las condiciones de iluminación no se mantuvieron constantes, se provocaron variaciones en el color del fondo. Para resolver esto, se desarrolló un algoritmo específico de tipo *flood fill* que permitió extraer el objeto del fondo. Este algoritmo comienza desde los bordes de la imagen y marca los píxeles, extendiéndose a aquellos vecinos cuya diferencia de color esté por debajo de un cierto umbral. Este proceso se repite hasta que no se puedan marcar más píxeles. Todos los píxeles marcados se consideran parte del fondo y se rellenan de blanco, mientras que los no marcados se consideran parte de la fruta o verdura. El valor máximo permitido para la diferencia de color es un parámetro ajustado manualmente para cada grabación mediante prueba y error.

Hay diferentes versiones del *dataset* en las que varían la cantidad de imágenes y clases que hay incluidas. En este proyecto se ha trabajado con la versión 100x100, donde las imágenes tienen una resolución de 100x100 píxeles. Se ha escogido esta versión ya que es la que contiene una mayor cantidad de imágenes, en concreto 136766 imágenes divididas entre 200 clases. Otro de los aspectos para la elección de esta versión es la baja resolución de las imágenes, debido a que, como se ha comentado anteriormente, al tratarse de una tarea sencilla no es necesaria una gran resolución, y al prescindir de esta se pueden agilizar las tareas.

De entre todas las frutas que incluye el *dataset* se ha trabajado con las siguientes:

- Manzanas: el *dataset* incluye 30 clases diferentes de manzanas, con un total de 21444 imágenes entre el conjunto de entrenamiento y el de validación. De estas 30 clases la mayoría no tienen un nombre claro con el que identificar el tipo de

manzana que son, un ejemplo de esto puede ser Apple 5 o Apple 17, hay algunas excepciones como son Apple Pink Lady, Apple Granny Smith, Apple Golden y Apple Braeburn. En una gran cantidad de clases se presentan manzanas con defectos en ellas que pueden ir desde una pequeña zona podrida, hasta manzanas que han sufrido golpes. Para el entrenamiento específico de manzanas se han usado todas las clases de manzanas a excepción de Apple Core 1, Apple hit 1, Apple Rotten 1 y Apple Worm 1. Estas clases no han sido incluidas en el entrenamiento ya que presentan manzanas en condiciones muy concretas y no se ajustan al marco de aplicación con el que se pretende trabajar.

- Peras: en el caso de las peras el *dataset* cuenta con 10 clases diferentes y un total de 7013 imágenes entre el conjunto de entrenamiento y el de validación. Al igual que ocurre con las manzanas, algunas clases de pera no se pueden identificar haciendo uso del nombre de la clase como ocurre con Pear 1 o Pear 2 entre otros. También podemos encontrar la clase Pear 3 que muestra una pera con algunos desperfectos, donde se pueden ver zonas donde la fruta se ha empezado a pudrir, además de otras donde parece que haya recibido algún tipo de impacto. Para el entrenamiento en solitario de peras se han usado todas las clases disponibles.
- Uvas: para las uvas el *dataset* incluye 6 clases diferentes, con un total de 4565 imágenes entre el conjunto de entrenamiento y el de validación. Las uvas están divididas en clases en función del color de la uva que puede variar entre uva blanca, uva azul o uva rosa. A diferencia de las manzanas, no se incluyen clases con uvas que tengan defectos, y para el entrenamiento concreto de uvas se ha trabajado con todas las clases disponibles.
- Cerezas: hay 7 clases diferentes de cerezas en el *dataset*, constituyendo un total de 5492 imágenes entre todas sus clases y entre imágenes para entrenamiento y validación. Al igual que ocurre con frutas anteriores, las cerezas no tienen nombres que indiquen el tipo de especie que es a excepción de la clase Cherry Rainier. También, como ocurre con las manzanas y peras, encontramos una clase que contiene imágenes con desperfectos, este es el caso de la clase Cherry 1. Para el entrenamiento en solitario de cerezas se han usado todas las clases disponibles.
- Conjunto: Por último, encontramos las frutas que se han empleado en el entrenamiento conjunto, algunas de estas ya han sido mencionadas como algunas clases de manzanas, peras, uvas y cerezas, pero además de estas frutas al

entrenamiento se han añadido otras: plátanos, limones, melones, naranjas, melocotones, piñas, fresas y sandías, haciendo un total de 22 clases diferentes con un total de 15430 imágenes entre el conjunto de entrenamiento y el de validación. Un ejemplo de las frutas empleadas se presenta en la Figura 7.



Figura 7: Imágenes de las frutas empleadas del dataset Fruits-360. Fuente: [Fruits-360 dataset](#)

4.EXPERMIENTOS Y RESULTADOS

En este apartado se van a explicar y detallar tanto la metodología empleada para llevar a cabo las pruebas como los resultados de estas.

4.1 Clasificación

Para esta tarea, se pretende generar diferentes modelos capaces de identificar el tipo de fruta que se le presenta, eligiendo entre las clases que se han empleado en su entrenamiento. Estos entrenamientos se han realizado usando la versión YOLOv8n-cls, como se ha comentado previamente en el apartado 3.1.2 Ultralytics, siendo el modelo nano el más pequeño del que dispone YOLOv8. Se ha seleccionado este modelo porque el uso de versiones de mayor tamaño incrementaba los tiempos de entrenamiento hasta hacerlos inviables.

Se han realizado 5 entrenamientos diferentes para esta red, de 10 épocas cada uno. Cuatro de estos entrenamientos se han realizado con frutas de un solo tipo y un último donde aparecen clases de diferentes frutas. A continuación, se muestran las Tablas 1-5 donde se recogen los detalles de las clases de cada entrenamiento:

Manzanas		
Clases	Imágenes de entrenamiento	Imágenes de validación
Apple 5	436	146
Apple 6	469	157
Apple 7	690	229
Apple 8	683	228
Apple 9	690	231
Apple 10	695	231
Apple 11	426	142
Apple 12	462	154
Apple 13	695	235
Apple 14	462	154
Apple 17	606	201
Apple 18	480	160
Apple 19	725	241
Apple Braeburn 1	488	164
Apple Crimson Snow 1	440	148
Apple Golden 1	476	160
Apple Golden 2	488	164
Apple Golden 3	477	161
Apple Granny Smith 1	488	164
Apple Pink Lady 1	452	152

Apple Red 1	488	164
Apple Red 2	488	164
Apple Red 3	425	144
Apple Red Delicious 1	486	166
Apple Red Yellow 1	488	164
Apple Red Yellow 2	668	219
Total	13871	4643
Para este entrenamiento se han usado un total de 26 clases diferentes, donde cada clase cuenta con 4 imágenes para la tarea de predicción.		

Tabla 1: Detalles del entrenamiento de clasificación de las manzanas.

Peras		
Clases	Imágenes de entrenamiento	Imágenes de validación
Pear 1	487	164
Pear 2	691	232
Pear 3	210	72
Pear Abate 1	485	166
Pear Forelle 1	697	234
Pear Kaiser 1	295	102
Pear Monster 1	485	166
Pear Red 1	661	222
Pear Stone 1	706	237
Pear Williams 1	485	166
Total	5202	1761
Para este entrenamiento se han usado un total de 10 clases diferentes, donde cada clase cuenta con 5 imágenes para la tarea de predicción.		

Tabla 2: Detalles del entrenamiento de clasificación de las peras.

Uvas		
Clases	Imágenes de entrenamiento	Imágenes de validación
Grape Blue 1	979	328
Grape Pink 1	487	164
Grape White 1	485	166
Grape White 2	485	166
Grape White 3	487	164
Grape White 4	466	158
Total	3389	1146
Para este entrenamiento se han usado un total de 6 clases diferentes, donde cada clase cuenta con 5 imágenes para la tarea de predicción.		

Tabla 3: Detalles del entrenamiento de clasificación de las uvas.

Cerezas		
Clases	Imágenes de entrenamiento	Imágenes de validación
Cherry 1	487	164
Cherry 2	733	246
Cherry Rainier 1	733	246
Cherry Wax Black 1	487	164
Cherry Wax not rippen 1	670	225
Cherry Wax Red 1	487	164

Cherry Wax Yellow 1	487	164
Total	4084	1373
Para este entrenamiento se han usado un total de 7 clases diferentes, donde cada clase cuenta con 5 imágenes para la tarea de predicción.		

Tabla 4: Detalles del entrenamiento de clasificación de las cerezas.

Conjunto		
Clases	Imágenes de entrenamiento	Imágenes de validación
Apple 5	436	146
Apple Granny Smith 1	488	164
Apple Red 2	488	164
Banana 1	486	166
Banana 3	229	77
Banana Lady Finger 1	446	152
Cherry 1	488	164
Cherry 2	734	246
Grape White 1	486	166
Grape White 2	486	166
Grape White 4	467	158
Lemon 1	488	164
Melon Piel de Sapo 1	734	246
Orange 1	475	160
Peach 1	488	164
Pear 1	488	164
Pear 2	692	232
Pear Forelle 1	698	234
Pineapple 1	486	166
Strawberry 1	488	164
Strawberry Wedge 1	734	246
Watermelon 1	471	157
Total	11476	3866
Para este entrenamiento se han usado un total de 22 clases diferentes, donde cada clase cuenta con 4 imágenes para la tarea de predicción.		

Tabla 5: Detalles del entrenamiento de clasificación de las frutas conjuntas.

Como se aprecia en las tablas anteriores, el conjunto de datos se encuentra dividido en dos partes: imágenes de entrenamiento e imágenes de validación. Esta separación es indispensable, ya que el proceso de entrenamiento de un modelo, independientemente de la tarea, requiere de estas dos etapas. En primer lugar, el modelo utiliza las imágenes de entrenamiento para ajustar sus pesos: en cada iteración se realizan predicciones sobre estas imágenes, comparando los resultados con las anotaciones reales y modificando los pesos para mejorar su rendimiento. A continuación, se lleva a cabo la etapa de validación, en la que el modelo, sin modificar sus pesos, realiza predicciones sobre el conjunto de validación. Esto permite evaluar su capacidad de generalización mediante métricas como la precisión, entre otras.

Al finalizar un entrenamiento, la red genera automáticamente un archivo donde indica las características del entrenamiento. Los parámetros que aparecen en este archivo son:

- Epoch: indica la iteración en la que se encuentra el entrenamiento.
- Time: es el tiempo acumulado hasta esa época.
- Train/loss: refleja la pérdida que hay durante el entrenamiento en esa época. Una pérdida menor indica que el modelo se está ajustando a los datos.
- Metrics/accuracy_top1: es el porcentaje de veces que la clase predicha por el modelo coincide exactamente con la clase real.
- Metrics/accuracy_top5: es similar al parámetro anterior solo que este refleja el porcentaje de veces que la clase real está entre las 5 clases con mayor probabilidad predichas por el modelo.
- Val/loss: es la pérdida sobre el conjunto de validación. Es crucial para detectar sobreajuste, una muestra de este suceso ocurre cuando esta métrica empieza a aumentar mientras la de Train/loss disminuye.
- Lr/pg0, Lr/pg1, Lr/pg2: representan la tasa de aprendizaje para los tres grupos de parámetros definidos por YOLOv8. Corresponden a las diferentes partes del modelo: columna vertebral, cuello y cabeza.

A continuación, en las Tablas 6-10, se presentan los resultados de los diferentes entrenamientos:

epoch	time	train/loss	metrics/accuracy_top1	metrics/accuracy_top5	val/loss	lr/pg0	lr/pg1	lr/pg2
1	139.16	2.20504	0.92677	0.99978	0.37426	0.000110872	0.000110872	0.000110872
2	275.181	0.41597	0.97868	1	0.07807	0.000199907	0.000199907	0.000199907
3	410.536	0.16224	0.99375	1	0.02398	0.000266963	0.000266963	0.000266963
4	549.796	0.10351	0.99612	1	0.01469	0.000234099	0.000234099	0.000234099
5	689.059	0.07352	0.9972	1	0.0117	0.000201132	0.000201132	0.000201132
6	823.095	0.06094	0.99698	1	0.01354	0.000168165	0.000168165	0.000168165
7	958.176	0.04731	0.99914	1	0.00769	0.000135198	0.000135198	0.000135198
8	1098.08	0.04132	0.99935	1	0.00643	0.000102231	0.000102231	0.000102231
9	1233.79	0.03882	0.99914	1	0.00533	6.9264e-05	6.9264e-05	6.9264e-05
10	1368.68	0.03238	0.99914	1	0.0058	3.6297e-05	3.6297e-05	3.6297e-05

Tabla 6: Resultados del entrenamiento de clasificación de las manzanas.

epoch	time	train/loss	metrics/accuracy_top1	metrics/accuracy_top5	val/loss	lr/pg0	lr/pg1	lr/pg2
1	45.4983	1.1612	0.97558	1	0.09221	0.00023727	0.00023727	0.00023727
2	91.4592	0.12173	0.99659	1	0.02976	0.000428218	0.000428218	0.000428218
3	136.598	0.05911	0.98467	1	0.04106	0.000572042	0.000572042	0.000572042
4	181.564	0.04601	0.99943	1	0.00637	0.000501942	0.000501942	0.000501942
5	226.662	0.03084	1	1	0.00627	0.000431256	0.000431256	0.000431256
6	271.577	0.03368	1	1	0.00075	0.00036057	0.00036057	0.00036057
7	315.188	0.01736	1	1	0.00063	0.000289884	0.000289884	0.000289884
8	359.59	0.01544	1	1	0.00078	0.000219198	0.000219198	0.000219198
9	405.689	0.01057	1	1	0.00101	0.000148512	0.000148512	0.000148512
10	451.842	0.01418	1	1	0.00067	7.7826e-05	7.7826e-05	7.7826e-05

Tabla 7: Resultados del entrenamiento de clasificación de las peras.

epoch	time	train/loss	metrics/accuracy_top1	metrics/accuracy_top5	val/loss	lr/pg0	lr/pg1	lr/pg2
1	30.2574	0.84185	1	1	0.01129	0.000331761	0.000331761	0.000331761
2	60.2212	0.08393	1	1	0.0032	0.00059925	0.00059925	0.00059925
3	89.2359	0.05598	1	1	0.00302	0.000800739	0.000800739	0.000800739
4	117.723	0.05481	1	1	0.00046	0.000703	0.000703	0.000703
5	145.838	0.01873	1	1	0.00021	0.000604	0.000604	0.000604
6	174.432	0.0153	1	1	0.00022	0.000505	0.000505	0.000505
7	202.615	0.01654	1	1	0.00023	0.000406	0.000406	0.000406
8	231.64	0.01114	1	1	0.0002	0.000307	0.000307	0.000307
9	260.141	0.00772	1	1	0.00018	0.000208	0.000208	0.000208
10	288.778	0.00565	1	1	0.00012	0.000109	0.000109	0.000109

Tabla 8: Resultados del entrenamiento de clasificación de las uvas.

epoch	time	train/loss	metrics/accuracy_top1	metrics/accuracy_top5	val/loss	lr/pg0	lr/pg1	lr/pg2
1	36.6611	0.87865	0.98325	1	0.07675	0.000301816	0.000301816	0.000301816
2	71.5498	0.10388	1	1	0.0059	0.00054494	0.00054494	0.00054494
3	106.473	0.05293	1	1	0.00283	0.000728069	0.000728069	0.000728069
4	140.828	0.04172	1	1	0.0022	0.000639027	0.000639027	0.000639027
5	176.176	0.02925	1	1	0.00145	0.000549036	0.000549036	0.000549036
6	210.27	0.01756	1	1	0.00107	0.000459045	0.000459045	0.000459045
7	245.376	0.01561	1	1	0.00058	0.000369054	0.000369054	0.000369054
8	279.494	0.01547	1	1	0.00046	0.000279063	0.000279063	0.000279063
9	314.308	0.01583	1	1	0.00149	0.000189072	0.000189072	0.000189072
10	348.418	0.00705	1	1	0.00043	9.9081e-05	9.9081e-05	9.9081e-05

Tabla 9: Resultados del entrenamiento de clasificación de las cerezas.

epoch	time	train/loss	metrics/accuracy_top1	metrics/accuracy_top5	val/loss	lr/pg0	lr/pg1	lr/pg2
1	101.209	1.62316	0.9731	1	0.15097	0.000128155	0.000128155	0.000128155
2	201.03	0.18567	0.99379	1	0.02448	0.000231096	0.000231096	0.000231096
3	299.117	0.06963	0.99017	1	0.03687	0.000308627	0.000308627	0.000308627
4	397.423	0.04777	0.99379	1	0.02207	0.000270655	0.000270655	0.000270655
5	494.879	0.03142	0.99897	1	0.0049	0.00023254	0.00023254	0.00023254
6	591.872	0.02495	1	1	0.00189	0.000194425	0.000194425	0.000194425
7	689.182	0.02084	0.99845	1	0.00558	0.00015631	0.00015631	0.00015631
8	785.93	0.01838	0.99767	1	0.00463	0.000118195	0.000118195	0.000118195
9	883.099	0.01409	1	1	0.002	8.008e-05	8.008e-05	8.008e-05
10	979.904	0.01328	1	1	0.00139	4.1965e-05	4.1965e-05	4.1965e-05

Tabla 10: Resultados del entrenamiento de clasificación de las frutas conjuntas.

Como resultado de los entrenamientos mostrados en las Tablas 6-10, se ha obtenido un modelo de la red YOLOv8 que es capaz de clasificar manzanas, otro modelo peras, otro cerezas, otro uvas y por último uno capaz de clasificar entre diferentes tipos de frutas.

En todos estos entrenamientos se ha alcanzado una precisión que converge a 1, también se aprecia en todos ellos como el train/loss disminuye a la par del val/loss exceptuando las últimas épocas de algunos modelos, lo que indica sobreajuste. Por ello, para realizar las predicciones, se ha utilizado la versión best.pt de cada modelo. Esta versión se corresponde con los pesos de la época cuyo valor de precisión es el más elevado.

Al comparar la precisión en los diferentes entrenamientos se aprecia como en entrenamientos con menor cantidad de clases y con frutas con formas y colores sencillos la red alcanza el valor de precisión 1 desde la primera época o casi desde esta, como es el caso de las uvas y las cerezas. En cambio, en entrenamientos con una mayor cantidad de clases, como ocurre con las peras y el conjunto variado de frutas, este valor de precisión

tarda más en ser alcanzado, no llegando hasta él hasta la época 5 y la época 6 respectivamente. Por último, encontramos el entrenamiento de las manzanas, donde al tener una gran cantidad de clases y ser muy similares entre sí, la red no consigue alcanzar el valor de precisión 1 como en el resto de los entrenamientos, y alcanza su mejor valor en la época 8.

Para comprobar el correcto funcionamiento y las capacidades de la red se ha usado cada modelo entrenado para realizar predicciones sobre un grupo de imágenes. Estas imágenes han sido extraídas del conjunto de imágenes de entrenamiento antes de que se lleve a cabo el propio entrenamiento, para poder ser usadas como muestra de la capacidad de inferencia de los diferentes modelos. En los entrenamientos con una gran cantidad de clases se han extraído 4 imágenes por clase y en los que contienen una menor cantidad de clases se han extraído 5.

Todas las predicciones realizadas con los diferentes modelos han sido acertadas y con un grado de precisión cercano a 1, esto queda representado en la confianza, que es un parámetro numérico que representa la certeza del modelo sobre su predicción a la hora de asignarle una clase a la imagen. Todo lo anterior queda reflejado en la Tabla 11, que es un resumen de los resultados del proceso de predicción. Estos resultados completos se encuentran en el Anexo 1.

Manzanas		
Imagen	Clase	Confianza
Apple10 1.jpg	Apple 10	0.9999847412109375
Apple11 1.jpg	Apple 11	0.9999676942825317
Apple12 1.jpg	Apple 12	0.9999911785125732
El modelo de manzanas se ha evaluado con un total de 104 imágenes y no ha cometido ningún error.		
Peras		
Pear1 1.jpg	Pear 1	0.9999854564666748
Pear2 1.jpg	Pear 2	0.9999982118606567
Pear3 1.jpg	Pear 3	0.9999996423721313
El modelo de peras se ha evaluado con un total de 50 imágenes y no ha cometido ningún error.		
Uvas		
GrapeBlue 1.jpg	Grape Blue 1	0.9999995231628418
GrapePink 1.jpg	Grape Pink 1	0.9980897307395935
GrapeWhite1 1.jpg	Grape White 1	0.9999608993530273
El modelo de uvas se ha evaluado con un total de 30 imágenes y no ha cometido ningún error.		

Cerezas		
Cherry1_1.jpg	Cherry 1	0.9999890327453613
Cherry2_1.jpg	Cherry 2	0.9997666478157043
CherryRainier_1.jpg	Cherry Rainier 1	0.9999639987945557
El modelo de cerezas se ha evaluado con un total de 35 imágenes y no ha cometido ningún error.		
Conjunto		
Apple5_1.jpg	Apple 5	0.9999573230743408
Banana1_1.jpg	Banana 1	0.9999996423721313
Lemon1_1.jpg	Lemon 1	0.9999973773956299
El modelo de frutas conjuntas se ha evaluado con un total de 88 imágenes y no ha cometido ningún error.		

Tabla 11: Resumen de los resultados del proceso de predicción.

Con el objetivo de evaluar la capacidad de generalización de los diferentes modelos más allá del conjunto de datos Fruits-360, es decir, su habilidad para realizar predicciones correctas sobre imágenes nuevas, no vistas durante el entrenamiento y con mayor variabilidad, se han utilizado imágenes externas al *dataset* original, como se muestra en la Figura 8. La cantidad de imágenes seleccionadas para esta prueba ha sido proporcional al doble del número de clases del modelo utilizado para la predicción.



Figura 8: Imágenes externas al dataset.

A continuación, se presenta un breve resumen de los resultados de las predicciones realizadas, los resultados completos de estas predicciones se encuentran en el Anexo 2.

Manzanas			
Imagen	Clase	Confianza	Aciertos/Fallos
Manzana_1.png	Apple Red 1	0.4609639048576355	Acierto
Manzana_2.png	Apple 10	0.9268770217895508	Fallo
Manzana_3.png	Apple 18	0.3609108626842499	Fallo

El modelo de manzanas se ha evaluado con un total de 52 imágenes y ha cometido un total de 16 fallos, obteniendo un porcentaje de acierto del 69%			
Peras			
Pera_1.jpg	Pear 2	0.8508897423744202	Acierto
Pera_2.jpg	Pear 2	0.9896777868270874	Acierto
Pera_3.jpg	Pear 2	0.9975847005844116	Acierto
El modelo de peras se ha evaluado con un total de 20 imágenes y ha cometido un total de 6 fallos, obteniendo un porcentaje de acierto del 70%			
Uvas			
Uva_1.png	Grape White 4	0.9771832227706909	Acierto
Uva_2.png	Grape White 4	0.8769601583480835	Acierto
Uva_3.jpg	Grape White 2	0.7182070016860962	Fallo
El modelo de uvas se ha evaluado con un total de 12 imágenes y ha cometido un total de 2 fallos, obteniendo un porcentaje de acierto del 83%			
Cerezas			
Cereza_1.jpg	Cherry 2	0.5726609826087952	Acierto
Cereza_2.jpg	Cherry 1	0.9806481003761292	Acierto
Cereza_3.jpg	Cherry 1	0.9999022483825684	Acierto
El modelo de cerezas se ha evaluado con un total de 14 imágenes y ha cometido un total de 4 fallos, obteniendo un porcentaje de acierto del 71%			
Conjunto			
Fresa_1.jpg	Strawberry Wedge 1	0.9578763842582703	Acierto
Limon_1.jpg	Lemon 1	0.745867908000946	Acierto
Melocoton_1.jpg	Banana Lady Finger 1	0.8646714091300964	Fallo
El modelo de frutas conjuntas se ha evaluado con un total de 44 imágenes y ha cometido un total de 18 fallos, obteniendo un porcentaje de acierto del 60%			

Tabla 12: Resumen de los resultados del proceso de predicción con imágenes externas al dataset.

A diferencia de las predicciones realizadas con imágenes dentro del *dataset*, estas sufren una mayor cantidad de fallos. En general, los porcentajes de acierto se encuentran entre el 60 % y el 83 %, siendo el modelo de las uvas el que mejores resultados ha dado, y el modelo conjunto el que peores.

El aumento de errores frente a las predicciones realizadas con imágenes extraídas del *dataset* se debe a que el *dataset* Fruits-360 incluye en algunas clases imágenes atípicas, y las imágenes que se han usado para estas predicciones no se asemejan en muchos casos a otras con las que haya trabajado la red. Esto se acentúa en entrenamientos con gran cantidad de clases, ya que, al no tener referencias de imágenes parecidas, es más sencillo que la red cometa errores, debido a que tiene más posibilidades de que haya algún elemento dentro de una clase que se pueda asemejar ligeramente a la imagen y provocar un error por parte de la red.

4.1.1 Estudio de cambio de iluminación en la etapa de clasificación

Para probar la capacidad de la red frente a cambios de iluminación se han modificado las imágenes con las que se han realizado las predicciones inicialmente, aplicando cambios en el brillo, como se muestra en la Figura 9. Estos cambios se realizan aplicando un factor de brillo, que es un valor entre -0.8 y 0.8 generado de manera aleatoria no pudiendo estar en el rango de -0.1 a 0.1, para evitar así cambios demasiado pequeños, una vez se obtiene este factor de brillo se multiplica por 255, que es el rango máximo de las imágenes jpg, y el resultado se suma a todos los píxeles de la imagen. En el Anexo 5 se encuentra el código empleado para la modificación de las imágenes.




Figura 9: imágenes del conjunto de predicción sometidas a cambios de iluminación.

A continuación, se presenta un breve resumen de los resultados de las predicciones realizadas con las imágenes modificadas, los resultados completos de estas predicciones se encuentran en el Anexo 3.

Manzanas				
Imagen	Clase	Confianza	Factor Brillo	Aciertos/Fallos
Apple10_1_mod.jpg	Apple 17	0.57604765892028	-0.4116	Fallo
Apple11_1_mod.jpg	Apple Granny Smith 1	0.45086467266082	-0.7475	Fallo
Apple12_1_mod.jpg	Apple 12	0.94955283403396	-0.3901	Acierto
El modelo de manzanas se ha evaluado con un total de 104 imágenes y ha cometido un total de 35 fallos, obteniendo un porcentaje de acierto del 66%				
Peras				
Pear1_1_mod.jpg	Pear 1	0.99784648418426	-0.3512	Acierto
Pear2_1_mod.jpg	Pear 2	0.99973124265670	0.6063	Acierto

Pear3_1_mod.jpg	Pear Kaiser 1	0.53774392604827	-0.606	Fallo
El modelo de peras se ha evaluado con 50 imágenes y ha cometido un total de 12 fallos, obteniendo un porcentaje de acierto del 76%				
Uvas				
GrapeBlue_1_mod.jpg	Grape Blue 1	0.9922931194305	0.4613	Acierto
GrapePink_1_mod.jpg	Grape Pink 1	0.9889420270919	0.1478	Acierto
GrapeWhite1_1_mod.jpg	Grape White 1	0.99990355968475	0.1967	Acierto
El modelo de uvas se ha evaluado con un total de 30 imágenes y ha cometido un total de 7 fallos, obteniendo un porcentaje de acierto del 76%				
Cerezas				
Cherry1_1_mod.jpg	Cherry 1	0.99954897165298	0.1305	Acierto
Cherry2_1_mod.jpg	Cherry 1	0.82271438837051	-0.4888	Fallo
CherryRainier_1_mod.jpg	Cherry Rainier 1	0.99109745025634	0.477	Acierto
El modelo de cerezas se ha evaluado con un total de 35 imágenes y ha cometido un total de 12 fallos, obteniendo un porcentaje de acierto del 65%				
Conjunto				
Apple5_1_mod.jpg	Apple 5	0.83580750226974	0.4419	Acierto
Banana1_1_mod.jpg	Banana 1	0.94191855192184	0.6175	Acierto
Lemon1_1_mod.jpg	Lemon 1	0.99998307228088	-0.4154	Acierto
El modelo de frutas conjuntas se ha evaluado con un total de 88 imágenes y ha cometido un total de 29 fallos, obteniendo un porcentaje de acierto del 67%				

Tabla 13: Resumen de los resultados del proceso de predicción con imágenes modificadas con cambios de iluminación.

La red comete una gran cantidad de errores, alrededor del 30% en todos los modelos. Esto se debe a que en los conjuntos de entrenamiento con los que se han entrenado los diferentes modelos no contienen imágenes con diferentes iluminaciones, provocando que la red no sepa identificar las clases correctamente o lo haga con una menor confianza. Para solventar este problema, se ha empleado Roboflow con el fin de introducir los conjuntos con los que se han entrenado los diferentes modelos y modificarlos para obtener una versión de cada imagen cuya iluminación haya sido modificada, de esta manera estos nuevos modelos incluyen las imágenes originales más las que tienen cambios de iluminación.

