

**UNIVERSIDAD TÉCNICA DEL NORTE**



Facultad de Ingeniería en Ciencias Aplicadas Carrera de  
Ingeniería de Software

**DETECCIÓN AUTOMÁTICA DE MALEZAS EN CULTIVOS DE MAÍZ Y/O PAPA UTILIZANDO  
IMÁGENES ADQUIRIDAS POR DRONES EMPLEANDO LA ARQUITECTURA DE RED NEURONAL  
CONVOLUCIONAL XCEPTION.**

Trabajo de grado previo a la obtención del título de Ingeniero de Software

Autor:

Kevin Johao Lema Días

Director:

PhD. Iván Danilo García Santillán

Ibarra – Ecuador

2024



# UNIVERSIDAD TÉCNICA DEL NORTE

## BIBLIOTECA UNIVERSITARIA

### AUTORIZACIÓN DE USO Y PUBLICACIÓN A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE

#### 1. IDENTIFICACIÓN DE LA OBRA

En cumplimiento del Art. 144 de la Ley de Educación Superior, hago la entrega del presente trabajo a la Universidad Técnica del Norte para que sea publicado en el Repositorio Digital Institucional, para lo cual pongo a disposición la siguiente información:

| DATOS DE CONTACTO    |                            |                 |            |
|----------------------|----------------------------|-----------------|------------|
| CÉDULA DE IDENTIDAD: | 1003125596                 |                 |            |
| APELLIDOS Y NOMBRES: | Lema Dias Kevin Johao      |                 |            |
| DIRECCIÓN:           | Peguiche – Barrio Central. |                 |            |
| EMAIL:               | kjlemad@utn.edu.ec         |                 |            |
| TELÉFONO FIJO:       | 062690091                  | TELÉFONO MÓVIL: | 0990294791 |

| DATOS DE LA OBRA                   |  |
|------------------------------------|--|
| TÍTULO:                            | Detección automática de malezas en cultivos de maíz y/o papa utilizando imágenes adquiridas por drones empleando la arquitectura de red neuronal convolucional Xception. |
| AUTOR (ES):                        | Kevin Johao Lema Dias  |
| FECHA DE APROBACIÓN:<br>DD/MM/AAAA | 30/07/2024   |
| PROGRAMA:                          | <input checked="" type="checkbox"/> PREGRADO <input type="checkbox"/> POSGRADO   |
| TITULO POR EL QUE<br>OPTA:         | Ingeniero de software  |
| ASESOR /DIRECTOR:                  | PhD. Iván Danilo García Santillán  |

#### 2. CONSTANCIAS

El autor (es) manifiesta (n) que la obra objeto de la presente autorización es original y se la desarrolló, sin violar derechos de autor de terceros, por lo tanto la obra es original y que es (son) el (los) titular (es) de los derechos patrimoniales, por lo que asume (n) la responsabilidad sobre el contenido de la misma y saldrá (n) en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 30 días del mes de julio de 2024

EL AUTOR:

Kevin Johao Lema Dias  
1003125596

## CERTIFICACIÓN DIRECTOR

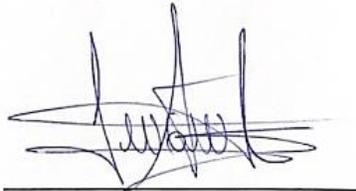
Ibarra, 30 de julio del 2024

### CERTIFICACIÓN DIRECTOR DEL TRABAJO DE TITULACIÓN

Por medio del presente yo, PhD. Iván Danilo García Santillán, certifico que el sr. Kevin Johao Lema Dias portador de la cedula de ciudadanía número 1003125596, ha trabajado en el desarrollo del proyecto de grado **“Detección automática de malezas en cultivos de maíz y/o papa utilizando imágenes adquiridas por drones empleando la arquitectura de red neuronal convolucional Xception.”**, previo a la obtención del Título de Ingeniero en Software realizado con interés profesional y responsabilidad que certifico con honor de verdad.

Es todo en cuanto puedo certificar a la verdad

Atentamente



PhD. Iván Danilo García Santillán

DIRECTOR DE TRABAJO DE GRADO

## **DEDICATORIA**

En primer lugar, dedicar este proyecto a mi madre, padre, hermanos y hermanas, en una sola palabra, a toda mi familia que en todo el tiempo que han estado conmigo han encontrado maneras de enseñarme a ver la vida de diferente manera, me han enseñado que nada es imposible y cada uno de ellos me han demostrado que siempre se puede salir adelante con voluntad propia, y sobre todo me han demostrado todo el amor que me tienen.

Citando a un buen y gran amigo “esta dedicatoria es un recordatorio de que cuando nos apasionamos por algo, podemos alcanzar metas increíbles”, por lo que este trabajo y esfuerzo va dedicado a mi persona, que por instantes pensó en rendirse y hoy culmina una etapa de su vida profesional.

Por último, pero no por ello menos importante. Mi hermano, que sé que estaría orgulloso de ver lo que logré, la dedicatoria va a alguien que por mucho tiempo fue quien tuvo unida a la familia, la dedicatoria va a alguien que extraño y que me hubiese gustado saber que palabras tendría para esta ocasión.

Kevin Johao Lema Dias

## **AGRADECIMIENTO**

Expresar mi más sincero agradecimiento a toda mi familia, a todos mis amigos y demás personas que han formado parte de mi vida, que aunque ya no tengo a varios de ellos presentes en mi vida, su presencia ha ayudado a formar la persona que soy hoy en día y la ausencia de varios de ellos me ha ayudado a valorar los pequeños detalles que nos da la vida, esos pequeños detalles que sin darnos cuenta resultan ser una gran memoria.

Gracias a quienes a raíz de una pequeña amistad formaron parte importante de mi crecimiento y me acompañaron en todo este transcurso, gracias a quienes de manera desinteresada me ayudaron y brindaron más de un consejo, gracias a quienes me hicieron sentir como en familia, en palabras cortas, gracias a la vida por ponerme a personas maravillosas en mi camino con quienes tratar y gracias por la familia en la que crecí, pues sin ninguno de ellos nada de esto culminaría en la finalización de mi proyecto.

Asimismo, extender mis agradecimientos a la Universidad Técnica del Norte, que me enseñó que quienes la conforman son los que la hacen grande, pues dentro de sus aulas conocí a excelentes compañeros, docentes y demás personal. Gracias por hacer una contribución significativa en el desarrollo de mi vida profesional.

Así llegar a dar las gracias al PhD. García Santillán Iván Danilo y al PhD. Pusdá Chulde Marco Remigio que sin ellos nada de este proyecto y su culminación habría sido posible, pues su mentoría, sabiduría y experiencia fueron clave en todo el proyecto, muchas gracias.

Kevin Johao Lema Dias

## Índice de contenido

|   |           |
|---|-----------|
| <b>DEDICATORIA .....</b>                | <b>4</b>  |
| <b>AGRADECIMIENTO.....</b>              | <b>5</b>  |
| <b>Índice de tablas .....</b>           | <b>10</b> |
| <b>Índice de figuras .....</b>          | <b>12</b> |
| <b>RESUMEN .....</b>                    | <b>14</b> |
| <b>ABSTRACT .....</b>                   | <b>16</b> |
| <b>INTRODUCCIÓN .....</b>               | <b>17</b> |
| <b>Tema .....</b>                       | <b>17</b> |
| <b>Antecedentes.....</b>                | <b>17</b> |
| <b>Situación Actual .....</b>           | <b>17</b> |
| <b>Planteamiento del Problema .....</b> | <b>17</b> |
| <b>Objetivos.....</b>                   | <b>18</b> |
| <b>Objetivo General.....</b>            | <b>18</b> |
| <b>Objetivos Específicos.....</b>       | <b>18</b> |
| <b>Alcance .....</b>                    | <b>19</b> |
| <b>Justificación.....</b>               | <b>20</b> |
| <b>Justificación Tecnológica .....</b>  | <b>21</b> |
| <b>Justificación Agrícola .....</b>     | <b>21</b> |

|  |           |
|--|-----------|
| <b>CAPÍTULO 1 .....</b>                                | <b>22</b> |
| <b>Marco teórico.....</b>                              | <b>22</b> |
| <b>1.1. Fundamentación Teórica .....</b>               | <b>22</b> |
| 1.1.1. Malezas en Cultivos .....                       | 22        |
| 1.1.2. Tipos de Malezas en Papas y/o Maíz.....         | 22        |
| 1.1.3. Agricultura de Precisión .....                  | 26        |
| 1.1.4. Tecnologías en la Agricultura de Precisión..... | 27        |
| <b>1.2. Inteligencia Artificial (IA) .....</b>         | <b>27</b> |
| 1.2.1. Inteligencia Artificial (IA) .....              | 27        |
| 1.2.2. Visión por Computador .....                     | 28        |
| 1.2.3. Redes Neuronales Convolucionales (CNN).....     | 28        |
| 1.2.4. Arquitectura Xception .....                     | 29        |
| 1.2.5. Arquitectura EfficientDet .....                 | 30        |
| <b>1.3. Metodología de Desarrollo de Software.....</b> | <b>33</b> |
| 1.3.1. Knowledge Discovery in Databases (KDD) .....    | 33        |
| <b>1.4. ISO .....</b>                                  | <b>34</b> |
| 1.4.1. ISO 25010 .....                                 | 34        |
| 1.4.2. ISO 25023 .....                                 | 34        |
| <b>1.5. Trabajos Relacionados .....</b>                | <b>34</b> |
| <b>1.6. Preguntas de Investigación .....</b>           | <b>37</b> |
| <b>CAPÍTULO 2 .....</b>                                | <b>40</b> |
| <b>Desarrollo .....</b>                                | <b>40</b> |

|                                       |   |           |
|---------------------------------------|---|-----------|
| <b>2.1.</b>                           | <b>Análisis de Requerimientos.....</b>                    | <b>40</b> |
| <b>2.2.</b>                           | <b>Metodología KDD .....</b>                              | <b>41</b> |
| 2.2.1.                                | Fase de Recolección de Datos .....                        | 41        |
| 2.2.2.                                | Fase de Selección, Preprocesamiento y Transformación..... | 45        |
| 2.2.3.                                | Fase de Minería de Datos .....                            | 51        |
| 2.2.4.                                | Fase de Evaluación e Interpretación .....                 | 56        |
| 2.2.5.                                | Difusión y Uso.....                                       | 57        |
| <b>CAPÍTULO 3 .....</b>               |   | <b>60</b> |
| <b>Validación de Resultados .....</b> |   | <b>60</b> |
| <b>3.1.</b>                           | <b>Análisis de Resultados .....</b>                       | <b>60</b> |
| <b>3.2.</b>                           | <b>Métricas del modelo EfficientDet.....</b>              | <b>60</b> |
| 3.2.1.                                | Comparativa Método Tradicional y EfficientDet .....       | 64        |
| 3.2.2.                                | Pruebas Estadísticas.....                                 | 65        |
| <b>3.3.</b>                           | <b>ISO 25010 - 25023 .....</b>                            | <b>74</b> |
| 3.3.1.                                | Compleitud Funcional .....                                | 74        |
| 3.3.2.                                | Corrección Funcional.....                                 | 75        |
| 3.3.3.                                | Pertinencia Funcional.....                                | 77        |
| 3.3.4.                                | Validación de Resultados. ....                            | 78        |
| 3.3.5.                                | Análisis de Resultados .....                              | 79        |
| <b>DISCUSIÓN .....</b>                |   | <b>79</b> |
| <b>CONCLUSIONES.....</b>              |   | <b>81</b> |
| <b>RECOMENDACIONES.....</b>           |   | <b>82</b> |

**BIBLIOGRAFÍA.....84**

**ANEXOS.....89**

## Índice de tablas

|  |    |
|--|----|
| <b>Tabla 1</b> Nombres comunes de malezas en las zonas paperas del Ecuador ..... | 22 |
| <b>Tabla 2</b> Malezas en cultivo de papa y su grado de nocividad .....          | 24 |
| <b>Tabla 3</b> Versiones de EfficientDet.....                                    | 31 |
| <b>Tabla 4</b> Preguntas de investigación .....                                  | 37 |
| <b>Tabla 5</b> Requerimientos del proyecto .....                                 | 40 |
| <b>Tabla 6</b> Parámetros para captura de imágenes.....                          | 44 |
| <b>Tabla 7</b> Fechas en las que se obtuvieron las imágenes .....                | 44 |
| <b>Tabla 8</b> Número de imágenes tomadas por cada fecha en cada terreno .....   | 45 |
| <b>Tabla 9</b> Número de imágenes útiles resultantes.....                        | 49 |
| <b>Tabla 10</b> Imágenes utilizables de todos los terrenos .....                 | 49 |
| <b>Tabla 11</b> Costos de Colab Pro .....  | 55 |
| <b>Tabla 12</b> Hiperparámetros de entrenamiento .....                           | 56 |
| <b>Tabla 13</b> Resultados de experimentaciones con EfficientDet .....           | 61 |
| <b>Tabla 14</b> Comparativa de Tiempos .....                                     | 64 |
| <b>Tabla 15</b> Media y Varianza en tiempos de detección.....                    | 65 |
| <b>Tabla 16</b> T Student en tiempos de detección .....                          | 65 |
| <b>Tabla 17</b> Correlación de Pearson en tiempos de detección .....             | 66 |
| <b>Tabla 18</b> Comparación entre EfficientDet y expertos .....                  | 66 |
| <b>Tabla 19</b> Resultados Media y Varianza de Dron + EfficientDet .....         | 68 |
| <b>Tabla 20</b> T-Student Dron + EfficientDet.....                               | 68 |
| <b>Tabla 21</b> Correlación de Pearson EfficientDet.....                         | 68 |

|  |    |
|--|----|
| <b>Tabla 22</b> T-Student en detección de papas con EfficientDet vs expertos .....                   | 69 |
| <b>Tabla 23</b> Resultados Media y Varianza en detección de papas con EfficientDet vs expertos ..... | 70 |
| <b>Tabla 24</b> Prueba T-Student en detección de papas con EfficientDet vs expertos.....             | 71 |
| <b>Tabla 25</b> Resultado de correlación en detección de papas con EfficientDet vs expertos.....     | 71 |
| <b>Tabla 26</b> Comparación de modelo EfficientDet vs expertos .....                                 | 71 |
| <b>Tabla 27</b> Resultados Media y Varianza .....  | 73 |
| <b>Tabla 28</b> Prueba T de Student .....  | 73 |
| <b>Tabla 29</b> Correlación de Pearson .....   | 73 |
| <b>Tabla 30</b> Cumplimiento de los requisitos .....   | 74 |
| <b>Tabla 31</b> Cumplimiento de los requisitos .....   | 75 |
| <b>Tabla 32</b> Resultados de la Encuesta para la Pertinencia Funcional.....                         | 77 |
| <b>Tabla 33</b> Discusión EfficientDet con otras arquitecturas .....                                 | 79 |

## Índice de figuras

|  |    |
|--|----|
| <b>Figura 1</b> Árbol de problemas .....                                   | 18 |
| <b>Figura 2</b> Arquitectura.....  | 19 |
| <b>Figura 3</b> Arquitectura Xception.....                                 | 20 |
| <b>Figura 4</b> Capas de una cnn general.....                              | 29 |
| <b>Figura 5</b> Arquitectura Xception.....                                 | 29 |
| <b>Figura 6</b> Arquitectura EfficientDet.....                             | 30 |
| <b>Figura 7</b> Métricas EfficientDet FLOPs .....                          | 32 |
| <b>Figura 8</b> Métricas EfficientDet parámetros .....                     | 32 |
| <b>Figura 9</b> Características y subcaracterísticas de la ISO 25010 ..... | 34 |
| <b>Figura 10</b> DJi Mavic 2 Pro.....                                      | 42 |
| <b>Figura 11</b> Mapeo de los terrenos con el software Drone Deploy .....  | 43 |
| <b>Figura 12</b> Interfaz de Drone Deploy para el mapeo de terrenos.....   | 43 |
| <b>Figura 13</b> Imagen descartada .....                                   | 47 |
| <b>Figura 14</b> Imagen descartada .....                                   | 47 |
| <b>Figura 15</b> Imagen descartada .....                                   | 48 |
| <b>Figura 16</b> Interfaz de Roboflow para la anotación de imágenes.....   | 51 |
| <b>Figura 17</b> Health Check del dataset .....                            | 52 |
| <b>Figura 18</b> Estructura del dataset.....                               | 53 |
| <b>Figura 19</b> Estructura del dataset.....                               | 54 |
| <b>Figura 20</b> Interfaz creada con Gradio .....                          | 58 |
| <b>Figura 21</b> Imagen a procesar .....                                   | 58 |

|   |    |
|---|----|
| <b>Figura 22</b> Resultado de la imagen procesada ..... | 59 |
| <b>Figura 23</b> mean Average Precision .....           | 62 |
| <b>Figura 24</b> IoU.....                               | 63 |
| <b>Figura 25</b> Focal Loss y Smooth L1 Loos.....       | 63 |

## RESUMEN

La detección automática de malezas en el campo de la agricultura de precisión tiene un peso importante por los recursos que se ven involucrados en el desarrollo e implementación, siendo positivo o negativo de acorde a los resultados obtenidos, pues un buen modelo ayuda a eliminar de mejor manera las malezas de los cultivos, los cuales son responsables de apoderarse de los nutrientes, agua y luz solar que son necesarios para el correcto desarrollo de los cultivos.

El proyecto abarca el desarrollo de un dataset propio de cultivos en los que se encuentran malezas y papas, las imágenes son adquiridas desde un dron, el entrenamiento de la arquitectura Xception que es propuesta desde un inicio y al cambio de arquitectura por EfficientDet, para posteriormente realizar el despliegue del modelo en una interfaz para ser difundida a terceros, para llegar a esto último se usan métricas relacionadas a deep learning para escoger el mejor modelo.

El primer capítulo maneja la obtención de literatura sobre agricultura de precisión, modelos usados en este ámbito, la diversidad de malezas y cultivos que existen en la Sierra norte del Ecuador, con la información que se tiene se hace respuesta a varias preguntas de investigación que se encuentran en este primer capítulo del documento, las cuales dan una base sólida de como empezar con la obtención de datos, su manejo y su difusión. Temas distintos a tratar en este capítulo es la explicación de la ISO 25010 y la ISO 25023 que ayudan a la cuantificación de la calidad del software que se desarrolla para presentar a terceros y la metodología KDD que es fundamental para nuestro correcto desarrollo, pues marcar pautas a seguir.

El segundo capítulo toca de manera más detallada el desarrollo, desde la entrevista para la aplicación de la ISO 25010, siguiendo con el tema central se describe todo el proceso de obtención de datos, desde los problemas que se presentan en este transcurso hasta las soluciones que se pudieron dar, para continuar con la explicación de los hiperparámetros de la arquitectura usada y su deploy, todo el capítulo sigue la estructura de la metodología KDD.

En el tercer capítulo se trata las métricas obtenidas por el modelo, se detalla en una tabla las variaciones que se tuvo durante las experimentaciones de la arquitectura para así llegar a un solo modelo. La medición de la calidad de software se hizo con el uso de un checklist que con la

ayuda de la ISO 25023 se cuantificó el porcentaje de la calidad del software, también se emplea el análisis estadístico T-Student para descartar o aceptar las hipótesis propuestas en el capítulo.

Finalmente, en la sección de discusión se pone a detalle trabajos relacionados a la detección de malezas con las cuales se hace una comparativa con nuestro modelo para evaluar las métricas y llegar a conclusiones del trabajo realizado.

## ABSTRACT

The automatic detection of weeds in the field of precision agriculture is significant due to the resources involved in its development and implementation, which can have positive or negative impacts based on the results obtained. A good model aids in better weed removal from crops, which are responsible for depriving crops of necessary nutrients, water, and sunlight essential for their proper growth.

The project encompasses the development of a custom dataset of crops with weeds and potatoes, where the images are acquired from a drone. It involves the training of the Xception architecture, initially proposed, and subsequently switching to the EfficientDet architecture. The final model is deployed in an interface for dissemination to third parties, with the best model being selected using deep learning metrics.

The first chapter deals with obtaining literature on precision agriculture, models used in this field, and the diversity of weeds and crops in the northern highlands of Ecuador. This information helps answer several research questions in the first chapter, providing a solid foundation for data acquisition, management, and dissemination. Other topics covered include the explanation of ISO 25010 and ISO 25023, which assist in quantifying the quality of software developed for third-party presentation, and the KDD methodology, which is fundamental for proper development as it sets guidelines to follow.

The second chapter delves into the detailed development process, from the interview for applying ISO 25010 to the central topic of the data acquisition process. It discusses the issues encountered and the solutions provided, explains the hyperparameters of the used architecture and its deployment, all structured according to the KDD methodology.

In the third chapter, the metrics obtained by the model are addressed, detailing in a table the variations experienced during the experimentation with the architecture to converge on a single model. Software quality measurement was conducted using a checklist based on ISO 25023 to quantify the software's quality percentage. The T-Student statistical analysis was employed to reject or accept the hypotheses proposed in the chapter.

Finally, the discussion section details related works on weed detection, comparing them with our model to evaluate metrics and draw conclusions about the work conducted.

# INTRODUCCIÓN

## Tema

Detección automática de malezas en cultivos de maíz y/o papa utilizando imágenes adquiridas por drones empleando la arquitectura de red neuronal convolucional Xception.

## Antecedentes

### Situación Actual

### Planteamiento del Problema

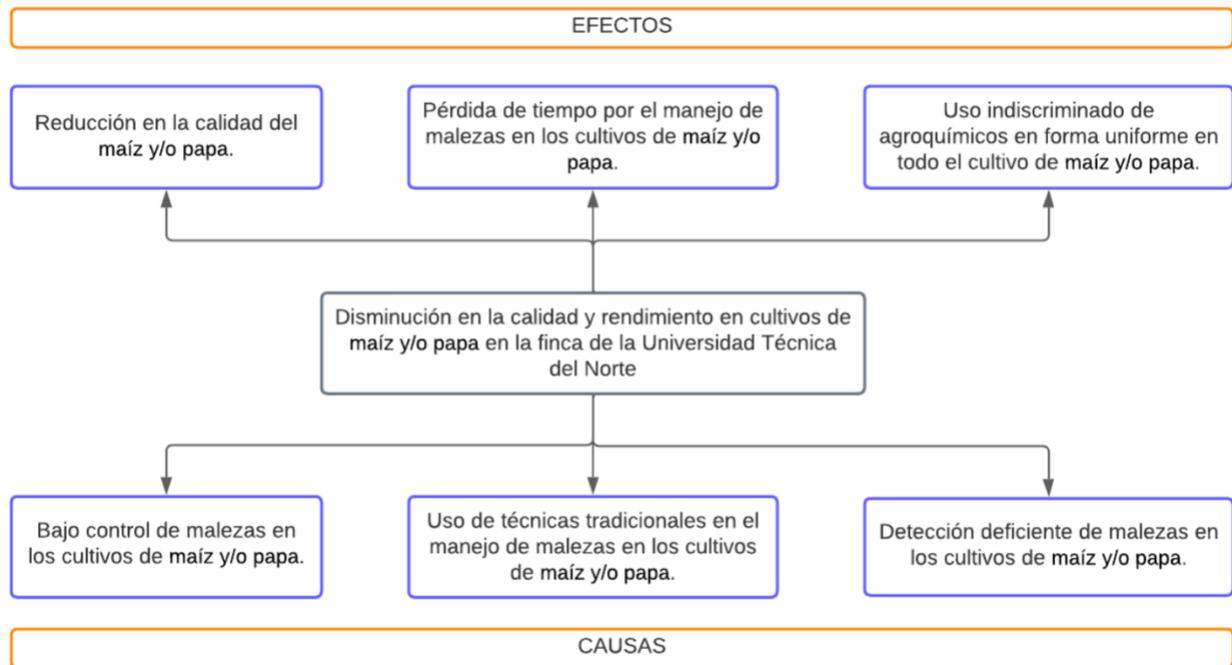
La detección y tratamiento oportuno de las malezas en la agricultura es de suma importancia. Estas plantas indeseables (malezas) no necesitan condiciones específicas para crecer, germinar o reproducirse (Charles Darwin Servicio Parque Nacional Galápagos et al., 2006). Al encontrarse en gran medida en los campos de cultivos compiten por elementos necesarios como la luz, suelo, agua, nutrientes y fertilizantes. Además, son usadas como hogar de plagas y organismos patógenos, que provocan pérdidas en la calidad de los cultivos (INIAP, 2019).

Las malezas llevan a pérdidas significativas en el rendimiento de los cultivos, comenzando con la cantidad y calidad de los productos, hasta el precio y el abastecimiento en los mercados. Sin embargo, el tratamiento tradicional de las malas hierbas es el uso indiscriminado de agroquímicos en forma uniforme en todo el cultivo, aun cuando las malezas no se distribuyen uniformemente en el campo. Es el método más extendido, aunque el mal uso junto al exceso de agroquímicos resulta en la contaminación del suelo y agua subterránea, pudiendo impactar la salud de las personas, plantas, animales y del medio ambiente.

Para la investigación se usará como guía estas preguntas:

- ¿Qué drones y cámaras están usando para la tarea de detección automática de malas hierbas?
- ¿Qué cultivos y tipos de malezas se están detectando y dónde?
- ¿Cómo crear y anotar un conjunto de datos propio?
- ¿Qué arquitectura de CNN se usan para la detección automática de malas hierbas?
- ¿Qué hardware específico o servicios en la nube resulta adecuado para entrenar modelos de DL?
- ¿Qué métricas y gráficas se usan para validar el rendimiento de los modelos de DL?

Figura 1 *Árbol de problemas*



Nota. Elaboración propia.

## Objetivos

### Objetivo General

Detectar automáticamente malezas en cultivos de maíz y/o papa utilizando imágenes adquiridas por drones empleando la arquitectura de red neuronal convolucional Xception.

### Objetivos Específicos

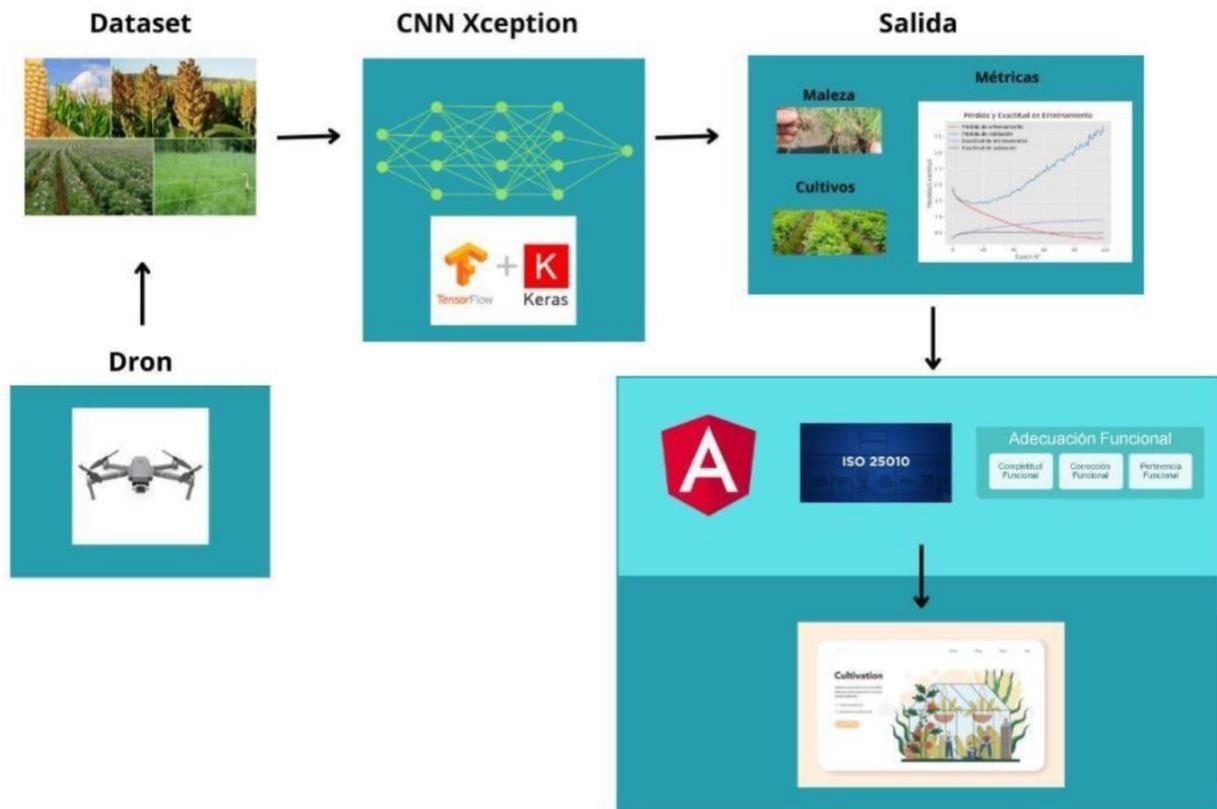
- Elaborar un marco teórico sobre soluciones de deep learning aplicadas a la detección de malezas en cultivos de maíz y/o papa.
- Desplegar el modelo de red neuronal convolucional (CNN), usando la normativa ISO 25010 la característica de adecuación funcional.
- Validar los resultados del modelo mediante métricas de rendimiento de algoritmos de inteligencia artificial y el aplicativo con la normativa ISO 25023.

## Alcance

Para llevar a cabo el entrenamiento del modelo de red neuronal convolucional (CNN) es necesario establecer un conjunto de datos compuesto de imágenes con las que se definirá un protocolo de etiquetado manual, tanto de cultivos como de malezas. Se etiquetarán 50 imágenes adquiridas en la granja La Pradera de la UTN las cuales servirán para el entrenamiento del modelo de deep learning Xception.

La metodología KDD (Knowledge Discovery in Databases) es un proceso que se utiliza para descubrir conocimiento útil a partir de los datos. La metodología consta de una serie de pasos que incluyen la selección de datos, la limpieza y preprocesamiento de estos, la transformación y reducción de datos, la minería de datos y la evaluación de resultados.

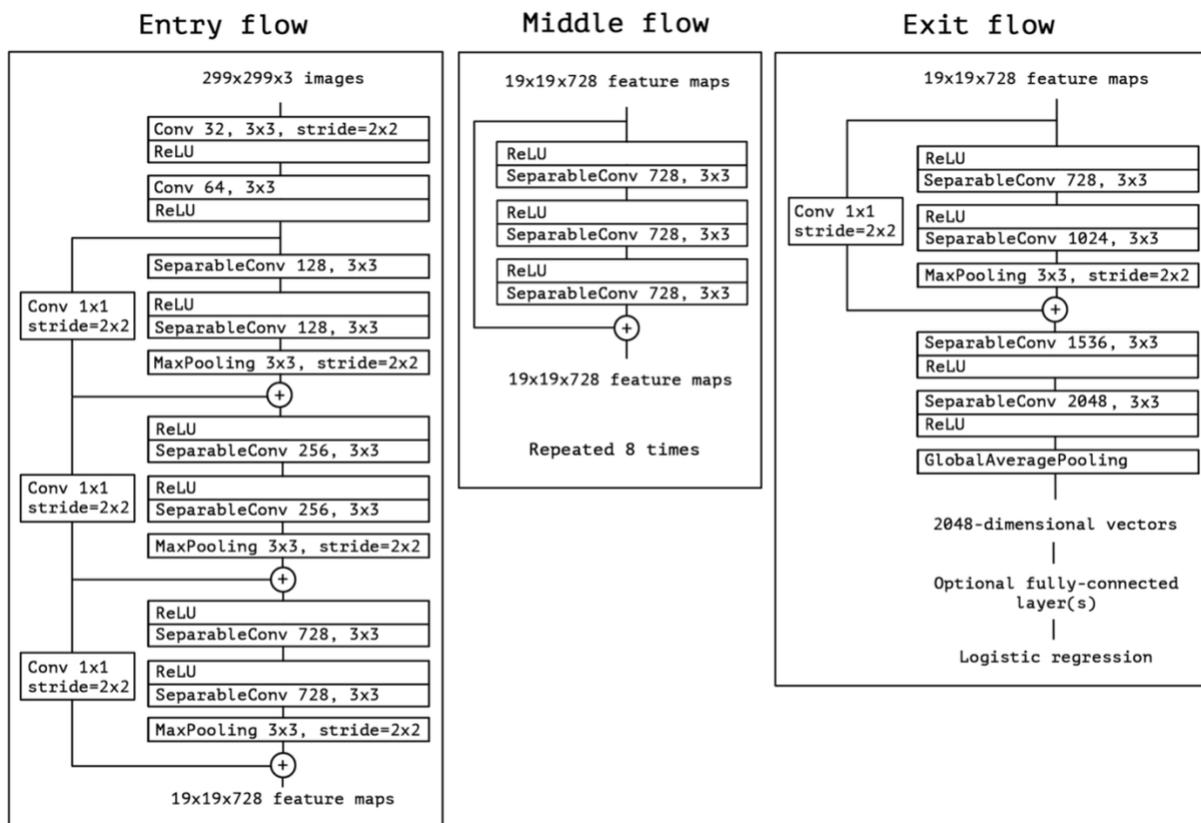
**Figura 2** Arquitectura



*Nota.* Elaboración propia.

En el desarrollo del modelo de la red convolucional Xception se usará el lenguaje de programación Python integrando Tensor Flow y Keras, que son librerías de código abierto, que emplean APIs para el fácil desarrollo e implementación de modelos de aprendizaje automático (Padmapriya et al., 2021). Xception es una arquitectura de CNN que se destaca por su eficiencia computacional y su capacidad de aprendizaje, y ha sido utilizada en diversas aplicaciones de visión artificial, en la figura 3 se muestra su arquitectura.

**Figura 3** Arquitectura Xception



Nota. Tomado de *Xception: Deep Learning with Depthwise Separable Convolutions* por (Chollet, 2017)

### Justificación

El enfoque del proyecto va hacia el desarrollo sostenible “Industria, Innovación e Infraestructura”, con el objetivo:

9.b Apoyar el desarrollo de tecnologías, la investigación y la innovación nacionales en los países en desarrollo, incluso garantizando un entorno normativo propicio a la diversificación industrial y la adición de los valores a los productos básicos, entre otras cosas (Naciones Unidas, 2022).

Con la detección eficaz de las malezas en los cultivos de maíz y/o papa se aporta a la calidad y al aumento de la producción de estos alimentos, dirigiéndose a un buen nivel del producto, además de la disminución de contaminantes como los agroquímicos que son usados de manera indiscriminada en todo el cultivo.

### **Justificación Tecnológica**

El desarrollo del proyecto fomenta la modernización de procesos tradicionales como es la discriminación de malezas y cultivos de maíz y/o papa, a través del uso de técnicas de inteligencia artificial.

### **Justificación Agrícola**

La detección y tratamiento temprano de malezas o malas hierbas es fundamental en la agricultura, al automatizar la detección se apoya al sector agrícola reduciendo tiempo y costo en la producción de papa o maíz y disminuyendo carga operacional del agricultor.

# CAPÍTULO 1

## Marco teórico

### 1.1. Fundamentación Teórica

#### 1.1.1. Malezas en Cultivos

Las malezas son plantas que crecen en lugares no deseados, en este caso en los cultivos, y compiten con las plantas cultivadas por agua, nutrientes y luz solar. Esto puede disminuir el rendimiento de los cultivos y reducir la calidad de los productos agrícolas (Jiménez López et al., 2020).

En el estudio (Jiménez López et al., 2020) menciona que la resistencia de las malezas constituye un gran problema, provocando el uso de agroquímicos sin control provocando efectos negativos, entre los que están la pérdida económica, la contaminación del suelo y aguas subterráneas y la afectación la salud y seguridad alimentaria.

#### 1.1.2. Tipos de Malezas en Papas y/o Maíz

Los tipos de malezas que podemos encontrar en estos cultivos varían mucho dependiendo de las zonas en las que se encuentran las plantaciones y cada una de las malezas tiene un grado de nocividad para el cultivo, esto se aprecia en la tabla 1 y en la tabla 2 respectivamente.