A continuación, en las Tablas 14-18, se presentan los resultados de los diferentes entrenamientos con cambios de iluminación:

epoch	time	train/loss	metrics/accuracy_top1	metrics/accuracy_top5	val/loss	lr/pg0	lr/pg1	lr/pg2
1	250.271	2.07256	0.87928	0.99074	0.43172	0.000110936	0.000110936	0.000110936
2	494.806	0.58326	0.94131	0.99666	0.17776	0.000199964	0.000199964	0.000199964
3	735.307	0.35335	0.96005	0.99698	0.12008	0.000267015	0.000267015	0.000267015
4	975.982	0.27188	0.96737	0.99795	0.09344	0.000234099	0.000234099	0.000234099
5	1222.57	0.22161	0.97879	0.99914	0.0679	0.000201132	0.000201132	0.000201132
6	1479.08	0.19826	0.98223	0.99978	0.05621	0.000168165	0.000168165	0.000168165
7	1734.83	0.17664	0.98471	0.99968	0.05077	0.000135198	0.000135198	0.000135198
8	1976.68	0.16015	0.986	0.99935	0.04463	0.000102231	0.000102231	0.000102231
9	2237.33	0.15304	0.98363	0.99968	0.04732	6.9264e-05	6.9264e-05	6.9264e-05
10	2482.51	0.14515	0.98557	0.99968	0.04419	3.6297e-05	3.6297e-05	3.6297e-05

Tabla 14: Resultados del entrenamiento de clasificación de las manzanas con cambios de iluminación.

epoch	time	train/loss	metrics/accuracy_top1	metrics/accuracy_top5	val/loss	lr/pg0	lr/pg1	lr/pg2
1	90.4981	1.06524	0.94009	0.99801	0.21747	0.000237634	0.000237634	0.000237634
2	179.618	0.20902	0.97076	1	0.08084	0.000428547	0.000428547	0.000428547
3	267.583	0.14579	0.99205	1	0.03626	0.000572335	0.000572335	0.000572335
4	354.885	0.1126	0.97388	0.99943	0.07252	0.000501942	0.000501942	0.000501942
5	442.13	0.08724	0.97445	1	0.08169	0.000431256	0.000431256	0.000431256
6	529.333	0.06709	0.98978	1	0.03533	0.00036057	0.00036057	0.00036057
7	616.445	0.05504	0.99602	1	0.01167	0.000289884	0.000289884	0.000289884
8	704.007	0.05004	0.99404	1	0.02428	0.000219198	0.000219198	0.000219198
9	792.243	0.04072	0.99262	1	0.02893	0.000148512	0.000148512	0.000148512
10	879.123	0.0419	0.99347	1	0.02921	7.7826e-05	7.7826e-05	7.7826e-05

Tabla 15: Resultados del entrenamiento de clasificación de las peras con cambios de iluminación.

epoch	time	train/loss	metrics/accuracy_top1	metrics/accuracy_top5	val/loss	lr/pg0	lr/pg1	lr/pg2
1	62.115	0.79413	0.96248	1	0.13121	0.000332547	0.000332547	0.000332547
2	120.477	0.20958	0.97077	1	0.0667	0.000599958	0.000599958	0.000599958
3	179.259	0.16309	0.97208	1	0.0675	0.000801369	0.000801369	0.000801369
4	237.92	0.12905	0.96815	1	0.08365	0.000703	0.000703	0.000703
5	296.356	0.11184	0.98429	1	0.05312	0.000604	0.000604	0.000604
6	355.63	0.09657	0.97775	1	0.04489	0.000505	0.000505	0.000505
7	414.856	0.08316	0.98604	1	0.03767	0.000406	0.000406	0.000406
8	472.948	0.07468	0.98211	1	0.04779	0.000307	0.000307	0.000307
9	531.708	0.07356	0.99084	1	0.02892	0.000208	0.000208	0.000208
10	590.451	0.06634	0.98342	1	0.03153	0.000109	0.000109	0.000109

Tabla 16: Resultados del entrenamiento de clasificación de las uvas con cambios de iluminación.

epoch	time	train/loss	metrics/accuracy_top1	metrics/accuracy_top5	val/loss	lr/pg0	lr/pg1	lr/pg2
1	75.3292	0.83686	0.96103	0.99964	0.1186	0.000302407	0.000302407	0.000302407
2	147.933	0.18025	0.98653	0.99927	0.03828	0.000545472	0.000545472	0.000545472
3	220.03	0.14109	0.98798	1	0.03398	0.000728542	0.000728542	0.000728542
4	294.155	0.11074	0.99417	1	0.01908	0.000639027	0.000639027	0.000639027
5	365.432	0.08019	0.9949	1	0.01591	0.000549036	0.000549036	0.000549036
6	436.367	0.06044	0.99527	1	0.01249	0.000459045	0.000459045	0.000459045
7	507.463	0.05353	0.99417	1	0.01152	0.000369054	0.000369054	0.000369054
8	579.193	0.04135	0.99745	1	0.00598	0.000279063	0.000279063	0.000279063
9	650.299	0.03434	0.99636	1	0.00743	0.000189072	0.000189072	0.000189072
10	720.701	0.03823	0.99854	1	0.00473	9.9081e-05	9.9081e-05	9.9081e-05

Tabla 17: Resultados del entrenamiento de clasificación de las cerezas con cambios de iluminación.

epoch	time	train/loss	metrics/accuracy_top1	metrics/accuracy_top5	val/loss	lr/pg0	lr/pg1	lr/pg2
1	202.01	1.47703	0.95939	0.9978	0.18142	0.000128244	0.000128244	0.000128244
2	398.412	0.27035	0.97193	0.99897	0.08907	0.000231176	0.000231176	0.000231176
3	593.931	0.16629	0.98215	0.99897	0.06345	0.000308698	0.000308698	0.000308698
4	787.797	0.12298	0.98267	0.99948	0.05108	0.000270655	0.000270655	0.000270655
5	981.526	0.10326	0.98668	0.99987	0.03596	0.00023254	0.00023254	0.00023254
6	1177.49	0.08246	0.99133	1	0.02459	0.000194425	0.000194425	0.000194425
7	1370.32	0.07126	0.98901	0.99987	0.0349	0.00015631	0.00015631	0.00015631
8	1567.39	0.06851	0.99263	0.99987	0.02338	0.000118195	0.000118195	0.000118195
9	1762.96	0.05905	0.99185	0.99961	0.02288	8.008e-05	8.008e-05	8.008e-05
10	1957.92	0.04982	0.99211	0.99987	0.02208	4.1965e-05	4.1965e-05	4.1965e-05

Tabla 18: Resultados del entrenamiento de clasificación de las frutas conjuntas con cambios de iluminación.

A diferencia de lo ocurrido con los modelos sin cambios de iluminación, estos modelos no llegan a alcanzar un valor de 1 en la precisión. Esto se debe a que estos nuevos modelos contienen el doble de imágenes con respecto a los originales, además de que al contar con cambios de iluminación variantes la red tiene mayor dificultad a la hora de aprender. No obstante, los resultados siguen siendo bastantes cercanos a 1 y los modelos al incluir cambios de iluminación deben ser más robustos que sus versiones originales.

Para comprobar esto se han realizado predicciones para cada modelo entrenado con cambios de iluminación con las mismas imágenes que se usaron con los modelos originales, tanto las que no contienen cambios de iluminación como las que si.

A continuación, se presenta un breve resumen de los resultados de las predicciones, los resultados completos de estas predicciones se encuentran en el Anexo 4.

Manzanas				
Imagen	Clase	Confianza	Factor Brillo	Aciertos/Fallos
Apple10_1.jpg	Apple 10	0.9999475	0.0	Acierto
Apple10_1_mod.jpg	Apple 10	0.9758608	-0.4116	Acierto
Apple11_1.jpg	Apple 11	0.9995833	0.0	Acierto
Apple11_1_mod.jpg	Apple 11	0.8288116	-0.7475	Acierto
Apple12_1.jpg	Apple 12	0.9999607	0.0	Acierto
Apple12_1_mod.jpg	Apple 12	0.9999978	-0.3901	Acierto
El modelo de manzanas se ha evaluado con un total de 208 imágenes y ha cometido un total de 3 fallos, obteniendo un porcentaje de acierto del 98%				
Peras				
Pear1_1.jpg	Pear 1	0.9997152	0.0	Acierto
Pear1_1_mod.jpg	Pear 1	0.9995587	-0.3512	Acierto
Pear2_1.jpg	Pear 2	0.9999812	0.0	Acierto
Pear2_1_mod.jpg	Pear 2	0.9998813	0.6063	Acierto
Pear3_1.jpg	Pear 3	1.0	0.0	Acierto
Pear3_1_mod.jpg	Pear 3	0.9646279	-0.606	Acierto
El modelo de peras se ha evaluado con un total de 100 imágenes y no ha cometido ningún fallo, obteniendo un porcentaje de acierto del 100%				
Uvas				
GrapeBlue_1.jpg	Grape Blue 1	0.9999974	0.0	Acierto
GrapeBlue_1_mod.jpg	Grape Blue 1	0.9999996	0.4613	Acierto
GrapePink_1.jpg	Grape Pink 1	0.9995160	0.0	Acierto
GrapePink_1_mod.jpg	Grape Pink 1	0.9994463	0.1478	Acierto
GrapeWhite1_1.jpg	Grape White 1	0.9999933	0.0	Acierto
GrapeWhite1_1_mod.jpg	Grape White 1	0.9999767	0.1967	Acierto
El modelo de uvas se ha evaluado con un total de 60 imágenes y no ha cometido ningún fallo, obteniendo un porcentaje de acierto del 100%				

Cerezas				
Cherry1_1.jpg	Cherry 1	0.9999998	0.0	Acierto
Cherry1_1_mod.jpg	Cherry 1	0.9999998	0.1305	Acierto
Cherry2_1.jpg	Cherry 2	0.9988086	0.0	Acierto
Cherry2_1_mod.jpg	Cherry 2	0.9443233	-0.4888	Acierto
CherryWaxRed_1.jpg	Cherry Wax Red 1	0.9999984	0.0	Acierto
CherryWaxRed_1_mod.jpg	Cherry Wax Red 1	0.9992694	-0.4371	Acierto
El modelo de cerezas se ha evaluado con un total de 70 imágenes y no ha cometido ningún fallo, obteniendo un porcentaje de acierto del 100%				
Conjunto				
Lemon1_1.jpg	Lemon 1	0.9999756	0.0	Acierto
Lemon1_1_mod.jpg	Lemon 1	0.9999039	-0.4154	Acierto
AppleRed2_1.jpg	Apple Red 2	0.9999653	0.0	Acierto
AppleRed2_1_mod.jpg	Apple Red 2	0.9972547	0.7639	Acierto
Banana1_1.jpg	Banana 1	0.9999998	0.0	Acierto
Banana1_1_mod.jpg	Banana 1	0.9991365	0.6175	Acierto
El modelo de frutas conjunto se ha evaluado con un total de 176 imágenes y ha cometido un total de 5 fallos, obteniendo un porcentaje de acierto del 97%				

Tabla 19: Resumen de los resultados del proceso de predicción empleando los diferentes modelos entrenados con cambios de iluminación.

En los resultados de estas predicciones se aprecia como, pese a incluir imágenes con cambios de iluminación en el entrenamiento de los modelos, los resultados de las predicciones de las imágenes sin cambios de iluminación se mantienen con una tasa de acierto del 100%. También queda reflejado cómo incluir imágenes con cambios de iluminación durante el entrenamiento ha provocado que la tasa de acierto para las imágenes con cambios de iluminación haya incrementado significativamente, llegando en los entrenamientos con menor cantidad de clases al 100% y en los que no, obteniendo un resultado cercano a este valor. De esta manera, estos nuevos modelos se han vuelto una versión más versátil que sus versiones iniciales, donde los cambios de iluminación dejan de ser un impedimento para la correcta clasificación de las imágenes.

4.2 Detección

En la etapa anterior se han generado diferentes modelos empleando conjuntos que contuviesen un solo tipo de fruta y uno que contuviese diferentes tipos. También se han realizado pruebas para comprobar cómo afectan al rendimiento de los modelos las condiciones lumínicas variables. En cambio, para la tarea de detección, únicamente se pretende desarrollar un modelo entrenado con diferentes tipos de fruta que, además de ser capaz de identificar el tipo de fruta que es, al igual que ocurría en clasificación, debe generar una *bounding box* alrededor de esta. Además, se pretende probar su rendimiento

con imágenes tanto extraídas previamente del *dataset* como externas a este, sin entrar en cómo afectan los cambios de iluminación al rendimiento del modelo de detección.

Para el entrenamiento de detección se ha utilizado el mismo modelo de YOLO que para los entrenamientos de clasificación, solo que la versión preparada para esta tarea. Otra diferencia con respecto a los entrenamientos de clasificación, como se ha comentado previamente, es que en detección tan solo se va a entrenar un modelo, el cual se va a generar a partir de las imágenes empleadas en el modelo de frutas conjuntas sin cambios de iluminación, para ser exactos únicamente empleando las imágenes de entrenamiento y no las de validación.

Para acelerar el proceso de entrenamiento y poder usar el *dataset* Fruits-360 en esta tarea, se ha usado el código expuesto en el anexo 5, el cual genera una nueva imagen empleando una imagen de cada una de las 22 clases disponibles, para colocarlas de manera aleatoria en una rejilla 5x5, donde los espacios vacíos se rellenan de blanco, evitando que la red asocie una posición de la rejilla con una clase concreta. Este proceso se repite sin usar dos veces la misma imagen, y aunque una clase se quede sin imágenes, el proceso no se detiene, sino que el espacio de esa clase pasa a rellenarse con un espacio en blanco, así hasta agotar todas las imágenes de todas las clases, generando un total de 734 nuevas imágenes. De esta manera, el número de clases por imagen irá variando, ya que no todas las clases tienen la misma cantidad de imágenes. Esto evita que la red sea entrenada completamente con la misma cantidad de clases por imagen.



Figura 10: Ejemplo de rejillas generadas.

Una vez preparado el conjunto de datos, se ha utilizado la herramienta de anotación automática de Roboflow para generar las anotaciones. Para lograr esto, Roboflow emplea una herramienta de inteligencia artificial que genera unas anotaciones iniciales, las cuales muestran una previsualización de las futuras anotaciones en una cantidad de imágenes limitadas. De esta manera, el usuario puede modificar la confianza con la que se quiere detectar cada clase para ajustar la herramienta de anotación automática a las necesidades de la tarea.

No obstante, esta herramienta comete una cantidad significativa de errores, tanto a la hora de generar una caja alrededor de todas las frutas como a la hora de asignar la clase correcta a cada caja, por ello las clases han sido simplificadas, es decir, se ha eliminado la distinción entre diferentes tipos de una misma fruta, por ejemplo, Apple 5, Apple Granny Smith 1 y Apple Red 2 se han asignado bajo el nombre de Apple, así con todas las frutas de este entrenamiento, pasando de 22 clases a 12.

También a través de Roboflow se han separado las imágenes para las diferentes tareas. De las 734 imágenes, 440 serán utilizadas para entrenamiento, 220 para validación y 74 serán reservadas para predicción.




Figura 11: Proceso de anotado automático de Roboflow.

En contraste con los entrenamientos de clasificación, los entrenamientos de detección incluyen parámetros diferentes en el archivo de características del entrenamiento. Los parámetros que incluye este archivo son:

- Epoch: indica la iteración en la que se encuentra el entrenamiento.
- Time: es el tiempo acumulado hasta esa época.
- Train/box_loss: mide qué tan lejos están las cajas predichas de las reales en términos de posición, tamaño y forma. Una pérdida menor indica que el modelo está aprendiendo a encuadrar correctamente los objetos.
- Train/cls_loss: mide el error en la identificación de la clase del objeto detectado. Una pérdida menor indica que el modelo está aprendiendo a nombrar correctamente los objetos que detecta.
- Train/dfl_loss: es una pérdida especial usada para refinar la precisión de los bordes de las cajas. Una pérdida menor indica que el modelo está logrando una predicción muy precisa de las coordenadas de cada borde de la caja.
- Metrics/precision(B): este parámetro representa la proporción de verdaderos positivos respecto a todos los positivos predichos.
- Metrics/recall(B): este parámetro representa la proporción de verdaderos positivos detectados respecto a los presentes.
- Metrics/mAP50(B): este parámetro representa la precisión promedio del modelo para todas las clases cuando se considera una predicción como correcta si IoU (*Intersection over Union*) entre la caja predicha y la caja real es mayor o igual a 0.5.
- Metrics/mAP50-95(B): este parámetro representa la precisión promedio del modelo para todas las clases, calculada como el promedio de mAPs a diferentes umbrales de IoU, desde 0.50 hasta 0.95 en pasos de 0.05.
- Val/box_loss: mide que tan bien el modelo predice la ubicación, el tamaño y la forma de las cajas delimitadoras en el conjunto de validación. Un valor bajo en esta pérdida indica que el modelo es capaz de localizar los objetos de manera precisa en imágenes no vistas.
- Val/cls_loss: representa la pérdida de clasificación, es decir, qué tan bien el modelo identifica la clase correcta de cada objeto detectado en los datos de validación. Un valor bajo en esta métrica indica que el modelo distingue adecuadamente entre distintas clases, incluso en situaciones nuevas.

- Val/dfl_loss: este parámetro se encarga de evaluar la precisión de las coordenadas de los bordes de las cajas predichas. Un valor bajo significa que el modelo está logrando una localización muy precisa y fina de los objetos
- Lr/pg0, Lr/pg1, Lr/pg2: representan la tasa de aprendizaje para los tres grupos de parámetros definidos por YOLOv8. Corresponden a las diferentes partes del modelo: columna vertebral, cuello y cabeza.

Debido a que el entrenamiento contiene una menor cantidad de imágenes, es más rápido y ligero, por ello se ha aumentado la cantidad de épocas con respecto a otros entrenamientos subiéndolas a 200 para lograr un modelo con la mayor precisión posible. En la tabla 20 se muestra un fragmento de los resultados del entrenamiento, estos resultados completos se encuentran en el Anexo 5.

En los resultados se puede apreciar como la precisión a lo largo del entrenamiento oscila alrededor de valores similares, y que no alcanza su mejor resultado hasta la época 183 con un valor de 0.9814 en el parámetro de metrics/mAP50-95(B). Los pesos de esta época han sido utilizados para poner a prueba la capacidad de predicción del modelo. A continuación, en la Tabla 21 se muestra un resumen de los resultados de las predicciones, los resultados completos se encuentran en el Anexo 6.

epoch	time	train/box_loss	train/cls_loss	train/dfl_loss	metrics/precision(B)	metrics/recall(B)	metrics/mAP50(B)	metrics/mAP50-95(B)	val/box_loss	val/cls_loss	val/dfl_loss	lr/pg0	lr/pg1	lr/pg2
1	12.6251	0.52911	3.89344	0.97435	0.01867	0.75452	0.09582	0.08617	0.36592	3.62617	0.78518	0.00016875	0.00016875	0.00016875
2	21.217	0.44735	2.92477	0.89791	0.56577	0.14898	0.335	0.31061	0.37735	3.00649	0.80454	0.000342048	0.000342048	0.000342048
3	29.7378	0.4527	1.84693	0.91603	0.74993	0.4314	0.55061	0.51785	0.35176	2.09076	0.84137	0.000513614	0.000513614	0.000513614
4	39.0872	0.43369	1.11662	0.91539	0.79372	0.82077	0.9029	0.82399	0.47008	0.94259	0.97412	0.000615719	0.000615719	0.000615719
5	46.7539	0.39986	0.80564	0.90655	0.87758	0.84857	0.93801	0.88316	0.36354	0.7353	0.92054	0.000612625	0.000612625	0.000612625
6	56.016	0.36756	0.6298	0.89099	0.96459	0.97793	0.98665	0.94317	0.31492	0.49266	0.87365	0.000609531	0.000609531	0.000609531
7	65.0081	0.35621	0.58106	0.88054	0.96099	0.97081	0.98504	0.95866	0.26673	0.57731	0.82383	0.000606437	0.000606437	0.000606437
8	72.908	0.35286	0.54376	0.8777	0.9828	0.98167	0.98394	0.93943	0.33607	0.56338	0.82942	0.000603344	0.000603344	0.000603344
9	82.1923	0.32751	0.49635	0.86732	0.98038	0.95804	0.98106	0.95574	0.25121	0.46689	0.81803	0.00060025	0.00060025	0.00060025
10	90.5542	0.32183	0.4776	0.86039	0.98936	0.99478	0.98735	0.9698	0.23456	0.39432	0.81408	0.000597156	0.000597156	0.000597156

Tabla 20: Fragmento de los resultados del entrenamiento de detección.

imagen	objetos detectados																		
rejilla_457.jpg	Peach (0.99)	Lemon (0.98)	Apple (0.98)	Orange (0.98)	Apple (0.98)	Grape (0.98)	Grape (0.98)	Melon (0.98)	Grape (0.98)	Cherry (0.98)	Pear (0.97)	Pear (0.97)	Pineapple (0.97)	Strawberry (0.97)	Pear (0.97)	Cherry (0.97)	Strawberry (0.97)	Banana (0.97)	Watermelon (0.96)
rejilla_468.jpg	Watermelon (0.99)	Cherry (0.99)	Lemon (0.99)	Apple (0.98)	Pear (0.98)	Melon (0.98)	Strawberry (0.98)	Grape (0.98)	Grape (0.98)	Pear (0.98)	Cherry (0.98)	Peach (0.97)	Apple (0.97)	Pear (0.97)	Orange (0.97)	Banana (0.97)	Strawberry (0.96)	Pineapple (0.95)	
rejilla_469.jpg	Apple (0.99)	Cherry (0.98)	Pear (0.98)	Grape (0.98)	Strawberry (0.98)	Orange (0.98)	Cherry (0.98)	Strawberry (0.98)	Lemon (0.98)	Apple (0.98)	Peach (0.97)	Grape (0.97)	Pear (0.97)	Melon (0.97)	Watermelon (0.97)	Pear (0.96)	Pineapple (0.96)	Banana (0.94)	
rejilla_471.jpg	Apple (0.98)	Pear (0.98)	Apple (0.98)	Peach (0.98)	Cherry (0.98)	Strawberry (0.98)	Grape (0.98)	Cherry (0.98)	Lemon (0.98)	Pear (0.98)	Pear (0.97)	Strawberry (0.97)	Orange (0.97)	Banana (0.97)	Melon (0.97)	Grape (0.96)	Pineapple (0.95)		
rejilla_472.jpg	Apple (0.99)	Peach (0.99)	Apple (0.99)	Strawberry (0.98)	Cherry (0.98)	Grape (0.98)	Orange (0.98)	Cherry (0.98)	Lemon (0.98)	Pear (0.97)	Grape (0.97)	Banana (0.97)	Melon (0.97)	Pear (0.97)	Pear (0.96)	Strawberry (0.96)	Pineapple (0.96)		
rejilla_474.jpg	Apple (0.98)	Cherry (0.98)	Apple (0.98)	Grape (0.98)	Grape (0.98)	Orange (0.98)	Pear (0.98)	Melon (0.98)	Peach (0.98)	Strawberry (0.97)	Cherry (0.97)	Lemon (0.97)	Pear (0.97)	Pear (0.97)	Strawberry (0.97)	Banana (0.96)	Pineapple (0.94)		
rejilla_475.jpg	Peach (0.99)	Apple (0.98)	Grape (0.98)	Cherry (0.98)	Grape (0.98)	Lemon (0.98)	Cherry (0.98)	Pear (0.98)	Banana (0.98)	Apple (0.98)	Strawberry (0.97)	Pear (0.97)	Strawberry (0.97)	Melon (0.96)	Pear (0.95)	Pineapple (0.95)			
rejilla_476.jpg	Pear (0.99)	Apple (0.99)	Cherry (0.99)	Peach (0.99)	Lemon (0.99)	Cherry (0.98)	Grape (0.98)	Apple (0.98)	Grape (0.98)	Melon (0.98)	Banana (0.98)	Strawberry (0.98)	Pear (0.97)	Pear (0.97)	Pineapple (0.96)	Strawberry (0.95)			
rejilla_477.jpg	Apple (0.98)	Grape (0.98)	Cherry (0.98)	Peach (0.98)	Apple (0.98)	Pear (0.98)	Pear (0.98)	Grape (0.98)	Strawberry (0.98)	Lemon (0.98)	Melon (0.97)	Pear (0.97)	Banana (0.97)	Cherry (0.97)	Strawberry (0.95)	Pineapple (0.94)			

Tabla 21: Resumen de resultados del proceso de predicción.

La totalidad de las predicciones ha sido acertada, además con valores de confianza cercanos a 1. Esto demuestra la capacidad que tiene el modelo de poder detectar correctamente imágenes que nunca ha visto. En la Figura 12 se muestra un ejemplo de las predicciones que ha realizado el modelo.




Figura 12: Ejemplo de predicción realizado por el modelo de detección.

Para comprobar de manera más exhaustiva la capacidad de la red para generalizar, se han empleado las imágenes utilizadas en el proceso de predicción con imágenes externas al *dataset* al que se sometieron los diferentes modelos de clasificación. No obstante, para esta prueba, las imágenes que se van a emplear también se han colocado en una rejilla 5x5 para que el modelo encuentre menos dificultades, por lo tanto, de las 44 imágenes iniciales, han resultado en un total de 6 imágenes. A continuación, en la Tabla 22 se presentan los resultados de las predicciones y en la Tabla 23 los porcentajes de acierto de cada fruta:

Column1	Column2	Column3	Column4	Column5	Column6	Column7	Column8	Column9	Column10	Column11	Column12	Column13
imagen	objetos detectados											
rejilla_000.png	Pear (0.98)	Banana (0.97)	Watermelon (0.97)	Grape (0.97)	Strawberry (0.96)	Banana (0.94)	Watermelon (0.94)	Watermelon (0.88)	Grape (0.85)	Pear (0.78)	Strawberry (0.44)	Lemon (0.36)
rejilla_001.png	Strawberry (0.98)	Banana (0.98)	Grape (0.97)	Melon (0.97)	Pear (0.97)	Watermelon (0.94)	Cherry (0.87)	Lemon (0.86)	Strawberry (0.80)	Strawberry (0.74)	Banana (0.43)	
rejilla_002.png	Banana (0.98)	Grape (0.97)	Strawberry (0.96)	Strawberry (0.95)	Grape (0.94)							
rejilla_003.png	Pear (0.98)	Banana (0.98)	Grape (0.96)	Peach (0.86)	Strawberry (0.84)	Cherry (0.60)						
rejilla_004.png	Grape (0.96)	Banana (0.96)	Pear (0.94)	Grape (0.86)								
rejilla_005.png	Pear (0.98)	Grape (0.97)	Banana (0.93)	Cherry (0.93)								

Tabla 22: Resultados del proceso de predicción con imágenes externas al *dataset*.

Porcentajes de acierto			
Manzanas			
Total de imágenes	Aciertos	Fallos	Porcentaje de acierto
6	0	6	0%
Plátanos			
6	6	0	100%
Cerezas			

4	2	2	50%
Uvas			
6	6	0	100%
Limones			
2	1	1	50%
Melones			
2	1	1	50%
Naranjas			
2	0	2	0%
Melocotones			
2	0	2	0%
Peras			
6	5	1	83%
Piñas			
2	0	2	0%
Fresas			
4	4	0	100%
Sandías			
2	2	0	100%

Tabla 23: Porcentaje de acierto del proceso de predicción con imágenes externas al dataset.

Los resultados de la prueba han sido bastante variables, ya que algunas frutas tienen una tasa de acierto muy elevada mientras que otras no, incluso llegando en una de las imágenes de las cerezas y en otra de los melocotones a no ser detectadas por el modelo. Esto demuestra una capacidad limitada de la red para generalizar con imágenes muy diferentes a las del entrenamiento. Este problema se podría solventar incluyendo una mayor cantidad de imágenes y de mayor diversidad al *dataset*, volviendo así el modelo más robusto a la hora de generalizar.




Figura 13: Ejemplo de predicción con imágenes externas al dataset realizado por el modelo de detección.

Esta fase de detección se ha llevado a cabo con el objetivo de generar un modelo capaz de detectar diferentes tipos de frutas. Para ello, se ha entrenado el modelo utilizando las imágenes del conjunto de entrenamiento, empleadas anteriormente para el modelo de frutas conjuntas en la tarea de clasificación, excluyendo las del conjunto de validación y en base a los resultados, se ha podido comprobar que el modelo ofrece una alta precisión en imágenes similares a las que se han usado para entrenarlo, pero carece de una alta capacidad de generalización.



5.CONCLUSIONES Y TRABAJOS FUTUROS

El objetivo de este TFG es detectar y clasificar frutas mediante la red YOLOv8 y emplear técnicas de visión por computador para trabajar bajo condiciones lumínicas variables. Tareas logradas gracias a los diferentes entrenamientos que han generado modelos capaces de desempeñarlas.

Una vez realizados los experimentos de clasificación y detección de frutas utilizando diferentes modelos de la familia YOLOv8, es posible llegar a las siguientes conclusiones a través del análisis de los resultados.

Para los experimentos de clasificación y detección, podemos determinar que la elección de la versión *nano* de YOLOv8 ha sido una buena elección, ya que ha proporcionado buenos resultados a un coste computacional bajo, a excepción de su capacidad de generación la cual es limitada.

Por otro lado, el *dataset* Fruits-360 sí ha presentado diferentes limitaciones para ambas tareas. La primera ha sido el tipo de imágenes que contiene, pese a contar con gran cantidad de frutas diferentes, en la mayoría de las ocasiones, las imágenes distan bastante de ser casos comunes. Esto es un problema ya que a la hora de realizar predicciones con imágenes externas al *dataset* la red, independientemente del modelo o la tarea en la mayoría de los casos no ha sido capaz de clasificar correctamente las imágenes o de reconocer algunas frutas, como se ha podido comprobar en los resultados de las pruebas con imágenes externas al *dataset*. Por ello, generando *datasets* personalizados que cuenten con imágenes similares a las que va a tener que predecir la red el problema desaparecería, ya que en las pruebas en las que se han empleado imágenes extraídas previamente del *dataset* la red clasifica correctamente todas las imágenes sin importar el modelo con un grado de confianza cercano a 1.

La otra limitación que se ha encontrado es la falta de imágenes con cambios de luminosidad, lo que ha provocado que al realizar predicciones con los modelos de clasificación a imágenes que, si cuentan con ellos, estos no fueran capaces de proporcionar resultados correctos en una gran cantidad de ocasiones, lo que vuelve inviable el uso de estos modelos fuera de entornos controlados. No obstante, al incluir imágenes con cambios de iluminación variables dentro de los conjuntos de entrenamiento

y validación, los modelos han vuelto a demostrar una gran eficacia como muestran los resultados donde su tasa de acierto se ha elevado hasta alcanzar prácticamente el 100%, volviéndolos capaces de operar en entornos con cambios de iluminación dinámicos.

Por último, en la tarea de detección el dataset Fruits-360 ha supuesto otro problema al no estar adaptado para esta tarea. No obstante, al modificar las imágenes y emplear Roboflow para generar las anotaciones esta limitación se ha resuelto sin impedir entrenar un modelo de detección funcional.

En conclusión, YOLOv8 en su versión *nano* es una excelente opción tanto para tareas de clasificación como de detección, siempre que el objetivo de estas tareas no requiera una alta capacidad de generalización. En caso de que así fuese, sería necesario trabajar con modelos de mayor tamaño como el *small* o el *large*.

Como trabajos futuros, se podría continuar con el proyecto probando otros *datasets* o generando un *dataset* propio, como se ha comentado previamente, con la idea de conseguir una base de datos suficientemente extensa para entrenar el modelo de detección de una manera más robusta, y así contar con una mayor cantidad de referencias. En este sentido, también sería interesante realizar pruebas con diferentes versiones y modelos de YOLO para encontrar la que mejor se ajuste a la tarea.

Además, este trabajo podría emplearse como base para desarrollar modelos de clasificación especializados para desarrollar tareas de control de calidad en frutos una vez realizada la cosecha, pudiendo clasificar por tamaño o color. También se podría utilizar para generar un modelo de detección, con el objetivo de implementarlo en un robot y que en tiempo real sea capaz de ir monitorizando el grado de madurez de algún tipo de fruta o cultivo. De esta manera, se automatizarían dos labores costosas en el ámbito de la agricultura, reduciendo los costes totales de estos procesos.