**Tabla 1** Nombres comunes de malezas en las zonas paperas del Ecuador

| Nombre propuesto<br>para todo el país | Zona Norte                     | Zona Centro                                    | Zona Sur                                |
|---------------------------------------|--------------------------------|--|---|
|                                       | Carchi – Imbabura              | Pichincha – Cotopaxi<br>– Tungurahua           | Bolívar – Chimborazo<br>– Cañar – Azuay |
| <b>Hoja ancha</b>                     |                                |  |   |
| Alfarillo                             | Linacilla, alfarillo           | Pata de pajarillo,<br>alfarillo, sachá ilusión | Alfarillo                               |
| Alpatezera                            | Falso alfarillo,<br>alpatezera | Alpatezera, pobreza                            | Alpatezera                              |

---

| Bledo                               | Bledo                                      | Bledo   | Ataco, bledo                                    |
|-------------------------------------|--|---|---|
| Cien nudos                          | Alfarillo, cien nudos,<br>sangre de toro   | Cien nudos,<br>gonorres, coloradilla,<br>caminadora,<br>gateadora | Cien nudos                                      |
| Corazón herido (oreja<br>de diablo) | Corazón herido, oreja<br>de diablo         | -   | -   |
| Duraznillo                          | Duraznillo                                 | Gualola, duraznillo,<br>gloria                                    | Gualola, duraznillo                             |
| Forastera                           | Forastera                                  | Forastera   | Forastera                                       |
| Hierba de cuy                       | Botoncillo, hierba de<br>cuy               | Hierba de cuy,<br>guasca,<br>abuelaquihua,<br>pacouyuyo           | Hierba de cuy                                   |
| Llantén                             | Llantén                                    | Llantén   | Llantén   |
| Malva blanca                        | Malva                                      | Malva, cuchimalva   | Malva, cuchimalva,<br>sachamalva                |
| Malva morada                        | Malva                                      | Malva, cuchimalva   | Malva, cuchimalva,<br>sachamalva                |
| Mostaza                             | Mostaza                                    | Mostaza   | Mostaza   |
| Nabo                                | Nabo                                       | Nabo  | Nabo  |
| Pacta                               | Barrabas,<br>huagracallo, callo de<br>toro | Pacta, lengua de vaca   | Pacta, lengua de<br>vaca, gulag, julag<br>gulag |

---

|             |   |                                    |                                       |
|-------------|---|------------------------------------|---------------------------------------|
| Pactilla    | Barrabacillo,<br>coloradilla, sangre de<br>toro, pactilla | Pactilla, alfarillo,<br>acederilla | Gulilla, coloradilla,<br>pactilla     |
| Pajarera    | Pajarera  | Pajarera                           | Pajarera                              |
| Quimbilla   | Mastuerzo, quimbilla                                      | Mastuerzo, quimbilla               | Tze – tzera macho,<br>quimbilla       |
| Rábano      | Rábano  | Rábano                             | Rábano                                |
| Taraxaco    | Taraxaco, diente de<br>león                               | Taraxaco, diente de<br>león        | Taraxaco, diente de<br>león, chicoris |
| Tze – tzera | Tze – tzera   | Tze – tzera                        | Tze – tzera hembra                    |
| Verónica    | Verónica  | Verónic, golondrina,<br>azulita    | Verónic, golondrina,<br>azulita       |

#### Hoja angosta

|             |                                       |                                |                                      |
|-------------|---------------------------------------|--------------------------------|--------------------------------------|
| Cabrestillo | Gramma, cabrestillo                   | Cabrestillo, pajilla,<br>grama | Hierba virgen,<br>cabrestillo, grama |
| Gramma      | Gramma                                | Gramma, grama azul             | Gramma                               |
| Kikuyo      | Gramma, picuyo,<br>carricillo, kikuyo | Kikuyo, picuyo, ticuyo         | Cuyucha, kikuyo,<br>grama            |
| Saraquihua  | Chagrillo, sarahigua,<br>saraquihua   | Saraquihua                     | Saraquihua                           |

*Nota.* Esta tabla fue modificada de (Cárdenas, 1987), en la que habla de los nombres comunes de las malezas en la región Sierra del Ecuador.

**Tabla 2** Malezas en cultivo de papa y su grado de nocividad

| Nombre de la maleza | Nocividad |
|---------------------|-----------|
|---------------------|-----------|

| Vulgar                           | Científico                             | Alto | Medio | Bajo |
|----------------------------------|--|------|-------|------|
| <b>Hoja ancha</b>                |  |      |       |      |
| Alfarillo                        | <i>Spergula arvensis</i> L.            |      | x     |      |
| Alpatezera                       | <i>Scleranthus annuus</i> L.           |      | x     |      |
| Bledo                            | <i>Amaranthus</i> spp                  |      |       | x    |
| Cien nudos                       | <i>Polygonum aviculare</i> L.          |      |       | x    |
| Corazón herido (oreja de diablo) | <i>Polygonum nepalense</i>             | x    |       |      |
| Duraznillo                       | <i>Polygonum segetum</i> H.B.K.        |      |       | x    |
| Forastera                        | <i>Silene gallica</i> L.               |      | x     |      |
| Hierba de cuy                    | <i>Galinsoga ciliata</i> (Raf.) Blade  |      |       | x    |
|                                  | <i>Gilinsoga parviflora</i> Cav.       |      |       | x    |
| Llantén                          | <i>Plantago lanceolata</i> L.          | x    |       |      |
| Malva blanca                     | <i>Malvastrum peruvianum</i> (L.) Gray |      |       | x    |
| Malva morada                     | <i>Malva silvestris</i> L.             |      |       | x    |
| Mostaza                          | <i>Sinapsis nigra</i> L.               |      | x     |      |
| Nabo                             | <i>Brassica napus</i> L.               |      | x     |      |
|                                  | <i>Brassica napus</i> L.               |      | x     |      |
| Pacta                            | <i>Rumex crispus</i> L.                | x    |       |      |
|                                  | <i>Rumex obtusifolius</i> L.           | x    |       |      |
| Pactilla                         | <i>Rumex acetosella</i> L.             | x    |       |      |

|                     |  |   |
|---------------------|--|---|
| Pajarera            | Stellaria media (L.) Cyrill                | x |
| Quimbilla           | Lepidium chinchicara                       | x |
| Rábano              | Raphanus raphanistrum L.                   | x |
| Taraxaco            | Taraxacum officinale Weber in<br>Wiggers   | x |
| Tze – tzera         | Lepidium bipinnatifidum Desv               | x |
| Verónica            | Veronica persica Poir                      | x |
| <b>Hoja angosta</b> |  |   |
| Cabrestillo         | Graminea (sin identificar)                 | x |
| Gramas              | Graminea (sin identificar)                 | x |
| Kikuyo              | Pennisetum clandestinum Hochst<br>ex Chiov | x |
| Saraqihua           | Graminea (sin identificar)                 | x |

*Nota.* Esta tabla fue modificada de (Cárdenas, 1987), en la que habla sobre el grado de nocividad en los cultivos de papas en el Ecuador.

### 1.1.3. Agricultura de Precisión

Este es un término que cada vez tiene más importancia en el sector agrícola, trata del uso de la información como soporte para la toma de decisiones en el manejo de los cultivos, ayudando a producir más mientras se usan menos recursos mediante la combinación de tecnologías como sistemas de información geográfica (SIG), sensores remotos y enfoques operativos (Vecchio et al., 2022).

Además, permite la detección, muestreo y gestión de los campos de cultivos haciéndolos más diversos, aplicando insumos de manera precisa y reduciendo así los desechos y los costos sean privados y ambientales, como los vinculados con los residuos de agroquímicos. Con el

desarrollo de nuevas tecnologías y el manejo de big data la implementación de esta herramienta en la agricultura ha mejorado la precisión y eficacia en sus resultados (Finger et al., 2019).

#### **1.1.4. Tecnologías en la Agricultura de Precisión**

Dentro del área de la agricultura de precisión hay varias herramientas que surgen de la combinación entre el hardware y el software, (Pathmudi et al., 2023) nos muestra en su investigación varios de los materiales de uso en los que se destaca los sensores IoT como: sensores de pH, sensores LDR (Resistencia Dependiente de la Luz), sensores de velocidad del viento, cámaras RGB, cámaras hiperespectrales, sensores de lluvia, sensores NPK (Nitrógeno, fósforo y potasio).

Por parte del software existen varias herramientas, como son el uso de inteligencia artificial (IA) dentro del que existen varias arquitecturas de redes neuronales y algoritmos que ayudan en la tareas como clasificación y detección de imágenes, mejor procesamiento de datos. El estudio de (Melgar-García et al., 2022) se presenta el algoritmo bigTriGen para el tratamiento de grandes cantidades de datos que se basa en algoritmos genéticos en donde se muestra una buena escalabilidad y precisión en la búsqueda de patrones, como este existen varios algoritmos que ayudan en la agricultura de precisión. Así como este estudio existen varias propuestas más para la agricultura de precisión y con diferentes arquitecturas pueden hacer uso para la detección de malezas en cultivos.

### **1.2. Inteligencia Artificial (IA)**

#### **1.2.1. Inteligencia Artificial (IA)**

Existen varias definiciones en cuanto al tema, pues con el pasar del tiempo la manera en la que entendemos o interpretamos la palabra inteligencia ha ido variando, (F. Berzal, 2018) en su libro presenta varias definiciones, siendo la más aceptada por él lo dicho por Elaine Rich de la Universidad de Texas en Austin: el estudio de cómo hacer que los ordenadores hagan cosas que, por ahora, los humanos hacemos mejor.

Por otra parte (HLEG, 2019) siendo parte de la Unión Europea aporta con su definición para la inteligencia artificial (IA) y lo define como:

Los sistemas que exhiben comportamiento inteligente al analizar su entorno y tomar medidas con cierto nivel de autonomía para lograr objetivos específicos. Estos sistemas pueden

e incluyen software y herramientas para fines como el análisis de imágenes, en los últimos años incluso se ha visto la integración de estas tecnologías a motores de búsqueda y otras tecnologías más involucradas en nuestra día a día como sistemas de reconocimiento de voz y reconocimiento facial, entre otros. Además, la IA también puede ser incorporada en dispositivos de hardware como robots avanzados, vehículos autónomos, drones y aplicaciones de Internet de las cosas.

### **1.2.2. Visión por Computador**

La visión por computador se ha convertido en una herramienta muy útil en varios campos como en este caso la agricultura moderna, con el propósito de obtener un máximo rendimiento (Dairath et al., 2023)

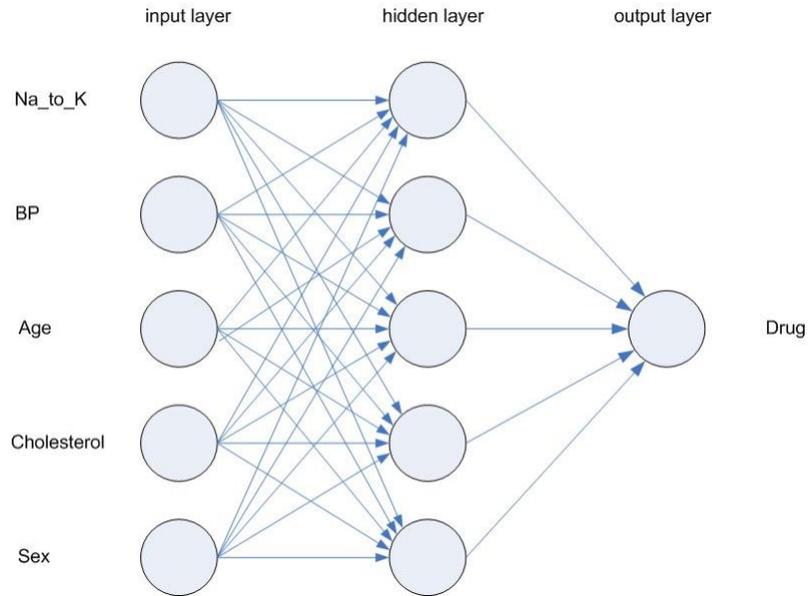
El campo de la visión por computadora se enfoca en permitir que las computadoras comprendan datos visuales del entorno, a través del desarrollo de algoritmos y técnicas que les permiten analizar y dar sentido a imágenes y videos. Recientes investigaciones en este ámbito incluyen la búsqueda de formas eficientes de escalar redes para distintos casos de uso, como la visión móvil y el manejo de grandes volúmenes de datos (Szegedy et al., 2015), la exploración de modelos bayesianos de aprendizaje profundo que permitan modelar la incertidumbre en tareas de visión, y el desarrollo de nuevos modelos para diversas tareas de visión por computadora.

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

Es un modelo simplificado que simula el procesamiento de información del cerebro humano mediante un gran número de unidades de procesamiento interconectadas, similares a neuronas cerebrales. Estas se organizan en capas: las capas de entrada que representa los datos que trabajan de input, una o varias capas ocultas que realizan convoluciones, y una capa de salida que representa el output que es el resultado. Las conexiones entre unidades tienen ponderaciones variables. Los datos se presentan en la capa de entrada y se propagan a través de las capas, produciendo un resultado final en la capa de salida. La red aprende ajustando sus parámetros tras realizar predicciones incorrectas, repitiendo este proceso muchas veces hasta alcanzar los criterios de parada establecidos (IBM, 2021).

En la figura 4 se aprecia de mejor manera como es una CNN general, sin especificar un tipo de arquitectura y de igual manera se distinguen las capas de entrada, las capas ocultas y las capas de salida.

**Figura 4** Capas de una cnn general



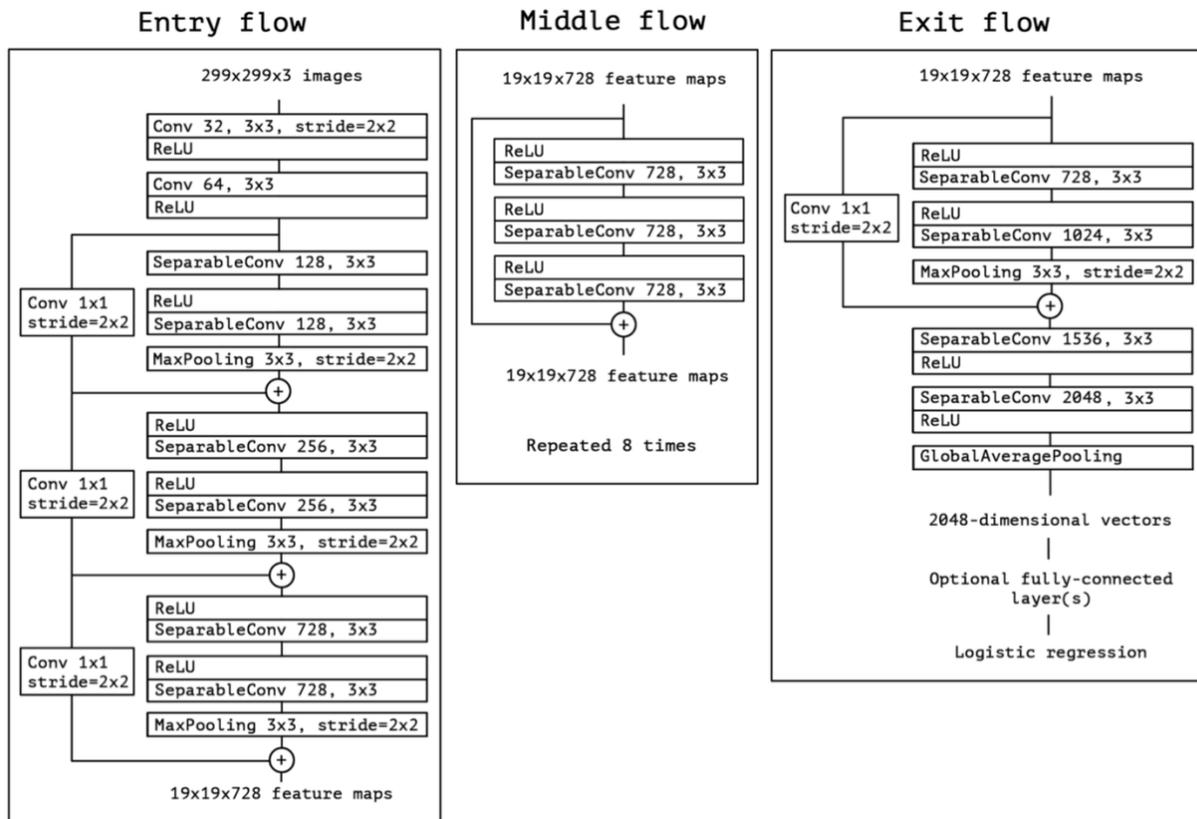
*Nota.* Tomado de (IBM, 2021).

#### 1.2.4. Arquitectura Xception

La arquitectura Xception utiliza convoluciones separables en profundidad para mejorar la eficiencia y el rendimiento de las redes convolucionales. En lugar de realizar una convolución en todas las dimensiones del tensor de entrada, la convolución separable en profundidad separa la convolución espacial y la convolución en profundidad en dos pasos separados, lo que reduce significativamente la cantidad de parámetros y operaciones necesarias para entrenar la red (Chollet, 2017).

Esta idea de convoluciones separables en profundidad es usada en todas sus capas y se basa en el concepto de las redes convolucionales residuales (ResNet) para crear bloques residuales, lo que permite que la información fluya más fácilmente a través de la red. Además, se utiliza el aprendizaje de transferencia para mejorar aún más la precisión y la eficiencia de la red, al tiempo que utiliza menos parámetros y operaciones en la red.

**Figura 5** Arquitectura Xception



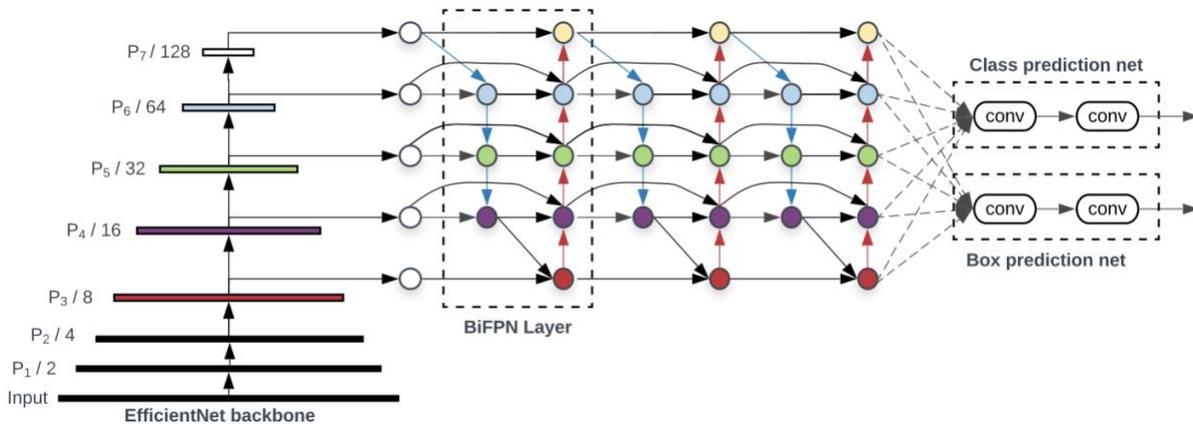
Nota. Tomado de *Xception: Deep Learning with Depthwise Separable Convolutions* por (Chollet, 2017).

### 1.2.5. Arquitectura EfficientDet

EfficientDet es desarrollado por el equipo de Google Brain, se propone una red piramidal de características bidireccional ponderada (BiFPN), esto facilita y agiliza la fusión de características en múltiples escalas, también introduce un método de escalado compuesto que ajusta de manera uniforme la resolución, la profundidad y el ancho de todas las redes involucradas, incluidas las redes de respaldo, de características y de predicción de cajas/clases (Tan et al., 2019).

En la figura 6 se muestra la arquitectura de la red EfficientDet.

**Figura 6** *Arquitectura EfficientDet*



*Nota.* Arquitectura EfficientDet adquirida de (Tan et al., 2019).

A este nuevo modelo se le fue nombrado como EfficientDet que cuenta con 7 diferentes versiones que se distinguen por las dimensiones que acepta en el input, en la tabla 3 se da más detalles.

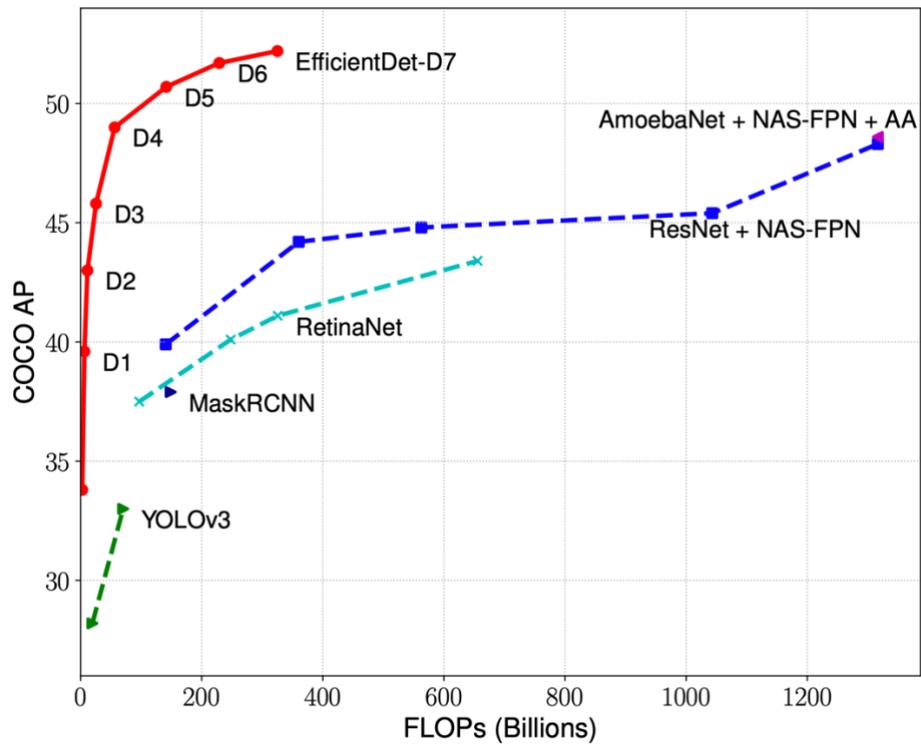
**Tabla 3** Versiones de *EfficientDet*

|                 | Input size | Backbone Network |
|-----------------|------------|------------------|
| EfficientDet-D0 | 512        | B1               |
| EfficientDet-D1 | 640        | B2               |
| EfficientDet-D2 | 768        | B3               |
| EfficientDet-D3 | 896        | B4               |
| EfficientDet-D4 | 1024       | B5               |
| EfficientDet-D5 | 1280       | B6               |
| EfficientDet-D6 | 1280       | B6               |
| EfficientDet-D7 | 1536       | B7               |

*Nota.* Esta tabla fue modificada de (Tan et al., 2019), muestras las versiones del modelo EfficientDet.

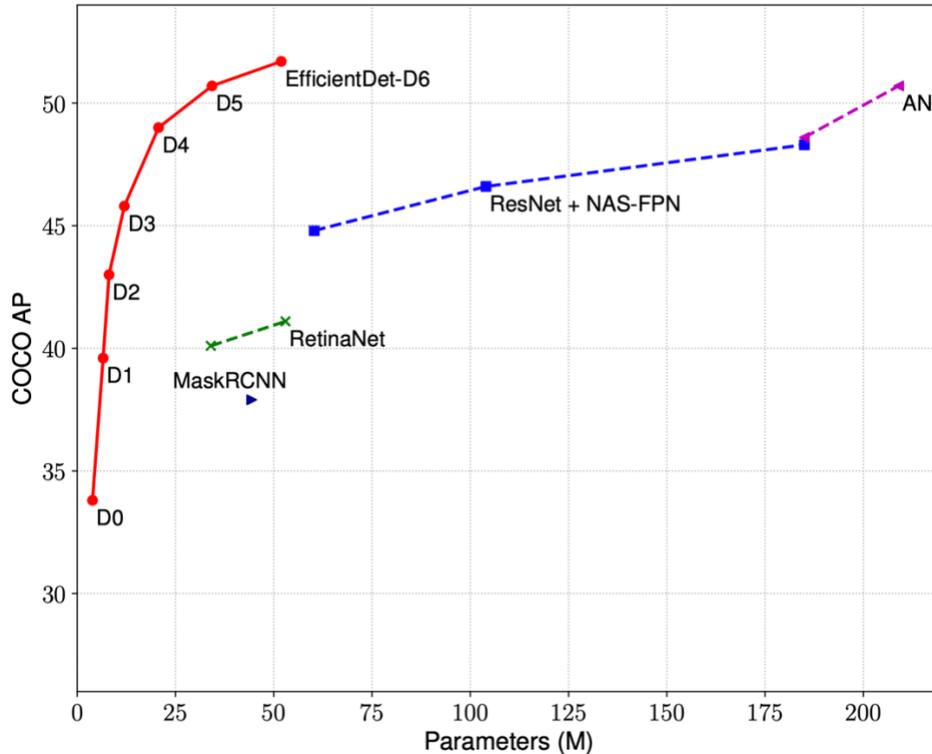
Especializada en la detección de objetos, sus características clave incluyen el uso de un concepto llamado escalado compuesto, una red piramidal bidireccional (BiFPN) para la detección de características, y una arquitectura base derivada de EfficientNet, que supera en rendimiento y eficiencia a otras redes neuronales como Yolov, Inception y Resnet, como podemos ver en la figura 7 en donde se usan menos FLOPs y se obtienen mejores resultados, y en la figura 8 vemos que con menos parámetros se obtienen mejores métricas.

**Figura 7** Métricas EfficientDet FLOPs



Nota. Tomado de (Tan et al., 2019)

**Figura 8** Métricas EfficientDet parámetros



*Nota.* Tomado de (Tan et al., 2019)

### 1.3. Metodología de Desarrollo de Software

#### 1.3.1. Knowledge Discovery in Databases (KDD)

"Knowledge Discovery and Data Mining", en español "Descubrimiento de Conocimiento en Base de Datos" es una metodología de investigación, con la combinación de técnicas para la automatización de patrones que representan el conocimiento que se encuentra en las bases de datos (Singh et al., 2018).

Es una rama de la ciencia de datos que utiliza herramientas como estadísticas, machine learning, inteligencia artificial y bases de datos para analizar grandes cantidades de información y extraer conocimientos útiles, se enfoca en la interpretación y utilización de datos de manera eficiente y efectiva para obtener beneficios prácticos en diferentes campos de aplicación (Ma et al., 2021).

## 1.4. ISO

### 1.4.1. ISO 25010

Esta ISO define las características de calidad que se considerarán al evaluar las propiedades de un software específico, la calidad se mide por el grado de satisfacción en los requisitos de usuarios proporcionando así un valor (ISO 25010, 2024). En la figura 9 se observa a detalle las características y subcaracterísticas con las que trabaja la ISO 25010.

**Figura 9** Características y subcaracterísticas de la ISO 25010

| CALIDAD DEL PRODUCTO SOFTWARE |                         |                   |  |                     |                  |                             |                  |                           |
|-------------------------------|-------------------------|-------------------|--|---------------------|------------------|-----------------------------|------------------|---------------------------|
| ADECUACIÓN FUNCIONAL          | EFICIENCIA DE DESEMPEÑO | COMPATIBILIDAD    | CAPACIDAD DE INTERACCIÓN               | FIABILIDAD          | SEGURIDAD        | MANTENIBILIDAD              | FLEXIBILIDAD     | PROTECCIÓN                |
| COMPLETITUD FUNCIONAL         | COMPORTAMIENTO TEMPORAL | COEXISTENCIA      | RECONOCIBILIDAD DE ADECUACIÓN          | AUSENCIA DE FALLOS  | CONFIDENCIALIDAD | MODULARIDAD                 | ADAPTABILIDAD    | RESTRICCIÓN OPERATIVA     |
| CORRECCIÓN FUNCIONAL          | UTILIZACIÓN DE RECURSOS | INTEROPERABILIDAD | APRENDIZABILIDAD                       | DISPONIBILIDAD      | INTEGRIDAD       | REUSABILIDAD                | ESCALABILIDAD    | IDENTIFICACIÓN DE RIESGOS |
| PERTINENCIA FUNCIONAL         | CAPACIDAD               |                   | OPERABILIDAD                           | TOLERANCIA A FALLOS | NO-REPUDIO       | ANALIZABILIDAD              | INSTALABILIDAD   | PROTECCIÓN ANTE FALLOS    |
|                               |                         |                   | PROTECCIÓN FRENTE A ERRORES DE USUARIO | RECUPERABILIDAD     | RESPONSABILIDAD  | CAPACIDAD DE SER MODIFICADO | REEMPLAZABILIDAD | ADVERTENCIA DE PELIGRO    |
|                               |                         |                   | INVOLUCRACIÓN DEL USUARIO              |                     | AUTENTICIDAD     | CAPACIDAD DE SER PROBADO    |                  | INTEGRACIÓN SEGURA        |
|                               |                         |                   | INCLUSIVIDAD                           |                     | RESISTENCIA      |                             |                  |                           |
|                               |                         |                   | ASISTENCIA AL USUARIO                  |                     |                  |                             |                  |                           |
|                               |                         |                   | AUTO-DESCRIPTIVIDAD                    |                     |                  |                             |                  |                           |

*Nota.* Imagen adquirida de (ISO 25010, 2024), características y subcaracterísticas de la ISO 25010.

### 1.4.2. ISO 25023

Esta Norma Internacional define varias medidas que tienen como finalidad la evaluación de la calidad de productos y sistemas de software basándose en las características y subcaracterísticas establecidas en la Norma ISO 25010. Además, la norma ISO 25023 puede emplearse junto con las normas de las divisiones ISO/IEC 2503n e ISO/IEC 2504n, o para satisfacer las necesidades de los usuarios en cuanto a la calidad de sistemas y productos de software (Martínez, 2021).

## 1.5. Trabajos Relacionados

### Deep convolutional neural network models for weed detection in polyhouse grown bell peppers

(Subeesh et al., 2022) muestra como el estudio se enfocó en la detección de malezas en cultivos de pimientos utilizando arquitecturas CNN como Alexnet, GoogLeNet, InceptionV3 y Xception, con imágenes RGB. Se experimentó con diferentes valores de épocas y tamaños de lote

para el entrenamiento de los modelos, así como la selección de hiperparámetros para lograr el mejor rendimiento. En general, los modelos seleccionados obtuvieron una precisión del 94,5% al 97,7%, siendo InceptionV3 el que logró el mejor desempeño con una precisión del 97,7% en 30 épocas y lotes de 16 elementos. También se logró una precisión del 98,5% y una recuperación del 97,8%, con un error tipo I del 1,4% y un error tipo II del 0,9%.

En conclusión, los resultados sugieren que la detección de malezas en cultivos de pimientos utilizando arquitecturas CNN es viable y se puede lograr una alta precisión con el uso adecuado de valores de épocas, tamaños de lote y hiperparámetros ajustados. Además, el modelo InceptionV3 fue el que presentó el mejor desempeño en este estudio.

### **Weed Recognition for Depthwise Separable Network Based on Transfer Learning**

(Xu et al., 2021) en su investigación dan a conocer el objetivo de mejorar la precisión en la detección de malezas en condiciones complejas dentro de los cultivos. Para ello, se propuso una metodología basada en una CNN separable en profundidad mediante transferencia de aprendizaje. Se utilizó la CNN Xception, la cual se perfeccionó a través de la transferencia y ajuste fino de los parámetros de peso que previamente fueron entrenados con el dataset de ImageNet. Se reemplazó la capa de conexión completa con una capa de agrupación promedio global y se incorporó un clasificador XGBoost en la capa superior del modelo para generar los resultados.

Los resultados experimentales mostraron que el modelo propuesto tuvo una mejora significativa en cuanto a la precisión de clasificación y velocidad de entrenamiento en comparación con los modelos de profundidad VGG16, ResNet50 y Xception. El modelo propuesto alcanzó una precisión de reconocimiento de prueba del 99,63%, y el costo de tiempo de entrenamiento por ronda fue de 208 segundos, lo que representa una mejora respecto a los modelos VGG16, ResNet50 y Xception.

### **Identification of maize and wheat seedlings and weeds based on deep learning**

(Guo et al., 2023) en su estudio se enfocaron en la identificación de maíz, trigo y malezas en los campos a través de deep learning, proponen una metodología para la detección de malezas en los cultivos utilizando el modelo de red UNet y el algoritmo de clasificación ViT. El modelo UNet se utiliza para segmentar las imágenes y se emplea un algoritmo de biblioteca de imágenes de Python para segmentar las hojas de plantas verdes a partir de imágenes binarias, lo que

permite una mejor extracción de características de las hojas. Luego se utiliza la imagen segmentada para crear un modelo de clasificación ViT, que mejora la precisión en la identificación de plántulas de maíz, trigo y malezas en el campo.

Los resultados se evaluaron mediante medidas de rendimiento como la precisión promedio, el recuerdo promedio y la puntuación F1. Se logró una tasa de precisión del 99,3% en la identificación precisa de las plántulas y malezas en el campo. En comparación con otros modelos como Alexnet, VGG16 y MobileNet V3, los resultados indican que el modelo propuesto en este documento tiene un mejor efecto de reconocimiento.

### **An automated weed detection approach using deep learning and UAV imagery in smart agriculture system.**

En el proyecto realizado por (B. Liu, 2023) se hace uso de YOLOv5 para la detección de malezas, la elección de esta arquitectura es por su buena tasa de precisión y el costo computacional que es relativamente bajo en comparación con otros modelos. Las experimentaciones y evaluaciones del trabajo muestran que los resultados dan una contribución importante al campo de la agricultura de precisión aprovechando las técnicas de deep learning, así dando una solución o un aporte a una solución genetal al problema a resolver del paper que se centran en la poca precisión y el alto costo computacional que tiene el entrenamiento de este tipo de modelos.

### **DeepSeaNet: Improving Underwater Object Detection using EfficientDet**

El proyecto presentado por (Jain, 2023) evalúa y compara varias arquitecturas como: EfficientDet, YOLOv5, YOLOv8 y Detectron2 para detección de objetos, estas arquitecturas son entrenadas con datasets de vida marina en bajas condiciones de luminosidad dando estos resultados, YOLOv3 (31.10% de Precisión Media (mAP)), YOLOv4 (83.72% mAP), YOLOv5 (97.6%), YOLOv8 (98.20%), EfficientDet (98.56% mAP) y Detectron2 (95.20% mAP), finalizando, los resultados indican que la arquitectura EfficientDet con variaciones alcanza una mejor precisión mediante validación cruzada de cinco pliegues, superando a los otros modelos con un 88.54% de IoU.

## 1.6. Preguntas de Investigación

RQ1 ¿Qué drones y cámaras están usando para la tarea de detección automática de malas hierbas?

RQ2 ¿Cuál es la altura y velocidad adecuada del dron para capturar imágenes y regiones de interés (ROIs) de alta resolución (px/cm)?

RQ3 ¿Qué espacio de color y formato de imágenes resulta adecuado?

RQ4 ¿En qué bandas del espectro electromagnético (visible, infrarrojo, ultravioleta) están trabajando?

RQ5 ¿Qué cultivos y tipos de malezas se están detectando y dónde?

RQ6 ¿Qué conjunto de datos se encuentran disponibles públicamente para el entrenamiento de un modelo de Deep Learning?

RQ7 ¿Cómo crear y anotar un conjunto de datos propio?

RQ8 ¿Qué arquitectura de CNN se usan para la detección automática de malas hierbas?

RQ9 ¿Qué hardware específico o servicios en la nube resulta adecuado para entrenar modelos de DL?

RQ10 ¿Qué métricas y gráficas se usan para validar el rendimiento de los modelos de DL?

RQ11 ¿Cómo afinar un modelo de DL para mejorar el rendimiento?