6.BIBLIOGRAFÍA

- [1] W. S. McCulloch y W. Pitts, «(1943) Warren S. McCulloch and Walter Pitts, A logical calculus of the ideas immanent in nervous activity, Bulletin of Mathematical Biophysics 5: 115-133», *Neurocomputing, Volume 1*, pp. 18-28, oct. 1988, doi: 10.7551/MITPRESS/4943.003.0004.
- [2] F. Rosenblatt, «The perceptron: A probabilistic model for information storage and organization in the brain», *Psychol Rev*, vol. 65, n.º 6, pp. 386-408, nov. 1958, doi: 10.1037/H0042519.
- [3] A. Turing, «Computing Machinery and Intelligence (1950)», *The Essential Turing*, pp. 433-464, sep. 2004, doi: 10.1093/OSO/9780198250791.003.0017.
- [4] P. O. Rodríguez y R. Coordinadora, «Inteligencia artificial y datos masivos en archivos digitales sonoros y audiovisuales», p. 190, 2020, Accedido: 20 de febrero de 2025. [En línea]. Disponible en: https://ru.iibi.unam.mx/jspui/handle/IIBI_UNAM/88
- [5] P. Ramires Hernandez, D. Valle Cruz, y D. Mx, «Los Asistentes virtuales basados en Inteligencia Artificial», *ReCIBE, Revista electrónica de Computación, Informática, Biomédica y Electrónica*, vol. 11, n.º 2, pp. C1-11, nov. 2022, doi: 10.32870/RECIBE.V11I2.251.
- [6] A. Estefania, R. Córdova, y M. F. Salgado, «Diseño e implementación de un sistema de generación de trayectoria para el control de un robot móvil, utilizando inteligencia artificial», 2021, Accedido: 20 de febrero de 2025. [En línea]. Disponible en: <http://dspace.uazuay.edu.ec/handle/datos/11228>
- [7] N. Narisetti, M. Henke, K. Neumann, F. Stolzenburg, T. Altmann, y E. Gladilin, «Deep Learning Based Greenhouse Image Segmentation and Shoot Phenotyping (DeepShoot)», *Front Plant Sci*, vol. 13, p. 906410, jul. 2022, doi: 10.3389/FPLS.2022.906410/BIBTEX.
- [8] R. Bautista, P. Constante, A. Gordon, y D. Mendoza, «Diseño e implementación de un sistema de visión artificial para análisis de datos NDVI en imágenes espectrales de cultivos de brócoli obtenidos mediante una aeronave pilotada

- remotamente», *Infociencia*, vol. 12, n.º 1, p. 30, abr. 2019, doi: 10.24133/INFOCIENCIA.V12I1.1230.
- [9] J. P. Bonilla-González y F. A. Prieto-Ortiz, «Determinación del estado de maduración de frutos de feijoa mediante un sistema de visión por computador utilizando información de color», *Revista de Investigación, Desarrollo e Innovación*, vol. 7, n.º 1, pp. 111-126, dic. 2016, doi: 10.19053/20278306.V7.N1.2016.5603.
- [10] O. E. Apolo-Apolo, M. Pérez-Ruiz, J. Martínez-Guanter, y J. Valente, «A Cloud-Based Environment for Generating Yield Estimation Maps From Apple Orchards Using UAV Imagery and a Deep Learning Technique», *Front Plant Sci*, vol. 11, p. 540046, jul. 2020, doi: 10.3389/FPLS.2020.01086/BIBTEX.
- [11] C. De, A. Á. Ochoa, D. Xavier, L. Campozano, y J. Javier, «UNIVERSIDAD AGRARIA DEL ECUADOR FACULTAD DE CIENCIAS AGRARIAS SISTEMA DE VISIÓN POR COMPUTADORA PARA LA CLASIFICACIÓN DEL MANGO DE EXPORTACIÓN TOMMY ATKINS PROPUESTA TECNOLÓGICA».
- [12] K. Fukushima, «Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position», *Biol Cybern*, vol. 36, n.º 4, pp. 193-202, abr. 1980, doi: 10.1007/BF00344251/METRICS.
- [13] Y. LeCun, L. Bottou, Y. Bengio, y P. Haffner, «Gradient-based learning applied to document recognition», *Proceedings of the IEEE*, vol. 86, n.º 11, pp. 2278-2323, 1998, doi: 10.1109/5.726791.
- [14] A. Krizhevsky, I. Sutskever, y G. E. Hinton, «ImageNet Classification with Deep Convolutional Neural Networks», Accedido: 20 de febrero de 2025. [En línea]. Disponible en: <http://code.google.com/p/cuda-convnet/>
- [15] K. Simonyan y A. Zisserman, «Very Deep Convolutional Networks for Large-Scale Image Recognition», *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, sep. 2014, Accedido: 1 de mayo de 2025. [En línea]. Disponible en: <https://arxiv.org/abs/1409.1556v6>

- [16] C. Szegedy *et al.*, «Going Deeper with Convolutions», *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 07-12-June-2015, pp. 1-9, sep. 2014, doi: 10.1109/CVPR.2015.7298594.
- [17] K. He, X. Zhang, S. Ren, y J. Sun, «Deep Residual Learning for Image Recognition», *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 2016-December, pp. 770-778, dic. 2015, doi: 10.1109/CVPR.2016.90.
- [18] M. Tan y Q. V Le, «EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks», 24 de mayo de 2019, *PMLR*. Accedido: 1 de mayo de 2025. [En línea]. Disponible en: <https://proceedings.mlr.press/v97/tan19a.html>
- [19] Z. Liu, H. Mao, C.-Y. Wu, C. Feichtenhofer, T. Darrell, y S. Xie, «A ConvNet for the 2020s», 2022. Accedido: 1 de mayo de 2025. [En línea]. Disponible en: <https://github.com/facebookresearch/ConvNeXt>
- [20] H. Chen, X. Chu, Y. Ren, X. Zhao, y K. Huang, «PeLK: Parameter-efficient Large Kernel ConvNets with Peripheral Convolution».
- [21] A. Sociales, C. Velásquez Henao, J. David, F. Cardona, y C. Jaime, «INNOVAR. Revista de Ciencias», Accedido: 20 de febrero de 2025. [En línea]. Disponible en: <http://www.redalyc.org/articulo.oa?id=81819028002>
- [22] D. Brahim Benmouna, «Procesamiento de imágenes hiperespectrales mediante redes neuronales convolucionales aplicado a la agricultura», *Proyecto de investigación*., oct. 2024, Accedido: 20 de febrero de 2025. [En línea]. Disponible en: <https://digitum.um.es/digitum/handle/10201/144497>
- [23] S. S. Figueroa Sacoto, «Diseño y desarrollo de un chatbot usando redes neuronales recurrentes y procesamiento de lenguaje natural para tiendas virtuales en comercio electrónico», 2021, Accedido: 20 de febrero de 2025. [En línea]. Disponible en: <http://dspace.upse.edu.ec/handle/123456789/21195>
- [24] R. A. Apanqui Otoyá y R. Flores Morales, «Traductor automático español-quechua, basado en el procesamiento del lenguaje natural», 2021.
- [25] R. DE Rostros y N. Y. Algoritmos De Reconocimiento De Objetos De La Biblioteca Opencv Edison Rene Caballero Barriga, «Aplicación Práctica de la Visión Artificial para el Reconocimiento de Rostros en una Imagen, Utilizando

Redes Neuronales y Algoritmos de Reconocimiento de Objetos de la Biblioteca OPENCV», 2017. Accedido: 20 de febrero de 2025. [En línea]. Disponible en: <http://hdl.handle.net/11349/6104>

- [26] A. A. Garcés Cadena *et al.*, «Clasificación de calidad de manzana para monitoreo de cosechabilidad utilizando visión por computador y algoritmos de aprendizaje profundo», *Ingeniare. Revista chilena de ingeniería*, vol. 31, pp. 0-0, 2023, doi: 10.4067/S0718-33052023000100215.
- [27] D. H. Dos Reis, D. Welfer, M. A. De Souza Leite Cuadros, y D. F. T. Gamarra, «Mobile Robot Navigation Using an Object Recognition Software with RGBD Images and the YOLO Algorithm», *Applied Artificial Intelligence*, vol. 33, n.º 14, pp. 1290-1305, dic. 2019, doi: 10.1080/08839514.2019.1684778/ASSET/68960593-B1F6-4B1C-80FC-626DD010B357/ASSETS/IMAGES/UAAI_A_1684778_F0014_OC.JPG.
- [28] P. P. Garcia, T. G. Santos, M. A. Machado, y N. Mendes, «Deep Learning Framework for Controlling Work Sequence in Collaborative Human–Robot Assembly Processes», *Sensors*, vol. 23, n.º 1, p. 553, ene. 2023, doi: 10.3390/S23010553/S1.
- [29] B. Yan, P. Fan, X. Lei, Z. Liu, y F. Yang, «A Real-Time Apple Targets Detection Method for Picking Robot Based on Improved YOLOv5», *Remote Sensing 2021, Vol. 13, Page 1619*, vol. 13, n.º 9, p. 1619, abr. 2021, doi: 10.3390/RS13091619.
- [30] «colab.google». Accedido: 7 de mayo de 2025. [En línea]. Disponible en: <https://colab.google/>
- [31] «Ultralytics | Revolucionando el mundo de la IA de visión». Accedido: 7 de mayo de 2025. [En línea]. Disponible en: <https://www.ultralytics.com/es>
- [32] «Fruits-360 dataset». Accedido: 7 de mayo de 2025. [En línea]. Disponible en: <https://www.kaggle.com/datasets/moltean/fruits/data>
- [33] Z. A. Khan *et al.*, «EA-CNN: Enhanced attention-CNN with explainable AI for fruit and vegetable classification», *Heliyon*, vol. 10, n.º 23, p. e40820, dic. 2024, doi: 10.1016/J.HELIYON.2024.E40820.
- [34] N. Rathnayake, U. Rathnayake, T. L. Dang, y Y. Hoshino, «An Efficient Automatic Fruit-360 Image Identification and Recognition Using a Novel

- Modified Cascaded-ANFIS Algorithm», *Sensors* 2022, Vol. 22, Page 4401, vol. 22, n.º 12, p. 4401, jun. 2022, doi: 10.3390/S22124401.
- [35] H. M. Mureş,an, M. K. Kogălniceanu, B.- Babes,-, y M. Oltean, «Fruit recognition from images using deep learning», *Acta Univ. Sapientiae, Informatica*, vol. 10, pp. 26-42, 2018.



7.ANEXO 1: TABLAS DE RESULTADOS DE LAS PREDICCIONES CON IMÁGENES DEL DATASET

Imagen	Clase	Confianza
Apple10_1.jpg	Apple 10	0.9999847412109375
Apple10_2.jpg	Apple 10	0.9999127388000488
Apple10_3.jpg	Apple 10	0.9998683929443359
Apple10_4.jpg	Apple 10	0.999798595905304
Apple11_1.jpg	Apple 11	0.9999676942825317
Apple11_2.jpg	Apple 11	0.9999719858169556
Apple11_3.jpg	Apple 11	0.9999843835830688
Apple11_4.jpg	Apple 11	0.9984948635101318
Apple12_1.jpg	Apple 12	0.9999911785125732
Apple12_2.jpg	Apple 12	0.9999504089355469
Apple12_3.jpg	Apple 12	0.9999912977218628
Apple12_4.jpg	Apple 12	0.9993599057197571
Apple13_1.jpg	Apple 13	0.9997144341468811
Apple13_2.jpg	Apple 13	0.9872565269470215
Apple13_3.jpg	Apple 13	0.9998427629470825
Apple13_4.jpg	Apple 13	0.9997203946113586
Apple14_1.jpg	Apple 14	0.999962329864502
Apple14_2.jpg	Apple 14	0.9993112087249756
Apple14_3.jpg	Apple 14	0.9999315738677979
Apple14_4.jpg	Apple 14	0.9994966983795166
Apple17_1.jpg	Apple 17	0.9741271138191223
Apple17_2.jpg	Apple 17	0.9998630285263062
Apple17_3.jpg	Apple 17	0.9995176792144775
Apple17_4.jpg	Apple 17	0.9979265928268433
Apple18_1.jpg	Apple 18	0.9998409748077393
Apple18_2.jpg	Apple 18	0.9999750852584839
Apple18_3.jpg	Apple 18	0.9996848106384277
Apple18_4.jpg	Apple 18	0.9996046423912048
Apple19_1.jpg	Apple 19	0.9948267340660095
Apple19_2.jpg	Apple 19	0.9986532926559448
Apple19_3.jpg	Apple 19	0.9984660148620605
Apple19_4.jpg	Apple 19	0.9981784820556641
Apple5_1.jpg	Apple 5	0.9999452829360962
Apple5_2.jpg	Apple 5	0.9999136924743652
Apple5_3.jpg	Apple 5	0.9999401569366455
Apple5_4.jpg	Apple 5	0.9991531372070312
Apple6_1.jpg	Apple 6	0.9999634027481079
Apple6_2.jpg	Apple 6	0.9997085928916931
Apple6_3.jpg	Apple 6	0.9997338652610779
Apple6_4.jpg	Apple 6	0.9998096823692322
Apple7_1.jpg	Apple 7	0.999942421913147
Apple7_2.jpg	Apple 7	0.9999719858169556
Apple7_3.jpg	Apple 7	0.9999960660934448
Apple7_4.jpg	Apple 7	0.9999984502792358
Apple8_1.jpg	Apple 8	0.999935507774353
Apple8_2.jpg	Apple 8	0.9997658133506775
Apple8_3.jpg	Apple 8	0.999997615814209
Apple8_4.jpg	Apple 8	0.9996529817581177
Apple9_1.jpg	Apple 9	0.9997854828834534
Apple9_2.jpg	Apple 9	0.9990566372871399
Apple9_3.jpg	Apple 9	0.9924152493476868

Imagen	Clase	Confianza
Apple9_4.jpg	Apple 9	0.9981820583343506
AppleBraeburn_1.jpg	Apple Braeburn 1	0.9999762773513794
AppleBraeburn_2.jpg	Apple Braeburn 1	0.9999575614929199
AppleBraeburn_3.jpg	Apple Braeburn 1	0.9999885559082031
AppleBraeburn_4.jpg	Apple Braeburn 1	0.9999419450759888
AppleCrimsonSnow_1.jpg	Apple Crimson Snow 1	0.9999697208404541
AppleCrimsonSnow_2.jpg	Apple Crimson Snow 1	0.999942421913147
AppleCrimsonSnow_3.jpg	Apple Crimson Snow 1	0.999956488609314
AppleCrimsonSnow_4.jpg	Apple Crimson Snow 1	0.9997339844703674
AppleGolden1_1.jpg	Apple Golden 1	0.9990997314453125
AppleGolden1_2.jpg	Apple Golden 1	0.9997971653938293
AppleGolden1_3.jpg	Apple Golden 1	0.9999171495437622
AppleGolden1_4.jpg	Apple Golden 1	0.9996950626373291
AppleGolden2_1.jpg	Apple Golden 2	0.9999911785125732
AppleGolden2_2.jpg	Apple Golden 2	0.9999996423721313
AppleGolden2_3.jpg	Apple Golden 2	0.9999939203262329
AppleGolden2_4.jpg	Apple Golden 2	0.9999924898147583
AppleGolden3_1.jpg	Apple Golden 3	0.9994244575500488
AppleGolden3_2.jpg	Apple Golden 3	0.999800980091095
AppleGolden3_3.jpg	Apple Golden 3	0.9996474981307983
AppleGolden3_4.jpg	Apple Golden 3	0.999406099319458
AppleGrannySmith_1.jpg	Apple Granny Smith 1	0.9997310042381287
AppleGrannySmith_2.jpg	Apple Granny Smith 1	0.9999157190322876
AppleGrannySmith_3.jpg	Apple Granny Smith 1	0.9996746778488159
AppleGrannySmith_4.jpg	Apple Granny Smith 1	0.9998829364776611
ApplePinkLady_1.jpg	Apple Pink Lady 1	0.998609185218811
ApplePinkLady_2.jpg	Apple Pink Lady 1	0.9999853372573853
ApplePinkLady_3.jpg	Apple Pink Lady 1	0.9983910918235779
ApplePinkLady_4.jpg	Apple Pink Lady 1	0.9998294115066528
AppleRed1_1.jpg	Apple Red 1	0.9999988079071045
AppleRed1_2.jpg	Apple Red 1	0.9999276399612427
AppleRed1_3.jpg	Apple Red 1	0.9998692274093628
AppleRed1_4.jpg	Apple Red 1	0.9999423027038574
AppleRed2_1.jpg	Apple Red 2	0.9998952150344849
AppleRed2_2.jpg	Apple Red 2	0.9998424053192139
AppleRed2_3.jpg	Apple Red 2	0.9998816251754761
AppleRed2_4.jpg	Apple Red 2	0.999943733215332
AppleRed3_1.jpg	Apple Red 3	0.9994100332260132
AppleRed3_2.jpg	Apple Red 3	0.9989400506019592
AppleRed3_3.jpg	Apple Red 3	0.9989957213401794
AppleRed3_4.jpg	Apple Red 3	0.9998266100883484
AppleRedDelicious_1.jpg	Apple Red Delicious 1	0.9995212554931641
AppleRedDelicious_2.jpg	Apple Red Delicious 1	0.999906063079834
AppleRedDelicious_3.jpg	Apple Red Delicious 1	0.9998666048049927
AppleRedDelicious_4.jpg	Apple Red Delicious 1	0.9991631507873535
AppleRedYellow1_1.jpg	Apple Red Yellow 1	0.999943733215332
AppleRedYellow1_2.jpg	Apple Red Yellow 1	0.9999972581863403
AppleRedYellow1_3.jpg	Apple Red Yellow 1	0.9999738931655884
AppleRedYellow1_4.jpg	Apple Red Yellow 1	0.9992080330848694
AppleRedYellow2_1.jpg	Apple Red Yellow 2	0.9998370409011841
AppleRedYellow2_2.jpg	Apple Red Yellow 2	0.999405026435852
AppleRedYellow2_3.jpg	Apple Red Yellow 2	0.9999945163726807
AppleRedYellow2_4.jpg	Apple Red Yellow 2	0.9998817443847656

Tabla 24: Resultados de las predicciones del entrenamiento de las manzanas.

Imagen	Clase	Confianza
Pear1_1.jpg	Pear 1	0.9999854564666748
Pear1_2.jpg	Pear 1	0.9999827146530151
Pear1_3.jpg	Pear 1	0.9999716281890869
Pear1_4.jpg	Pear 1	0.9999967813491821
Pear1_5.jpg	Pear 1	0.9999959468841553
Pear2_1.jpg	Pear 2	0.9999982118606567
Pear2_2.jpg	Pear 2	0.9999164342880249
Pear2_3.jpg	Pear 2	0.9998995065689087
Pear2_4.jpg	Pear 2	0.9999779462814331
Pear2_5.jpg	Pear 2	0.9999879598617554
Pear3_1.jpg	Pear 3	0.9999996423721313
Pear3_2.jpg	Pear 3	1.0
Pear3_3.jpg	Pear 3	0.9999991655349731
Pear3_4.jpg	Pear 3	0.9999988079071045
Pear3_5.jpg	Pear 3	0.9999998807907104
PearAbate_1.jpg	Pear Abate 1	0.9999842643737793
PearAbate_2.jpg	Pear Abate 1	0.9999654293060303
PearAbate_3.jpg	Pear Abate 1	0.9998819828033447
PearAbate_4.jpg	Pear Abate 1	0.9999977350234985
PearAbate_5.jpg	Pear Abate 1	0.9999897480010986
PearForelle_1.jpg	Pear Forelle 1	0.9999867677688599
PearForelle_2.jpg	Pear Forelle 1	0.999503493309021
PearForelle_3.jpg	Pear Forelle 1	0.9997419714927673
PearForelle_4.jpg	Pear Forelle 1	0.9999892711639404
PearForelle_5.jpg	Pear Forelle 1	0.9999761581420898
PearKaiser_1.jpg	Pear Kaiser 1	0.9999988079071045
PearKaiser_2.jpg	Pear Kaiser 1	0.9999898672103882
PearKaiser_3.jpg	Pear Kaiser 1	0.9999850988388062
PearKaiser_4.jpg	Pear Kaiser 1	0.9999794960021973
PearKaiser_5.jpg	Pear Kaiser 1	0.9999735355377197
PearMonster_1.jpg	Pear Monster 1	0.9999933242797852
PearMonster_2.jpg	Pear Monster 1	0.9999947547912598
PearMonster_3.jpg	Pear Monster 1	0.9999903440475464
PearMonster_4.jpg	Pear Monster 1	0.999995231628418
PearMonster_5.jpg	Pear Monster 1	0.9999985694885254
PearRed_1.jpg	Pear Red 1	0.9999635219573975
PearRed_2.jpg	Pear Red 1	0.9999687671661377
PearRed_3.jpg	Pear Red 1	0.9999880790710449
PearRed_4.jpg	Pear Red 1	0.9999381303787231
PearRed_5.jpg	Pear Red 1	0.9999921321868896
PearStone_1.jpg	Pear Stone 1	0.9999866485595703
PearStone_2.jpg	Pear Stone 1	0.9999897480010986
PearStone_3.jpg	Pear Stone 1	0.999997615814209
PearStone_4.jpg	Pear Stone 1	0.9999386072158813
PearStone_5.jpg	Pear Stone 1	0.9999959468841553
PearWilliams_1.jpg	Pear Williams 1	0.9999849796295166
PearWilliams_2.jpg	Pear Williams 1	0.9999997615814209
PearWilliams_3.jpg	Pear Williams 1	0.9999736547470093
PearWilliams_4.jpg	Pear Williams 1	0.999983549118042
PearWilliams_5.jpg	Pear Williams 1	0.9999960660934448

Tabla 25: Resultados de las predicciones del entrenamiento de las peras.

Imagen	Clase	Confianza
GrapeBlue_1.jpg	Grape Blue 1	0.9999995231628418
GrapeBlue_2.jpg	Grape Blue 1	0.9999955892562866
GrapeBlue_3.jpg	Grape Blue 1	0.9999998807907104
GrapeBlue_4.jpg	Grape Blue 1	0.9999997615814209
GrapeBlue_5.jpg	Grape Blue 1	0.9999995231628418
GrapePink_1.jpg	Grape Pink 1	0.9980897307395935
GrapePink_2.jpg	Grape Pink 1	0.9999432563781738
GrapePink_3.jpg	Grape Pink 1	0.9990233182907104
GrapePink_4.jpg	Grape Pink 1	0.9999939203262329
GrapePink_5.jpg	Grape Pink 1	0.9999861717224121
GrapeWhite1_1.jpg	Grape White 1	0.9999608993530273
GrapeWhite1_2.jpg	Grape White 1	0.9999434947967529
GrapeWhite1_3.jpg	Grape White 1	0.9999004602432251
GrapeWhite1_4.jpg	Grape White 1	0.9999951124191284
GrapeWhite1_5.jpg	Grape White 1	0.9999740123748779
GrapeWhite2_1.jpg	Grape White 2	0.999984622001648
GrapeWhite2_2.jpg	Grape White 2	0.9999681711196899
GrapeWhite2_3.jpg	Grape White 2	0.9999805688858032
GrapeWhite2_4.jpg	Grape White 2	0.9999971389770508
GrapeWhite2_5.jpg	Grape White 2	0.999995231628418
GrapeWhite3_1.jpg	Grape White 3	0.9999935626983643
GrapeWhite3_2.jpg	Grape White 3	0.9999223947525024
GrapeWhite3_3.jpg	Grape White 3	0.9999591112136841
GrapeWhite3_4.jpg	Grape White 3	0.9996803998947144
GrapeWhite3_5.jpg	Grape White 3	0.9999678134918213
GrapeWhite4_1.jpg	Grape White 4	0.9999140501022339
GrapeWhite4_2.jpg	Grape White 4	0.9999769926071167
GrapeWhite4_3.jpg	Grape White 4	0.9999759197235107
GrapeWhite4_4.jpg	Grape White 4	0.9999839067459106
GrapeWhite4_5.jpg	Grape White 4	0.9999973773956299

Tabla 26: Resultados de las predicciones del entrenamiento de las uvas.

Imagen	Clase	Confianza
Cherry1_1.jpg	Cherry 1	0.9999890327453613
Cherry1_2.jpg	Cherry 1	0.999996542930603
Cherry1_3.jpg	Cherry 1	0.9999538660049438
Cherry1_4.jpg	Cherry 1	0.9999954700469971
Cherry1_5.jpg	Cherry 1	0.999976634979248
Cherry2_1.jpg	Cherry 2	0.9997666478157043
Cherry2_2.jpg	Cherry 2	0.9999676942825317
Cherry2_3.jpg	Cherry 2	0.9999932050704956
Cherry2_4.jpg	Cherry 2	0.9991260170936584
Cherry2_5.jpg	Cherry 2	0.9999933242797852
CherryRainier_1.jpg	Cherry Rainier 1	0.9999639987945557
CherryRainier_2.jpg	Cherry Rainier 1	0.9999823570251465
CherryRainier_3.jpg	Cherry Rainier 1	0.9999629259109497
CherryRainier_4.jpg	Cherry Rainier 1	0.9994051456451416
CherryRainier_5.jpg	Cherry Rainier 1	0.9998836517333984
CherryWaxBlack_1.jpg	Cherry Wax Black 1	0.9999954700469971
CherryWaxBlack_2.jpg	Cherry Wax Black 1	0.999988317489624
CherryWaxBlack_3.jpg	Cherry Wax Black 1	0.999997615814209
CherryWaxBlack_4.jpg	Cherry Wax Black 1	0.9999926090240479
CherryWaxBlack_5.jpg	Cherry Wax Black 1	0.9999887943267822
CherryWaxNotRippen_1.jpg	Cherry Wax not rippen 1	0.9998278617858887
CherryWaxNotRippen_2.jpg	Cherry Wax not rippen 1	0.9998248219490051
CherryWaxNotRippen_3.jpg	Cherry Wax not rippen 1	0.9998854398727417
CherryWaxNotRippen_4.jpg	Cherry Wax not rippen 1	0.9997747540473938
CherryWaxNotRippen_5.jpg	Cherry Wax not rippen 1	0.9997127652168274
CherryWaxRed_1.jpg	Cherry Wax Red 1	0.9999960660934448
CherryWaxRed_2.jpg	Cherry Wax Red 1	0.9999933242797852
CherryWaxRed_3.jpg	Cherry Wax Red 1	0.9999898672103882
CherryWaxRed_4.jpg	Cherry Wax Red 1	0.9999947547912598
CherryWaxRed_5.jpg	Cherry Wax Red 1	0.999980092048645
CherryWaxYellow_1.jpg	Cherry Wax Yellow 1	0.999976396560669
CherryWaxYellow_2.jpg	Cherry Wax Yellow 1	0.9999643564224243
CherryWaxYellow_3.jpg	Cherry Wax Yellow 1	0.9999215602874756
CherryWaxYellow_4.jpg	Cherry Wax Yellow 1	0.9998892545700073
CherryWaxYellow_5.jpg	Cherry Wax Yellow 1	0.9999856948852539

Tabla 27: Resultados de las predicciones del entrenamiento de las cerezas.

Imagen	Clase	Confianza
Apple5_1.jpg	Apple 5	0.9999573230743408
Apple5_2.jpg	Apple 5	0.9999887943267822
Apple5_3.jpg	Apple 5	0.9999895095825195
Apple5_4.jpg	Apple 5	0.9999428987503052
AppleRed2_1.jpg	Apple Red 2	0.999925971031189
AppleRed2_2.jpg	Apple Red 2	0.9998698234558105
AppleRed2_3.jpg	Apple Red 2	0.9999024868011475
AppleRed2_4.jpg	Apple Red 2	0.999976634979248
ApppleGrannySmith_1.jpg	Apple Granny Smith 1	0.9999439716339111
ApppleGrannySmith_2.jpg	Apple Granny Smith 1	0.9999576807022095
ApppleGrannySmith_3.jpg	Apple Granny Smith 1	0.9999401569366455
ApppleGrannySmith_4.jpg	Apple Granny Smith 1	0.9999687671661377
Banana1_1.jpg	Banana 1	0.9999996423721313
Banana1_2.jpg	Banana 1	0.9999779462814331
Banana1_3.jpg	Banana 1	0.9999843835830688
Banana1_4.jpg	Banana 1	0.9991637468338013
Banana3_1.jpg	Banana 3	0.9999032020568848
Banana3_2.jpg	Banana 3	0.9999780654907227
Banana3_3.jpg	Banana 3	0.999824583530426
Banana3_4.jpg	Banana 3	0.9999967813491821
BananaLadyFinger_1.jpg	Banana Lady Finger 1	0.9995032548904419
BananaLadyFinger_2.jpg	Banana Lady Finger 1	0.9994589686393738
BananaLadyFinger_3.jpg	Banana Lady Finger 1	0.9999618530273438
BananaLadyFinger_4.jpg	Banana Lady Finger 1	0.9999599456787109
Cherry1_1.jpg	Cherry 1	0.9999145269393921
Cherry1_2.jpg	Cherry 1	0.9999469518661499
Cherry1_3.jpg	Cherry 1	0.9999343156814575
Cherry1_4.jpg	Cherry 1	0.9999295473098755
Cherry2_1.jpg	Cherry 2	0.9984207153320312
Cherry2_2.jpg	Cherry 2	0.9999939203262329
Cherry2_3.jpg	Cherry 2	0.9992924928665161
Cherry2_4.jpg	Cherry 2	0.9997822642326355
GrapeWhite1_1.jpg	Grape White 1	0.9999685287475586
GrapeWhite1_2.jpg	Grape White 1	0.9999141693115234
GrapeWhite1_3.jpg	Grape White 1	0.9999959468841553
GrapeWhite1_4.jpg	Grape White 1	0.9999940395355225
GrapeWhite2_1.jpg	Grape White 2	0.9996726512908936
GrapeWhite2_2.jpg	Grape White 2	0.9997814297676086
GrapeWhite2_3.jpg	Grape White 2	0.9997324347496033
GrapeWhite2_4.jpg	Grape White 2	0.9991912245750427
GrapeWhite4_1.jpg	Grape White 4	0.9999972581863403
GrapeWhite4_2.jpg	Grape White 4	0.9999953508377075
GrapeWhite4_3.jpg	Grape White 4	0.9999963045120239
GrapeWhite4_4.jpg	Grape White 4	0.9999953508377075

Imagen	Clase	Confianza
Lemon1_1.jpg	Lemon 1	0.9999973773956299
Lemon1_2.jpg	Lemon 1	0.9999970197677612
Lemon1_3.jpg	Lemon 1	0.9999732971191406
Lemon1_4.jpg	Lemon 1	0.9999904632568359
MelonPielDeSapo_1.jpg	Melon Piel de Sapo 1	0.9999942779541016
MelonPielDeSapo_2.jpg	Melon Piel de Sapo 1	0.999993085861206
MelonPielDeSapo_3.jpg	Melon Piel de Sapo 1	0.9999969005584717
MelonPielDeSapo_4.jpg	Melon Piel de Sapo 1	0.9999953508377075
Orange_1.jpg	Orange 1	0.9999923706054688
Orange_2.jpg	Orange 1	0.9999847412109375
Orange_3.jpg	Orange 1	0.9998267292976379
Orange_4.jpg	Orange 1	0.9999804496765137
Peach1_1.jpg	Peach 1	0.9999703168869019
Peach1_2.jpg	Peach 1	0.9997950196266174
Peach1_3.jpg	Peach 1	0.9999819993972778
Peach1_4.jpg	Peach 1	0.9999796152114868
Pear1_1.jpg	Pear 1	0.9999935626983643
Pear1_2.jpg	Pear 1	0.9999868869781494
Pear1_3.jpg	Pear 1	0.9999885559082031
Pear1_4.jpg	Pear 1	0.9999834299087524
Pear2_1.jpg	Pear 2	0.9998258948326111
Pear2_2.jpg	Pear 2	0.9999727010726929
Pear2_3.jpg	Pear 2	0.999982476234436
Pear2_4.jpg	Pear 2	0.9999932050704956
PearForelle_1.jpg	Pear Forelle 1	0.9998993873596191
PearForelle_2.jpg	Pear Forelle 1	0.9995478987693787
PearForelle_3.jpg	Pear Forelle 1	0.9999963045120239
PearForelle_4.jpg	Pear Forelle 1	0.9999120235443115
Pineapple1_1.jpg	Pineapple 1	0.9998013377189636
Pineapple1_2.jpg	Pineapple 1	0.9999558925628662
Pineapple1_3.jpg	Pineapple 1	0.9998070597648621
Pineapple1_4.jpg	Pineapple 1	0.9999645948410034
Strawberry1_1.jpg	Strawberry 1	0.9999849796295166
Strawberry1_2.jpg	Strawberry 1	0.9998592138290405
Strawberry1_3.jpg	Strawberry 1	0.9999464750289917
Strawberry1_4.jpg	Strawberry 1	0.9999980926513672
StrawberryWedge_1.jpg	Strawberry Wedge 1	0.9999964237213135
StrawberryWedge_2.jpg	Strawberry Wedge 1	0.9996402263641357
StrawberryWedge_3.jpg	Strawberry Wedge 1	0.9999359846115112
StrawberryWedge_4.jpg	Strawberry Wedge 1	0.9999061822891235
Watermelon1_1.jpg	Watermelon 1	0.9998527765274048
Watermelon1_2.jpg	Watermelon 1	0.9999557733535767
Watermelon1_3.jpg	Watermelon 1	0.9995759129524231
Watermelon1_4.jpg	Watermelon 1	0.9998811483383179

Tabla 28: Resultados de las predicciones del entrenamiento de las frutas conjuntas.

8.ANEXO 2: TABLAS DE RESULTADOS DE LAS PREDICCIONES CON IMÁGENES EXTERNAS AL DATASET

Imagen	Clase	Confianza	Acertos/Fallos
Manzana_1.png	Apple Red 1	0.4609639048576355	Acierto
Manzana_2.png	Apple 10	0.9268770217895508	Fallo
Manzana_3.png	Apple 18	0.3609108626842499	Fallo
Manzana_4.png	Apple Red 1	0.9606449007987976	Acierto
Manzana_5.png	Apple 10	0.9869304895401001	Fallo
Manzana_6.png	Apple 17	0.758062481880188	Acierto
Manzana_7.png	Apple Braeburn 1	0.88941890001297	Acierto
Manzana_8.png	Apple 10	0.7751535177230835	Fallo
Manzana_9.png	Apple Red Yellow 1	0.6064708828926086	Acierto
Manzana_10.png	Apple 10	0.6908156275749207	Fallo
Manzana_11.png	Apple 10	0.7496969699859619	Acierto
Manzana_12.png	Apple Red Yellow 1	0.5928303003311157	Acierto
Manzana_13.png	Apple Red 1	0.6553674340248108	Acierto
Manzana_14.png	Apple 10	0.7924764156341553	Acierto
Manzana_15.png	Apple Braeburn 1	0.6479162573814392	Acierto
Manzana_16.png	Apple Braeburn 1	0.6293500661849976	Acierto
Manzana_17.png	Apple Red 1	0.5831917524337769	Acierto
Manzana_18.png	Apple Braeburn 1	0.942212700843811	Acierto
Manzana_19.png	Apple 11	0.7810003161430359	Acierto
Manzana_20.png	Apple 7	0.466011106967926	Fallo
Manzana_21.png	Apple Red Yellow 1	0.7092433571815491	Acierto
Manzana_22.png	Apple Red Yellow 1	0.3873356580734253	Acierto
Manzana_23.png	Apple Braeburn 1	0.8516929149627686	Acierto
Manzana_24.png	Apple 17	0.4985158443450928	Fallo
Manzana_25.png	Apple 11	0.3809906542301178	Fallo
Manzana_26.png	Apple Red 1	0.3354099988937378	Acierto
Manzana_27.png	Apple 11	0.451344758272171	Fallo
Manzana_28.png	Apple Red Yellow 1	0.9186113476753235	Acierto
Manzana_29.png	Apple 11	0.4552951753139496	Fallo
Manzana_30.png	Apple Red Yellow 1	0.42690861225128174	Acierto
Manzana_31.png	Apple 7	0.6596204042434692	Fallo
Manzana_32.png	Apple Pink Lady 1	0.5047215223312378	Acierto
Manzana_33.png	Apple 14	0.6807664036750793	Acierto
Manzana_34.png	Apple 7	0.9985955357551575	Acierto
Manzana_35.png	Apple 7	0.7362480163574219	Acierto
Manzana_36.png	Apple 11	0.7714639902114868	Fallo
Manzana_37.png	Apple 11	0.862966001033783	Fallo
Manzana_38.png	Apple 7	0.9544475674629211	Acierto
Manzana_39.png	Apple 7	0.9728297591209412	Acierto
Manzana_40.png	Apple 12	0.9067128300666809	Acierto
Manzana_41.png	Apple Granny Smith 1	0.8897083401679993	Acierto
Manzana_42.png	Apple 7	0.9994879961013794	Acierto
Manzana_43.png	Apple 7	0.9049397706985474	Acierto
Manzana_44.png	Apple 7	0.8707703351974487	Fallo
Manzana_45.png	Apple 7	0.7028953433036804	Acierto
Manzana_46.png	Apple 12	0.7795157432556152	Acierto
Manzana_47.png	Apple 7	0.8298825621604919	Acierto
Manzana_48.png	Apple 7	0.9636173248291016	Acierto
Manzana_49.png	Apple 7	0.6051512360572815	Acierto
Manzana_50.png	Apple Golden 2	0.7121661305427551	Acierto
Manzana_51.png	Apple 7	0.8956490755081177	Fallo
Manzana_52.png	Apple 7	0.8068308234214783	Fallo

Tabla 29: Resultados de las predicciones del entrenamiento de las manzanas con imágenes externas al dataset.

Imagen	Clase	Confianza	Aciertos/Fallos
Pera_1.jpg	Pear 2	0.8508897423744202	Acierto
Pera_2.jpg	Pear 2	0.9896777868270874	Acierto
Pera_3.jpg	Pear 2	0.9975847005844116	Acierto
Pera_4.jpg	Pear Forelle 1	0.9005075693130493	Acierto
Pera_5.jpg	Pear Monster 1	0.5960736870765686	Acierto
Pera_6.jpg	Pear 2	0.6623013615608215	Acierto
Pera_7.jpg	Pear Forelle 1	0.9885693192481995	Acierto
Pera_8.jpg	Pear Monster 1	0.8235915899276733	Fallo
Pera_9.jpg	Pear 2	0.8330693244934082	Fallo
Pera_10.jpg	Pear Forelle 1	0.8921152353286743	Acierto
Pera_11.jpg	Pear 2	0.5847047567367554	Acierto
Pera_12.jpg	Pear 2	0.9680845141410828	Fallo
Pera_13.jpg	Pear 2	0.6603465676307678	Fallo
Pera_14.jpg	Pear 2	0.8389337658882141	Fallo
Pera_15.jpg	Pear Monster 1	0.9898461699485779	Acierto
Pera_16.jpg	Pear Monster 1	0.7236467003822327	Acierto
Pera_17.jpg	Pear 2	0.6723154187202454	Fallo
Pera_18.jpg	Pear 2	0.9862275719642639	Acierto
Pera_19.jpg	Pear 2	0.9196008443832397	Acierto
Pera_20.jpg	Pear 2	0.9945921301841736	Acierto

Tabla 30: Resultados de las predicciones del entrenamiento de las peras con imágenes externas al dataset.

Imagen	Clase	Confianza	Aciertos/Fallos
Uva_1.png	Grape White 4	0.9771832227706909	Acierto
Uva_2.png	Grape White 4	0.8769601583480835	Acierto
Uva_3.jpg	Grape White 2	0.7182070016860962	Fallo
Uva_4.jpg	Grape White 4	0.9178563952445984	Acierto
Uva_5.jpg	Grape White 4	0.8528698086738586	Fallo
Uva_6.jpg	Grape White 4	0.8238409161567688	Acierto
Uva_7.jpg	Grape White 4	0.9904530048370361	Acierto
Uva_8.jpg	Grape White 4	0.9288458824157715	Acierto
Uva_9.jpg	Grape Blue 1	0.8725098371505737	Acierto
Uva_10.jpg	Grape Blue 1	0.9363721609115601	Acierto
Uva_11.jpg	Grape Pink 1	0.9973178505897522	Acierto
Uva_12.jpg	Grape Pink 1	0.9973069429397583	Acierto

Tabla 31: Resultados de las predicciones del entrenamiento de las uvas con imágenes externas al dataset.

Imagen	Clase	Confianza	Aciertos/Fallos
Cereza_1.jpg	Cherry 2	0.5726609826087952	Acierto
Cereza_2.jpg	Cherry 1	0.9806481003761292	Acierto
Cereza_3.jpg	Cherry 1	0.9999022483825684	Acierto
Cereza_4.jpg	Cherry 1	0.9817579388618469	Acierto
Cereza_5.jpg	Cherry 2	0.7055829167366028	Acierto
Cereza_6.jpg	Cherry 1	0.9488085508346558	Acierto
Cereza_7.jpg	Cherry 1	0.9920769929885864	Acierto
Cereza_8.jpg	Cherry 1	0.9976317882537842	Fallo
Cereza_9.jpg	Cherry 1	0.9983231425285339	Fallo
Cereza_10.jpg	Cherry 1	0.9991425275802612	Fallo
Cereza_11.jpg	Cherry 1	0.9828422665596008	Fallo
Cereza_12.jpg	Cherry Wax not rippen 1	0.9703785181045532	Acierto
Cereza_13.jpg	Cherry Wax not rippen 1	0.9474930763244629	Acierto
Cereza_14.jpg	Cherry Wax not rippen 1	0.9043363928794861	Acierto

Tabla 32: Resultados de las predicciones del entrenamiento de las cerezas con imágenes externas al dataset.

Imagen	Clase	Confianza	Aciertos/Fallos
Cereza_1.jpg	Banana Lady Finger 1	0.8844704627990723	Fallo
Cereza_2.jpg	Banana Lady Finger 1	0.8547929525375366	Fallo
Cereza_3.jpg	Banana Lady Finger 1	0.8330696225166321	Fallo
Cereza_4.jpg	Banana Lady Finger 1	0.813346266746521	Fallo
Fresa_1.jpg	Strawberry Wedge 1	0.9578763842582703	Acierto
Fresa_2.jpg	Strawberry 1	0.6362997889518738	Acierto
Fresa_3.jpg	Strawberry Wedge 1	0.9895433187484741	Acierto
Fresa_4.jpg	Strawberry Wedge 1	0.994317352771759	Acierto
Limon_1.jpg	Lemon 1	0.745867908000946	Acierto
Limon_2.jpg	Pear 2	0.6903972625732422	Fallo
Manzana_1.png	Cherry 2	0.3379825949668884	Fallo
Manzana_2.png	Apple 5	0.47218140959739685	Acierto
Manzana_3.png	Cherry 2	0.9719455242156982	Fallo
Manzana_4.png	Banana Lady Finger 1	0.5627309679985046	Fallo
Manzana_5.png	Apple Granny Smith 1	0.9448624849319458	Acierto
Manzana_6.png	Apple Granny Smith 1	0.9546751379966736	Acierto
Melocoton_1.jpg	Banana Lady Finger 1	0.8646714091300964	Fallo
Melocoton_2.jpg	Banana Lady Finger 1	0.5842474102973938	Fallo
Melon_1.jpg	Watermelon 1	0.9061120748519897	Fallo
Melon_2.jpg	Melon Piel de Sapo 1	0.8676512837409973	Acierto
Naranja_1.jpg	Orange 1	0.9994913339614868	Acierto
Naranja_2.jpg	Orange 1	0.9888530969619751	Acierto
Pera_1.jpg	Pear Forelle 1	0.4976699948310852	Acierto
Pera_2.jpg	Pear 2	0.30425500869750977	Acierto
Pera_3.jpg	Pear 2	0.9967005848884583	Acierto
Pera_4.jpg	Pear 2	0.9425556659698486	Acierto
Pera_5.jpg	Pear 2	0.9797205328941345	Acierto
Pera_6.jpg	Pear 2	0.9711580872535706	Acierto
Piña_1.jpg	Melon Piel de Sapo 1	0.23747320473194122	Fallo
Piña_2.jpg	Pineapple 1	0.40228933095932007	Acierto
Platanano_1.jpg	Banana Lady Finger 1	0.9896339178085327	Acierto
Platano_2.jpg	Banana Lady Finger 1	0.987552285194397	Acierto
Platano_3.jpg	Banana Lady Finger 1	0.9995978474617004	Acierto
Platano_4.jpg	Banana Lady Finger 1	0.9769927263259888	Acierto
Platano_5.jpg	Banana Lady Finger 1	0.9863710999488831	Acierto
Platano_6.jpg	Banana Lady Finger 1	0.9987322688102722	Acierto
Sandia_1.jpg	Watermelon 1	0.4317004382610321	Acierto
Sandia_2.jpg	Watermelon 1	0.9951369166374207	Acierto
Uva_1.png	Apple Granny Smith 1	0.8548701405525208	Fallo
Uva_2.png	Apple Granny Smith 1	0.7003158926963806	Fallo
Uva_3.jpg	Apple Granny Smith 1	0.640913188457489	Fallo
Uva_4.jpg	Banana Lady Finger 1	0.9983175992965698	Fallo
Uva_5.jpg	Apple Granny Smith 1	0.38888293504714966	Fallo
Uva_6.jpg	Apple Granny Smith 1	0.5860318541526794	Fallo

Tabla 33: Resultados de las predicciones del entrenamiento de las frutas conjuntas con imágenes externas al dataset.

9. ANEXO 3: TABLAS DE RESULTADOS DE LAS PREDICCIONES CON IMÁGENES MODIFICADAS CON CAMBIOS DE ILUMINACIÓN

Imagen	Clase	Confianza	factor_brillo	Aciertos/Fallos
Apple10_1_mod.jpg	Apple 17	0.5760476589202881	-0.4116	Fallo
Apple10_2_mod.jpg	Apple 19	0.16191312670707703	-0.7529	Fallo
Apple10_3_mod.jpg	Apple 10	0.9991936087608337	0.1084	Acierto
Apple10_4_mod.jpg	Apple 18	0.9870753884315491	-0.4329	Fallo
Apple11_1_mod.jpg	Apple Granny Smith 1	0.45086467266082764	-0.7475	Fallo
Apple11_2_mod.jpg	Apple 11	0.9999184608459473	0.1253	Acierto
Apple11_3_mod.jpg	Apple 11	0.9981599450111389	-0.1242	Acierto
Apple11_4_mod.jpg	Apple 11	0.9988924860954285	0.7411	Acierto
Apple12_1_mod.jpg	Apple 12	0.9495528340339661	-0.3901	Acierto
Apple12_2_mod.jpg	Apple Granny Smith 1	0.474324494600296	-0.5962	Fallo
Apple12_3_mod.jpg	Apple 12	0.9999827146530151	0.1768	Acierto
Apple12_4_mod.jpg	Apple 12	0.8828773498535156	0.2982	Acierto
Apple13_1_mod.jpg	Apple Granny Smith 1	0.25786590576171875	-0.6656	Fallo
Apple13_2_mod.jpg	Apple 13	0.5706932544708252	0.607	Acierto
Apple13_3_mod.jpg	Apple 13	0.9457213282585144	0.4732	Acierto
Apple13_4_mod.jpg	Apple Braeburn 1	0.2593548893928528	-0.5795	Fallo
Apple14_1_mod.jpg	Apple Granny Smith 1	0.39483851194381714	-0.58	Fallo
Apple14_2_mod.jpg	Apple Golden 2	0.7665340304374695	0.6142	Fallo
Apple14_3_mod.jpg	Apple 9	0.7783544063568115	-0.2498	Fallo
Apple14_4_mod.jpg	Apple 14	0.791483998298645	0.3108	Acierto
Apple17_1_mod.jpg	Apple 5	0.9361550211906433	0.6339	Fallo
Apple17_2_mod.jpg	Apple Golden 2	0.3628309369087219	0.6468	Fallo
Apple17_3_mod.jpg	Apple 11	0.6146714091300964	0.5366	Fallo
Apple17_4_mod.jpg	Apple Crimson Snow 1	0.3297562599182129	0.4082	Fallo
Apple18_1_mod.jpg	Apple 18	0.9625971913337708	0.2835	Acierto
Apple18_2_mod.jpg	Apple 18	0.9886845946311951	0.2513	Acierto
Apple18_3_mod.jpg	Apple 18	0.9971365928649902	0.1404	Acierto
Apple18_4_mod.jpg	Apple Golden 1	0.2682531774044037	-0.7584	Fallo
Apple19_1_mod.jpg	Apple 19	0.9549585580825806	0.3169	Acierto
Apple19_2_mod.jpg	Apple 19	0.9943071007728577	-0.1087	Acierto
Apple19_3_mod.jpg	Apple 19	0.9657873511314392	0.63	Acierto
Apple19_4_mod.jpg	Apple 19	0.9773771166801453	0.5578	Acierto
Apple5_1_mod.jpg	Apple 5	0.9134447574615479	0.7556	Acierto
Apple5_2_mod.jpg	Apple Granny Smith 1	0.28641313314437866	-0.6244	Fallo
Apple5_3_mod.jpg	Apple Golden 1	0.21921572089195251	-0.7105	Fallo
Apple5_4_mod.jpg	Apple Braeburn 1	0.36345577239990234	-0.3736	Fallo
Apple6_1_mod.jpg	Apple Golden 2	0.9637012481689453	0.7412	Fallo
Apple6_2_mod.jpg	Apple 6	0.5800330638885498	0.5315	Acierto
Apple6_3_mod.jpg	Apple 6	0.8315849900245667	0.3866	Acierto
Apple6_4_mod.jpg	Apple 6	0.962270200252533	-0.3948	Acierto
Apple7_1_mod.jpg	Apple 7	0.9999815225601196	0.2114	Acierto
Apple7_2_mod.jpg	Apple 7	0.9312517046928406	-0.712	Acierto
Apple7_3_mod.jpg	Apple 7	0.9995206594467163	0.44	Acierto
Apple7_4_mod.jpg	Apple 7	0.9999831914901733	0.1068	Acierto
Apple8_1_mod.jpg	Apple 8	0.9986808896064758	0.1042	Acierto
Apple8_2_mod.jpg	Apple 7	0.3426731824874878	-0.6367	Fallo
Apple8_3_mod.jpg	Apple 8	0.999858021736145	0.1847	Acierto
Apple8_4_mod.jpg	Apple 8	0.9517735838890076	0.2689	Acierto
Apple9_1_mod.jpg	Apple 9	0.8985431790351868	-0.3702	Acierto
Apple9_2_mod.jpg	Apple Pink Lady 1	0.3150324523448944	0.5778	Fallo
Apple9_3_mod.jpg	Apple Red Delicious 1	0.3644101619720459	-0.5121	Fallo

Imagen	Clase	Confianza	factor brillo	Aciertos/Fallos
Apple9_4_mod.jpg	Apple 19	0.35546302795410156	-0.6096	Fallo
AppleBraeburn_1_mod.jpg	Apple Red 2	0.7694417834281921	0.4834	Fallo
AppleBraeburn_2_mod.jpg	Apple Braeburn 1	0.6277151703834534	0.7676	Acierto
AppleBraeburn_3_mod.jpg	Apple Braeburn 1	0.5333790183067322	-0.6555	Acierto
AppleBraeburn_4_mod.jpg	Apple Braeburn 1	0.9727877974510193	0.4349	Acierto
AppleCrimsonSnow_1_mod.jpg	Apple Granny Smith 1	0.21227945387363434	-0.6526	Fallo
AppleCrimsonSnow_2_mod.jpg	Apple Braeburn 1	0.19858522713184357	-0.7419	Fallo
AppleCrimsonSnow_3_mod.jpg	Apple Crimson Snow 1	0.9679057598114014	0.5791	Acierto
AppleCrimsonSnow_4_mod.jpg	Apple Crimson Snow 1	0.9402360320091248	0.6001	Acierto
AppleGolden1_1_mod.jpg	Apple Golden 1	0.9416868686676025	0.3332	Acierto
AppleGolden1_2_mod.jpg	Apple Golden 2	0.9727625250816345	0.7787	Fallo
AppleGolden1_3_mod.jpg	Apple Golden 1	0.9994261264801025	0.1853	Acierto
AppleGolden1_4_mod.jpg	Apple Golden 1	0.9975425004959106	-0.1734	Acierto
AppleGolden2_1_mod.jpg	Apple Golden 2	0.8839553594589233	-0.5743	Acierto
AppleGolden2_2_mod.jpg	Apple Golden 2	0.999998807907104	0.107	Acierto
AppleGolden2_3_mod.jpg	Apple Golden 2	0.6127097606658936	-0.6057	Acierto
AppleGolden2_4_mod.jpg	Apple Golden 2	0.9999967813491821	0.134	Acierto
AppleGolden3_1_mod.jpg	Apple Golden 3	0.8837485909461975	-0.6237	Acierto
AppleGolden3_2_mod.jpg	Apple Golden 2	0.9927238821983337	0.7918	Fallo
AppleGolden3_3_mod.jpg	Apple Golden 2	0.9119418859481812	0.6172	Fallo
AppleGolden3_4_mod.jpg	Apple Golden 3	0.9459381699562073	0.2528	Acierto
AppleGrannySmith_1_mod.jpg	Apple Granny Smith 1	0.9573362469673157	0.406	Acierto
AppleGrannySmith_2_mod.jpg	Apple Granny Smith 1	0.9796623587608337	-0.6617	Acierto
AppleGrannySmith_3_mod.jpg	Apple Granny Smith 1	0.9976697564125061	-0.3506	Acierto
AppleGrannySmith_4_mod.jpg	Apple Granny Smith 1	0.9541845917701721	0.4912	Acierto
ApplePinkLady_1_mod.jpg	Apple Pink Lady 1	0.9561675190925598	0.3408	Acierto
ApplePinkLady_2_mod.jpg	Apple Pink Lady 1	0.5998683571815491	-0.4212	Acierto
ApplePinkLady_3_mod.jpg	Apple Pink Lady 1	0.9353886842727661	-0.2976	Acierto
ApplePinkLady_4_mod.jpg	Apple Braeburn 1	0.3623479902744293	-0.6101	Fallo
AppleRed1_1_mod.jpg	Apple Red Delicious 1	0.9634771347045898	-0.5067	Fallo
AppleRed1_2_mod.jpg	Apple Red Delicious 1	0.4617759883403778	-0.7217	Fallo
AppleRed1_3_mod.jpg	Apple Red 1	0.9999384880065918	-0.2704	Acierto
AppleRed1_4_mod.jpg	Apple Red 1	0.7388770580291748	0.4688	Acierto
AppleRed2_1_mod.jpg	Apple Red 2	0.8346962332725525	0.5408	Acierto
AppleRed2_2_mod.jpg	Apple Red Delicious 1	0.5548050999641418	-0.7971	Fallo
AppleRed2_3_mod.jpg	Apple Red 2	0.9958284497261047	-0.2666	Acierto
AppleRed2_4_mod.jpg	Apple Red 2	0.9998047947883606	-0.1654	Acierto
AppleRed3_1_mod.jpg	Apple Red 3	0.8021166920661926	-0.464	Acierto
AppleRed3_2_mod.jpg	Apple Red 3	0.4829597473144531	-0.647	Acierto
AppleRed3_3_mod.jpg	Apple Red Yellow 2	0.455852210521698	-0.4947	Fallo
AppleRed3_4_mod.jpg	Apple Red 3	0.9995362758636475	-0.14	Acierto
AppleRedDelicious_1_mod.jpg	Apple Red Delicious 1	0.9995412826538086	0.6108	Acierto
AppleRedDelicious_2_mod.jpg	Apple Red Delicious 1	0.9999077320098877	0.4126	Acierto
AppleRedDelicious_3_mod.jpg	Apple Red Delicious 1	0.9997957348823547	0.2663	Acierto
AppleRedDelicious_4_mod.jpg	Apple Red Delicious 1	0.9605054259300232	-0.4558	Acierto
AppleRedYellow1_1_mod.jpg	Apple Red Yellow 1	0.818432092666626	0.6143	Acierto
AppleRedYellow1_2_mod.jpg	Apple Red Yellow 1	0.9917048215866089	0.7594	Acierto
AppleRedYellow1_3_mod.jpg	Apple Red Yellow 1	0.9999843835830688	0.2242	Acierto
AppleRedYellow1_4_mod.jpg	Apple 11	0.6104416251182556	0.757	Fallo
AppleRedYellow2_1_mod.jpg	Apple Red Yellow 2	0.9997681975364685	0.1113	Acierto
AppleRedYellow2_2_mod.jpg	Apple Red Yellow 2	0.9992803931236267	0.1143	Acierto
AppleRedYellow2_3_mod.jpg	Apple Red Yellow 2	0.9976038336753845	0.7202	Acierto
AppleRedYellow2_4_mod.jpg	Apple Red Yellow 2	0.9820036292076111	-0.3601	Acierto

Tabla 34: Resultados de las predicciones del entrenamiento de las manzanas con imágenes modificadas con cambios de iluminación.

Imagen	Clase	Confianza	factor_brillo	Aciertos/Fallos
Pear1_1_mod.jpg	Pear 1	0.9978464841842651	-0.3512	Acierto
Pear1_2_mod.jpg	Pear 1	0.9976689219474792	0.3154	Acierto
Pear1_3_mod.jpg	Pear Kaiser 1	0.6305184364318848	-0.5655	Fallo
Pear1_4_mod.jpg	Pear 1	0.9999841451644897	0.1691	Acierto
Pear1_5_mod.jpg	Pear 2	0.4629131853580475	0.6992	Fallo
Pear2_1_mod.jpg	Pear 2	0.9997312426567078	0.6063	Acierto
Pear2_2_mod.jpg	Pear 2	0.9999488592147827	0.3469	Acierto
Pear2_3_mod.jpg	Pear 2	0.9999693632125854	0.496	Acierto
Pear2_4_mod.jpg	Pear 2	0.5724171996116638	-0.5332	Acierto
Pear2_5_mod.jpg	Pear Abate 1	0.27571019530296326	0.6782	Fallo
Pear3_1_mod.jpg	Pear Kaiser 1	0.5377439260482788	-0.606	Fallo
Pear3_2_mod.jpg	Pear 3	0.9730369448661804	0.5491	Acierto
Pear3_3_mod.jpg	Pear 3	0.9979711174964905	-0.369	Acierto
Pear3_4_mod.jpg	Pear 3	0.9999996423721313	-0.1904	Acierto
Pear3_5_mod.jpg	Pear 3	0.9996554851531982	0.4145	Acierto
PearAbate_1_mod.jpg	Pear Abate 1	0.67226243019104	0.7158	Acierto
PearAbate_2_mod.jpg	Pear Abate 1	0.9999418258666992	-0.107	Acierto
PearAbate_3_mod.jpg	Pear Abate 1	0.9997261166572571	-0.147	Acierto
PearAbate_4_mod.jpg	Pear Abate 1	0.9998914003372192	0.5657	Acierto
PearAbate_5_mod.jpg	Pear Abate 1	0.9068343639373779	0.6201	Acierto
PearForelle_1_mod.jpg	Pear Forelle 1	0.9999797344207764	-0.121	Acierto
PearForelle_2_mod.jpg	Pear Forelle 1	0.9994639754295349	-0.3696	Acierto
PearForelle_3_mod.jpg	Pear Forelle 1	0.5224882364273071	0.5131	Acierto
PearForelle_4_mod.jpg	Pear Kaiser 1	0.7207498550415039	-0.2217	Fallo
PearForelle_5_mod.jpg	Pear Kaiser 1	0.7120259404182434	-0.2806	Fallo
PearKaiser_1_mod.jpg	Pear Kaiser 1	0.9999140501022339	0.3947	Acierto
PearKaiser_2_mod.jpg	Pear Kaiser 1	0.9999990463256836	-0.7187	Acierto
PearKaiser_3_mod.jpg	Pear Kaiser 1	0.9999645948410034	-0.3312	Acierto
PearKaiser_4_mod.jpg	Pear Kaiser 1	0.9998313188552856	0.348	Acierto
PearKaiser_5_mod.jpg	Pear Kaiser 1	0.9836132526397705	-0.4144	Acierto
PearMonster_1_mod.jpg	Pear Monster 1	0.999984622001648	-0.2061	Acierto
PearMonster_2_mod.jpg	Pear Monster 1	0.8337058424949646	0.5366	Acierto
PearMonster_3_mod.jpg	Pear Monster 1	0.9999231100082397	-0.2384	Acierto
PearMonster_4_mod.jpg	Pear Monster 1	0.999910831451416	-0.557	Acierto
PearMonster_5_mod.jpg	Pear Monster 1	0.9999619722366333	-0.2725	Acierto
PearRed_1_mod.jpg	Pear Red 1	0.9973660111427307	0.4422	Acierto
PearRed_2_mod.jpg	Pear Kaiser 1	0.9999902248382568	-0.7428	Fallo
PearRed_3_mod.jpg	Pear Red 1	0.9999483823776245	0.2405	Acierto
PearRed_4_mod.jpg	Pear 2	0.5249549746513367	0.7866	Fallo
PearRed_5_mod.jpg	Pear Red 1	0.8969948291778564	-0.4083	Acierto
PearStone_1_mod.jpg	Pear Stone 1	0.9999798536300659	0.2301	Acierto
PearStone_2_mod.jpg	Pear Kaiser 1	0.7949471473693848	-0.4859	Fallo
PearStone_3_mod.jpg	Pear Stone 1	0.9999980926513672	0.117	Acierto
PearStone_4_mod.jpg	Pear Kaiser 1	0.9716890454292297	-0.5787	Fallo
PearStone_5_mod.jpg	Pear Kaiser 1	0.9855297207832336	-0.5981	Fallo
PearWilliams_1_mod.jpg	Pear Kaiser 1	0.9997130036354065	-0.7906	Fallo
PearWilliams_2_mod.jpg	Pear Williams 1	0.9999057054519653	0.3848	Acierto
PearWilliams_3_mod.jpg	Pear Williams 1	0.9998557567596436	-0.2454	Acierto
PearWilliams_4_mod.jpg	Pear Williams 1	0.9958168864250183	-0.3154	Acierto
PearWilliams_5_mod.jpg	Pear Williams 1	0.9996312856674194	-0.3027	Acierto

Tabla 35: Resultados de las predicciones del entrenamiento de las peras con imágenes modificadas con cambios de iluminación.

Imagen	Clase	Confianza	factor_brillo	AcieritosFallos
GrapeBlue_1_mod.jpg	Grape Blue 1	0.992293119430542	0.4613	Acierto
GrapeBlue_2_mod.jpg	Grape Blue 1	0.8254889249801636	-0.6247	Acierto
GrapeBlue_3_mod.jpg	Grape Blue 1	0.5375772714614868	-0.3419	Acierto
GrapeBlue_4_mod.jpg	Grape Blue 1	0.999900221824646	0.3385	Acierto
GrapeBlue_5_mod.jpg	Grape Blue 1	0.999392032623291	0.3494	Acierto
GrapePink_1_mod.jpg	Grape Pink 1	0.98894202709198	0.1478	Acierto
GrapePink_2_mod.jpg	Grape White 1	0.43458980321884155	0.7876	Fallo
GrapePink_3_mod.jpg	Grape White 1	0.6582306027412415	0.7386	Fallo
GrapePink_4_mod.jpg	Grape Pink 1	0.9956199526786804	0.6292	Acierto
GrapePink_5_mod.jpg	Grape Blue 1	0.989007830619812	-0.5875	Fallo
GrapeWhite1_1_mod.jpg	Grape White 1	0.9999035596847534	0.1967	Acierto
GrapeWhite1_2_mod.jpg	Grape White 2	0.3654955327510834	0.6384	Fallo
GrapeWhite1_3_mod.jpg	Grape White 1	0.9957903027534485	0.3879	Acierto
GrapeWhite1_4_mod.jpg	Grape White 1	0.6467863917350769	-0.5453	Acierto
GrapeWhite1_5_mod.jpg	Grape White 1	0.9953997731208801	0.4109	Acierto
GrapeWhite2_1_mod.jpg	Grape White 2	0.9999524354934692	-0.5556	Acierto
GrapeWhite2_2_mod.jpg	Grape White 2	0.9990097284317017	-0.446	Acierto
GrapeWhite2_3_mod.jpg	Grape White 2	0.6375636458396912	-0.7193	Acierto
GrapeWhite2_4_mod.jpg	Grape White 2	0.9999955892562866	-0.1955	Acierto
GrapeWhite2_5_mod.jpg	Grape White 2	0.9977026581764221	0.3672	Acierto
GrapeWhite3_1_mod.jpg	Grape White 3	0.9999736547470093	-0.2021	Acierto
GrapeWhite3_2_mod.jpg	Grape White 2	0.9620778560638428	0.7466	Fallo
GrapeWhite3_3_mod.jpg	Grape White 3	0.999948263168335	0.2	Acierto
GrapeWhite3_4_mod.jpg	Grape White 3	0.9994840621948242	0.2868	Acierto
GrapeWhite3_5_mod.jpg	Grape White 3	0.935917317867279	0.5194	Acierto
GrapeWhite4_1_mod.jpg	Grape Blue 1	0.9447188973426819	-0.6004	Fallo
GrapeWhite4_2_mod.jpg	Grape White 4	0.9976953864097595	0.5483	Acierto
GrapeWhite4_3_mod.jpg	Grape Blue 1	0.9696220755577087	-0.6372	Fallo
GrapeWhite4_4_mod.jpg	Grape White 4	0.9990683197975159	0.4519	Acierto
GrapeWhite4_5_mod.jpg	Grape White 4	0.9993997812271118	0.5214	Acierto

Tabla 36: Resultados de las predicciones del entrenamiento de las uvas con imágenes modificadas con cambios de iluminación.