**Tabla 4** Preguntas de investigación

| Pregunta | Paper                | Respuesta  |
|----------|----------------------|--|
| RQ1      | (Raja et al., 2023)  | La cámara USB 3.0 de color digital de alta calidad, operada eléctricamente (modelo Scout scA1600gc, Basler Inc., Ahrens-burg, Alemania) tiene una resolución de 5 megapíxeles, estaba equipado con una lente de montaje en c (Modelo A5000, Sony Tokyo, Japón).  |
| RQ2      | (Raja et al., 2023)  | En el estudio realizado se obtuvo resultados a partir de una velocidad de 1.2 km/h, lo que representa un área de 114 mm * 101 mm, una velocidad de 3 FPS.  |
| RQ3      | (Wang et al., 2022)  | En el estudio se genera un gran dataset en el que se encuentran 25 tipos de malezas, en el artículo se hace mención a tres tipos de arquitecturas por lo que se usó un formato general para entrenar las redes, la cual es JPG y el espacio de color fue RBG. Estas características fueron usadas por la estandarización que existe para el uso de varios proyectos. |
| RQ4      | (Kim & Park, 2022)   | En el estudio hecho por los autores mencionados se trabaja en RGB y NIR.   |
| RQ5      | (Haq et al., 2023)   | El trabajo se realiza en la granja de investigación de la Universidad PMAS Arid Agriculture, en esta granja se ubica en Rawalpindi, Punjab, Pakistán y dentro de esta se encuentran cultivos de trigo que fueron tomadas a lo largo de la temporada de cultivo, junto con las malezas más comunes que se presentan.  |
| RQ6      | (Couto et al., 2023) | En el estudio se trabaja en diferentes tipos de datasets para el entrenamiento de su red neuronal y son: DeepMIMO, RadioML, CRAWDAD, OpenCellID, CIFAR-10. Estosa dataset son públicos y cada uno tiene su función específica.   |

---

|             |                                       |  |
|-------------|---------------------------------------|--|
| <b>RQ7</b>  | (Aggarwal et al., 2022)               | <p>Para la creación seleccionaron un campo en el que exista variedad de malezas, se usó un auto todoterreno en el que se instaló una cámara Sony WX350 a 14 pulgadas, eso para la obtención y posteriormente usaron el software LabelImg tool para crear anotaciones en recuadros y etiquetarlas.</p>  |
| <b>RQ8</b>  | (Kim & Park, 2022; Raja et al., 2023) | <p>En ambas investigaciones se usó YOLOV3 y Mask R-CNN. Esto no significa que sean las únicas arquitecturas para este tipo de proyectos, existen varias y cada uno tiene su uso específico.</p>  |
| <b>RQ9</b>  | (Nagrecha, 2023)                      | <p>En el estudio se menciona que los núcleos TPU soportan operaciones en paralelo y sus evaluaciones muestran que pueden lograr un rendimiento hasta 10 veces más rápido que las GPU, esto en algunas arquitecturas. Por lo que el uso de la nube puede variar dependiendo de las características que tenga la suscripción del servicio.</p> |
| <b>RQ10</b> | (Sharma & Kumar, 2022)                | <p>Para comparar sus modelos usaron métricas de rendimiento de IA como el accuracy, recall, precision, F1 score, area under ROC and precision–recall curve.</p>  |
| <b>RQ11</b> | (Jeong, 2024)                         | <p>El estudio habla de como el enfoque en el fine – tuning ayudan a una mejora considerable en los resultados que se hacen en modelos grandes de lenguaje LLM.</p>   |

---

*Nota.* Elaboración propia

## CAPÍTULO 2

### Desarrollo

#### 2.1. Análisis de Requerimientos

El proyecto abarca varios puntos por lo que se acudió al director de tesis para realizar varias preguntas y así obtener los requerimientos del proyecto. Las respuestas están en la tabla 5.

**Tabla 5** *Requerimientos del proyecto*

| Entrevista con el director  | Requisito   |
|---|---|
| Se desea conocer literatura sobre redes neuronales para detección de malezas, se requiere que la literatura sea actual.                                       | Investigar la literatura acerca de redes neuronales.  |
| Se desea conocer varios parámetros para dar inicio al proyecto, se requiere que sean parámetros para obtener imágenes desde un dron.                          | Investigar los parámetros en las cuales se puedan obtener imágenes propias para un dataset. |
| Se desea conocer el desarrollo que tienen los cultivos y malezas, se requiere que sean por semanas para entender los factores externos que influyen en ellos. | Seguimiento de cultivos y malezas en terrenos.  |
| Se desea crear un propio dataset, se requiere una variedad de malezas para tener un buen balance en el proyecto.  | Crear un propio dataset.  |
| Se desea obtener imágenes de papas desde un dron, se requiere imágenes aéreas por lo cual se hace uso de un dron.   | Adquirir imágenes de cultivos desde un dron.  |

|   |  |
|---|--|
| Se desea obtener imágenes de malezas desde un dron, se requiere imágenes aéreas por lo cual se hace uso de un dron. | Adquirir imágenes de malezas desde un dron.                                    |
| Se desea detectar de manera automática las malezas que existen, se requiere una cnn para este proyecto.             | Implementar una cnn para la detección de malezas.                              |
| Se desea usar una arquitectura actual, se requiere el uso de Xception al ser una actualización de Inception.        | Usar la arquitectura Xception para la detección de malezas.                    |
| Se desea conocer el avance en la obtención de datos, se requiere un registro de las salidas de campo.               | Crear una bitácora en las salidas de campo para tomas de imágenes con el dron. |
| Se desea tener resultados óptimos, se requiere validar los resultados con métricas adecuadas.                       | Validar los resultados con métricas adecuadas para detección de objetos.       |

---

*Nota.* Elaboración propia.

## **2.2. Metodología KDD**

### **2.2.1. Fase de Recolección de Datos**

Los dataset son conjuntos de datos que desempeñan un papel crucial en el procesamiento de datos, en especial en ámbitos tecnológicos como big data, IA y más. Estos conjuntos de datos se utilizan ampliamente y su creación requiere la aplicación de métodos que garanticen la depuración de los datos, eliminando de datos duplicados, valores nulos, información incorrecta, entre otros (Cumbal, 2022).

Ya establecido el objetivo del estudio en la etapa de selección se crea un conjunto de datos objetivo en donde constan datos o muestras representativas (Timarán Pereira et al., 2016)

para esto se trabaja con un dron que se aprecia en la figura 10 con el que se encarga de obtener las imágenes de los cultivos a una altura de 9 metros.

**Figura 10** *Dji Mavic 2 Pro*



*Nota.* Tomado de *Dji Mavic 2 Pro* [Fotografía], por Dji, (<https://www.dji.com/global/mavic-2/info>)

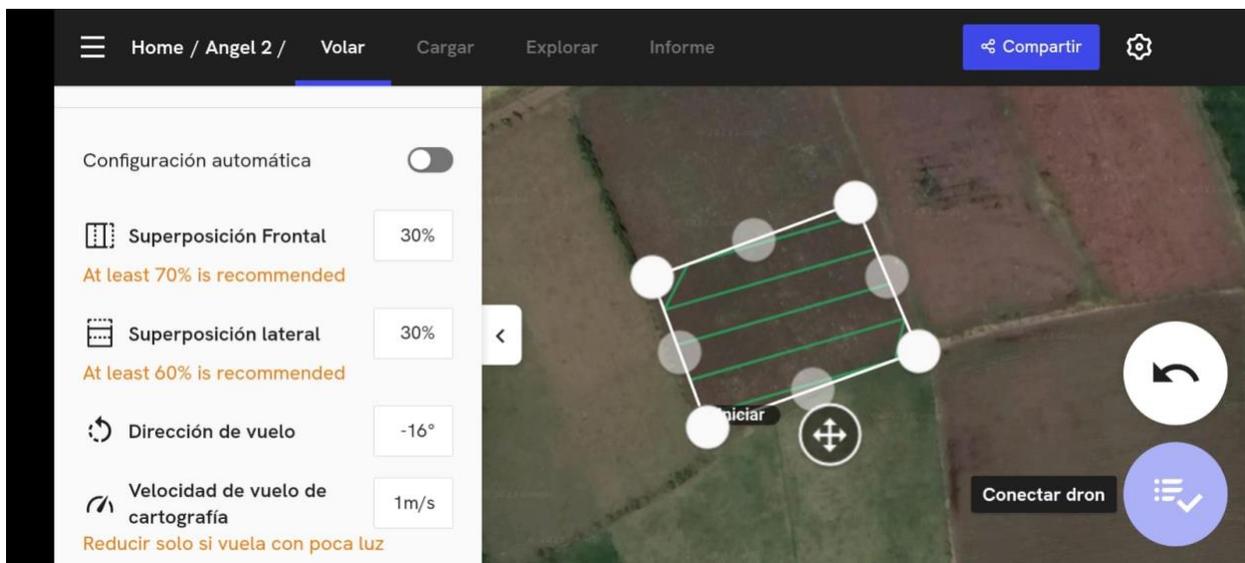
Las plantaciones a selección están en el cantón Espejo y Montufar, para el mapeo y obtención de imágenes se usó el software DroneDeploy pues nos ayuda a mapear en vivo, tener análisis, informes y más (DroneDeploy, 2024) como se puede observar en la figura 11 y figura 12.

Figura 11 Mapeo de los terrenos con el software Drone Deploy



Nota: Capturas realizadas del software Drone Deploy.

Figura 12 Interfaz de Drone Deploy para el mapeo de terrenos



Nota. Capturas realizadas del software Drone Deploy.

Los parámetros elegidos para la captura de imágenes se aprecia en la tabla 6.

**Tabla 6** *Parámetros para captura de imágenes*

| <b>Parámetro</b>                     | <b>Valor</b>         |
|--------------------------------------|----------------------|
| Altura de vuelo.                     | 9 metros.            |
| Velocidad de vuelo.                  | 1 metro/segundo.     |
| Resolución de imagen.                | 5472 x 3648 píxeles. |
| Tiempo entre captura de cada imagen. | 4 segundos.          |

*Nota.* Elaboración propia.

El seguimiento y recolección de muestras comenzó desde el 20 de mayo de 2023, aproximadamente 3 semanas después de la siembra debido al desarrollo de la planta y que posea un tamaño considerable para ser visualizado desde el aire, en la tabla 7 se detallada de mejor manera los datos de las tomas realizadas.

**Tabla 7** *Fechas en las que se obtuvieron las imágenes*

| <b>Terreno</b>   | <b>Fecha</b> |
|--|--------------|
| Terreno 1 - San Gabriel, comunidad de Chutan Bajo, 77o51'03''W (Propiedad del padre del Ing. Marco Pusdá). | 20/05/2023.  |
| -  | 28/05/2023.  |
| -  | 04/06/2023.  |
| Terreno 2 - San Gabriel, 77o48'403''W (Propiedad anónima).   | 04/06/2023.  |

|   |             |
|---|-------------|
| Terreno 3 – Cuesaca, Avenida de la Prehistoria, 77o52'40''W (Propiedad del tío del estudiante Kevin Vinueza). | 17/06/2023. |
| Terreno 4 - El Ángel, barrio San Vicente, 0o38'21''N (Propiedad anónima).                                     | 16/12/2023. |
| Terreno 5 - El Ángel, barrio San Vicente, 77o55'59''W (Propiedad anónima).                                    | 16/12/2023. |
| Terreno 6 - El Ángel, barrio San Vicente, 77o55'59''W (Propiedad anónima).                                    | 16-12-2023. |
| Terreno 7 - El Ángel, barrio San Vicente, 0o38'13''N (Propiedad anónima).                                     | 16-12-2023. |

---

*Nota.* Elaboración propia.

### 2.2.2. Fase de Selección, Preprocesamiento y Transformación

Para la selección se filtra entre imágenes apropiadas y las que son irrelevantes para el proyecto (Nigro et al., 2004). En la tabla 8 se detalla el número de imágenes que se obtuvo en cada terreno, que aunque son muchas, no todas son apropiadas para la elaboración del dataset.

**Tabla 8** *Número de imágenes tomadas por cada fecha en cada terreno*

| Terreno  | Fecha y hora               | Número de imágenes(4K) |
|--|----------------------------|------------------------|
| Terreno 1 - San Gabriel, comunidad de Chutan Bajo, 77o51'03''W (Propiedad del padre del Ing. Marco Pusdá). | 20/05/2023, 9:10 - 9:55.   | 539                    |
|  | 28/05/2023, 10:07 - 10:42. | 409                    |

|   |                            |     |
|---|----------------------------|-----|
|   | 04/06/2023, 11:25 - 12:38. | 926 |
| Terreno 2 - San Gabriel,<br>77o48'403''W (Propiedad<br>anónima).  | 04/06/2023, 14:12 - 14:20. | 197 |
| Terreno 3 – Cuesaca,<br>Avenida de la Prehistoria,<br>77o52'40''W (Propiedad del<br>tío del estudiante Kevin<br>Vinueza). | 17/06/2023, 8:58 - 9:20.   | 209 |
| Terreno 4 - El Ángel, barrio<br>San Vicente, 0o38'21''N<br>(Propiedad anónima).   | 16/12/2023, 10:23 - 10:28. | 61  |
| Terreno 5 - El Ángel, barrio<br>San Vicente, 77o55'59''W<br>(Propiedad anónima).  | 16/12/2023, 10:52 - 10:55. | 28  |
| Terreno 6 - El Ángel, barrio<br>San Vicente, 77o55'59''W<br>(Propiedad anónima).  | 16-12-2023, 11:18 - 11:25. | 53  |
| Terreno 7 - El Ángel, barrio<br>San Vicente, 0o38'13''N<br>(Propiedad anónima).   | 16-12-2023, 11:51 - 11:55. | 25  |
| Terreno 8 – Cotacachi,<br>comunidad Tunibamba de<br>Bellavista, (0o 19'00.1''<br>N78o15'56.2'' W                          | 11/05/2024 – 17/05/2024    | 400 |

---

*Nota.* Elaboración propia.

En la fase de preprocesamiento se toma decisiones de acuerdo a nuestro objetivo y con respecto a valores faltantes, atípicos, erróneos, etc. (Nigro et al., 2004), esto se puede apreciar en la figura 13, en donde se mira la sobreexposición de malezas, la figura 14 muestra malezas de poco tamaño por lo que es difícil la diferenciación y la figura 15 en la que no existen malezas.

**Figura 13** *Imagen descartada*



*Nota.* Elaboración propia, imagen de malezas sobrepuestas.

**Figura 14** *Imagen descartada*



*Nota.* Elaboración propia, imagen con poca visibilidad de malezas.

**Figura 15** *Imagen descartada*



*Nota.* Elaboración propia, imagen con nula existencia de malezas.

En el preprocesamiento se identificó varios problemas en algunos de los terrenos por lo que fueron eliminadas varias imágenes como se lee en la tabla 9.

**Tabla 9 Número de imágenes útiles resultantes**

| <b>Criterio de eliminación</b>   | <b>Número de imágenes utilizables resultantes(4K)</b> |
|--|---|
| Eliminación de todas las imágenes adquiridas en el terreno 1 y 3.      | 364.  |
| Eliminación de aquellas que en su nomenclatura no eran múltiplos de 3. | 121.  |
| Eliminación de aquellas que presentaban desenfoque.                    | 108.  |
| Total.   | 108.  |

*Nota.* Elaboración propia.

Realizada la fase de preprocesamiento el número de imágenes se disminuyó, en la tabla 10 tenemos una comparativa del número de imágenes obtenidas en los terrenos con el número de imágenes que son útiles.

**Tabla 10 Imágenes utilizables de todos los terrenos**

| <b>Terreno</b>  | <b>Número de imágenes capturadas(4K)</b> | <b>Número de imágenes utilizables(4K)</b> |
|---|--|---|
| Terreno 1 - San Gabriel, comunidad de Chutan Bajo, 77o51'03''W (Propiedad del padre del Ing. Marco Pusedá). | 539                                      | 0   |

|   |     |    |
|---|-----|----|
|   | 409 | 0  |
|   | 926 | 0  |
| Terreno 2 - San Gabriel,<br>77o48'403''W (Propiedad<br>anónima).  | 197 | 55 |
| Terreno 3 - Cuesaca,<br>Avenida de la Prehistoria,<br>77o52'40''W (Propiedad del<br>tío del estudiante Kevin<br>Vinueza). | 209 | 0  |
| Terreno 4 - El Ángel, barrio<br>San Vicente, 0o38'21''N<br>(Propiedad anónima).   | 61  | 19 |
| Terreno 5 - El Ángel, barrio<br>San Vicente, 77o55'59''W<br>(Propiedad anónima).  | 28  | 9  |
| Terreno 6 - El Ángel, barrio<br>San Vicente, 77o55'59''W<br>(Propiedad anónima).  | 53  | 17 |
| Terreno 7 - El Ángel, barrio<br>San Vicente, 0o38'13''N<br>(Propiedad anónima).   | 25  | 8  |

|   |      |     |
|---|------|-----|
| Terreno 8 – Cotacachi,<br>comunidad Tunibamba de<br>Bellavista. | 400  | 400 |
| Total   | 2847 | 508 |

---

*Nota.* Elaboración propia.

### **2.2.3. Fase de Minería de Datos**

Para esta fase se planteó el uso de la arquitectura Xception, esta arquitectura fue elegida como parte de un proyecto de investigación propuesta por el director. Xception es una red de clasificación por lo que para aplicarla al proyecto de detección de malezas tuvo que ser modificado y ser usada como un backbone y así usar la arquitectura para la extracción de características (Y. Liu et al., 2019).

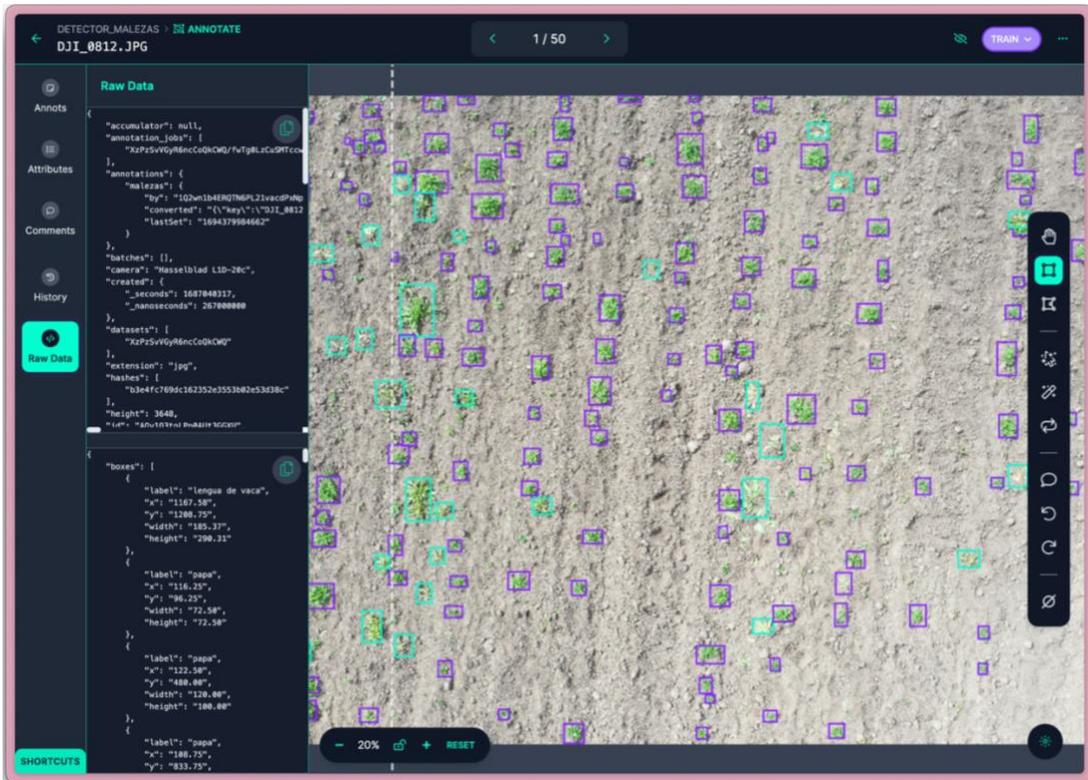
Tras presentarse varios problemas como:

- Incompatibilidad con el proyecto, puesto que Xception desde un inicio fue hecho para clasificación de imágenes y el proyecto a desarrollarse trata sobre detección de objetos.
- Muy poca literatura de integración de Xception como backbone para proyectos de detección de objetos.
- Aparición de nuevas arquitecturas más afines al tipo de proyecto que se está desarrollando.