Imagen	Clase	Confianza	factor brillo	Aciertos/Fallos
Cherry1_1_mod.jpg	Cherry 1	0.9995489716529846	0.1305	Acierto
Cherry1_2_mod.jpg	Cherry 1	0.9878722429275513	0.3712	Acierto
Cherry1_3_mod.jpg	Cherry 1	0.9999252557754517	-0.2733	Acierto
Cherry1_4_mod.jpg	Cherry 1	0.9656891822814941	0.3845	Acierto
Cherry1_5_mod.jpg	Cherry 1	0.4854602813720703	0.6291	Acierto
Cherry2_1_mod.jpg	Cherry 1	0.8227143883705139	-0.4888	Fallo
Cherry2_2_mod.jpg	Cherry 2	0.9998955726623535	-0.1462	Acierto
Cherry2_3_mod.jpg	Cherry 2	0.9999866485595703	0.2714	Acierto
Cherry2_4_mod.jpg	Cherry 1	0.9764707088470459	-0.6332	Fallo
Cherry2_5_mod.jpg	Cherry 2	0.9999678134918213	-0.1632	Acierto
CherryRainier_1_mod.jpg	Cherry Rainier 1	0.9910974502563477	0.477	Acierto
CherryRainier_2_mod.jpg	Cherry Rainier 1	0.9653469324111938	0.5635	Acierto
CherryRainier_3_mod.jpg	Cherry 1	0.9659522175788879	-0.6789	Fallo
CherryRainier_4_mod.jpg	Cherry Wax Black 1	0.8207156658172607	-0.7355	Fallo
CherryRainier_5_mod.jpg	Cherry Rainier 1	0.9998579025268555	0.1695	Acierto
CherryWaxBlack_1_mod.jpg	Cherry Wax Black 1	0.9955371618270874	0.6313	Acierto
CherryWaxBlack_2_mod.jpg	Cherry Wax Black 1	0.9985999464988708	-0.1967	Acierto
CherryWaxBlack_3_mod.jpg	Cherry Wax Black 1	0.8904517889022827	0.798	Acierto
CherryWaxBlack_4_mod.jpg	Cherry Wax Black 1	0.9991655349731445	-0.1294	Acierto
CherryWaxBlack_5_mod.jpg	Cherry Wax Black 1	0.9622101783752441	0.7525	Acierto
CherryWaxNotRippen_1_mod.jpg	Cherry Rainier 1	0.7094448208808899	0.4129	Fallo
CherryWaxNotRippen_2_mod.jpg	Cherry Wax not rippen 1	0.4201986789703369	0.3964	Acierto
CherryWaxNotRippen_3_mod.jpg	Cherry Wax Yellow 1	0.6507059335708618	0.5768	Fallo
CherryWaxNotRippen_4_mod.jpg	Cherry 1	0.9444551467895508	-0.7253	Fallo
CherryWaxNotRippen_5_mod.jpg	Cherry Wax not rippen 1	0.9657815098762512	0.3578	Acierto
CherryWaxRed_1_mod.jpg	Cherry 1	0.5827541947364807	-0.4371	Fallo
CherryWaxRed_2_mod.jpg	Cherry Wax Red 1	0.9607387781143188	0.3999	Acierto
CherryWaxRed_3_mod.jpg	Cherry Wax Red 1	0.6783260107040405	0.5965	Acierto
CherryWaxRed_4_mod.jpg	Cherry Wax Black 1	0.9788640141487122	-0.4293	Fallo
CherryWaxRed_5_mod.jpg	Cherry Wax Yellow 1	0.6709152460098267	0.6494	Fallo
CherryWaxYellow_1_mod.jpg	Cherry Wax Yellow 1	0.9997859597206116	0.2831	Acierto
CherryWaxYellow_2_mod.jpg	Cherry Wax Yellow 1	0.9999475479125977	-0.1012	Acierto
CherryWaxYellow_3_mod.jpg	Cherry 1	0.9716429114341736	-0.7418	Fallo
CherryWaxYellow_4_mod.jpg	Cherry Wax Red 1	0.5123093724250793	-0.6657	Fallo
CherryWaxYellow_5_mod.jpg	Cherry Wax Yellow 1	0.9997257590293884	0.4347	Acierto

Tabla 37: Resultados de las predicciones del entrenamiento de las cerezas con imágenes modificadas con cambios de iluminación.

Imagen	Clase	Confianza	factor_brillo	Aciertos/Fallos
Apple5_1_mod.jpg	Apple 5	0.8358075022697449	0.4419	Acierto
Apple5_2_mod.jpg	Cherry 1	0.9046783447265625	-0.2867	Fallo
Apple5_3_mod.jpg	Cherry 1	0.7574732303619385	-0.6907	Fallo
Apple5_4_mod.jpg	Apple 5	0.8642104268074036	0.6044	Acierto
AppleRed2_1_mod.jpg	Grape White 2	0.651940643787384	0.7639	Fallo
AppleRed2_2_mod.jpg	Cherry 1	0.9126134514808655	-0.3414	Fallo
AppleRed2_3_mod.jpg	Cherry 1	0.8849945664405823	-0.7073	Fallo
AppleRed2_4_mod.jpg	Apple Red 2	0.6374754309654236	-0.486	Acierto
ApppleGrannySmith_1_mod.jpg	Apple Granny Smith 1	0.8361141681671143	0.6158	Acierto
ApppleGrannySmith_2_mod.jpg	Apple Granny Smith 1	0.9999415874481201	0.1824	Acierto
ApppleGrannySmith_3_mod.jpg	Grape White 2	0.3500823378562927	0.7337	Fallo
ApppleGrannySmith_4_mod.jpg	Apple Granny Smith 1	0.5639283657073975	-0.7007	Acierto
Banana1_1_mod.jpg	Banana 1	0.9419185519218445	0.6175	Acierto
Banana1_2_mod.jpg	Banana 1	0.9271149039268494	-0.5558	Acierto
Banana1_3_mod.jpg	Banana 1	0.9998633861541748	-0.2307	Acierto
Banana1_4_mod.jpg	Banana 1	0.6333215236663818	0.7001	Acierto
Banana3_1_mod.jpg	Banana 3	0.9993384480476379	-0.3194	Acierto
Banana3_2_mod.jpg	Banana 3	0.9997989535331726	0.3904	Acierto
Banana3_3_mod.jpg	Banana 3	0.9528309106826782	-0.6139	Acierto
Banana3_4_mod.jpg	Banana 3	0.9997537732124329	0.3807	Acierto
BananaLadyFinger_1_mod.jpg	Banana Lady Finger 1	0.9998202919960022	0.5573	Acierto
BananaLadyFinger_2_mod.jpg	Banana Lady Finger 1	0.9592573046684265	-0.4517	Acierto
BananaLadyFinger_3_mod.jpg	Banana Lady Finger 1	0.9999690055847168	-0.184	Acierto
BananaLadyFinger_4_mod.jpg	Banana Lady Finger 1	0.967798113822937	-0.5381	Acierto
Cherry1_1_mod.jpg	Cherry 1	0.9610589742660522	0.3146	Acierto
Cherry1_2_mod.jpg	Cherry 1	0.9998384714126587	-0.3992	Acierto
Cherry1_3_mod.jpg	Cherry 1	0.9988375306129456	-0.5778	Acierto
Cherry1_4_mod.jpg	Cherry 1	0.5929599404335022	0.3275	Acierto
Cherry2_1_mod.jpg	Cherry 2	0.9960752129554749	0.1081	Acierto
Cherry2_2_mod.jpg	Cherry 2	0.9999912977218628	-0.1503	Acierto
Cherry2_3_mod.jpg	Cherry 1	0.9865994453430176	-0.6975	Fallo
Cherry2_4_mod.jpg	Cherry 2	0.9998069405555725	-0.1055	Acierto
GrapeWhite1_1_mod.jpg	Grape White 2	0.8992182016372681	0.4944	Fallo
GrapeWhite1_2_mod.jpg	Grape White 1	0.9990192651748657	0.2576	Acierto
GrapeWhite1_3_mod.jpg	Grape White 1	0.6696192026138306	-0.513	Acierto
GrapeWhite1_4_mod.jpg	Grape White 1	0.9998539686203003	-0.3173	Acierto
GrapeWhite2_1_mod.jpg	Grape White 2	0.8702342510223389	-0.5512	Acierto
GrapeWhite2_2_mod.jpg	Grape White 2	0.9978411197662354	-0.4739	Acierto
GrapeWhite2_3_mod.jpg	Grape White 2	0.9978631138801575	-0.4175	Acierto
GrapeWhite2_4_mod.jpg	Cherry 1	0.921436607837677	-0.7844	Fallo
GrapeWhite4_1_mod.jpg	Banana Lady Finger 1	0.2443777322769165	0.784	Fallo
GrapeWhite4_2_mod.jpg	Grape White 4	0.9998262524604797	-0.2333	Acierto
GrapeWhite4_3_mod.jpg	Cherry 1	0.9506184458732605	-0.61	Fallo
GrapeWhite4_4_mod.jpg	Grape White 4	0.9769615530967712	-0.3148	Acierto

Imagen	Clase	Confianza	factor brillo	Aciertos/Fallos
Lemon1_1_mod.jpg	Lemon 1	0.9999830722808838	-0.4154	Acierto
Lemon1_2_mod.jpg	Grape White 2	0.6020362973213196	0.5697	Fallo
Lemon1_3_mod.jpg	Grape White 2	0.7533661127090454	0.705	Fallo
Lemon1_4_mod.jpg	Lemon 1	0.9999887943267822	-0.1196	Acierto
MelonPielDeSapo_1_mod.jpg	Cherry 1	0.9575172066688538	-0.7969	Fallo
MelonPielDeSapo_2_mod.jpg	Melon Piel de Sapo 1	0.9997416138648987	-0.3767	Acierto
MelonPielDeSapo_3_mod.jpg	Cherry 1	0.7533740401268005	-0.7702	Fallo
MelonPielDeSapo_4_mod.jpg	Melon Piel de Sapo 1	0.8656711578369141	-0.6074	Acierto
Orange_1_mod.jpg	Orange 1	0.5310907959938049	-0.759	Acierto
Orange_2_mod.jpg	Orange 1	0.9987801909446716	-0.3749	Acierto
Orange_3_mod.jpg	Orange 1	0.7029022574424744	0.3605	Acierto
Orange_4_mod.jpg	Lemon 1	0.999632716178894	0.659	Fallo
Peach1_1_mod.jpg	Cherry 1	0.7048499584197998	-0.4304	Fallo
Peach1_2_mod.jpg	Peach 1	0.8990044593811035	0.5884	Acierto
Peach1_3_mod.jpg	Peach 1	0.9998327493667603	0.2434	Acierto
Peach1_4_mod.jpg	Grape White 2	0.7002416253089905	0.6158	Fallo
Pear1_1_mod.jpg	Pear 1	0.9977813363075256	0.3211	Acierto
Pear1_2_mod.jpg	Pear 2	0.6954896450042725	0.4579	Fallo
Pear1_3_mod.jpg	Grape White 2	0.2828911244869232	0.6977	Fallo
Pear1_4_mod.jpg	Pear 1	0.9983452558517456	-0.2816	Acierto
Pear2_1_mod.jpg	Pear 2	0.9999755620956421	0.336	Acierto
Pear2_2_mod.jpg	Pear 2	0.9903656244277954	0.4582	Acierto
Pear2_3_mod.jpg	Pear 2	0.9986540079116821	0.3543	Acierto
Pear2_4_mod.jpg	Pear 2	0.9999654293060303	-0.1245	Acierto
PearForelle_1_mod.jpg	Pear 2	0.9461445212364197	0.609	Fallo
PearForelle_2_mod.jpg	Pear Forelle 1	0.9775474071502686	0.2274	Acierto
PearForelle_3_mod.jpg	Pear Forelle 1	0.6947337985038757	0.4725	Acierto
PearForelle_4_mod.jpg	Apple Granny Smith 1	0.24773551523685455	-0.6357	Fallo
Pineapple1_1_mod.jpg	Pineapple 1	0.9997186064720154	0.1141	Acierto
Pineapple1_2_mod.jpg	Cherry 1	0.780067503452301	-0.5986	Fallo
Pineapple1_3_mod.jpg	Pineapple 1	0.9997567534446716	0.1433	Acierto
Pineapple1_4_mod.jpg	Cherry 1	0.8326575756072998	-0.7881	Fallo
Strawberry1_1_mod.jpg	Strawberry 1	0.9995837807655334	0.2848	Acierto
Strawberry1_2_mod.jpg	Strawberry 1	0.9986259937286377	0.198	Acierto
Strawberry1_3_mod.jpg	Strawberry 1	0.7868172526359558	0.7875	Acierto
Strawberry1_4_mod.jpg	Pear 2	0.6759077906608582	0.7939	Fallo
StrawberryWedge_1_mod.jpg	Strawberry Wedge 1	0.9917601943016052	-0.3482	Acierto
StrawberryWedge_2_mod.jpg	Cherry 1	0.93057781457901	-0.7508	Fallo
StrawberryWedge_3_mod.jpg	Cherry 1	0.9775089025497437	-0.7606	Fallo
StrawberryWedge_4_mod.jpg	Apple 5	0.3110276162624359	-0.7937	Fallo
Watermelon1_1_mod.jpg	Watermelon 1	0.9997249245643616	-0.2013	Acierto
Watermelon1_2_mod.jpg	Watermelon 1	0.9999195337295532	-0.1679	Acierto
Watermelon1_3_mod.jpg	Watermelon 1	0.9995135068893433	0.1505	Acierto
Watermelon1_4_mod.jpg	Cherry 1	0.6867306232452393	-0.7617	Fallo

Tabla 38: Resultados de las predicciones del entrenamiento de las frutas conjuntas con imágenes modificadas con cambios de iluminación.

10.ANEXO 4: TABLAS DE RESULTADOS DE LAS PREDICCIONES EMPLEANDO LOS MODELOS CON CAMBIOS DE ILUMINACIÓN

Imagen	Clase	Confianza	factor_brillo	Acieros/Fallos
Apple10_1.jpg	Apple 10	0.9999475479125977	0.0	Acierto
Apple10_1_mod.jpg	Apple 10	0.9758608341217041	-0.4116	Acierto
Apple10_2.jpg	Apple 10	0.999606192111969	0.0	Acierto
Apple10_2_mod.jpg	Apple 18	0.35518720746040344	-0.7529	Fallo
Apple10_3.jpg	Apple 10	0.999498724937439	0.0	Acierto
Apple10_3_mod.jpg	Apple 10	0.999624490737915	0.1084	Acierto
Apple10_4.jpg	Apple 10	0.9998505115509033	0.0	Acierto
Apple10_4_mod.jpg	Apple 10	0.9908762574195862	-0.4329	Acierto
Apple11_1.jpg	Apple 11	0.9995833039283752	0.0	Acierto
Apple11_1_mod.jpg	Apple 11	0.8288116455078125	-0.7475	Acierto
Apple11_2.jpg	Apple 11	0.9998902082443237	0.0	Acierto
Apple11_2_mod.jpg	Apple 11	0.9998562335968018	0.1253	Acierto
Apple11_3.jpg	Apple 11	0.9996262788772583	0.0	Acierto
Apple11_3_mod.jpg	Apple 11	0.9995563626289368	-0.1242	Acierto
Apple11_4.jpg	Apple 11	0.9995404481887817	0.0	Acierto
Apple11_4_mod.jpg	Apple 11	0.6388610005378723	0.7411	Acierto
Apple12_1.jpg	Apple 12	0.9999607801437378	0.0	Acierto
Apple12_1_mod.jpg	Apple 12	0.9999978542327881	-0.3901	Acierto
Apple12_2.jpg	Apple 12	0.9999904632568359	0.0	Acierto
Apple12_2_mod.jpg	Apple 12	0.9307853579521179	-0.5962	Acierto
Apple12_3.jpg	Apple 12	0.9999396800994873	0.0	Acierto
Apple12_3_mod.jpg	Apple 12	0.9999502897262573	0.1768	Acierto
Apple12_4.jpg	Apple 12	0.9999682903289795	0.0	Acierto
Apple12_4_mod.jpg	Apple 12	0.999911904335022	0.2982	Acierto
Apple13_1.jpg	Apple 13	0.9995762705802917	0.0	Acierto
Apple13_1_mod.jpg	Apple 13	0.6294741630554199	-0.6656	Acierto
Apple13_2.jpg	Apple 13	0.9996575117111206	0.0	Acierto
Apple13_2_mod.jpg	Apple 13	0.994413435459137	0.607	Acierto
Apple13_3.jpg	Apple 13	0.9989314675331116	0.0	Acierto
Apple13_3_mod.jpg	Apple 13	0.9999405145645142	0.4732	Acierto
Apple13_4.jpg	Apple 13	0.9981335997581482	0.0	Acierto
Apple13_4_mod.jpg	Apple 13	0.7649602293968201	-0.5795	Acierto
Apple14_1.jpg	Apple 14	0.9999231100082397	0.0	Acierto
Apple14_1_mod.jpg	Apple 14	0.6865800023078918	-0.58	Acierto
Apple14_2.jpg	Apple 14	0.999927282333374	0.0	Acierto
Apple14_2_mod.jpg	Apple 14	0.9983245730400085	0.6142	Acierto
Apple14_3.jpg	Apple 14	0.9998248219490051	0.0	Acierto
Apple14_3_mod.jpg	Apple 14	0.9968294501304626	-0.2498	Acierto
Apple14_4.jpg	Apple 14	0.9945567846298218	0.0	Acierto
Apple14_4_mod.jpg	Apple 14	0.9988899827003479	0.3108	Acierto
Apple17_1.jpg	Apple 17	0.9161380529403687	0.0	Acierto
Apple17_1_mod.jpg	Apple 17	0.9779234528541565	0.6339	Acierto
Apple17_2.jpg	Apple 17	0.9998594522476196	0.0	Acierto
Apple17_2_mod.jpg	Apple 17	0.9999778270721436	0.6468	Acierto
Apple17_3.jpg	Apple 17	0.9994204044342041	0.0	Acierto
Apple17_3_mod.jpg	Apple 17	0.9997081160545349	0.5366	Acierto
Apple17_4.jpg	Apple 17	0.9960926175117493	0.0	Acierto
Apple17_4_mod.jpg	Apple 17	0.9921830296516418	0.4082	Acierto
Apple18_1.jpg	Apple 18	0.9999948740005493	0.0	Acierto
Apple18_1_mod.jpg	Apple 18	0.9999910593032837	0.2835	Acierto
Apple18_2.jpg	Apple 18	0.9999749660491943	0.0	Acierto
Apple18_2_mod.jpg	Apple 18	0.9999746084213257	0.2513	Acierto

Imagen	Clase	Confianza	factor_brillo	Aciertos/Fallos
Apple18_3.jpg	Apple 18	0.9999927282333374	0.0	Acierto
Apple18_3_mod.jpg	Apple 18	0.9999836683273315	0.1404	Acierto
Apple18_4.jpg	Apple 18	0.999995231628418	0.0	Acierto
Apple18_4_mod.jpg	Apple 17	0.2404213845729828	-0.7584	Fallo
Apple19_1.jpg	Apple 19	0.9996008276939392	0.0	Acierto
Apple19_1_mod.jpg	Apple 19	0.9997512698173523	0.3169	Acierto
Apple19_2.jpg	Apple 19	0.9991660118103027	0.0	Acierto
Apple19_2_mod.jpg	Apple 19	0.9990044236183167	-0.1087	Acierto
Apple19_3.jpg	Apple 19	0.9994865655899048	0.0	Acierto
Apple19_3_mod.jpg	Apple 19	0.999899864196777	0.63	Acierto
Apple19_4.jpg	Apple 19	0.999570906162262	0.0	Acierto
Apple19_4_mod.jpg	Apple 19	0.9998353719711304	0.5578	Acierto
Apple5_1.jpg	Apple 5	0.9956721067428589	0.0	Acierto
Apple5_1_mod.jpg	Apple 5	0.7127882242202759	0.7556	Acierto
Apple5_2.jpg	Apple 5	0.9998273849487305	0.0	Acierto
Apple5_2_mod.jpg	Apple 5	0.4549902081489563	-0.6244	Acierto
Apple5_3.jpg	Apple 5	0.9994087219238281	0.0	Acierto
Apple5_3_mod.jpg	Apple 5	0.34751757979393005	-0.7105	Acierto
Apple5_4.jpg	Apple 5	0.9994816184043884	0.0	Acierto
Apple5_4_mod.jpg	Apple 5	0.8299427628517151	-0.3736	Acierto
Apple6_1.jpg	Apple 6	0.9996052384376526	0.0	Acierto
Apple6_1_mod.jpg	Apple 6	0.9035007953643799	0.7412	Acierto
Apple6_2.jpg	Apple 6	0.9994394183158875	0.0	Acierto
Apple6_2_mod.jpg	Apple 6	0.9947817921638489	0.5315	Acierto
Apple6_3.jpg	Apple 6	0.9997134804725647	0.0	Acierto
Apple6_3_mod.jpg	Apple 6	0.9998680353164673	0.3866	Acierto
Apple6_4.jpg	Apple 6	0.9998459815979004	0.0	Acierto
Apple6_4_mod.jpg	Apple 6	0.9998375177383423	-0.3948	Acierto
Apple7_1.jpg	Apple 7	0.9998471736907959	0.0	Acierto
Apple7_1_mod.jpg	Apple 7	0.9999806880950928	0.2114	Acierto
Apple7_2.jpg	Apple 7	0.9999369382858276	0.0	Acierto
Apple7_2_mod.jpg	Apple 7	0.9973076581954956	-0.712	Acierto
Apple7_3.jpg	Apple 7	0.9999344348907471	0.0	Acierto
Apple7_3_mod.jpg	Apple 7	0.9999908208847046	0.44	Acierto
Apple7_4.jpg	Apple 7	0.9999583959579468	0.0	Acierto
Apple7_4_mod.jpg	Apple 7	0.9999301433563232	0.1068	Acierto
Apple8_1.jpg	Apple 8	0.9999648332595825	0.0	Acierto
Apple8_1_mod.jpg	Apple 8	0.9999783039093018	0.1042	Acierto
Apple8_2.jpg	Apple 8	0.9997852444648743	0.0	Acierto
Apple8_2_mod.jpg	Apple 8	0.9121819138526917	-0.6367	Acierto
Apple8_3.jpg	Apple 8	0.9999488592147827	0.0	Acierto
Apple8_3_mod.jpg	Apple 8	0.9999450445175171	0.1847	Acierto
Apple8_4.jpg	Apple 8	0.9936125874519348	0.0	Acierto
Apple8_4_mod.jpg	Apple 8	0.9982985854148865	0.2689	Acierto
Apple9_1.jpg	Apple 9	0.9977509379386902	0.0	Acierto
Apple9_1_mod.jpg	Apple 9	0.9994101524353027	-0.3702	Acierto
Apple9_2.jpg	Apple 9	0.9996442794799805	0.0	Acierto
Apple9_2_mod.jpg	Apple 9	0.9999805688858032	0.5778	Acierto
Apple9_3.jpg	Apple 9	0.9995742440223694	0.0	Acierto
Apple9_3_mod.jpg	Apple 9	0.99718177318573	-0.5121	Acierto
Apple9_4.jpg	Apple 9	0.9999876022338867	0.0	Acierto
Apple9_4_mod.jpg	Apple 9	0.8906719088554382	-0.6096	Acierto

Imagen	Clase	Confianza	factor_brillo	Aciertos/Fallos
AppleBraeburn_1.jpg	Apple Braeburn 1	0.999988317489624	0.0	Acierto
AppleBraeburn_1_mod.jpg	Apple Braeburn 1	0.9999979734420776	0.4834	Acierto
AppleBraeburn_2.jpg	Apple Braeburn 1	0.999998927116394	0.0	Acierto
AppleBraeburn_2_mod.jpg	Apple Braeburn 1	0.9999591112136841	0.7676	Acierto
AppleBraeburn_3.jpg	Apple Braeburn 1	0.9999966621398926	0.0	Acierto
AppleBraeburn_3_mod.jpg	Apple Braeburn 1	0.9626673460006714	-0.6555	Acierto
AppleBraeburn_4.jpg	Apple Braeburn 1	0.9998526573181152	0.0	Acierto
AppleBraeburn_4_mod.jpg	Apple Braeburn 1	0.9999483823776245	0.4349	Acierto
AppleCrimsonSnow_1.jpg	Apple Crimson Snow 1	0.9999511241912842	0.0	Acierto
AppleCrimsonSnow_1_mod.jpg	Apple Crimson Snow 1	0.9580066204071045	-0.6526	Acierto
AppleCrimsonSnow_2.jpg	Apple Crimson Snow 1	0.9999510049819946	0.0	Acierto
AppleCrimsonSnow_2_mod.jpg	Apple Crimson Snow 1	0.924858808517456	-0.7419	Acierto
AppleCrimsonSnow_3.jpg	Apple Crimson Snow 1	0.9999755620956421	0.0	Acierto
AppleCrimsonSnow_3_mod.jpg	Apple Crimson Snow 1	0.9999240636825562	0.5791	Acierto
AppleCrimsonSnow_4.jpg	Apple Crimson Snow 1	0.9999724626541138	0.0	Acierto
AppleCrimsonSnow_4_mod.jpg	Apple Crimson Snow 1	0.9999905824661255	0.6001	Acierto
AppleGolden1_1.jpg	Apple Golden 1	0.9994924068450928	0.0	Acierto
AppleGolden1_1_mod.jpg	Apple Golden 1	0.999954342842102	0.3332	Acierto
AppleGolden1_2.jpg	Apple Golden 1	0.9998927116394043	0.0	Acierto
AppleGolden1_2_mod.jpg	Apple Golden 1	0.9844003319740295	0.7787	Acierto
AppleGolden1_3.jpg	Apple Golden 1	0.9998869895935059	0.0	Acierto
AppleGolden1_3_mod.jpg	Apple Golden 1	0.9999881982803345	0.1853	Acierto
AppleGolden1_4.jpg	Apple Golden 1	0.9998219609260559	0.0	Acierto
AppleGolden1_4_mod.jpg	Apple Golden 1	0.9997311234474182	-0.1734	Acierto
AppleGolden2_1.jpg	Apple Golden 2	0.9998531341552734	0.0	Acierto
AppleGolden2_1_mod.jpg	Apple Golden 2	0.9986213445663452	-0.5743	Acierto
AppleGolden2_2.jpg	Apple Golden 2	0.9999582767486572	0.0	Acierto
AppleGolden2_2_mod.jpg	Apple Golden 2	0.9999672174453735	0.107	Acierto
AppleGolden2_3.jpg	Apple Golden 2	0.9996123909950256	0.0	Acierto
AppleGolden2_3_mod.jpg	Apple Golden 2	0.9945201277732849	-0.6057	Acierto
AppleGolden2_4.jpg	Apple Golden 2	0.9999582767486572	0.0	Acierto
AppleGolden2_4_mod.jpg	Apple Golden 2	0.9999873638153076	0.134	Acierto
AppleGolden3_1.jpg	Apple Golden 3	0.9904758334159851	0.0	Acierto
AppleGolden3_1_mod.jpg	Apple Golden 3	0.9965509176254272	-0.6237	Acierto
AppleGolden3_2.jpg	Apple Golden 3	0.9998700618743896	0.0	Acierto
AppleGolden3_2_mod.jpg	Apple Golden 3	0.5258036851882935	0.7918	Acierto
AppleGolden3_3.jpg	Apple Golden 3	0.9990723133087158	0.0	Acierto
AppleGolden3_3_mod.jpg	Apple Golden 3	0.9788028001785278	0.6172	Acierto
AppleGolden3_4.jpg	Apple Golden 3	0.996124804019928	0.0	Acierto
AppleGolden3_4_mod.jpg	Apple Golden 3	0.9952919483184814	0.2528	Acierto
AppleGrannySmith_1.jpg	Apple Granny Smith 1	0.9992170333862305	0.0	Acierto
AppleGrannySmith_1_mod.jpg	Apple Granny Smith 1	0.9987452030181885	0.406	Acierto
AppleGrannySmith_2.jpg	Apple Granny Smith 1	0.9999210834503174	0.0	Acierto
AppleGrannySmith_2_mod.jpg	Apple Granny Smith 1	0.999984622001648	-0.6617	Acierto
AppleGrannySmith_3.jpg	Apple Granny Smith 1	0.9992302656173706	0.0	Acierto
AppleGrannySmith_3_mod.jpg	Apple Granny Smith 1	0.9995525479316711	-0.3506	Acierto
AppleGrannySmith_4.jpg	Apple Granny Smith 1	0.9999784231185913	0.0	Acierto
AppleGrannySmith_4_mod.jpg	Apple Granny Smith 1	0.9999680519104004	0.4912	Acierto
ApplePinkLady_1.jpg	Apple Pink Lady 1	0.9999672174453735	0.0	Acierto
ApplePinkLady_1_mod.jpg	Apple Pink Lady 1	0.9999066591262817	0.3408	Acierto
ApplePinkLady_2.jpg	Apple Pink Lady 1	0.999925971031189	0.0	Acierto
ApplePinkLady_2_mod.jpg	Apple Pink Lady 1	0.9999202489852905	-0.4212	Acierto

Imagen	Clase	Confianza	factor brillo	Aciertos/Fallos
ApplePinkLady_3.jpg	Apple Pink Lady 1	0.9999644756317139	0.0	Acierto
ApplePinkLady_3_mod.jpg	Apple Pink Lady 1	0.9999971389770508	-0.2976	Acierto
ApplePinkLady_4.jpg	Apple Pink Lady 1	0.9995083808898926	0.0	Acierto
ApplePinkLady_4_mod.jpg	Apple Pink Lady 1	0.9752731323242188	-0.6101	Acierto
AppleRed1_1.jpg	Apple Red 1	0.9999946355819702	0.0	Acierto
AppleRed1_1_mod.jpg	Apple Red 1	0.9990543723106384	-0.5067	Acierto
AppleRed1_2.jpg	Apple Red 1	0.9999419450759888	0.0	Acierto
AppleRed1_2_mod.jpg	Apple Red 1	0.9999091625213623	-0.7217	Acierto
AppleRed1_3.jpg	Apple Red 1	0.9999537467956543	0.0	Acierto
AppleRed1_3_mod.jpg	Apple Red 1	0.9999914169311523	-0.2704	Acierto
AppleRed1_4.jpg	Apple Red 1	0.9999006986618042	0.0	Acierto
AppleRed1_4_mod.jpg	Apple Red 1	0.9998973608016968	0.4688	Acierto
AppleRed2_1.jpg	Apple Red 2	0.9786404967308044	0.0	Acierto
AppleRed2_1_mod.jpg	Apple Red 2	0.5224058032035828	0.5408	Acierto
AppleRed2_2.jpg	Apple Red 2	0.9999462366104126	0.0	Acierto
AppleRed2_2_mod.jpg	Apple Braeburn 1	0.7111254334449768	-0.7971	Fallo
AppleRed2_3.jpg	Apple Red 2	0.9253693222999573	0.0	Acierto
AppleRed2_3_mod.jpg	Apple Red 2	0.9212338328361511	-0.2666	Acierto
AppleRed2_4.jpg	Apple Red 2	0.9999324083328247	0.0	Acierto
AppleRed2_4_mod.jpg	Apple Red 2	0.9999191761016846	-0.1654	Acierto
AppleRed3_1.jpg	Apple Red 3	0.9985402822494507	0.0	Acierto
AppleRed3_1_mod.jpg	Apple Red 3	0.995226263999939	-0.464	Acierto
AppleRed3_2.jpg	Apple Red 3	0.99912029504776	0.0	Acierto
AppleRed3_2_mod.jpg	Apple Red 3	0.9977967739105225	-0.647	Acierto
AppleRed3_3.jpg	Apple Red 3	0.9999680519104004	0.0	Acierto
AppleRed3_3_mod.jpg	Apple Red 3	0.9975090026855469	-0.4947	Acierto
AppleRed3_4.jpg	Apple Red 3	0.9999737739562988	0.0	Acierto
AppleRed3_4_mod.jpg	Apple Red 3	0.9999856948852539	-0.14	Acierto
AppleRedDelicious_1.jpg	Apple Red Delicious 1	0.9999239444732666	0.0	Acierto
AppleRedDelicious_1_mod.jpg	Apple Red Delicious 1	0.9987064599990845	0.6108	Acierto
AppleRedDelicious_2.jpg	Apple Red Delicious 1	0.9998922348022461	0.0	Acierto
AppleRedDelicious_2_mod.jpg	Apple Red Delicious 1	0.9999693632125854	0.4126	Acierto
AppleRedDelicious_3.jpg	Apple Red Delicious 1	0.9999680519104004	0.0	Acierto
AppleRedDelicious_3_mod.jpg	Apple Red Delicious 1	0.9999371767044067	0.2663	Acierto
AppleRedDelicious_4.jpg	Apple Red Delicious 1	0.9998451471328735	0.0	Acierto
AppleRedDelicious_4_mod.jpg	Apple Red Delicious 1	0.9758579730987549	-0.4558	Acierto
AppleRedYellow1_1.jpg	Apple Red Yellow 1	0.9847859740257263	0.0	Acierto
AppleRedYellow1_1_mod.jpg	Apple Red Yellow 1	0.998602569103241	0.6143	Acierto
AppleRedYellow1_2.jpg	Apple Red Yellow 1	0.9999949932098389	0.0	Acierto
AppleRedYellow1_2_mod.jpg	Apple Red Yellow 1	0.9995505213737488	0.7594	Acierto
AppleRedYellow1_3.jpg	Apple Red Yellow 1	0.9999549388885498	0.0	Acierto
AppleRedYellow1_3_mod.jpg	Apple Red Yellow 1	0.9999103546142578	0.2242	Acierto
AppleRedYellow1_4.jpg	Apple Red Yellow 1	0.9998992681503296	0.0	Acierto
AppleRedYellow1_4_mod.jpg	Apple Red Yellow 1	0.9589250087738037	0.757	Acierto
AppleRedYellow2_1.jpg	Apple Red Yellow 2	0.9998353719711304	0.0	Acierto
AppleRedYellow2_1_mod.jpg	Apple Red Yellow 2	0.9998588562011719	0.1113	Acierto
AppleRedYellow2_2.jpg	Apple Red Yellow 2	0.9997988343238831	0.0	Acierto
AppleRedYellow2_2_mod.jpg	Apple Red Yellow 2	0.9998636245727539	0.1143	Acierto
AppleRedYellow2_3.jpg	Apple Red Yellow 2	0.9996019005775452	0.0	Acierto
AppleRedYellow2_3_mod.jpg	Apple Red Yellow 2	0.9997742772102356	0.7202	Acierto
AppleRedYellow2_4.jpg	Apple Red Yellow 2	0.9993425011634827	0.0	Acierto
AppleRedYellow2_4_mod.jpg	Apple Red Yellow 2	0.9993947744369507	-0.3601	Acierto

Tabla 39: Resultados de las predicciones del entrenamiento de las manzanas con cambios de iluminación.

Imagen	Clase	Confianza	factor_brillo	Aciertos/Fallos
Pear1_1.jpg	Pear 1	0.999715268611908	0.0	Acierto
Pear1_1_mod.jpg	Pear 1	0.9995587468147278	-0.3512	Acierto
Pear1_2.jpg	Pear 1	0.999990701675415	0.0	Acierto
Pear1_2_mod.jpg	Pear 1	0.9999749660491943	0.3154	Acierto
Pear1_3.jpg	Pear 1	0.9999655485153198	0.0	Acierto
Pear1_3_mod.jpg	Pear 1	0.9999666213989258	-0.5655	Acierto
Pear1_4.jpg	Pear 1	0.9999147653579712	0.0	Acierto
Pear1_4_mod.jpg	Pear 1	0.9999493360519409	0.1691	Acierto
Pear1_5.jpg	Pear 1	0.9999710321426392	0.0	Acierto
Pear1_5_mod.jpg	Pear 1	0.9984855055809021	0.6992	Acierto
Pear2_1.jpg	Pear 2	0.9999812841415405	0.0	Acierto
Pear2_1_mod.jpg	Pear 2	0.999881386756897	0.6063	Acierto
Pear2_2.jpg	Pear 2	0.9997287392616272	0.0	Acierto
Pear2_2_mod.jpg	Pear 2	0.9999849796295166	0.3469	Acierto
Pear2_3.jpg	Pear 2	0.9994589686393738	0.0	Acierto
Pear2_3_mod.jpg	Pear 2	0.9998020529747009	0.496	Acierto
Pear2_4.jpg	Pear 2	0.9998877048492432	0.0	Acierto
Pear2_4_mod.jpg	Pear 2	0.9999337196350098	-0.5332	Acierto
Pear2_5.jpg	Pear 2	0.9999974966049194	0.0	Acierto
Pear2_5_mod.jpg	Pear 2	0.9997313618659973	0.6782	Acierto
Pear3_1.jpg	Pear 3	1.0	0.0	Acierto
Pear3_1_mod.jpg	Pear 3	0.9646279215812683	-0.606	Acierto
Pear3_2.jpg	Pear 3	0.9999997615814209	0.0	Acierto
Pear3_2_mod.jpg	Pear 3	1.0	0.5491	Acierto
Pear3_3.jpg	Pear 3	1.0	0.0	Acierto
Pear3_3_mod.jpg	Pear 3	0.9999209642410278	-0.369	Acierto
Pear3_4.jpg	Pear 3	0.9999998807907104	0.0	Acierto
Pear3_4_mod.jpg	Pear 3	0.9999994039535522	-0.1904	Acierto
Pear3_5.jpg	Pear 3	1.0	0.0	Acierto
Pear3_5_mod.jpg	Pear 3	1.0	0.4145	Acierto
PearAbate_1.jpg	Pear Abate 1	0.9999909400939941	0.0	Acierto
PearAbate_1_mod.jpg	Pear Abate 1	0.9946172833442688	0.7158	Acierto
PearAbate_2.jpg	Pear Abate 1	0.999976396560669	0.0	Acierto
PearAbate_2_mod.jpg	Pear Abate 1	0.9999747276306152	-0.107	Acierto
PearAbate_3.jpg	Pear Abate 1	0.9999940395355225	0.0	Acierto
PearAbate_3_mod.jpg	Pear Abate 1	0.9999973773956299	-0.147	Acierto
PearAbate_4.jpg	Pear Abate 1	0.9999971389770508	0.0	Acierto
PearAbate_4_mod.jpg	Pear Abate 1	0.9999840259552002	0.5657	Acierto
PearAbate_5.jpg	Pear Abate 1	0.9999885559082031	0.0	Acierto
PearAbate_5_mod.jpg	Pear Abate 1	0.999995231628418	0.6201	Acierto
PearForelle_1.jpg	Pear Forelle 1	0.9995595812797546	0.0	Acierto
PearForelle_1_mod.jpg	Pear Forelle 1	0.9991509914398193	-0.121	Acierto
PearForelle_2.jpg	Pear Forelle 1	0.9994118213653564	0.0	Acierto
PearForelle_2_mod.jpg	Pear Forelle 1	0.997952938079834	-0.3696	Acierto
PearForelle_3.jpg	Pear Forelle 1	0.9964097142219543	0.0	Acierto
PearForelle_3_mod.jpg	Pear Forelle 1	0.9998278617858887	0.5131	Acierto
PearForelle_4.jpg	Pear Forelle 1	0.9996825456619263	0.0	Acierto
PearForelle_4_mod.jpg	Pear Forelle 1	0.9998929500579834	-0.2217	Acierto
PearForelle_5.jpg	Pear Forelle 1	0.9999673366546631	0.0	Acierto
PearForelle_5_mod.jpg	Pear Forelle 1	0.9999052286148071	-0.2806	Acierto

Imagen	Clase	Confianza	factor brillo	Aciertos/Fallos
PearKaiser_1.jpg	Pear Kaiser 1	0.9999097585678101	0.0	Acierto
PearKaiser_1_mod.jpg	Pear Kaiser 1	0.9999547004699707	0.3947	Acierto
PearKaiser_2.jpg	Pear Kaiser 1	0.9996787309646606	0.0	Acierto
PearKaiser_2_mod.jpg	Pear Kaiser 1	0.9993076324462891	-0.7187	Acierto
PearKaiser_3.jpg	Pear Kaiser 1	0.999900221824646	0.0	Acierto
PearKaiser_3_mod.jpg	Pear Kaiser 1	0.9996094107627869	-0.3312	Acierto
PearKaiser_4.jpg	Pear Kaiser 1	0.9993299245834351	0.0	Acierto
PearKaiser_4_mod.jpg	Pear Kaiser 1	0.9999634027481079	0.348	Acierto
PearKaiser_5.jpg	Pear Kaiser 1	0.9999337196350098	0.0	Acierto
PearKaiser_5_mod.jpg	Pear Kaiser 1	0.9597161412239075	-0.4144	Acierto
PearMonster_1.jpg	Pear Monster 1	0.9999996423721313	0.0	Acierto
PearMonster_1_mod.jpg	Pear Monster 1	0.9999996423721313	-0.2061	Acierto
PearMonster_2.jpg	Pear Monster 1	0.9999967813491821	0.0	Acierto
PearMonster_2_mod.jpg	Pear Monster 1	0.9978923201560974	0.5366	Acierto
PearMonster_3.jpg	Pear Monster 1	0.9999979734420776	0.0	Acierto
PearMonster_3_mod.jpg	Pear Monster 1	0.9999973773956299	-0.2384	Acierto
PearMonster_4.jpg	Pear Monster 1	0.9999099969863892	0.0	Acierto
PearMonster_4_mod.jpg	Pear Monster 1	0.999953031539917	-0.557	Acierto
PearMonster_5.jpg	Pear Monster 1	0.9999947547912598	0.0	Acierto
PearMonster_5_mod.jpg	Pear Monster 1	0.9999926090240479	-0.2725	Acierto
PearRed_1.jpg	Pear Red 1	0.9999908208847046	0.0	Acierto
PearRed_1_mod.jpg	Pear Red 1	0.9999896287918091	0.4422	Acierto
PearRed_2.jpg	Pear Red 1	0.9999459981918335	0.0	Acierto
PearRed_2_mod.jpg	Pear Red 1	0.9992952346801758	-0.7428	Acierto
PearRed_3.jpg	Pear Red 1	0.9998979568481445	0.0	Acierto
PearRed_3_mod.jpg	Pear Red 1	0.9999470710754395	0.2405	Acierto
PearRed_4.jpg	Pear Red 1	0.9999059438705444	0.0	Acierto
PearRed_4_mod.jpg	Pear Red 1	0.9968523383140564	0.7866	Acierto
PearRed_5.jpg	Pear Red 1	0.9999339580535889	0.0	Acierto
PearRed_5_mod.jpg	Pear Red 1	0.999929666519165	-0.4083	Acierto
PearStone_1.jpg	Pear Stone 1	0.9997795224189758	0.0	Acierto
PearStone_1_mod.jpg	Pear Stone 1	0.9999608993530273	0.2301	Acierto
PearStone_2.jpg	Pear Stone 1	0.9997923970222473	0.0	Acierto
PearStone_2_mod.jpg	Pear Stone 1	0.9996354579925537	-0.4859	Acierto
PearStone_3.jpg	Pear Stone 1	0.9999951124191284	0.0	Acierto
PearStone_3_mod.jpg	Pear Stone 1	0.9999974966049194	0.117	Acierto
PearStone_4.jpg	Pear Stone 1	0.9999734163284302	0.0	Acierto
PearStone_4_mod.jpg	Pear Stone 1	0.9999570846557617	-0.5787	Acierto
PearStone_5.jpg	Pear Stone 1	0.9999966621398926	0.0	Acierto
PearStone_5_mod.jpg	Pear Stone 1	0.9996423721313477	-0.5981	Acierto
PearWilliams_1.jpg	Pear Williams 1	0.9999986886978149	0.0	Acierto
PearWilliams_1_mod.jpg	Pear Williams 1	0.9983665347099304	-0.7906	Acierto
PearWilliams_2.jpg	Pear Williams 1	0.9999998807907104	0.0	Acierto
PearWilliams_2_mod.jpg	Pear Williams 1	0.9999979734420776	0.3848	Acierto
PearWilliams_3.jpg	Pear Williams 1	1.0	0.0	Acierto
PearWilliams_3_mod.jpg	Pear Williams 1	1.0	-0.2454	Acierto
PearWilliams_4.jpg	Pear Williams 1	0.999963641166687	0.0	Acierto
PearWilliams_4_mod.jpg	Pear Williams 1	0.9999902248382568	-0.3154	Acierto
PearWilliams_5.jpg	Pear Williams 1	0.999994158744812	0.0	Acierto
PearWilliams_5_mod.jpg	Pear Williams 1	0.9999982118606567	-0.3027	Acierto

Tabla 40: Resultados de las predicciones del entrenamiento de las peras con cambios de iluminación.

Imagen	Clase	Confianza	factor_brillo	Aciertos/Fallos
GrapeBlue_1_mod.jpg	Grape Blue 1	0.9999996423721313	0.4613	Acierto
GrapeBlue_2_mod.jpg	Grape Blue 1	0.9558809995651245	-0.6247	Acierto
GrapeBlue_3_mod.jpg	Grape Blue 1	0.9956575632095337	-0.3419	Acierto
GrapeBlue_4_mod.jpg	Grape Blue 1	0.9999994039535522	0.3385	Acierto
GrapeBlue_5_mod.jpg	Grape Blue 1	0.9999994039535522	0.3494	Acierto
GrapePink_1_mod.jpg	Grape Pink 1	0.9994463324546814	0.1478	Acierto
GrapePink_2_mod.jpg	Grape Pink 1	0.9971253275871277	0.7876	Acierto
GrapePink_3_mod.jpg	Grape Pink 1	0.9999774694442749	0.7386	Acierto
GrapePink_4_mod.jpg	Grape Pink 1	0.9999988079071045	0.6292	Acierto
GrapePink_5_mod.jpg	Grape Pink 1	0.9999538660049438	-0.5875	Acierto
GrapeWhite1_1_mod.jpg	Grape White 1	0.9999767541885376	0.1967	Acierto
GrapeWhite1_2_mod.jpg	Grape White 1	0.30447161197662354	0.6384	Acierto
GrapeWhite1_3_mod.jpg	Grape White 1	0.9999769926071167	0.3879	Acierto
GrapeWhite1_4_mod.jpg	Grape White 1	0.9999622106552124	-0.5453	Acierto
GrapeWhite1_5_mod.jpg	Grape White 1	0.990767776966095	0.4109	Acierto
GrapeWhite2_1_mod.jpg	Grape White 2	0.9999135732650757	-0.5556	Acierto
GrapeWhite2_2_mod.jpg	Grape White 2	0.9997588992118835	-0.446	Acierto
GrapeWhite2_3_mod.jpg	Grape White 2	0.9960997104644775	-0.7193	Acierto
GrapeWhite2_4_mod.jpg	Grape White 2	0.9999901056289673	-0.1955	Acierto
GrapeWhite2_5_mod.jpg	Grape White 2	0.9922173023223877	0.3672	Acierto
GrapeWhite3_1_mod.jpg	Grape White 3	0.9999531507492065	-0.2021	Acierto
GrapeWhite3_2_mod.jpg	Grape White 3	0.9947431087493896	0.7466	Acierto
GrapeWhite3_3_mod.jpg	Grape White 3	0.9999958276748657	0.2	Acierto
GrapeWhite3_4_mod.jpg	Grape White 3	0.999995231628418	0.2868	Acierto
GrapeWhite3_5_mod.jpg	Grape White 3	0.9999992847442627	0.5194	Acierto
GrapeWhite4_1_mod.jpg	Grape White 4	0.41292476654052734	-0.6004	Acierto
GrapeWhite4_2_mod.jpg	Grape White 4	1.0	0.5483	Acierto
GrapeWhite4_3_mod.jpg	Grape White 4	0.5733953714370728	-0.6372	Acierto
GrapeWhite4_4_mod.jpg	Grape White 4	0.9999998807907104	0.4519	Acierto
GrapeWhite4_5_mod.jpg	Grape White 4	0.9999998807907104	0.5214	Acierto
GrapeBlue_1.jpg	Grape Blue 1	0.9999974966049194	0.0	Acierto
GrapeBlue_2.jpg	Grape Blue 1	0.999990701675415	0.0	Acierto
GrapeBlue_3.jpg	Grape Blue 1	0.9999979734420776	0.0	Acierto
GrapeBlue_4.jpg	Grape Blue 1	0.999998927116394	0.0	Acierto
GrapeBlue_5.jpg	Grape Blue 1	0.9999985694885254	0.0	Acierto
GrapePink_1.jpg	Grape Pink 1	0.9995160102844238	0.0	Acierto
GrapePink_2.jpg	Grape Pink 1	0.9999949932098389	0.0	Acierto
GrapePink_3.jpg	Grape Pink 1	0.9999619722366333	0.0	Acierto
GrapePink_4.jpg	Grape Pink 1	0.9999817609786987	0.0	Acierto
GrapePink_5.jpg	Grape Pink 1	0.9999923706054688	0.0	Acierto
GrapeWhite1_1.jpg	Grape White 1	0.9999933242797852	0.0	Acierto
GrapeWhite1_2.jpg	Grape White 1	0.9998753070831299	0.0	Acierto
GrapeWhite1_3.jpg	Grape White 1	0.999994158744812	0.0	Acierto
GrapeWhite1_4.jpg	Grape White 1	0.9998194575309753	0.0	Acierto
GrapeWhite1_5.jpg	Grape White 1	0.9999808073043823	0.0	Acierto
GrapeWhite2_1.jpg	Grape White 2	0.9999806880950928	0.0	Acierto
GrapeWhite2_2.jpg	Grape White 2	0.9999517202377319	0.0	Acierto
GrapeWhite2_3.jpg	Grape White 2	0.9999880790710449	0.0	Acierto
GrapeWhite2_4.jpg	Grape White 2	0.999993085861206	0.0	Acierto
GrapeWhite2_5.jpg	Grape White 2	0.9999775886535645	0.0	Acierto
GrapeWhite3_1.jpg	Grape White 3	0.9999779462814331	0.0	Acierto
GrapeWhite3_2.jpg	Grape White 3	0.9999908208847046	0.0	Acierto
GrapeWhite3_3.jpg	Grape White 3	0.9999961853027344	0.0	Acierto
GrapeWhite3_4.jpg	Grape White 3	0.9999961853027344	0.0	Acierto
GrapeWhite3_5.jpg	Grape White 3	0.9999986886978149	0.0	Acierto
GrapeWhite4_1.jpg	Grape White 4	0.9999929666519165	0.0	Acierto
GrapeWhite4_2.jpg	Grape White 4	0.9999959468841553	0.0	Acierto
GrapeWhite4_3.jpg	Grape White 4	0.9999966621398926	0.0	Acierto
GrapeWhite4_4.jpg	Grape White 4	0.9999979734420776	0.0	Acierto
GrapeWhite4_5.jpg	Grape White 4	0.9999971389770508	0.0	Acierto

Tabla 41: Resultados de las predicciones del entrenamiento de las uvas con cambios de iluminación.

Imagen	Clase	Confianza	factor brillo	Acieros/Fallos
Cherry1_1.jpg	Cherry 1	0.999998807907104	0.0	Acierto
Cherry1_1_mod.jpg	Cherry 1	0.999998807907104	0.1305	Acierto
Cherry1_2.jpg	Cherry 1	0.9996925592422485	0.0	Acierto
Cherry1_2_mod.jpg	Cherry 1	0.999980926513672	0.3712	Acierto
Cherry1_3.jpg	Cherry 1	0.9999988079071045	0.0	Acierto
Cherry1_3_mod.jpg	Cherry 1	0.9999643564224243	-0.2733	Acierto
Cherry1_4.jpg	Cherry 1	0.9999977350234985	0.0	Acierto
Cherry1_4_mod.jpg	Cherry 1	0.9999903440475464	0.3845	Acierto
Cherry1_5.jpg	Cherry 1	0.9999978542327881	0.0	Acierto
Cherry1_5_mod.jpg	Cherry 1	0.9999960660934448	0.6291	Acierto
Cherry2_1.jpg	Cherry 2	0.9988086223602295	0.0	Acierto
Cherry2_1_mod.jpg	Cherry 2	0.9443233013153076	-0.4888	Acierto
Cherry2_2.jpg	Cherry 2	0.9999969005584717	0.0	Acierto
Cherry2_2_mod.jpg	Cherry 2	0.9999891519546509	-0.1462	Acierto
Cherry2_3.jpg	Cherry 2	0.9999209642410278	0.0	Acierto
Cherry2_3_mod.jpg	Cherry 2	0.9999719858169556	0.2714	Acierto
Cherry2_4.jpg	Cherry 2	0.999816358089447	0.0	Acierto
Cherry2_4_mod.jpg	Cherry 2	0.9015493392944336	-0.6332	Acierto
Cherry2_5.jpg	Cherry 2	0.9999738931655884	0.0	Acierto
Cherry2_5_mod.jpg	Cherry 2	0.9997813105583191	-0.1632	Acierto
CherryRainier_1.jpg	Cherry Rainier 1	0.9999951124191284	0.0	Acierto
CherryRainier_1_mod.jpg	Cherry Rainier 1	0.9999599456787109	0.477	Acierto
CherryRainier_2.jpg	Cherry Rainier 1	0.9999957084655762	0.0	Acierto
CherryRainier_2_mod.jpg	Cherry Rainier 1	0.9999915361404419	0.5635	Acierto
CherryRainier_3.jpg	Cherry Rainier 1	0.9999977350234985	0.0	Acierto
CherryRainier_3_mod.jpg	Cherry Rainier 1	0.9963237047195435	-0.6789	Acierto
CherryRainier_4.jpg	Cherry Rainier 1	0.9999791383743286	0.0	Acierto
CherryRainier_4_mod.jpg	Cherry Rainier 1	0.9920985698699951	-0.7355	Acierto
CherryRainier_5.jpg	Cherry Rainier 1	0.9999853372573853	0.0	Acierto
CherryRainier_5_mod.jpg	Cherry Rainier 1	0.9999791383743286	0.1695	Acierto
CherryWaxBlack_1.jpg	Cherry Wax Black 1	0.999996542930603	0.0	Acierto
CherryWaxBlack_1_mod.jpg	Cherry Wax Black 1	0.9999949932098389	0.6313	Acierto
CherryWaxBlack_2.jpg	Cherry Wax Black 1	0.9999954700469971	0.0	Acierto
CherryWaxBlack_2_mod.jpg	Cherry Wax Black 1	0.9999971389770508	-0.1967	Acierto
CherryWaxBlack_3.jpg	Cherry Wax Black 1	0.999983549118042	0.0	Acierto
CherryWaxBlack_3_mod.jpg	Cherry Wax Black 1	0.9997254014015198	0.798	Acierto
CherryWaxBlack_4.jpg	Cherry Wax Black 1	0.9999876022338867	0.0	Acierto
CherryWaxBlack_4_mod.jpg	Cherry Wax Black 1	0.9999873638153076	-0.1294	Acierto
CherryWaxBlack_5.jpg	Cherry Wax Black 1	0.9999783039093018	0.0	Acierto
CherryWaxBlack_5_mod.jpg	Cherry Wax Black 1	0.999077320098877	0.7525	Acierto
CherryWaxNotRippen_1.jpg	Cherry Wax not rippen 1	0.9995859265327454	0.0	Acierto
CherryWaxNotRippen_1_mod.jpg	Cherry Wax not rippen 1	0.9996745586395264	0.4129	Acierto
CherryWaxNotRippen_2.jpg	Cherry Wax not rippen 1	0.9999706745147705	0.0	Acierto
CherryWaxNotRippen_2_mod.jpg	Cherry Wax not rippen 1	0.9999957084655762	0.3964	Acierto
CherryWaxNotRippen_3.jpg	Cherry Wax not rippen 1	0.9998650550842285	0.0	Acierto
CherryWaxNotRippen_3_mod.jpg	Cherry Wax not rippen 1	0.9999861717224121	0.5768	Acierto
CherryWaxNotRippen_4.jpg	Cherry Wax not rippen 1	0.9997938275337219	0.0	Acierto
CherryWaxNotRippen_4_mod.jpg	Cherry Wax not rippen 1	0.9997076392173767	-0.7253	Acierto
CherryWaxNotRippen_5.jpg	Cherry Wax not rippen 1	0.9980523586273193	0.0	Acierto
CherryWaxNotRippen_5_mod.jpg	Cherry Wax not rippen 1	0.999477207660675	0.3578	Acierto
CherryWaxRed_1.jpg	Cherry Wax Red 1	0.9999984502792358	0.0	Acierto
CherryWaxRed_1_mod.jpg	Cherry Wax Red 1	0.999269425868988	-0.4371	Acierto

Imagen	Clase	Confianza	factor_brillo	Aciertos/Fallos
CherryWaxRed_2.jpg	Cherry Wax Red 1	0.9999897480010986	0.0	Acierto
CherryWaxRed_2_mod.jpg	Cherry Wax Red 1	0.9999984502792358	0.3999	Acierto
CherryWaxRed_3.jpg	Cherry Wax Red 1	0.9999902248382568	0.0	Acierto
CherryWaxRed_3_mod.jpg	Cherry Wax Red 1	0.999993085861206	0.5965	Acierto
CherryWaxRed_4.jpg	Cherry Wax Red 1	0.999771773815155	0.0	Acierto
CherryWaxRed_4_mod.jpg	Cherry Wax Red 1	0.9971639513969421	-0.4293	Acierto
CherryWaxRed_5.jpg	Cherry Wax Red 1	0.9995777010917664	0.0	Acierto
CherryWaxRed_5_mod.jpg	Cherry Wax Red 1	0.999984860420227	0.6494	Acierto
CherryWaxYellow_1.jpg	Cherry Wax Yellow 1	0.9999831914901733	0.0	Acierto
CherryWaxYellow_1_mod.jpg	Cherry Wax Yellow 1	0.9999911785125732	0.2831	Acierto
CherryWaxYellow_2.jpg	Cherry Wax Yellow 1	0.999972939491272	0.0	Acierto
CherryWaxYellow_2_mod.jpg	Cherry Wax Yellow 1	0.9999765157699585	-0.1012	Acierto
CherryWaxYellow_3.jpg	Cherry Wax Yellow 1	0.9999043941497803	0.0	Acierto
CherryWaxYellow_3_mod.jpg	Cherry Wax Yellow 1	0.999752938747406	-0.7418	Acierto
CherryWaxYellow_4.jpg	Cherry Wax Yellow 1	0.9999092817306519	0.0	Acierto
CherryWaxYellow_4_mod.jpg	Cherry Wax Yellow 1	0.9999055862426758	-0.6657	Acierto
CherryWaxYellow_5.jpg	Cherry Wax Yellow 1	0.9997318387031555	0.0	Acierto
CherryWaxYellow_5_mod.jpg	Cherry Wax Yellow 1	0.9999117851257324	0.4347	Acierto

Tabla 42: Resultados de las predicciones del entrenamiento de las cerezas con cambios de iluminación.