Por las razones presentadas se decidió usar la arquitectura EfficientDet como arquitectura principal y porque es más flexible en el tamaño de los inputs que se puede apreciar en la tabla 3.

En la preparación de los datos se normaliza las imágenes creando subconjuntos de imágenes y se prosigue al etiquetado o anotación de imágenes usando el software Roboflow que está diseñado para este tipo de proyectos (Lin et al., 2022) como se puede apreciar en la figura 16.

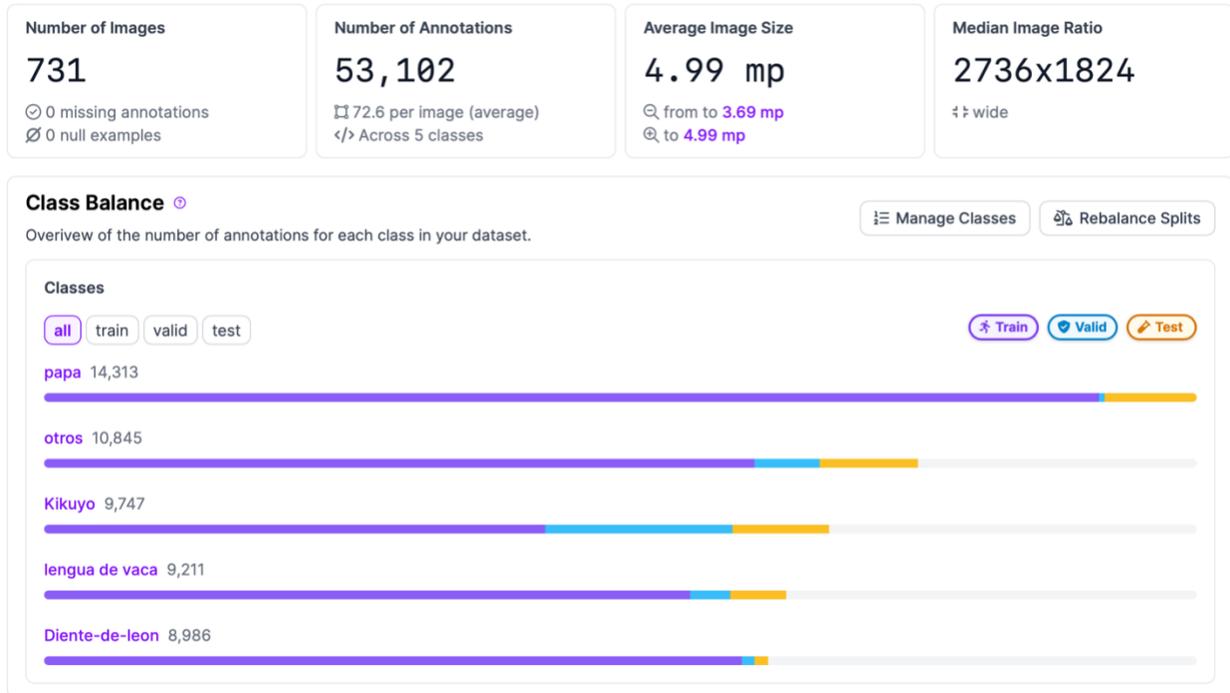
**Figura 16** *Interfaz de Roboflow para la anotación de imágenes*



Nota. Captura de pantalla del software Roboflow.

Finalizado el proceso de etiquetado del dataset tenemos las clases de papa, lengua de vaca, kikuyo, otros y diente de león, en la figura 17 se detalla de mejor manera los datos actuales con los que contamos, que son el número de imágenes, número de anotaciones, promedio del tamaño de la imagen y la mediana de la relación de imagen, también se detalla el balance que existe por clases.

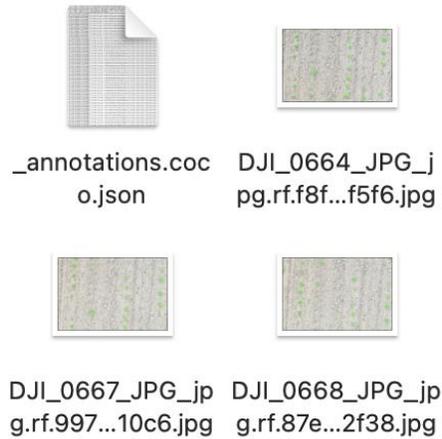
**Figura 17** Health Check del dataset



*Nota.* Captura de pantalla del software Roboflow en donde nos muestra la información del dataset.

Para seguir con el entrenamiento descargamos el dataset en el formato compatible para la arquitectura, en este caso, EfficientDet trabaja con COCO JSON, en la figura 18 se muestra que los archivos del dataset son un archivo .json que aloja las etiquetas y las imágenes en formato .jpg y en la figura 19 se observa como se compone el archivo .json.

**Figura 18** Estructura del dataset



Nota. Captura de pantalla de la estructura del dataset.

Figura 19 Estructura del dataset

```

1 {
2   "info": {
3     "year": "2024",
4     "version": "7",
5     "description": "Exported from roboflow.com",
6     "contributor": "",
7     "url": "https://public.roboflow.com/object-detection/undefined",
8     "date_created": "2024-07-02T04:15:36+00:00"
9   },
10  "licenses": [
11    {
12      "id": 1,
13      "url": "https://creativecommons.org/licenses/by/4.0/",
14      "name": "CC BY 4.0"
15    }
16  ],
17  "categories": [
18    {
19      "id": 0,
20      "name": "maleza01",
21      "supercategory": "none"
22    },
23    {
24      "id": 1,
25      "name": "Diente-de-leon",
26      "supercategory": "maleza01"
27    },
28    {
29      "id": 2,
30      "name": "Kikuyo",
31      "supercategory": "maleza01"
32    },
33    {
34      "id": 3,
35      "name": "lengua de vaca",
36      "supercategory": "maleza01"
37    },
38    {
39      "id": 4,
40      "name": "otros",
41      "supercategory": "maleza01"
42    },
43    {
44      "id": 5,
45      "name": "papa",
46      "supercategory": "maleza01"
47    }
48  ],
49  "images": [
50    {
51      "id": 0,
52      "license": 1,
53      "file_name": "DJI_0681_JPG_jpg.rf.0ff8ea2af500812e56a670c669b2cb57.jpg",
54      "height": 1824,
55      "width": 2736,
56      "date_captured": "2024-07-02T04:15:36+00:00"
57    },
58    {
59      "id": 1,
60      "license": 1,
61      "file_name": "DJI_0679_JPG_jpg.rf.0e0125e133f34ead3d7c7beb24d4ae07.jpg",
62      "height": 1824,
63      "width": 2736,
64      "date_captured": "2024-07-02T04:15:36+00:00"
65    }
66  ]
67 }

```

Nota. Captura de pantalla de la estructura del dataset.

Un método que se usa para verificar el etiquetado correcto en el dataset es la evaluación de auto-consistencia o self-consistency check que ayuda en la verificación de las anotaciones de las etiquetas en el dataset manteniendo coherencia en las predicciones de una misma imagen, pero en distintos puntos de vista (Zhai et al., 2023). Se hizo uso del método descrito para facilitar la revisión del dataset usando un mismo conjunto de datos como conjunto de entrenamiento y validación, al entrenar con estos datos los valores que presentan las épocas dan una guía de cuan bien están etiquetadas las imágenes.

### **Entrenamiento de la Red Neuronal Convolutiva**

Una vez ya desarrollado el dataset propio se continua con el entrenamiento de la red convolutiva, la arquitectura es de código abierto y existen algunos proyectos que son mantenidos por empresas, en este caso se usa el que tienen el respaldo de Google y vamos a la fase de entrenamiento. La fase de entrenamiento implica la alimentación de datos de entrenamiento a través de la red, ajustando sus parámetros mediante el cálculo del error y la propagación hacia atrás, con el objetivo de mejorar su capacidad de clasificación y reconocimiento de patrones en imágenes (Subeesh et al., 2022).

Se usa Google Colab como entorno de desarrollo por las prestaciones y facilidades que nos brinda como acceso a recursos de GPU y TPU, es una solución adecuada para proyectos de IA (Google, 2024). En la tabla 11 se detalla los planes que nos da Colab Pro.

**Tabla 11** *Costos de Colab Pro*

| <b>Plan</b> | <b>Descripción</b>  | <b>Valor</b> |
|-------------|---|--------------|
| Colab Pro   | 100 unidades informáticas al mes, GPU más rápidas, más memoria y terminal.  | \$9.99/mes   |
| Colab Pro+  | Todas las ventajas de Pro y, además: 400 unidades de computación adicionales para un total de 500 al mes, GPU más rápidas y ejecución en segundo plano. | \$49.99/mes  |

|                  |   |                      |
|------------------|---|----------------------|
| Colab Enterprise | Solución integrada, almacenamiento de cuadernos adecuado para empresas y productividad. | Paga por lo que uses |
|------------------|---|----------------------|

*Nota.* Resumen de planes de Colab Pro, elaborado desde (Google, 2024).

En el entrenamiento del modelo para detección de objetos se hizo varios experimentos que se muestran más adelante en el documento, de momento en la tabla 12 se ven los hiperparámetros que se usaron en todos los entrenamientos.

**Tabla 12** *Hiperparámetros de entrenamiento*

| Hiperparámetros     | Descripción  | Impacto en el entrenamiento                     |
|---------------------|--|---|
| Número de épocas    | Número de veces en las que el modelo repite el procesamiento de los conjuntos de datos | En la precisión y en el tiempo                  |
| Tamaño de lote      | Número de mientras que se procesan antes de que el modelo se actualice                 | En la velocidad y en la memoria                 |
| Tamaño de imagen    | Dimensiones que tiene la imagen a entrenar   | En el tiempo y la precisión                     |
| Modelo preentrenado | Modelo ya entrenado con anterioridad con datos similares                               | Reduce el tiempo alcanzando una mejor precisión |
| Optimizador         | Se usa para actualizar los pesos de los modelos  | En la estabilidad y la velocidad                |

*Nota.* Elaboración propia, tabla con hiperparámetros de entrenamiento.

#### 2.2.4. Fase de Evaluación e Interpretación

Para la fase de evaluación e interpretación se realizan métricas de acorde al énfasis de nuestro proyecto que trata sobre detección de objetos. No existe un estándar que mencione que

métricas se deben usar para este tipo de proyectos, así que se basó en el paper “A Survey on Performance Metrics for Object-Detection Algorithms” que establece una guía.

Se analiza y compara la variedad de métricas para evaluar el rendimiento de los algoritmos de detección de objetos, una métrica popular es la precisión promedio (AP), que evalúa la precisión de los detectores de objetos mediante la estimación del área bajo la curva (AUC) de la relación precisión  $\times$  recall (Padilla et al., 2020).

Esta fase de la metodología KDD se encuentra en el capítulo 3, en donde se profundiza de mejor manera la evaluación e interpretación.

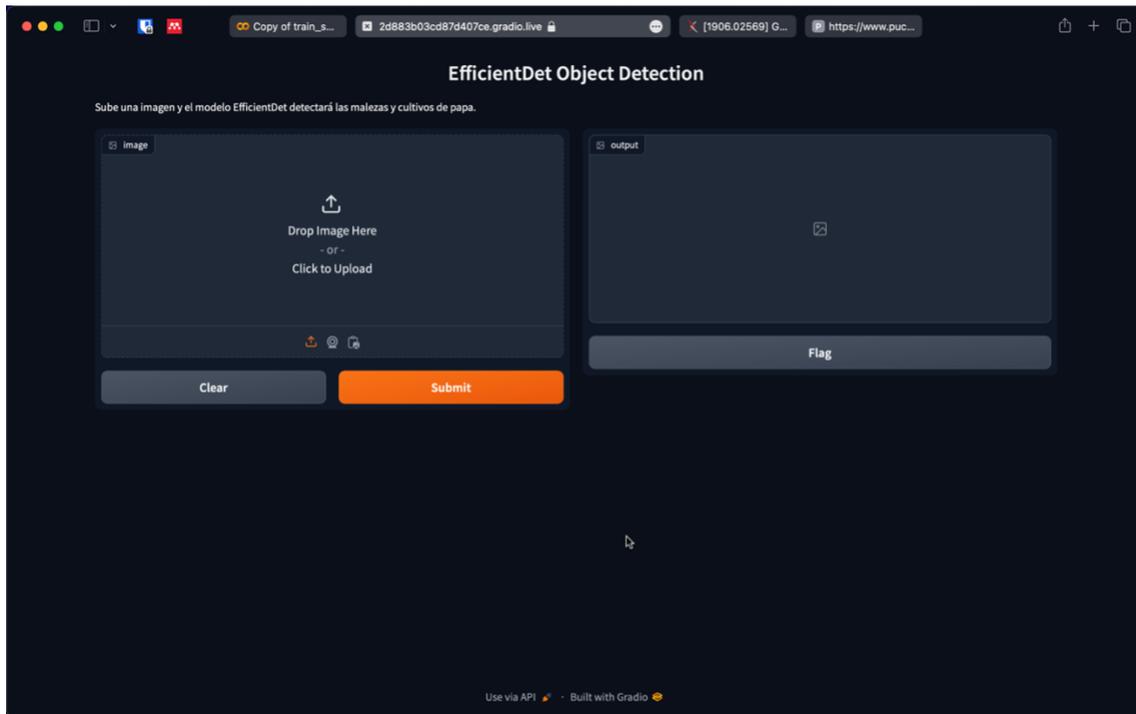
### **2.2.5 Difusión y Uso**

#### **Deploy - Gradio**

Se hace uso de Gradio porque su diseño se fundamenta en entrevistas con varios investigadores de machine learning involucrados en colaboraciones interdisciplinarias. Los aportes señalan que Gradio soporta múltiples interfaces y frameworks, facilita el compartir la interfaz, permitir la manipulación de entradas y la inferencia interactiva por parte de expertos en el área, además posibilita la integración de la interfaz en cuadernos de Python (Abid et al., 2019).

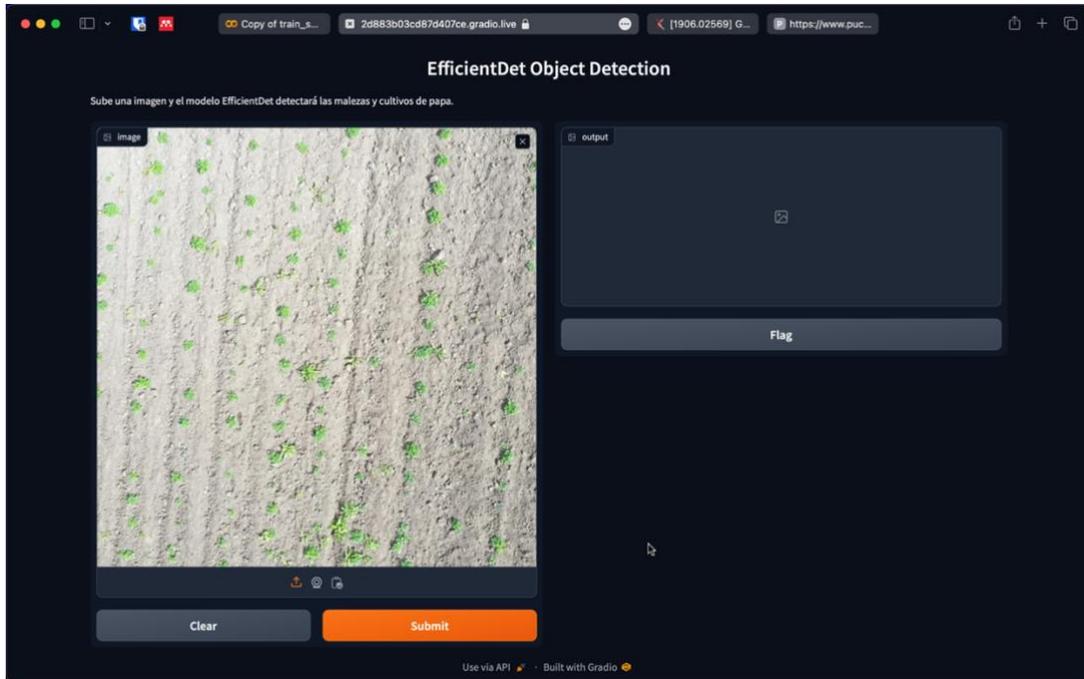
La interfaz creada para el proyecto se presenta en la figura 20, en la figura 21 se muestra la imagen que será procesará y en la figura 22 se mira el resultado.