Imagen	Clase	Confianza	factor_brillo	Aciertos/Fallos
Apple5_1.jpg	Apple 5	0.9995046854019165	0.0	Acierto
Apple5_1_mod.jpg	Apple 5	0.9998338222503662	0.4419	Acierto
Apple5_2.jpg	Apple 5	0.9999548196792603	0.0	Acierto
Apple5_2_mod.jpg	Apple 5	0.9999111890792847	-0.2867	Acierto
Apple5_3.jpg	Apple 5	0.9998227953910828	0.0	Acierto
Apple5_3_mod.jpg	Apple 5	0.8970044255256653	-0.6907	Acierto
Apple5_4.jpg	Apple 5	0.9999643564224243	0.0	Acierto
Apple5_4_mod.jpg	Apple 5	0.9999707937240601	0.6044	Acierto
AppleRed2_1.jpg	Apple Red 2	0.9999653100967407	0.0	Acierto
AppleRed2_1_mod.jpg	Apple Red 2	0.9972547888755798	0.7639	Acierto
AppleRed2_2.jpg	Apple Red 2	0.9998989105224609	0.0	Acierto
AppleRed2_2_mod.jpg	Apple Red 2	0.998703122138977	-0.3414	Acierto
AppleRed2_3.jpg	Apple Red 2	0.9999768733978271	0.0	Acierto
AppleRed2_3_mod.jpg	Apple Red 2	0.960962176322937	-0.7073	Acierto
AppleRed2_4.jpg	Apple Red 2	0.9999985694885254	0.0	Acierto
AppleRed2_4_mod.jpg	Apple Red 2	0.9997732043266296	-0.486	Acierto
AppleGrannySmith_1.jpg	Apple Granny Smith 1	0.9988757967948914	0.0	Acierto
AppleGrannySmith_1_mod.jpg	Apple Granny Smith 1	0.9988788962364197	0.6158	Acierto
AppleGrannySmith_2.jpg	Apple Granny Smith 1	0.999431312084198	0.0	Acierto
AppleGrannySmith_2_mod.jpg	Apple Granny Smith 1	0.9996836185455322	0.1824	Acierto
AppleGrannySmith_3.jpg	Apple Granny Smith 1	0.9985343217849731	0.0	Acierto
AppleGrannySmith_3_mod.jpg	Apple Granny Smith 1	0.8694059252738953	0.7337	Acierto
AppleGrannySmith_4.jpg	Apple Granny Smith 1	0.999941349029541	0.0	Acierto
AppleGrannySmith_4_mod.jpg	Apple Granny Smith 1	0.6717855334281921	-0.7007	Acierto
Banana1_1.jpg	Banana 1	0.999998807907104	0.0	Acierto
Banana1_1_mod.jpg	Banana 1	0.9991365075111389	0.6175	Acierto
Banana1_2.jpg	Banana 1	0.9999786615371704	0.0	Acierto
Banana1_2_mod.jpg	Banana 1	0.997755229473114	-0.5558	Acierto
Banana1_3.jpg	Banana 1	0.9999685287475586	0.0	Acierto
Banana1_3_mod.jpg	Banana 1	0.9999246597290039	-0.2307	Acierto
Banana1_4.jpg	Banana 1	0.9996080994606018	0.0	Acierto
Banana1_4_mod.jpg	Banana 1	0.6860089302062988	0.7001	Acierto
Banana3_1.jpg	Banana 3	0.9996154308319092	0.0	Acierto
Banana3_1_mod.jpg	Banana 3	0.9989959597587585	-0.3194	Acierto
Banana3_2.jpg	Banana 3	0.9994495511054993	0.0	Acierto
Banana3_2_mod.jpg	Banana 3	0.999803364276886	0.3904	Acierto
Banana3_3.jpg	Banana 3	0.9999372959136963	0.0	Acierto
Banana3_3_mod.jpg	Banana 3	0.9957712292671204	-0.6139	Acierto
Banana3_4.jpg	Banana 3	0.9999996423721313	0.0	Acierto
Banana3_4_mod.jpg	Banana 3	0.9999988079071045	0.3807	Acierto
BananaLadyFinger_1.jpg	Banana Lady Finger 1	0.999996542930603	0.0	Acierto
BananaLadyFinger_1_mod.jpg	Banana Lady Finger 1	0.9999973773956299	0.5573	Acierto
BananaLadyFinger_2.jpg	Banana Lady Finger 1	0.999681830406189	0.0	Acierto
BananaLadyFinger_2_mod.jpg	Banana Lady Finger 1	0.9987469911575317	-0.4517	Acierto
BananaLadyFinger_3.jpg	Banana Lady Finger 1	0.99482661485672	0.0	Acierto
BananaLadyFinger_3_mod.jpg	Banana Lady Finger 1	0.9984287619590759	-0.184	Acierto
BananaLadyFinger_4.jpg	Banana Lady Finger 1	0.9998225569725037	0.0	Acierto
BananaLadyFinger_4_mod.jpg	Banana Lady Finger 1	0.9997852444648743	-0.5381	Acierto
Cherry1_1.jpg	Cherry 1	0.9993962049484253	0.0	Acierto
Cherry1_1_mod.jpg	Cherry 1	0.9999368190765381	0.3146	Acierto
Cherry1_2.jpg	Cherry 1	0.9999805688858032	0.0	Acierto
Cherry1_2_mod.jpg	Cherry 1	0.9999996423721313	-0.3992	Acierto

Imagen	Clase	Confianza	factor brillo	Acieros/Fallos
Cherry1_3.jpg	Cherry 1	0.9999520778656006	0.0	Acierto
Cherry1_3_mod.jpg	Cherry 1	0.9999991655349731	-0.5778	Acierto
Cherry1_4.jpg	Cherry 1	0.999948263168335	0.0	Acierto
Cherry1_4_mod.jpg	Cherry 1	0.9999943971633911	0.3275	Acierto
Cherry2_1.jpg	Cherry 2	0.999983549118042	0.0	Acierto
Cherry2_1_mod.jpg	Cherry 2	0.9999761581420898	0.1081	Acierto
Cherry2_2.jpg	Cherry 2	0.9999855756759644	0.0	Acierto
Cherry2_2_mod.jpg	Cherry 2	0.9999881982803345	-0.1503	Acierto
Cherry2_3.jpg	Cherry 2	0.9999057054519653	0.0	Acierto
Cherry2_3_mod.jpg	Cherry 2	0.9999755620956421	-0.6975	Acierto
Cherry2_4.jpg	Cherry 2	0.9999610185623169	0.0	Acierto
Cherry2_4_mod.jpg	Cherry 2	0.9999256134033203	-0.1055	Acierto
GrapeWhite1_1.jpg	Grape White 1	0.9999722242355347	0.0	Acierto
GrapeWhite1_1_mod.jpg	Grape White 1	0.9730923771858215	0.4944	Acierto
GrapeWhite1_2.jpg	Grape White 1	0.9999364614486694	0.0	Acierto
GrapeWhite1_2_mod.jpg	Grape White 1	0.9995361566543579	0.2576	Acierto
GrapeWhite1_3.jpg	Grape White 1	0.9999914169311523	0.0	Acierto
GrapeWhite1_3_mod.jpg	Grape White 1	0.9999982118606567	-0.513	Acierto
GrapeWhite1_4.jpg	Grape White 1	0.9999802112579346	0.0	Acierto
GrapeWhite1_4_mod.jpg	Grape White 1	0.9999810457229614	-0.3173	Acierto
GrapeWhite2_1.jpg	Grape White 2	0.9999418258666992	0.0	Acierto
GrapeWhite2_1_mod.jpg	Grape White 2	0.9998555183410645	-0.5512	Acierto
GrapeWhite2_2.jpg	Grape White 2	0.9999632835388184	0.0	Acierto
GrapeWhite2_2_mod.jpg	Grape White 2	0.9995951056480408	-0.4739	Acierto
GrapeWhite2_3.jpg	Grape White 2	0.9999701976776123	0.0	Acierto
GrapeWhite2_3_mod.jpg	Grape White 2	0.9999372959136963	-0.4175	Acierto
GrapeWhite2_4.jpg	Grape White 2	0.9995916485786438	0.0	Acierto
GrapeWhite2_4_mod.jpg	Cherry 2	0.574146032333374	-0.7844	Fallo
GrapeWhite4_1.jpg	Grape White 4	0.9999920129776001	0.0	Acierto
GrapeWhite4_1_mod.jpg	Lemon 1	0.5141847729682922	0.784	Fallo
GrapeWhite4_2.jpg	Grape White 4	0.99997878074646	0.0	Acierto
GrapeWhite4_2_mod.jpg	Grape White 4	0.999909520149231	-0.2333	Acierto
GrapeWhite4_3.jpg	Grape White 4	0.9999562501907349	0.0	Acierto
GrapeWhite4_3_mod.jpg	Grape White 4	0.7161982655525208	-0.61	Acierto
GrapeWhite4_4.jpg	Grape White 4	0.9999927282333374	0.0	Acierto
GrapeWhite4_4_mod.jpg	Grape White 4	0.9998284578323364	-0.3148	Acierto
Lemon1_1.jpg	Lemon 1	0.9999756813049316	0.0	Acierto
Lemon1_1_mod.jpg	Lemon 1	0.9999039173126221	-0.4154	Acierto
Lemon1_2.jpg	Lemon 1	0.999895453453064	0.0	Acierto
Lemon1_2_mod.jpg	Lemon 1	0.9990652203559875	0.5697	Acierto
Lemon1_3.jpg	Lemon 1	0.9999088048934937	0.0	Acierto
Lemon1_3_mod.jpg	Lemon 1	0.9855778813362122	0.705	Acierto
Lemon1_4.jpg	Lemon 1	0.9999696016311646	0.0	Acierto
Lemon1_4_mod.jpg	Lemon 1	0.9999719858169556	-0.1196	Acierto
MelonPielDeSapo_1.jpg	Melon Piel de Sapo 1	0.9999978542327881	0.0	Acierto
MelonPielDeSapo_1_mod.jpg	Strawberry Wedge 1	0.23181474208831787	-0.7969	Fallo
MelonPielDeSapo_2.jpg	Melon Piel de Sapo 1	0.9999114274978638	0.0	Acierto
MelonPielDeSapo_2_mod.jpg	Melon Piel de Sapo 1	0.9997875094413757	-0.3767	Acierto
MelonPielDeSapo_3.jpg	Melon Piel de Sapo 1	0.9997550845146179	0.0	Acierto
MelonPielDeSapo_3_mod.jpg	Pear Forelle 1	0.38141581416130066	-0.7702	Fallo
MelonPielDeSapo_4.jpg	Melon Piel de Sapo 1	0.9999997615814209	0.0	Acierto
MelonPielDeSapo_4_mod.jpg	Melon Piel de Sapo 1	0.9999322891235352	-0.6074	Acierto

Imagen	Clase	Confianza	factor_brillo	Aciertos/Fallos
Orange_1.jpg	Orange 1	0.9999772310256958	0.0	Acierto
Orange_1_mod.jpg	Orange 1	0.993842363357544	-0.759	Acierto
Orange_2.jpg	Orange 1	0.9999892711639404	0.0	Acierto
Orange_2_mod.jpg	Orange 1	0.9999673366546631	-0.3749	Acierto
Orange_3.jpg	Orange 1	0.9999250173568726	0.0	Acierto
Orange_3_mod.jpg	Orange 1	0.9999905824661255	0.3605	Acierto
Orange_4.jpg	Orange 1	0.9999967813491821	0.0	Acierto
Orange_4_mod.jpg	Orange 1	0.9999988079071045	0.659	Acierto
Peach1_1.jpg	Peach 1	0.9992569088935852	0.0	Acierto
Peach1_1_mod.jpg	Peach 1	0.9988008737564087	-0.4304	Acierto
Peach1_2.jpg	Peach 1	0.9994785189628601	0.0	Acierto
Peach1_2_mod.jpg	Peach 1	0.9997538924217224	0.5884	Acierto
Peach1_3.jpg	Peach 1	0.9998088479042053	0.0	Acierto
Peach1_3_mod.jpg	Peach 1	0.9998370409011841	0.2434	Acierto
Peach1_4.jpg	Peach 1	0.9993242025375366	0.0	Acierto
Peach1_4_mod.jpg	Peach 1	0.9988836646080017	0.6158	Acierto
Pear1_1.jpg	Pear 1	0.9999524354934692	0.0	Acierto
Pear1_1_mod.jpg	Pear 1	0.9999784231185913	0.3211	Acierto
Pear1_2.jpg	Pear 1	0.9999923706054688	0.0	Acierto
Pear1_2_mod.jpg	Pear 1	0.9999121427536011	0.4579	Acierto
Pear1_3.jpg	Pear 1	0.9999343156814575	0.0	Acierto
Pear1_3_mod.jpg	Pear 1	0.9999716281890869	0.6977	Acierto
Pear1_4.jpg	Pear 1	0.9999842643737793	0.0	Acierto
Pear1_4_mod.jpg	Pear 1	0.9999324083328247	-0.2816	Acierto
Pear2_1.jpg	Pear 2	0.9999159574508667	0.0	Acierto
Pear2_1_mod.jpg	Pear 2	0.999991774559021	0.336	Acierto
Pear2_2.jpg	Pear 2	0.9995303153991699	0.0	Acierto
Pear2_2_mod.jpg	Pear 2	0.9999219179153442	0.4582	Acierto
Pear2_3.jpg	Pear 2	0.9774009585380554	0.0	Acierto
Pear2_3_mod.jpg	Pear 2	0.9937406182289124	0.3543	Acierto
Pear2_4.jpg	Pear 2	0.9996059536933899	0.0	Acierto
Pear2_4_mod.jpg	Pear 2	0.9998229146003723	-0.1245	Acierto
PearForelle_1.jpg	Pear Forelle 1	0.9989933371543884	0.0	Acierto
PearForelle_1_mod.jpg	Pear Forelle 1	0.9998243451118469	0.609	Acierto
PearForelle_2.jpg	Pear Forelle 1	0.9994179010391235	0.0	Acierto
PearForelle_2_mod.jpg	Pear Forelle 1	0.9995967745780945	0.2274	Acierto
PearForelle_3.jpg	Pear Forelle 1	0.9999912977218628	0.0	Acierto
PearForelle_3_mod.jpg	Pear Forelle 1	0.9999940395355225	0.4725	Acierto
PearForelle_4.jpg	Pear Forelle 1	0.9998704195022583	0.0	Acierto
PearForelle_4_mod.jpg	Pear Forelle 1	0.9997439980506897	-0.6357	Acierto
Pineapple1_1.jpg	Pineapple 1	0.9999964237213135	0.0	Acierto
Pineapple1_1_mod.jpg	Pineapple 1	0.9999935626983643	0.1141	Acierto
Pineapple1_2.jpg	Pineapple 1	0.9999985694885254	0.0	Acierto
Pineapple1_2_mod.jpg	Pineapple 1	0.999447762966156	-0.5986	Acierto
Pineapple1_3.jpg	Pineapple 1	0.999996542930603	0.0	Acierto
Pineapple1_3_mod.jpg	Pineapple 1	0.999992847442627	0.1433	Acierto
Pineapple1_4.jpg	Pineapple 1	0.9999929666519165	0.0	Acierto
Pineapple1_4_mod.jpg	Pineapple 1	0.9987767338752747	-0.7881	Acierto
Strawberry1_1.jpg	Strawberry 1	0.9998888969421387	0.0	Acierto
Strawberry1_1_mod.jpg	Strawberry 1	0.999800980091095	0.2848	Acierto
Strawberry1_2.jpg	Strawberry 1	0.9999932050704956	0.0	Acierto
Strawberry1_2_mod.jpg	Strawberry 1	0.9999936819076538	0.198	Acierto

Imagen	Clase	Confianza	factor_brillo	Aciertos/Fallos
Strawberry1_3.jpg	Strawberry 1	0.999997615814209	0.0	Acierto
Strawberry1_3_mod.jpg	Strawberry 1	0.9999669790267944	0.7875	Acierto
Strawberry1_4.jpg	Strawberry 1	0.9999994039535522	0.0	Acierto
Strawberry1_4_mod.jpg	Strawberry 1	0.9999967813491821	0.7939	Acierto
StrawberryWedge_1.jpg	Strawberry Wedge 1	0.9998364448547363	0.0	Acierto
StrawberryWedge_1_mod.jpg	Strawberry Wedge 1	0.9999651908874512	-0.3482	Acierto
StrawberryWedge_2.jpg	Strawberry Wedge 1	0.99983811378479	0.0	Acierto
StrawberryWedge_2_mod.jpg	Strawberry Wedge 1	0.8602526187896729	-0.7508	Acierto
StrawberryWedge_3.jpg	Strawberry Wedge 1	0.9999942779541016	0.0	Acierto
StrawberryWedge_3_mod.jpg	Strawberry Wedge 1	0.999889135360718	-0.7606	Acierto
StrawberryWedge_4.jpg	Strawberry Wedge 1	0.9983994364738464	0.0	Acierto
StrawberryWedge_4_mod.jpg	Strawberry Wedge 1	0.9478126168251038	-0.7937	Acierto
Watermelon1_1.jpg	Watermelon 1	0.9999897480010986	0.0	Acierto
Watermelon1_1_mod.jpg	Watermelon 1	0.9999910593032837	-0.2013	Acierto
Watermelon1_2.jpg	Watermelon 1	0.9999874830245972	0.0	Acierto
Watermelon1_2_mod.jpg	Watermelon 1	0.999992847442627	-0.1679	Acierto
Watermelon1_3.jpg	Watermelon 1	0.9999964237213135	0.0	Acierto
Watermelon1_3_mod.jpg	Watermelon 1	0.9999977350234985	0.1505	Acierto
Watermelon1_4.jpg	Watermelon 1	0.9999986886978149	0.0	Acierto
Watermelon1_4_mod.jpg	Pear Forelle 1	0.9386956095695496	-0.7617	Fallo

Tabla 43: Resultados de las predicciones del entrenamiento de las frutas conjuntas con cambios de iluminación.



11.ANEXO 5: RESULTADOS DEL ENTRENAMIENTO DE DETECCIÓN

epoch	time	train/box_loss	train/cls_loss	train/dfl_loss	metrics/precision(B)	metrics/recall(B)	metrics/mAP50(B)	metrics/mAP50-95(B)	val/box_loss	val/cls_loss	val/dfl_loss	lr/pg0	lr/pg1	lr/pg2
1	12.6251	0.52911	3.89344	0.97435	0.01867	0.75452	0.09582	0.08617	0.36592	3.62617	0.78518	0.00016875	0.00016875	0.00016875
2	21.217	0.44735	2.92477	0.89791	0.56577	0.14898	0.335	0.31061	0.37735	3.00649	0.80454	0.000342048	0.000342048	0.000342048
3	29.7378	0.4527	1.84693	0.91603	0.74993	0.4314	0.55061	0.51785	0.35176	2.09076	0.84137	0.000513614	0.000513614	0.000513614
4	39.0872	0.43369	1.11662	0.91539	0.79372	0.82077	0.9029	0.82399	0.47008	0.94259	0.97412	0.000615719	0.000615719	0.000615719
5	46.7539	0.39986	0.80564	0.90655	0.87758	0.84857	0.93801	0.88316	0.36354	0.7353	0.92054	0.000612625	0.000612625	0.000612625
6	56.016	0.36756	0.6298	0.90909	0.96459	0.97793	0.98665	0.94317	0.31492	0.49266	0.87365	0.000609531	0.000609531	0.000609531
7	65.0081	0.35621	0.58106	0.88054	0.96099	0.97081	0.98504	0.95866	0.26673	0.57731	0.82383	0.000606437	0.000606437	0.000606437
8	72.908	0.35286	0.54376	0.8777	0.9828	0.98167	0.98394	0.93943	0.33607	0.56338	0.82942	0.000603344	0.000603344	0.000603344
9	82.1923	0.32751	0.49635	0.86732	0.98038	0.95804	0.98106	0.95574	0.25121	0.46689	0.81803	0.00060025	0.00060025	0.00060025
10	90.5542	0.32183	0.4776	0.86039	0.98936	0.99478	0.98735	0.9698	0.23456	0.39432	0.81408	0.000597156	0.000597156	0.000597156
11	99.5649	0.31419	0.45556	0.85602	0.98822	0.99493	0.98719	0.96045	0.24798	0.42572	0.80913	0.000594062	0.000594062	0.000594062
12	108.82	0.30899	0.44489	0.85645	0.98776	0.99508	0.9873	0.96042	0.25746	0.43396	0.80766	0.000590969	0.000590969	0.000590969
13	116.469	0.3047	0.43631	0.85369	0.98718	0.99508	0.98758	0.96514	0.25837	0.4141	0.81057	0.000587875	0.000587875	0.000587875
14	125.885	0.31153	0.43458	0.85644	0.98873	0.99476	0.98779	0.96764	0.23054	0.38752	0.80079	0.000584781	0.000584781	0.000584781
15	134.424	0.30968	0.40777	0.85056	0.98923	0.99508	0.98833	0.96746	0.23123	0.35381	0.80188	0.000581687	0.000581687	0.000581687
16	142.598	0.29537	0.39404	0.84146	0.98995	0.99508	0.98831	0.96925	0.22418	0.34108	0.79795	0.000578594	0.000578594	0.000578594
17	151.736	0.2889	0.39018	0.84544	0.99061	0.99508	0.98945	0.9681	0.22267	0.3397	0.79893	0.0005755	0.0005755	0.0005755
18	159.468	0.29061	0.3921	0.8482	0.98929	0.99461	0.98718	0.9698	0.22395	0.33918	0.79988	0.000572406	0.000572406	0.000572406
19	168.776	0.29082	0.38451	0.84497	0.9893	0.99427	0.98698	0.9696	0.22296	0.3425	0.79126	0.000569313	0.000569313	0.000569313
20	177.675	0.28368	0.3661	0.84201	0.98944	0.99484	0.98698	0.96601	0.23313	0.34233	0.78919	0.000566219	0.000566219	0.000566219
21	185.492	0.29626	0.36925	0.84268	0.98741	0.99438	0.98704	0.97215	0.24318	0.32607	0.78866	0.000563125	0.000563125	0.000563125
22	194.859	0.283	0.3578	0.84305	0.98985	0.99447	0.98829	0.97126	0.22952	0.30379	0.78672	0.000560031	0.000560031	0.000560031
23	202.72	0.28044	0.3537	0.84046	0.98849	0.99377	0.98716	0.97164	0.22049	0.32471	0.78534	0.000556938	0.000556938	0.000556938
24	211.647	0.28258	0.34472	0.84359	0.98913	0.99437	0.98762	0.97186	0.20371	0.30288	0.78431	0.000553844	0.000553844	0.000553844
25	220.932	0.28147	0.33757	0.8417	0.98901	0.99463	0.98811	0.97323	0.22195	0.29572	0.78637	0.00055075	0.00055075	0.00055075
26	228.818	0.27594	0.33278	0.83417	0.99026	0.99494	0.98601	0.96732	0.22272	0.29343	0.78849	0.000547656	0.000547656	0.000547656
27	238.057	0.27922	0.32846	0.83602	0.99004	0.99493	0.98609	0.96944	0.22951	0.28276	0.78775	0.000544563	0.000544563	0.000544563
28	246.577	0.27902	0.32871	0.83872	0.99051	0.99496	0.986731	0.21905	0.27617	0.7837	0.000541469	0.000541469	0.000541469	0.000541469
29	254.664	0.27858	0.32423	0.83947	0.99013	0.99454	0.98685	0.97192	0.20831	0.26998	0.78404	0.000538375	0.000538375	0.000538375
30	264.052	0.2763	0.3241	0.83887	0.98764	0.99508	0.98715	0.97245	0.19386	0.27295	0.78251	0.000535281	0.000535281	0.000535281
31	271.769	0.2695	0.31521	0.83624	0.9905	0.99504	0.98751	0.97273	0.20222	0.2614	0.78721	0.000532187	0.000532187	0.000532187
32	281.058	0.26881	0.31682	0.8398	0.98694	0.99081	0.98879	0.97485	0.20313	0.26355	0.78667	0.000529094	0.000529094	0.000529094
33	290.159	0.28007	0.32061	0.83987	0.99055	0.99508	0.98644	0.97134	0.22667	0.26566	0.79096	0.000526	0.000526	0.000526
34	297.944	0.27048	0.30703	0.83397	0.99009	0.99474	0.98639	0.9712	0.20997	0.26111	0.78672	0.000523906	0.000523906	0.000523906
35	307.283	0.263	0.29886	0.83609	0.99078	0.99425	0.98748	0.97055	0.21595	0.2521	0.79011	0.000519812	0.000519812	0.000519812
36	315.356	0.26321	0.30349	0.83207	0.99099	0.99508	0.98733	0.97311	0.19358	0.2494	0.78607	0.000516719	0.000516719	0.000516719
37	324.284	0.26364	0.30359	0.83354	0.99099	0.99508	0.98641	0.97131	0.20327	0.26262	0.78572	0.000513625	0.000513625	0.000513625
38	333.532	0.26417	0.29597	0.83445	0.99103	0.99508	0.98623	0.96911	0.20656	0.24768	0.78562	0.000510531	0.000510531	0.000510531
39	341.077	0.26033	0.28728	0.83392	0.99081	0.99508	0.98834	0.97556	0.1951	0.24466	0.78545	0.000507438	0.000507438	0.000507438
40	350.355	0.25968	0.28777	0.83122	0.99015	0.99508	0.98738	0.97218	0.21616	0.24772	0.78569	0.000504344	0.000504344	0.000504344
41	359.134	0.25816	0.28644	0.83325	0.99069	0.99508	0.98561	0.97025	0.18682	0.23699	0.78447	0.00050125	0.00050125	0.00050125
42	367.383	0.26112	0.28479	0.82969	0.99042	0.99508	0.98644	0.97315	0.20774	0.24711	0.78532	0.000498156	0.000498156	0.000498156
43	376.667	0.25724	0.28463	0.83302	0.99063	0.99508	0.98583	0.97305	0.19132	0.23254	0.78419	0.000495063	0.000495063	0.000495063
44	384.416	0.2577	0.28393	0.82912	0.99059	0.99508	0.98733	0.97249	0.20378	0.23574	0.78333	0.000491969	0.000491969	0.000491969
45	393.739	0.25914	0.27866	0.83032	0.99086	0.99508	0.98712	0.9735	0.19923	0.23162	0.78711	0.000488875	0.000488875	0.000488875
46	403.115	0.26143	0.28593	0.83452	0.99041	0.99497	0.98869	0.97257	0.20137	0.23292	0.79061	0.000485781	0.000485781	0.000485781
47	410.896	0.25978	0.27841	0.83127	0.99094	0.99508	0.98729	0.97349	0.21225	0.23846	0.78677	0.000482687	0.000482687	0.000482687
48	420.251	0.25	0.27289	0.82789	0.99069	0.99508	0.98781	0.97325	0.23098	0.23098	0.78493	0.000479594	0.000479594	0.000479594
49	428.489	0.2528	0.26921	0.8288	0.99044	0.99508	0.98821	0.97474	0.19224	0.23792	0.78584	0.0004765	0.0004765	0.0004765
50	436.932	0.25295	0.27158	0.83074	0.99004	0.99453	0.98693	0.97197	0.18706	0.22198	0.78177	0.000473406	0.000473406	0.000473406
51	446.109	0.24843	0.26866	0.8323	0.9907	0.99508	0.98761	0.97442	0.19371	0.23222	0.78994	0.000470312	0.000470312	0.000470312
52	453.929	0.25226	0.27025	0.83341	0.9908	0.99508	0.98614	0.97411	0.19912	0.21966	0.78908	0.000467219	0.000467219	0.000467219
53	463.293	0.2503	0.26808	0.82767	0.99053	0.99501	0.98731	0.97447	0.21318	0.22881	0.79252	0.000464125	0.000464125	0.000464125
54	472.083	0.25521	0.26785	0.82747	0.99092	0.99508	0.98779	0.97588	0.18208	0.22394	0.78197	0.000461031	0.000461031	0.000461031
55	480.135	0.24915	0.26176	0.82741	0.99081	0.99476	0.98591	0.97294	0.18868	0.22564	0.78139	0.000457938	0.000457938	0.000457938
56	489.493	0.25221	0.26103	0.83015	0.99085	0.99508	0.9861	0.97621	0.1781	0.21852	0.7803	0.000454844	0.000454844	0.000454844
57	497.422	0.25042	0.26355	0.83098	0.9909	0.99508	0.9866	0.97555	0.18899	0.21321	0.78366	0.00045175	0.00045175	0.00045175
58	506.457	0.24662	0.25876	0.82798	0.9909	0.99508	0.9888	0.97827	0.18288	0.20786	0.78505	0.000448656	0.000448656	0.000448656
59	515.667	0.2479	0.25746	0.82819	0.99098	0.99508	0.98669	0.97274	0.18266	0.21344	0.78838	0.000445562	0.000445562	0.000445562
60	523.436	0.24306	0.25421	0.8314	0.99104	0.99508	0.9864	0.97535	0.17967	0.21179	0.7845	0.000442469	0.000442469	0.000442469
61	532.729	0.25217	0.26044	0.83093	0.99083	0.99508	0.98776	0.97569	0.17548	0.21388	0.78293	0.000439375	0.000439375	0.000439375
62	540.935	0.24131	0.24856	0.82406	0.9901	0.99508	0.98614	0.97452	0.1912	0.22049	0.78374	0.000436281	0.000436281	0.000436281
63	549.597	0.2473	0.25762	0.83068	0.99007	0.99434	0.98909	0.97479	0.20247	0.23333	0.78875	0.000433187	0.000433187	0.000433187
64	558.905	0.24929	0.25629	0.8314	0.99048	0.99508	0.98672	0.9763	0.1879	0.20731	0.78202	0.000430094	0.000430094	0.000430094
65	566.631	0.24717	0.25748	0.8235										

epoch	time	train/box loss	train/cls loss	train/dfl loss	metrics/precision(B)	metrics/recall(B)	metrics/mAP50(B)	metrics/mAP50-95(B)	val/box loss	val/cls loss	val/dfl loss	lr/p0	lr/p1	lr/p2
101	877.79	0.23108	0.21508	0.82494	0.99093	0.99508	0.98599	0.97527	0.17433	0.18358	0.78083	0.000315625	0.000315625	0.000315625
102	887.152	0.22749	0.21178	0.82388	0.99038	0.99508	0.98764	0.97812	0.16256	0.17352	0.78074	0.000312531	0.000312531	0.000312531
103	896.172	0.22555	0.20969	0.82633	0.99116	0.99508	0.9865	0.97734	0.17343	0.17552	0.78328	0.000309437	0.000309437	0.000309437
104	903.952	0.22798	0.21394	0.82151	0.99075	0.99508	0.98823	0.97852	0.17702	0.19131	0.78331	0.000306344	0.000306344	0.000306344
105	913.348	0.22794	0.21307	0.82439	0.991	0.99508	0.98728	0.97801	0.17026	0.17571	0.77981	0.00030325	0.00030325	0.00030325
106	920.991	0.22626	0.2105	0.81663	0.99065	0.99508	0.98855	0.98003	0.17256	0.18575	0.78153	0.000300156	0.000300156	0.000300156
107	930.262	0.2287	0.21042	0.82378	0.99076	0.99508	0.98708	0.97634	0.18524	0.17986	0.7836	0.000297063	0.000297063	0.000297063
108	939.39	0.22741	0.20735	0.822	0.99109	0.99508	0.98782	0.9766	0.17857	0.17494	0.7839	0.000293969	0.000293969	0.000293969
109	947.226	0.22751	0.20605	0.8226	0.99118	0.99508	0.98616	0.97492	0.17416	0.17779	0.78175	0.000290875	0.000290875	0.000290875
110	956.426	0.22908	0.21089	0.82116	0.99046	0.99492	0.9866	0.97748	0.17559	0.18229	0.78143	0.000287781	0.000287781	0.000287781
111	964.642	0.22335	0.20263	0.81873	0.991	0.99508	0.98894	0.97933	0.16641	0.17029	0.78091	0.000284688	0.000284688	0.000284688
112	973.157	0.22104	0.2028	0.81604	0.99108	0.99508	0.98868	0.9779	0.18001	0.17788	0.78089	0.000281594	0.000281594	0.000281594
113	982.502	0.22382	0.20181	0.8192	0.99071	0.99508	0.98946	0.98009	0.18077	0.17957	0.78134	0.0002785	0.0002785	0.0002785
114	990.217	0.22644	0.20666	0.82272	0.99072	0.99508	0.9876	0.9788	0.16974	0.17483	0.78118	0.000275406	0.000275406	0.000275406
115	999.428	0.22432	0.2021	0.82321	0.99113	0.99508	0.98803	0.97819	0.17	0.17211	0.7823	0.000272313	0.000272313	0.000272313
116	1008.48	0.23076	0.20616	0.82369	0.99099	0.99508	0.98822	0.97881	0.16841	0.1733	0.77921	0.000269219	0.000269219	0.000269219
117	1016.61	0.22441	0.20288	0.8191	0.99063	0.99508	0.9873	0.97886	0.16853	0.17669	0.78157	0.000266125	0.000266125	0.000266125
118	1025.77	0.22363	0.20207	0.82226	0.99087	0.99508	0.98623	0.97736	0.17866	0.18005	0.78412	0.000263031	0.000263031	0.000263031
119	1033.7	0.22348	0.1999	0.82465	0.99088	0.99506	0.9873	0.97927	0.16757	0.17114	0.78144	0.000259938	0.000259938	0.000259938
120	1042.56	0.22265	0.19904	0.8213	0.99111	0.99508	0.98766	0.9785	0.16043	0.16928	0.77974	0.000256844	0.000256844	0.000256844
121	1051.68	0.22561	0.19932	0.8246	0.99086	0.99508	0.98763	0.97748	0.17169	0.17745	0.78247	0.00025375	0.00025375	0.00025375
122	1059.34	0.22258	0.19851	0.82226	0.99122	0.99508	0.98714	0.97861	0.16819	0.17056	0.78079	0.000250656	0.000250656	0.000250656
123	1068.51	0.22342	0.1966	0.82019	0.9911	0.99508	0.98688	0.9786	0.16393	0.17113	0.77908	0.000247563	0.000247563	0.000247563
124	1076.69	0.22568	0.20115	0.82268	0.99101	0.99508	0.98797	0.9776	0.16664	0.17207	0.78086	0.000244469	0.000244469	0.000244469
125	1085.36	0.22362	0.20111	0.81935	0.99117	0.99508	0.98859	0.97844	0.16546	0.17225	0.78094	0.000241375	0.000241375	0.000241375
126	1094.71	0.22693	0.20087	0.82494	0.99086	0.99508	0.98777	0.97711	0.16497	0.16968	0.77791	0.000238281	0.000238281	0.000238281
127	1102.39	0.22007	0.19787	0.81919	0.99101	0.99508	0.9888	0.97973	0.18153	0.17773	0.78551	0.000235188	0.000235188	0.000235188
128	1111.64	0.21974	0.19217	0.81868	0.99102	0.99508	0.98799	0.97949	0.16431	0.16649	0.78291	0.000232094	0.000232094	0.000232094
129	1120.35	0.21829	0.19404	0.81964	0.99119	0.99508	0.98739	0.97771	0.16576	0.16632	0.78197	0.000229	0.000229	0.000229
130	1128.58	0.22411	0.1983	0.81994	0.99128	0.99508	0.98802	0.97749	0.16823	0.16793	0.78169	0.000225906	0.000225906	0.000225906
131	1137.97	0.21957	0.19429	0.81653	0.99132	0.99508	0.987	0.97883	0.15823	0.16603	0.78215	0.000222813	0.000222813	0.000222813
132	1145.67	0.21993	0.19376	0.82389	0.99113	0.99508	0.98852	0.97662	0.1709	0.1645	0.78481	0.000219719	0.000219719	0.000219719
133	1155.12	0.22013	0.19457	0.8209	0.99125	0.99508	0.9885	0.97872	0.16736	0.16086	0.78194	0.000216625	0.000216625	0.000216625
134	1164.3	0.2228	0.19321	0.81938	0.99103	0.99508	0.98937	0.97935	0.16508	0.16683	0.78227	0.000213531	0.000213531	0.000213531
135	1172.08	0.22049	0.19382	0.82092	0.99119	0.99508	0.9886	0.98019	0.16887	0.16442	0.78239	0.000210437	0.000210437	0.000210437
136	1181.51	0.21888	0.1933	0.81575	0.991	0.99508	0.98946	0.97914	0.16554	0.16368	0.78193	0.000207344	0.000207344	0.000207344
137	1189.79	0.22405	0.19392	0.82055	0.99096	0.99508	0.98952	0.98018	0.15929	0.16658	0.77999	0.00020425	0.00020425	0.00020425
138	1198.39	0.2163	0.18769	0.8194	0.99085	0.99508	0.98784	0.97731	0.15867	0.16106	0.78109	0.000201156	0.000201156	0.000201156
139	1207.74	0.21657	0.19045	0.82107	0.99091	0.99508	0.98813	0.97813	0.17361	0.16155	0.78425	0.000198063	0.000198063	0.000198063
140	1215.65	0.21997	0.19117	0.82331	0.99128	0.99508	0.98786	0.97961	0.16074	0.15598	0.7811	0.000194969	0.000194969	0.000194969
141	1224.91	0.21461	0.18993	0.8204	0.98977	0.99508	0.9875	0.97901	0.17051	0.15804	0.78291	0.000191875	0.000191875	0.000191875
142	1233.88	0.21369	0.18995	0.81757	0.99112	0.99508	0.98797	0.97944	0.16497	0.15515	0.78102	0.000188781	0.000188781	0.000188781
143	1241.89	0.21662	0.18906	0.81468	0.99103	0.99508	0.98886	0.98077	0.16518	0.15732	0.78152	0.000185688	0.000185688	0.000185688
144	1251.18	0.21635	0.18943	0.81543	0.99107	0.99508	0.9869	0.9781	0.16373	0.1524	0.78188	0.000182594	0.000182594	0.000182594
145	1259.33	0.21738	0.18967	0.8172	0.99109	0.99508	0.98718	0.97764	0.16751	0.16154	0.78189	0.0001795	0.0001795	0.0001795
146	1268.35	0.21643	0.18817	0.81932	0.99042	0.99508	0.98755	0.97668	0.16588	0.15529	0.78182	0.000176406	0.000176406	0.000176406
147	1277.67	0.21343	0.18489	0.816	0.99028	0.99508	0.98767	0.97715	0.16401	0.16033	0.78038	0.000173313	0.000173313	0.000173313
148	1285.62	0.21543	0.18846	0.81794	0.99081	0.99508	0.9893	0.97941	0.16695	0.15992	0.78049	0.000170219	0.000170219	0.000170219
149	1294.88	0.21342	0.18492	0.81745	0.99112	0.99508	0.9889	0.98022	0.16332	0.15919	0.78135	0.000167125	0.000167125	0.000167125
150	1303.84	0.21455	0.18269	0.81813	0.99094	0.99508	0.98776	0.9787	0.16481	0.15935	0.78269	0.000164031	0.000164031	0.000164031
151	1312.04	0.2127	0.18108	0.81775	0.99071	0.99508	0.98795	0.97759	0.16438	0.15585	0.7822	0.000160938	0.000160938	0.000160938
152	1321.42	0.21393	0.18373	0.8223	0.99017	0.99465	0.98812	0.97834	0.15532	0.14845	0.78085	0.000157844	0.000157844	0.000157844
153	1329.31	0.21468	0.18502	0.82178	0.99049	0.99444	0.98845	0.97945	0.16967	0.15327	0.7828	0.00015475	0.00015475	0.00015475
154	1338.69	0.21403	0.18307	0.81865	0.99093	0.99508	0.98823	0.97838	0.16081	0.1531	0.78071	0.000151656	0.000151656	0.000151656
155	1347.95	0.21218	0.17948	0.81502	0.99076	0.99508	0.98757	0.9791	0.16217	0.15126	0.78131	0.000148563	0.000148563	0.000148563
156	1355.62	0.21068	0.17926	0.81746	0.99076	0.99508	0.98793	0.98073	0.1664	0.15247	0.78231	0.000145469	0.000145469	0.000145469
157	1364.86	0.21435	0.18106	0.82077	0.9908	0.99508	0.98823	0.97903	0.15967	0.15435	0.7803	0.000142375	0.000142375	0.000142375
158	1373.15	0.21124	0.18108	0.81395	0.98968	0.99461	0.98842	0.98122	0.16072	0.14947	0.78002	0.000139281	0.000139281	0.000139281
159	1381.75	0.21327	0.18328	0.81647	0.9896	0.9944	0.98663	0.97861	0.15928	0.15079	0.77942	0.000136187	0.000136187	0.000136187
160	1391.01	0.21155	0.18128	0.81812	0.99048	0.99508	0.9878	0.97867	0.15776	0.15012	0.77993	0.000133094	0.000133094	0.000133094
161	1398.78	0.21711	0.18494	0.81886	0.99133	0.99508	0.98814	0.97893	0.16174	0.15305	0.77977	0.00013	0.00013	0.00013
162	1408	0.21316	0.18	0.81658	0.99117	0.99508	0.98836	0.98012	0.15788	0.14968	0.77892	0.000126906	0.000126906	0.000126906
163	1417.08	0.20804	0.17787	0.81452	0.99088	0.99508	0.98919	0.97952	0.16072	0.15713	0.78022	0.000123812	0.000123812	0.000123812
164	1424.99	0.21089	0.17661	0.81573	0.99099	0.99508	0.98922	0.97988	0.1676	0.15664	0.78244	0.000120719	0.000120719	0.000120719</

12.ANEXO 6: TABLA DE RESULTADO DE LAS PREDICCIONES DEL PROCESO DE DETECCIÓN CON IMÁGENES DEL DATASET

Column1	Column2	Column3	Column4	Column5	Column6	Column7	Column8	Column9	Column10	Column11	Column12	Column13	Column14	Column15	Column16	Column17	Column18	Column19	Column20
imagen	objetos detectados																		
regila_457.jpg	Peach (0.99)	Lemon (0.98)	Apple (0.98)	Orange (0.98)	Apple (0.98)	Grape (0.98)	Grape (0.98)	Melon (0.98)	Grape (0.98)	Cherry (0.98)	Pear (0.97)	Pear (0.97)	Pineapple (0.97)	Strawberry (0.97)	Pear (0.97)	Cherry (0.97)	Strawberry (0.97)	Banana (0.97)	Watermelon (0.96)
regila_468.jpg	Watermelon (0.99)	Cherry (0.99)	Lemon (0.99)	Apple (0.98)	Pear (0.98)	Melon (0.98)	Strawberry (0.98)	Grape (0.98)	Strawberry (0.98)	Cherry (0.98)	Peach (0.98)	Apple (0.98)	Peach (0.97)	Apple (0.97)	Pear (0.97)	Orange (0.97)	Banana (0.97)	Strawberry (0.96)	Pineapple (0.95)
regila_469.jpg	Apple (0.99)	Cherry (0.98)	Pear (0.98)	Grape (0.98)	Strawberry (0.98)	Orange (0.98)	Cherry (0.98)	Strawberry (0.98)	Lemon (0.98)	Apple (0.98)	Peach (0.97)	Grape (0.97)	Pear (0.97)	Melon (0.97)	Watermelon (0.97)	Pear (0.96)	Pineapple (0.96)	Banana (0.96)	
regila_471.jpg	Apple (0.98)	Pear (0.98)	Apple (0.98)	Peach (0.98)	Cherry (0.98)	Strawberry (0.98)	Grape (0.98)	Cherry (0.98)	Lemon (0.98)	Pear (0.98)	Pear (0.97)	Strawberry (0.97)	Orange (0.97)	Banana (0.97)	Melon (0.97)	Grape (0.96)	Pineapple (0.95)		
regila_472.jpg	Apple (0.99)	Peach (0.99)	Apple (0.99)	Strawberry (0.98)	Cherry (0.98)	Grape (0.98)	Orange (0.98)	Cherry (0.98)	Lemon (0.98)	Pear (0.97)	Grape (0.97)	Banana (0.97)	Melon (0.97)	Pear (0.97)	Pear (0.97)	Pear (0.96)	Strawberry (0.96)	Pineapple (0.96)	
regila_474.jpg	Apple (0.98)	Cherry (0.98)	Apple (0.98)	Grape (0.98)	Grape (0.98)	Orange (0.98)	Pear (0.98)	Melon (0.98)	Peach (0.98)	Strawberry (0.97)	Cherry (0.97)	Lemon (0.97)	Pear (0.97)	Pear (0.97)	Strawberry (0.97)	Banana (0.96)	Pineapple (0.96)		
regila_475.jpg	Peach (0.99)	Apple (0.98)	Grape (0.98)	Cherry (0.98)	Grape (0.98)	Lemon (0.98)	Cherry (0.98)	Pear (0.98)	Banana (0.98)	Apple (0.98)	Strawberry (0.97)	Pear (0.97)	Strawberry (0.97)	Melon (0.96)	Pear (0.95)	Pineapple (0.95)			
regila_476.jpg	Pear (0.99)	Apple (0.99)	Cherry (0.99)	Peach (0.99)	Lemon (0.99)	Cherry (0.98)	Grape (0.98)	Apple (0.98)	Grape (0.98)	Melon (0.98)	Banana (0.98)	Strawberry (0.98)	Pear (0.97)	Pear (0.97)	Pineapple (0.96)	Strawberry (0.95)			
regila_477.jpg	Apple (0.98)	Grape (0.98)	Cherry (0.98)	Peach (0.98)	Apple (0.98)	Pear (0.98)	Pear (0.98)	Grape (0.98)	Strawberry (0.98)	Lemon (0.98)	Melon (0.97)	Pear (0.97)	Banana (0.97)	Cherry (0.97)	Strawberry (0.95)	Pineapple (0.94)			
regila_478.jpg	Apple (0.99)	Pear (0.99)	Cherry (0.98)	Apple (0.98)	Pear (0.98)	Lemon (0.98)	Grape (0.98)	Banana (0.98)	Apple (0.98)	Pear (0.97)	Cherry (0.97)	Strawberry (0.97)	Peach (0.96)	Melon (0.96)	Strawberry (0.96)	Pineapple (0.94)			
regila_480.jpg	Apple (0.99)	Pear (0.98)	Pear (0.98)	Apple (0.98)	Apple (0.98)	Grape (0.98)	Cherry (0.98)	Peach (0.98)	Lemon (0.98)	Cherry (0.98)	Strawberry (0.97)	Melon (0.97)	Banana (0.97)	Strawberry (0.97)	Melon (0.97)	Banana (0.97)	Strawberry (0.96)	Pineapple (0.95)	
regila_482.jpg	Grape (0.99)	Melon (0.99)	Apple (0.99)	Apple (0.98)	Grape (0.98)	Lemon (0.98)	Pear (0.98)	Cherry (0.97)	Strawberry (0.97)	Pear (0.97)	Cherry (0.97)	Strawberry (0.97)	Banana (0.97)	Peach (0.96)	Pineapple (0.94)				
regila_483.jpg	Apple (0.99)	Apple (0.98)	Strawberry (0.98)	Cherry (0.98)	Lemon (0.98)	Cherry (0.98)	Grape (0.98)	Pear (0.98)	Strawberry (0.98)	Banana (0.98)	Pear (0.97)	Grape (0.97)	Pear (0.97)	Peach (0.97)	Melon (0.96)	Pineapple (0.94)			
regila_484.jpg	Apple (0.99)	Peach (0.99)	Melon (0.98)	Pear (0.98)	Grape (0.98)	Apple (0.98)	Grape (0.98)	Cherry (0.98)	Strawberry (0.97)	Pear (0.97)	Lemon (0.97)	Banana (0.97)	Pear (0.97)	Strawberry (0.96)	Pineapple (0.95)				
regila_485.jpg	Pear (0.98)	Apple (0.98)	Grape (0.98)	Apple (0.98)	Lemon (0.98)	Melon (0.98)	Cherry (0.98)	Strawberry (0.98)	Grape (0.97)	Peach (0.97)	Strawberry (0.97)	Pear (0.97)	Cherry (0.96)	Pineapple (0.96)	Banana (0.96)	Pear (0.96)			
regila_486.jpg	Lemon (0.98)	Apple (0.98)	Cherry (0.98)	Pear (0.98)	Cherry (0.98)	Apple (0.98)	Cherry (0.98)	Cherry (0.98)	Strawberry (0.98)	Peach (0.97)	Melon (0.97)	Pear (0.97)	Pear (0.96)	Strawberry (0.95)					
regila_487.jpg	Apple (0.98)	Pear (0.98)	Lemon (0.98)	Apple (0.98)	Cherry (0.98)	Cherry (0.98)	Cherry (0.98)	Strawberry (0.98)	Peach (0.97)	Melon (0.97)	Pear (0.97)	Pear (0.96)	Strawberry (0.95)						
regila_488.jpg	Pear (0.98)	Cherry (0.98)	Melon (0.98)	Pear (0.97)	Strawberry (0.96)														
regila_489.jpg	Pear (0.98)	Cherry (0.98)	Pear (0.98)	Strawberry (0.97)	Pear (0.96)	Melon (0.95)													
regila_490.jpg	Pear (0.98)	Cherry (0.97)	Pear (0.97)	Melon (0.95)	Strawberry (0.95)														
regila_492.jpg	Pear (0.98)	Cherry (0.98)	Pear (0.97)	Strawberry (0.97)	Melon (0.96)														
regila_493.jpg	Cherry (0.98)	Pear (0.97)	Strawberry (0.97)	Pear (0.97)	Melon (0.96)														
regila_494.jpg	Cherry (0.98)	Pear (0.97)	Melon (0.97)	Pear (0.96)	Strawberry (0.96)														
regila_495.jpg	Cherry (0.98)	Pear (0.98)	Pear (0.98)	Strawberry (0.96)	Melon (0.96)														
regila_496.jpg	Cherry (0.98)	Pear (0.97)	Pear (0.96)	Melon (0.95)	Strawberry (0.95)														
regila_497.jpg	Cherry (0.98)	Pear (0.97)	Strawberry (0.97)	Melon (0.96)	Pear (0.96)														
regila_498.jpg	Cherry (0.98)	Pear (0.97)	Melon (0.97)	Pear (0.97)	Strawberry (0.96)														
regila_499.jpg	Cherry (0.98)	Pear (0.97)	Melon (0.97)	Pear (0.96)	Strawberry (0.96)														
regila_500.jpg	Cherry (0.98)	Pear (0.97)	Pear (0.96)	Strawberry (0.96)	Melon (0.95)														
regila_501.jpg	Cherry (0.98)	Pear (0.97)	Strawberry (0.97)	Pear (0.96)	Melon (0.95)														
regila_502.jpg	Cherry (0.98)	Pear (0.98)	Pear (0.97)	Strawberry (0.97)	Melon (0.96)														
regila_503.jpg	Pear (0.98)	Cherry (0.98)	Strawberry (0.96)	Pear (0.96)	Melon (0.94)														
regila_504.jpg	Cherry (0.98)	Pear (0.98)	Melon (0.97)	Pear (0.97)	Strawberry (0.96)														
regila_505.jpg	Cherry (0.98)	Pear (0.98)	Strawberry (0.97)	Melon (0.97)	Pear (0.96)														
regila_506.jpg	Pear (0.98)	Cherry (0.98)	Strawberry (0.96)	Melon (0.97)	Pear (0.96)														
regila_507.jpg	Cherry (0.98)	Melon (0.98)	Pear (0.97)	Pear (0.96)	Strawberry (0.96)														
regila_508.jpg	Cherry (0.98)	Pear (0.98)	Melon (0.97)	Strawberry (0.97)	Pear (0.96)														
regila_509.jpg	Melon (0.98)	Cherry (0.98)	Pear (0.98)	Pear (0.97)	Strawberry (0.96)														
regila_510.jpg	Cherry (0.98)	Pear (0.97)	Melon (0.97)	Pear (0.97)	Strawberry (0.95)														
regila_511.jpg	Cherry (0.98)	Pear (0.98)	Pear (0.97)	Melon (0.97)	Strawberry (0.96)														
regila_512.jpg	Cherry (0.98)	Pear (0.98)	Pear (0.97)	Strawberry (0.96)	Melon (0.95)														
regila_514.jpg	Cherry (0.98)	Pear (0.98)	Strawberry (0.98)	Pear (0.97)	Melon (0.95)														
regila_516.jpg	Cherry (0.98)	Strawberry (0.98)	Melon (0.97)	Pear (0.97)	Pear (0.97)														
regila_517.jpg	Cherry (0.98)	Pear (0.98)	Strawberry (0.97)	Pear (0.97)	Melon (0.96)														
regila_518.jpg	Cherry (0.98)	Pear (0.97)	Melon (0.97)	Strawberry (0.97)	Pear (0.96)														
regila_519.jpg	Strawberry (0.97)	Cherry (0.97)	Pear (0.97)	Melon (0.96)	Pear (0.96)														
regila_520.jpg	Cherry (0.99)	Pear (0.98)	Pear (0.98)	Strawberry (0.97)	Melon (0.96)														
regila_521.jpg	Pear (0.98)	Cherry (0.98)	Melon (0.96)	Pear (0.96)	Strawberry (0.96)														
regila_522.jpg	Cherry (0.98)	Pear (0.97)	Strawberry (0.97)	Pear (0.97)	Melon (0.96)														
regila_523.jpg	Cherry (0.99)	Pear (0.98)	Strawberry (0.97)	Pear (0.97)	Melon (0.96)														
regila_524.jpg	Pear (0.98)	Cherry (0.98)	Pear (0.97)	Melon (0.95)	Strawberry (0.95)														
regila_525.jpg	Cherry (0.98)	Strawberry (0.97)	Pear (0.97)	Melon (0.97)	Pear (0.94)														
regila_526.jpg	Pear (0.98)	Cherry (0.98)	Pear (0.97)	Melon (0.97)	Strawberry (0.96)														
regila_527.jpg	Pear (0.99)	Cherry (0.98)	Strawberry (0.97)	Melon (0.97)	Pear (0.97)														
regila_528.jpg	Cherry (0.98)	Pear (0.98)	Melon (0.97)	Pear (0.97)	Strawberry (0.95)														
regila_529.jpg	Cherry (0.98)	Pear (0.98)	Strawberry (0.97)	Pear (0.96)	Melon (0.96)														
regila_530.jpg	Cherry (0.99)	Pear (0.98)	Pear (0.97)	Melon (0.96)	Strawberry (0.95)														
regila_531.jpg	Cherry (0.98)	Pear (0.98)	Strawberry (0.98)	Pear (0.98)	Melon (0.94)														
regila_532.jpg	Cherry (0.98)	Pear (0.97)	Strawberry (0.97)	Pear (0.97)	Melon (0.96)														
regila_533.jpg	Cherry (0.98)	Pear (0.97)	Melon (0.97)	Strawberry (0.97)	Pear (0.96)														
regila_534.jpg	Pear (0.98)	Cherry (0.97)	Melon (0.97)	Pear (0.97)	Strawberry (0.96)														
regila_535.jpg	Cherry (0.98)	Pear (0.97)	Strawberry (0.97)	Pear (0.97)	Melon (0.96)														
regila_536.jpg	Cherry (0.98)	Melon (0.98)	Pear (0.97)	Pear (0.97)	Strawberry (0.97)														
regila_537.jpg	Pear (0.98)	Cherry (0.98)	Pear (0.97)	Strawberry (0.97)	Melon (0.94)														
regila_538.jpg	Cherry (0.98)	Strawberry (0.98)	Pear (0.98)	Melon (0.96)	Pear (0.96)														
regila_565.jpg	Cherry (0.98)	Pear (0.97)	Pear (0.97)	Strawberry (0.96)	Melon (0.96)														
regila_572.jpg	Pear (0.98)	Cherry (0.98)	Pear (0.98)	Strawberry (0.97)	Melon (0.96)														
regila_575.jpg	Pear (0.99)	Cherry (0.98)	Melon (0.97)	Pear (0.97)	Strawberry (0.96)														
regila_576.jpg	Melon (0.98)	Pear (0.98)	Strawberry (0.98)	Cherry (0.98)	Pear (0.97)														
regila_577.jpg	Cherry (0.98)	Pear (0.98)	Pear (0.98)	Melon (0.96)	Strawberry (0.96)														
regila_578.jpg	Cherry (0.98)	Melon (0.97)	Pear (0.97)	Pear (0.97)	Strawberry (0.97)														
regila_579.jpg	Melon (0.98)	Cherry (0.97)	Pear (0.97)	Pear (0.97)	Strawberry (0.97)														
regila_580.jpg	Melon (0.97)	Strawberry (0.97)	Cherry (0.97)	Pear (0.97)	Pear (0.96)														

Tabla 45: Resultados de las predicciones del proceso de detección.

13. ANEXO 7: CÓDIGO DE LA APLICACIÓN

13.1 Código para el proceso de clasificación

```
from google.colab import drive
drive.mount('/content/drive')
!pip install ultralytics
```

Figura 14: Fragmento de código para conectar el cuaderno de Google Colab a Google Drive e instalar la biblioteca Ultralytics.

```
import os
from ultralytics import YOLO

ROOT_DIR = '/content/drive/MyDrive/ColabTFG/Yolov8ClasificaciónManzanaLuz/data'

model = YOLO("yolov8n-cls.pt")

results = model.train(data=ROOT_DIR, epochs=10, imgs=100, save_period=5, device="0", project=ROOT_DIR,
name="runs_classification")
```

Figura 15: Fragmento de código para realizar un entrenamiento de clasificación de la red YOLOv8.

```
from ultralytics import YOLO
import pandas as pd
import os
import csv
import re

model =
YOLO('/content/drive/MyDrive/ColabTFG/Yolov8ClasificaciónManzana/data/runs_classification/weights/best.pt')
results =
model.predict(source='/content/drive/MyDrive/ColabTFG/Yolov8ClasificaciónManzana/imagenes_predicción', save=False)

predicciones = []

# Recorrer los resultados y agregar datos a la lista
for result in results:
    nombre_imagen = os.path.basename(result.path)
    clase_predicha = result.names[result.probs.top1] # Clase predicha
    confianza = float(result.probs.top1conf) # Confianza de la predicción
    predicciones.append([nombre_imagen, clase_predicha, confianza])

# Función para extraer el número de la imagen
def extraer_numero(imagen):
    match = re.search(r'(\d+)', imagen) # Buscar un número en el nombre de la imagen
    return int(match.group(1)) if match else 0 # Si hay un número, devolverlo como entero

# Ordenar la lista de predicciones numéricamente por el número en el nombre de la imagen
predicciones.sort(key=lambda x: extraer_numero(x[0])) # Ordenar por número extraído

# Ruta donde guardarás el archivo CSV
output_dir = "/content/drive/MyDrive/ColabTFG/Yolov8ClasificaciónManzana/imagenes_predicción"
output_file = os.path.join(output_dir, "resultados_predicciones_manzanas.csv")

# Guardar los resultados ordenados en un archivo CSV
with open(output_file, mode='w', newline='') as file:
    writer = csv.writer(file)
    # Escribir el encabezado
    writer.writerow(["Imagen", "Clase", "Confianza"])
    # Escribir las filas de datos
    writer.writerows(predicciones)

print(f"✅ CSV guardado como '{output_file}' y ordenado numéricamente por imagen.")
```

Figura 13: Fragmento de código para realizar predicciones empleando un modelo de clasificación y generar un archivo con los resultados de las predicciones.

```

import cv2
import numpy as np
import random
import os
import csv

def modificar_brillo_aleatorio(imagen_path):
    img = cv2.imread(imagen_path)
    if img is None:
        print(f"No se pudo cargar la imagen {imagen_path}")
        return None, None

    # Generar un factor que esté fuera del rango (-0.1, 0.1)
    while True:
        factor = random.uniform(-0.8, 0.8)
        if abs(factor) >= 0.1:
            break

    img_float = img.astype(np.float32)
    brillo_cambio = 255 * factor
    img_mod = img_float + brillo_cambio
    img_mod = np.clip(img_mod, 0, 255).astype(np.uint8)
    return img_mod, factor

def procesar_carpeta(carpeta_entrada, carpeta_salida, archivo_csv):
    os.makedirs(carpeta_salida, exist_ok=True)

    with open(archivo_csv, mode='w', newline='') as f_csv:
        writer = csv.writer(f_csv)
        writer.writerow(['nombre_imagen', 'factor_brillo'])

    for archivo in os.listdir(carpeta_entrada):
        ruta_entrada = os.path.join(carpeta_entrada, archivo)
        if not os.path.isfile(ruta_entrada):
            continue

        img_modificada, factor = modificar_brillo_aleatorio(ruta_entrada)
        if img_modificada is not None:
            nombre, ext = os.path.splitext(archivo)
            nuevo_nombre = f"{nombre}_mod{ext}"
            ruta_salida = os.path.join(carpeta_salida, nuevo_nombre)
            cv2.imwrite(ruta_salida, img_modificada)
            print(f"Guardada imagen modificada: {nuevo_nombre}")

            writer.writerow([nuevo_nombre, round(factor, 4)])

if __name__ == "__main__":
    carpeta_entrada = "/content/drive/MyDrive/ColabTFG/Yolov8ClasificaciónManzana/imagenes_predicción"
    carpeta_salida = "/content/drive/MyDrive/ColabTFG/Yolov8ClasificaciónManzana/imagenes_predicción_luz"
    archivo_csv = os.path.join(carpeta_salida, "log.csv")
    procesar_carpeta(carpeta_entrada, carpeta_salida, archivo_csv)

```

Figura 14: Fragmento de código para generar cambios de iluminación en las imágenes de predicción.

13.2 Código para el proceso de detección

```
import os
import random
from PIL import Image
from tqdm import tqdm

# CONFIGURACIÓN
carpeta_principal = '/content/drive/MyDrive/ColabTFG/Yolov8ClasificaciónConjunta/data/train' # CAMBIA
ESTA_RUTA_según_tu_estructura
carpeta_salida = '/content/drive/MyDrive/ColabTFG/Deteccion/Imágenes_rejilla_2' # Ruta donde guardar
las_rejillas
os.makedirs(carpeta_salida, exist_ok=True)

filas, columnas = 5, 5
tamano_imagen = 100
tamano_rejilla = (columnas * tamano_imagen, filas * tamano_imagen)
color_blanco = (255, 255, 255)

# Leer imágenes por carpeta
carpetas = sorted([
    os.path.join(carpeta_principal, d) for d in os.listdir(carpeta_principal)
    if os.path.isdir(os.path.join(carpeta_principal, d))
])

imagenes_por_carpeta = {}
for i, carpeta in enumerate(carpetas):
    imagenes = [os.path.join(carpeta, f) for f in os.listdir(carpeta)
                 if f.lower().endswith(('.png', '.jpg', '.jpeg'))]
    random.shuffle(imagenes)
    imagenes_por_carpeta[i] = imagenes

# Calcular cuántas rejillas se pueden hacer
rejillas_posibles = 0
imagenes_temp = {(k: v.copy() for k, v in imagenes_por_carpeta.items())}
while any(imagenes_temp.values()):
    usados = 0
    for lst in imagenes_temp.values():
        if lst:
            lst.pop()
            usados += 1
    if usados == 0:
        break
    rejillas_posibles += 1

# Generar rejillas con barra de progreso
rejilla_idx = 0
with tqdm(total=rejillas_posibles, desc="Generando rejillas") as pbar:
    while True:
        rejilla = Image.new("RGB", tamano_rejilla, color_blanco)
        posiciones = [(i, j) for i in range(filas) for j in range(columnas)]
        random.shuffle(posiciones)

        usadas = 0
        for carpeta_id in list(imagenes_por_carpeta.keys()):
            if usadas >= filas * columnas:
                break

            if imagenes_por_carpeta[carpeta_id]:
                ruta_img = imagenes_por_carpeta[carpeta_id].pop()
                img = Image.open(ruta_img).resize((tamano_imagen, tamano_imagen))

                fila, col = posiciones.pop()
                x = col * tamano_imagen
                y = fila * tamano_imagen
                rejilla.paste(img, (x, y))

                usadas += 1
            else:
                if posiciones:
                    posiciones.pop() # espacio blanco

        if usadas == 0:
            break

        nombre_archivo = os.path.join(carpeta_salida, f"rejilla_{rejilla_idx:03d}.png")
        rejilla.save(nombre_archivo)
        rejilla_idx += 1
        pbar.update(1)

print(f"✅ Proceso finalizado. Rejillas guardadas en: {carpeta_salida}")
```

Figura 15: Fragmento de código para generar las nuevas imágenes para emplear en el proceso de detección.

```

import os
from ultralytics import YOLO

ROOT_DIR = '/content/drive/MyDrive/ColabTFG/Deteccion3/data.yaml'

model= YOLO("yolov8n.pt")

results = model.train(data=ROOT_DIR, epochs=200, imgsz=512, save_period=5, device="0")
!cp -r runs/detect/train '/content/drive/MyDrive/ColabTFG/Deteccion3/ResultadosEntrenamiento'

```

Figura 16: Fragmento de código para realizar un entrenamiento de detección de la red YOLOv8.

```

from ultralytics import YOLO
import csv
import os
import yaml

# Cargar clases desde data.yaml
with open("/content/drive/MyDrive/ColabTFG/Deteccion3/data.yaml", "r") as f:
    data = yaml.safe_load(f)
names = data["names"]

# Cargar modelo
model = YOLO("/content/drive/MyDrive/ColabTFG/Deteccion3/ResultadosEntrenamiento/weights/best.pt")

# Realizar predicciones
source_folder = '/content/drive/MyDrive/ColabTFG/Deteccion3/imagenes_predicción'
results = model.predict(source=os.path.join(source_folder, 'images'), save=True)

# Guardar resultados visuales
!cp -r runs/detect/predict5 '/content/drive/MyDrive/ColabTFG/Deteccion3/ResultadosPrediccion'

# Ruta del CSV
csv_path = os.path.join(source_folder, "images", "predicciones_por_imagen.csv")

print(f"Guardando CSV en: {csv_path}")
print(f"Total de imágenes procesadas: {len(results)}")

with open(csv_path, "w", newline="") as f:
    writer = csv.writer(f)
    writer.writerow(["imagen", "objetos_detectados"])

    for r in results:
        image_name = os.path.basename(r.path)
        objetos_detectados = []

        print(f"\nProcesando imagen: {image_name}")

        if not r.boxes or len(r.boxes) == 0:
            print("-> No se detectó nada.")
        else:
            for box in r.boxes:
                cls_id = int(box.cls[0])
                conf = float(box.conf[0])
                nombre_clase = names[cls_id]
                print(f"-> Detectado: {nombre_clase} ({conf:.2f})")
                objetos_detectados.append(f"{nombre_clase} ({conf:.2f})")

        texto_objetos = ", ".join(objetos_detectados) if objetos_detectados else "ninguno"
        writer.writerow([image_name] + objetos_detectados if objetos_detectados else [image_name, "ninguno"])

print("\nContenido de la carpeta después de guardar:")
!ls "/content/drive/MyDrive/ColabTFG/Deteccion3/imagenes_predicción/images"

```

Figura 7: Fragmento de código para realizar predicciones empleando un modelo de detección y generar un archivo con los resultados de las predicciones.