**Figura 20** *Interfaz creada con Gradio*



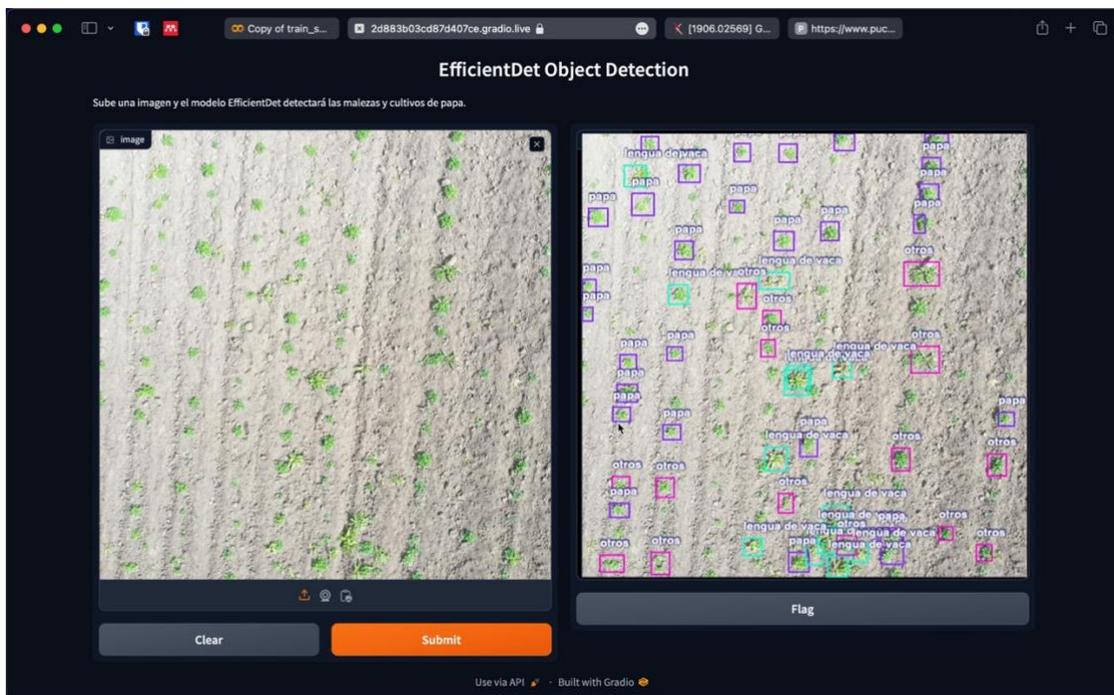
*Nota.* Captura de pantalla de la interfaz para subir una imagen con Gradio.

**Figura 21** *Imagen a procesar*



*Nota.* Captura de pantalla de la interfaz antes de procesar la imagen en Gradio.

**Figura 22** Resultado de la imagen procesada



*Nota.* Captura de pantalla de la interfaz con el resultado de la imagen procesada en Gradio.

## CAPÍTULO 3

### Validación de Resultados

#### 3.1. Análisis de Resultados

Para validar los resultados se propuso hacer uso de la normativa ISO/IEC 25010, en su característica de adecuación funcional que representa la capacidad del producto de software para proporcionar funciones que satisfacen las necesidades declaradas e implícitas, cuando el producto se usa en las condiciones especificadas (*ISO 25010, 2022*).

#### 3.2. Métricas del modelo EfficientDet

Se realiza varios entrenamientos del modelo, donde tras prueba y error se modificó varias veces los hiperparámetros con el propósito de obtener mejores resultados del modelo, en la tabla 13 se detalla de mejor manera los hiperparámetros usados y los resultado que nos dio cada uno de ellos.

**Tabla 13** Resultados de experimentaciones con EfficientDet

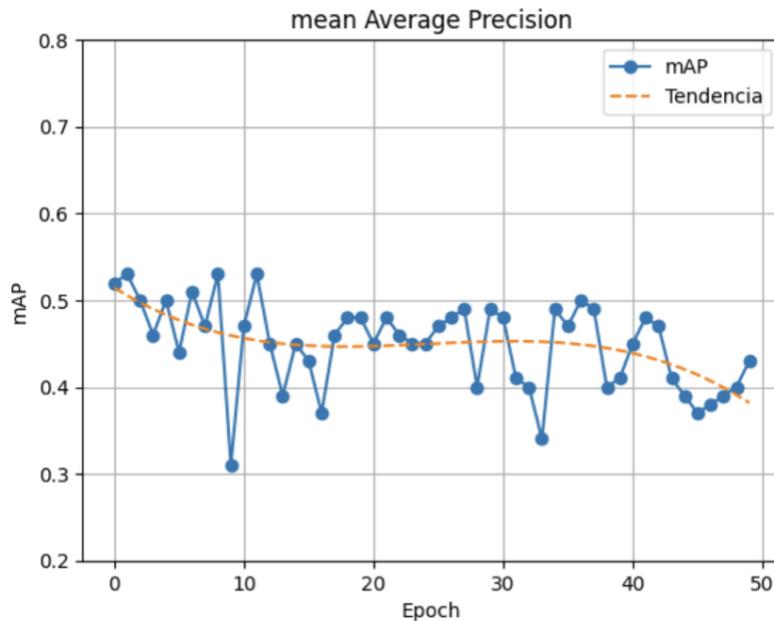
| Versión del modelo | Precision | Recall   | mAP      | Hiperparámetros cambiados |                  |            |        |             |         | Recursos  |             |
|--------------------|-----------|----------|----------|---------------------------|------------------|------------|--------|-------------|---------|-----------|-------------|
|                    |           |          |          | IoU                       | Tamaño de imagen | Batch size | Épocas | Optimizador | Tiempo  | GPU 40 GB | RAM 83.5 GB |
| 1                  | 0.536012  | 0.501834 | 0.508119 | 0.493422                  | 400x400          | 16         | 10     | Adam        | 18'21"  | 31.7      | 57          |
| 2                  | 0.541049  | 0.534632 | 0.537192 | 0.530294                  | 400x400          | 20         | 20     | Adam        | 22'50"  | 31.2      | 52.9        |
| 3                  | 0.509345  | 0.493824 | 0.506432 | 0.492003                  | 400x400          | 20         | 30     | Adam        | 29'24"  | 31.7      | 56.6        |
| 4                  | 0.475553  | 0.464223 | 0.465553 | 0.465204                  | 400x400          | 20         | 40     | Adam        | 32'36"  | 32.7      | 56.7        |
| 5                  | 0.513358  | 0.502298 | 0.508119 | 0.503394                  | 600x600          | 20         | 10     | Adam        | 37' 56" | 31.5      | 57.3        |
| 6                  | 0.450395  | 0.443382 | 0.444509 | 0.423715                  | 600x600          | 20         | 20     | Adam        | 40' 45" | 31.3      | 56          |
| 7                  | 0.520392  | 0.513984 | 0.519822 | 0.485623                  | 600x600          | 20         | 30     | Adam        | 45' 21" | 32.5      | 56.3        |
| 8                  | 0.488349  | 0.472289 | 0.474723 | 0.459489                  | 800x800          | 20         | 30     | Adam        | 40' 50" | 35        | 58.8        |
| 9                  | 0.551443  | 0.530933 | 0.539732 | 0.531094                  | 800x800          | 20         | 40     | Adam        | 46' 52" | 36        | 60          |
| 10                 | 0.502744  | 0.494238 | 0.489927 | 0.483928                  | 800x800          | 20         | 50     | Adam        | 50' 4"  | 35.2      | 59.8        |
| 11                 | 0.483284  | 0.472209 | 0.472710 | 0.453964                  | 1080x1080        | 20         | 30     | Adam        | 48' 45" | 33.6      | 58.6        |
| 12                 | 0.543044  | 0.539456 | 0.532451 | 0.539342                  | 1080x1080        | 20         | 45     | Adam        | 50' 32" | 34.7      | 60          |
| 13                 | 0.469133  | 0.555349 | 0.454987 | 0.444052                  | 1080x1080        | 20         | 50     | Adam        | 67' 34" | 35.8      | 61.2        |

Nota. Elaboración propia, tabla de hiperparámetros.

Con los resultados de las experimentaciones se escoge el mejor modelo guardado para realizar las métricas de mAP, IoU y la función de pérdida.

En la figura 23 se muestra la gráfica de mAP a lo largo de 50 épocas en donde se tiene una considerable variabilidad en el inicio y una tendencia a la baja en las primeras épocas, seguido de una estabilización en torno a un mAP de 0.5 a 0.55. La tendencia general que va en líneas entrecortadas muestra un ligero decrecimiento que indica que el rendimiento del modelo no mejora de manera sostenida y podría estar disminuyendo. Esto nos da a conocer que es necesario ajustar hiperparámetros o la aplicación de técnicas de regularización para mejorar la capacidad de generalización del modelo y así también mejorar las métricas.

**Figura 23** *mean Average Precision*

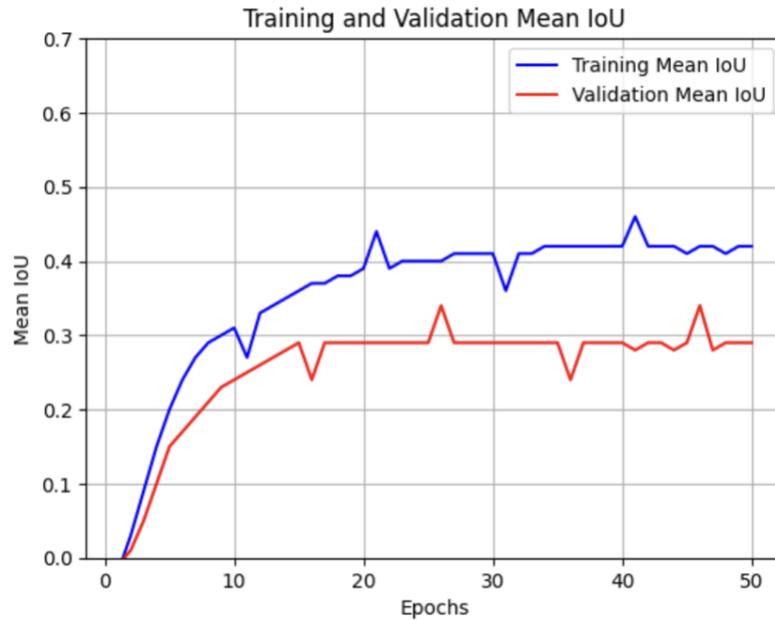


*Nota.* Elaboración propia.

La figura 24 muestra la métrica IoU en donde se ve una mejora significativa en las primeras 10 épocas tanto para el conjuntos de entrenamiento como para el de validación, en la validación alcanza un punto máximo alrededor de la época 10. Luego el IoU en la validación sigue una trayectoria en alza hasta la época 15 cuando se mira un pico de bajada en torno a un 0.25 y desde ahí va en un rango casi estable a los 0.3. En el entrenamiento en la época 10 tiene un pico de bajada en 0.29, para volver a subir y tener una relativa estabilidad de un 0.4. El gráfico muestra

picos durante las épocas lo que sugiere que se necesitan mejores técnicas en el tratado de los hiperparámetros y así obtener mejores resultados.

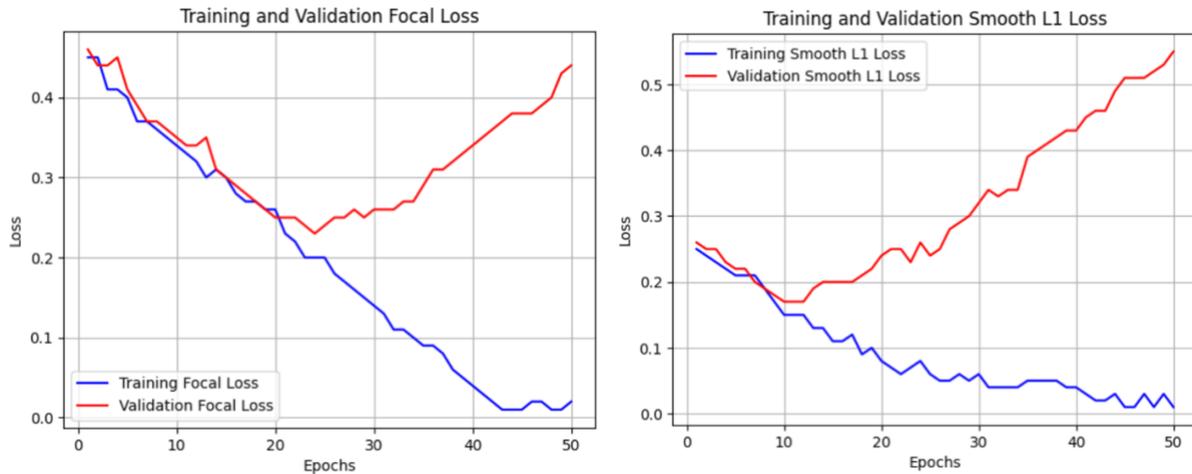
**Figura 24** *IoU*



*Nota.* Elaboración propia.

La figura 25 muestra focal loss y smooth L1 loss en donde ambas muestran que el modelo va aprendiendo hasta la época 20 con relativa normalidad y es desde ahí que se presenta el valor de validación con un aumento en la gráfica, este patrón presentado en ambas imágenes muestra un claro sobreajuste lo que quiere decir que el modelo está aprendiendo los datos de entrenamiento, pero no es capaz de generar nuevo aprendizaje con nuevos datos, para esto se puede usar varios métodos tanto para aumentar el dataset como para manejar de mejor manera las épocas y su entrenamiento.

**Figura 25** *Focal Loss y Smooth L1 Loos*



Nota. Elaboración propia.

### 3.2.1. Comparativa Método Tradicional y EfficientDet

Los métodos tradicionales implican caminar entre las filas del cultivo y realizar una estimación visual de la presencia de malezas. Aunque este proceso es intuitivo y se basa en la experiencia del agricultor, puede ser subjetivo y variar considerablemente en precisión y eficiencia dependiendo de la persona. Además, requiere un tiempo significativo y puede tener un impacto físico en los agricultores debido a la necesidad de cubrir grandes áreas a pie (Ortega, 2024).

En la comparativa se registra el tiempo que un agricultor necesita para evaluar la infestación de malezas en un cultivo de papa. Los resultados muestran que, en promedio el agricultor tarda aproximadamente 5 segundos en inspeccionar cada metro cuadrado del terreno (Ortega, 2024), partiendo con este dato se realiza la comparativa con la cnn EfficientDet que se muestra en la tabla 14.

**Tabla 14** Comparativa de Tiempos

| Identificación del Terreno | Extensión (m <sup>2</sup> ) | Método               | Tiempo total (Minutos) | Diferencia (Minutos) |
|----------------------------|-----------------------------|----------------------|------------------------|----------------------|
| Terreno 1                  | 800                         | Tradicional (Visual) | 66'00''                | 24'12''              |
|                            |                             | Dron + EfficientDet  | 41'48''                |                      |
| Terreno 2                  | 650                         | Tradicional (Visual) | 54'00''                | 18'56''              |
|                            |                             | Dron + EfficientDet  | 35'04''                |                      |

|           |      |                      |          |          |
|-----------|------|----------------------|----------|----------|
| Terreno 3 | 730  | Tradicional (Visual) | 60'00''  | 23'35''  |
|           |      | Dron + EfficientDet  | 36'25''  |          |
| Terreno 4 | 500  | Tradicional (Visual) | 41'35''  | 8'01''   |
|           |      | Dron + EfficientDet  | 33'34''  |          |
| Terreno 5 | 1600 | Tradicional (Visual) | 133'20'' | 60'29''  |
|           |      | Dron + EfficientDet  | 72'51''  |          |
| Terreno 8 | 500  | Tradicional (Visual) | 66' 40'' | 26' 08'' |
|           |      | Dron + EfficientDet  | 40' 32'' |          |

*Nota.* Elaboración propia.

### 3.2.2. Pruebas Estadísticas

#### T-Student en tiempos de detección de malezas

##### Resumen

Se evaluó la eficiencia en la inspección de maleza en diferentes campos de cultivos de papa, entre el método tradicional y el uso de EfficientDet con drones.

##### Desarrollo

Se utilizó la prueba T-Student de las muestras relacionadas y el coeficiente de Pearson con los siguientes resultados.

##### Hipótesis

H0: No hay inferencia estadísticamente significativa en el tiempo de detección entre el método tradicional entre el uso del método Dron + EfficientDet.

H1: Si hay inferencia estadísticamente significativa en el tiempo de detección entre el método tradicional entre el uso del método Dron + EfficientDet.

##### Resultados clave

**Tabla 15** *Media y Varianza en tiempos de detección*

| Métrica            | Método tradicional | Dron + EfficientDet |
|--------------------|--------------------|---------------------|
| Media (minutos)    | 70.26              | 43.37               |
| Varianza (minutos) | 1040.25            | 218.59              |

*Nota.* Elaboración propia.

**Tabla 16** *T Student en tiempos de detección*

| Métrica    | Valor  |
|------------|--------|
| Valor de t | 1.8565 |
| Valor p    | 0.0930 |

*Nota.* Elaboración propia.

**Tabla 17** *Correlación de Pearson en tiempos de detección*

| Métrica       | Valor  |
|---------------|--------|
| Coeficiente r | 0.9914 |

*Nota.* Elaboración propia.

### Conclusión

El valor p obtenido es 0.0930, que es mayor que el nivel de significancia comúnmente aceptado ( $\alpha = 0.05$ ). Dado que  $p > 0.05$ , no se puede rechazar la hipótesis nula lo que implica que no hay suficiente evidencia estadística para afirmar que existe una diferencia significativa en los tiempos medios entre los dos métodos.

La correlación de Pearson es 0.9914, lo que indica una relación muy fuerte y positiva entre los tiempos medidos por los dos métodos. Por lo que aunque los tiempos absolutos puedan diferir, los dos métodos son muy consistentes entre sí en términos relativos.

En base a los resultados obtenidos, no se rechaza la hipótesis nula. Por lo tanto, se concluye que no hay una diferencia significativa en los tiempos medios entre el método Tradicional (Visual) y el método Dron + EfficientDet. Sin embargo, la alta correlación de Pearson indica que ambos métodos producen resultados muy consistentes entre sí.

### T-Student en detección de malezas con EfficientDet y drones

#### Datos

En la comparación de etiquetas se usó una cantidad de etiquetas correctas realizadas por el modelo y la cantidad de etiquetas realizadas manualmente como se observa en la Tabla 18.

**Tabla 18** *Comparación entre EfficientDet y expertos*

| Nombre del Archivo | Cantidad de Malezas | Cantidad de Malezas |
|--------------------|---------------------|---------------------|
|                    | Etiquetas           | Predichas           |
| DJI_0664_JPG_jpg   | 36                  | 15                  |

|                  |     |    |
|------------------|-----|----|
| DJI_0748_JPG_jpg | 11  | 5  |
| DJI_0721_JPG_jpg | 105 | 43 |
| DJI_0746_JPG_jpg | 26  | 9  |
| DJI_0821_JPG_jpg | 48  | 13 |
| DJI_0019_JPG_jpg | 74  | 21 |
| DJI_0743_JPG_jpg | 40  | 12 |
| DJI_0812_JPG_jpg | 38  | 16 |
| DJI_0955_JPG_jpg | 102 | 34 |
| DJI_0054_JPG_jpg | 180 | 69 |
| DJI_0979_JPG_jpg | 29  | 11 |
| 00058_jpg        | 0   | 10 |
| 00094_jpg        | 0   | 0  |
| 00357_jpg        | 51  | 13 |
| 00387_jpg        | 74  | 31 |
| 00043_jpg        | 126 | 42 |
| 00112_jpg        | 0   | 0  |
| 00246_jpg        | 32  | 15 |
| 00055_jpg        | 40  | 10 |
| 00352_jpg        | 45  | 24 |
| 00001_jpg        | 2   | 0  |
| 00066_jpg        | 7   | 3  |
| 00280_jpg        | 79  | 22 |
| 00372_jpg        | 46  | 18 |

---

*Nota.* Elaboración propia.

### **Resumen**

En el siguiente estudio se evaluó la eficacia de detección de malezas en cultivos de papa, se realizó una comparación entre las etiquetas manuales y el dron + EfficientDet.

### **Hipótesis**

H0: No hay diferencia estadísticamente significativa en el número de malezas detectadas por el modelo y las etiquetas manualmente.

H1: Si hay diferencia estadísticamente significativa en el número de malezas detectadas por el modelo y las etiquetas manualmente.

### Desarrollo

Se hizo uso de la prueba de T-Student para muestras independientes para comparar las diferencias en la cantidad de malezas detectadas entre ambos métodos, se hizo uso de las fórmulas estándar para la prueba T-Student y la correlación de Pearson.

### Resultados clave

**Tabla 19** Resultados Media y Varianza de Dron + EfficientDet

| Estadística                    | Anotaciones Manuales | Detección EfficientDet |
|--------------------------------|----------------------|------------------------|
| Media (Cantidad de malezas)    | 49.625               | 18.17                  |
| Varianza (Cantidad de malezas) | 1895.651             | 250.81                 |

*Nota.* Elaboración propia.

**Tabla 20** T-Student Dron + EfficientDet

| Estadística | Valor  |
|-------------|--------|
| Valor t     | 3.256  |
| Valor p     | 0.0021 |

*Nota.* Elaboración propia.

### Correlación de Pearson

**Tabla 21** Correlación de Pearson EfficientDet

| Estadística    | Valor |
|----------------|-------|
| Coefficiente r | 0.965 |

*Nota.* Elaboración propia.

### Conclusión

Este resultado indica que hay una diferencia muy alta entre las cantidades de malezas etiquetadas manualmente y las predichas por el modelo. El valor p es menor que 0.05, lo que indica que la hipótesis nula se rechaza, dando como resultado la diferencia significativa entre la cantidad de maleza etiquetadas y predichas.

### **T-Student en detección de papas con EfficientDet vs expertos**

#### **Datos**

Para realizar la comparación se hizo uso de la cantidad de etiquetas de papa correctas realizadas por el modelo EfficientDet y la cantidad de etiquetas de papa realizadas de manera manual como se observa en la Tabla 22.

**Tabla 22** *T-Student en detección de papas con EfficientDet vs expertos*

| <b>Nombre del Archivo</b> | <b>Cantidad de papas<br/>etiquetas</b> | <b>Cantidad de papas<br/>predichas</b> |
|---------------------------|--|--|
| DJI_0664_JPG_jpg          | 46                                     | 44                                     |
| DJI_0748_JPG_jpg          | 40                                     | 18                                     |
| DJI_0721_JPG_jpg          | 266                                    | 116                                    |
| DJI_0746_JPG_jpg          | 132                                    | 72                                     |
| DJI_0821_JPG_jpg          | 341                                    | 103                                    |
| DJI_0019_JPG_jpg          | 0                                      | 0                                      |
| DJI_0743_JPG_jpg          | 220                                    | 85                                     |
| DJI_0812_JPG_jpg          | 175                                    | 89                                     |
| DJI_0955_JPG_jpg          | 0                                      | 8                                      |
| DJI_0054_JPG_jpg          | 0                                      | 5                                      |
| DJI_0979_JPG_jpg          | 0                                      | 0                                      |
| 00058_jpg                 | 104                                    | 69                                     |
| 00094_jpg                 | 180                                    | 116                                    |
| 00357_jpg                 | 13                                     | 5                                      |
| 00387_jpg                 | 15                                     | 9                                      |
| 00043_jpg                 | 159                                    | 59                                     |

|           |     |    |
|-----------|-----|----|
| 00112_jpg | 161 | 89 |
| 00246_jpg | 0   | 0  |
| 00055_jpg | 118 | 60 |
| 00352_jpg | 6   | 0  |
| 00001_jpg | 104 | 49 |
| 00066_jpg | 91  | 50 |
| 00280_jpg | 14  | 6  |
| 00372_jpg | 14  | 4  |

---

*Nota.* Elaboración propia.

### **Resumen**

En este estudio se evaluó la eficacia en la detección de malezas en cultivos de papa, comparando las etiquetas manuales con las detecciones realizadas por el modelo EfficientDet + Dron.

### **Hipótesis**

H0: No hay diferencia estadísticamente significativa en el número de papas detectadas por el modelo y las etiquetas manualmente.

H1: Si hay diferencia estadísticamente significativa en el número de papas detectadas por el modelo y las etiquetas manualmente.

### **Desarrollo**

Se realiza la prueba T-Student para muestras independientes para comparar las diferencias en la cantidad de papas detectadas entre el método tradicional vs EfficientDet + Dron, se hizo uso de las fórmulas estándar para la prueba T-Student y la correlación de Pearson.

### **Resultados clave**

**Tabla 23** *Resultados Media y Varianza en detección de papas con EfficientDet vs expertos*

| <b>Estadística</b>          | <b>Cantidad de papas etiquetas</b> | <b>Cantidad de papas predichas</b> |
|-----------------------------|------------------------------------|------------------------------------|
| Media (Cantidad de malezas) | 91.625                             | 44.0                               |

Varianza (Cantidad de malezas) 9303.46 1676.43

Nota. Elaboración propia.

**Tabla 24 Prueba T-Student en detección de papas con EfficientDet vs expertos**

| Estadística | Valor   |
|-------------|---------|
| Valor t     | 3.83    |
| Valor p     | 0.00081 |

Nota. Elaboración propia.

### Correlación de Pearson

**Tabla 25 Resultado de correlación en detección de papas con EfficientDet vs expertos**

| Estadística    | Valor |
|----------------|-------|
| Coefficiente r | 0.93  |

Nota. Elaboración propia.

### Conclusión

Los resultados muestran que P es menor que 0.5 por lo que se rechaza la hipótesis nula, dando lugar a una diferencia alta entre el método tradicional y el desarrollado. Dando a entender que el modelo captura bien las tendencias, pero necesita ajustes para así mejorar la cantidad de predicciones hechas.

### T-Student en detección de plantas con EfficientDet vs expertos

#### Datos

Para la comparación se utilizó la cantidad de etiquetas de plantas correctas realizadas por el modelo EfficientDet y la cantidad de etiquetas de plantas hechas manualmente como se observa en la tabla 26.

**Tabla 26 Comparación de modelo EfficientDet vs expertos**

| Nombre del Archivo | Cantidad de plantas<br>Etiquetas | Cantidad de plantas<br>Predichas |
|--------------------|----------------------------------|----------------------------------|
| DJI_0664_JPG_jpg   | 222                              | 102                              |

|                  |     |     |
|------------------|-----|-----|
| DJI_0748_JPG_jpg | 51  | 16  |
| DJI_0721_JPG_jpg | 371 | 132 |
| DJI_0746_JPG_jpg | 196 | 79  |
| DJI_0821_JPG_jpg | 300 | 121 |
| DJI_0019_JPG_jpg | 74  | 35  |
| DJI_0743_JPG_jpg | 260 | 119 |
| DJI_0812_JPG_jpg | 213 | 84  |
| DJI_0955_JPG_jpg | 102 | 58  |
| DJI_0054_JPG_jpg | 180 | 78  |
| DJI_0979_JPG_jpg | 88  | 57  |
| 00058_jpg        | 104 | 65  |
| 00094_jpg        | 180 | 113 |
| 00357_jpg        | 74  | 45  |
| 00387_jpg        | 90  | 39  |
| 00043_jpg        | 285 | 78  |
| 00112_jpg        | 161 | 112 |
| 00246_jpg        | 70  | 38  |
| 00055_jpg        | 158 | 85  |
| 00352_jpg        | 51  | 24  |
| 00001_jpg        | 104 | 76  |
| 00066_jpg        | 98  | 67  |
| 00280_jpg        | 94  | 39  |
| 00372_jpg        | 60  | 38  |

---

*Nota.* Elaboración propia.

### **Resumen**

Se evaluó la eficacia en la detección de malezas en cultivos de papa, comparando las anotaciones manuales con la detección realizada por el modelo EfficientDet + Dron.

### **Hipótesis**

H0: No hay diferencia estadísticamente significativa en el número de papas detectadas por el modelo y las etiquetas manualmente.

H1: Si hay diferencia estadísticamente significativa en el número de papas detectadas por el modelo y las etiquetas manualmente.

### **Desarrollo**

Se realizó la prueba T-Student para muestras independientes para comparar las diferencias en la cantidad de papas detectadas entre el método tradicional vs EfficientDet + Dron, se hizo uso de las fórmulas estándar para la prueba T-Student y la correlación de Pearson.

### **Resultados clave**

**Tabla 27** Resultados Media y Varianza

| <b>Estadística</b>             | <b>Método tradicional</b> | <b>Uso de EfficientDet y Dron</b> |
|--------------------------------|---------------------------|-----------------------------------|
| Media (Cantidad de malezas)    | 149.42                    | 70.83                             |
| Varianza (Cantidad de malezas) | 7842.86                   | 1101.36                           |

*Nota.* Elaboración propia.

**Tabla 28** Prueba T de Student

| <b>Estadística</b> | <b>Valor</b> |
|--------------------|--------------|
| Valor t            | 6.2          |
| Valor p            | 0.87         |

*Nota.* Elaboración propia.

### **Correlación de Pearson**

**Tabla 29** Correlación de Pearson

| <b>Estadística</b> | <b>Valor</b> |
|--------------------|--------------|
| Coefficiente r     | 0.87         |

*Nota.* Elaboración propia.

### **Conclusión**

La t-student y la P tienen valores bajos, por lo que muestran una diferencia significativa entre la detección de plantas manuales y con el modelo, por lo que la hipótesis alternativa es la que se acepta y la correlación de Pearson con un valor de 0.87 indica que las predicciones del modelo tienden a seguir una similitud con las etiquetas hechas de manera manual.

### 3.3. ISO 25010 - 25023

#### 3.3.1. Completitud Funcional

Es el grado en el cual el conjunto de funcionalidades cubre todas las tareas y los objetivos del usuario especificados (ISO 25010, 2022). Para esto en la tabla 30 se especifica cada requerimiento del usuario y se muestra cada uno de ellos con su respectivo cumplimiento.

**Tabla 30** Cumplimiento de los requisitos

| Número | Requerimientos  | Cumplimiento |
|--------|---|--------------|
| 1      | Investigar la literatura acerca de redes neuronales.  | ✓            |
| 2      | Investigar los parámetros en las cuales se puedan obtener imágenes propias para un dataset. | ✓            |
| 3      | Seguimiento de cultivos y malezas en terrenos.  | ✓            |
| 4      | Crear un propio dataset.  | ✓            |
| 5      | Adquirir imágenes de cultivos desde un dron.  | ✓            |
| 6      | Adquirir imágenes de malezas desde un dron.   | ✓            |
| 7      | Implementar una cnn para la detección de malezas.   | ✓            |
| 8      | Usar la arquitectura Xception para la detección de malezas.                                 |              |
| 9      | Crear una bitácora en las salidas de campo para tomas de imágenes con el dron.              | ✓            |
| 10     | Validar los resultados con métricas adecuadas para detección de objetos.                    | ✓            |

*Nota.* Elaboración propia.

Para la evaluación de la completitud funcional se hace uso de la siguiente fórmula:

$$x1 = 1 - ff/tf$$

Donde:

$x1$  = Completitud funcional.

$ff$  = Número de funciones faltantes.

$tf$  = Número de funciones establecidas en los requerimientos de los clientes.

Valor esperado = Mientras más cerca de 1 es mejor.

Se cumple con 9 requerimientos que se dieron a conocer, con el uso de la fórmula ya dada el resultado que nos da es el siguiente:

$$x1 = 1 - 1/10$$

$$x1 = 0.9$$

La respuesta que se obtiene es 0.9, que representa el 90% del cumplimiento de los requisitos.

### 3.3.2. Corrección Funcional

Es la capacidad del producto o sistema para proveer resultados correctos con el nivel de precisión requerido (*ISO 25010, 2022*). Para la validación de la corrección funcional se hizo uso de una encuesta al PhD. Iván García, quien es el director de este trabajo de titulación y quien valida que la información sea correcta.

El objetivo es conocer el cumplimiento o no con la exactitud requerida en cada una de las funciones implementadas, la encuesta cuenta con una pregunta que dice:

- Marque con un visto las funciones implementadas en base a los requerimientos que si cumplen con la exactitud requerida por la institución.

Las respuestas se muestran en la tabla 31:

**Tabla 31** *Cumplimiento de los requisitos*

| Número | Requerimientos                                       | Cumplimiento |
|--------|--|--------------|
| 1      | Investigar la literatura acerca de redes neuronales. | ✓            |

|    |   |   |
|----|---|---|
| 2  | Investigar los parámetros en las cuales se puedan obtener imágenes propias para un dataset. | ✓ |
| 3  | Seguimiento de cultivos y malezas en terrenos.  | ✓ |
| 4  | Crear un propio dataset.  | ✓ |
| 5  | Adquirir imágenes de cultivos desde un dron.  | ✓ |
| 6  | Adquirir imágenes de malezas desde un dron.   | ✓ |
| 7  | Implementar una cnn para la detección de malezas.   | ✓ |
| 8  | Usar la arquitectura Xception para la detección de malezas.                                 |   |
| 9  | Crear una bitácora en las salidas de campo para tomas de imágenes con el dron.              | ✓ |
| 10 | Validar los resultados con métricas adecuadas para detección de objetos.                    | ✓ |

*Nota.* Elaboración propia.

Para la evaluación de la corrección funcional se plantea la siguiente fórmula:

$$x2 = 1 - e/te$$

Donde:

$x2$  = Exactitud funcional

$e$  = Número de funciones que no cumplen con la exactitud necesaria

$te$  = Número de funciones establecidas en los requerimientos de los clientes

Valor esperado = Mientras más cerca de 1 es mejor

Se cumple con 9 requerimientos que se dieron a conocer, con el uso de la fórmula ya dada el resultado que nos da es el siguiente:

$$x2 = 1 - 1/10$$

$$x2 = 0.9$$

La respuesta que se obtiene es 0.9, que representa el 90% del cumplimiento de las funciones con una exactitud necesaria.

### 3.3.3. Pertinencia Funcional

Es la capacidad del producto software para proporcionar un conjunto apropiado de funciones para tareas y objetivos de usuario especificados (ISO 25010, 2022). Al igual que la función anterior, para su validación se presentó una encuesta al PhD. Iván García, con el objetivo de conocer si cada función implementada resulta idónea.

La encuesta comienza con:

- Marque con un visto las funciones implementadas en base a los requerimientos que sean percibidas como idóneas.

Las respuestas se presentan en la tabla 32:

**Tabla 32** Resultados de la Encuesta para la Pertinencia Funcional

| Número | Requerimientos  | Cumplimiento |
|--------|---|--------------|
| 1      | Investigar la literatura acerca de redes neuronales.  | ✓            |
| 2      | Investigar los parámetros en las cuales se puedan obtener imágenes propias para un dataset. | ✓            |
| 3      | Seguimiento de cultivos y malezas en terrenos.  | ✓            |
| 4      | Crear un propio dataset.  | ✓            |
| 5      | Adquirir imágenes de cultivos desde un dron.  | ✓            |
| 6      | Adquirir imágenes de malezas desde un dron.   | ✓            |
| 7      | Implementar una cnn para la detección de malezas.   | ✓            |
| 8      | Usar la arquitectura Xception para la detección de malezas.                                 |              |
| 9      | Crear una bitácora en las salidas de campo para tomas de imágenes con el dron.              | ✓            |
| 10     | Validar los resultados con métricas adecuadas para detección de objetos.                    | ✓            |

*Nota.* Elaboración propia.

Se presentaron 10 funcionalidades, de las cuales 1 no se considera idónea por el director. Para evaluar la pertinencia funcional se plantea la siguiente fórmula:

$$x_3 = fu/te$$

Donde:

$x_3$  = Pertinencia funcional

$fu$  = Número de funciones realmente útiles.

$te$  = Número de funciones establecidas en los requerimientos de los clientes.

Valor esperado = Mientras más cerca de 1 es mejor.

Son 9 las funciones implementadas que se consideran idóneas, por lo que utilizando la fórmula se obtiene lo siguiente:

$$x_3 = 9/10$$

$$x_3 = 0.9$$

Se obtiene como resultado 0.9, representando que un 90% de las funciones son consideradas idóneas.

#### **3.3.4. Validación de Resultados.**

La normativa ISO/IEC 25010 utiliza la siguiente fórmula para el cálculo de la característica de adecuación funcional:

$$\chi = \frac{\sum_{i=1}^n x_i}{n}$$

Donde:

$\chi$  = Adecuación funcional

$\sum_{i=1}^n x_i$  = Sumatoria de las sub características de la adecuación funcional.

$n$  = Número de sub características de adecuación funcional utilizadas y evaluadas.

Valor esperado = Mientras más cerca de 1 es mejor.

Ponderación de la calidad: 1 equivale a 100%.

Rango de calidad= Mayor a 85% Alto, mayor a 75% Medio y menor a 75% bajo.

### 3.3.5. Análisis de Resultados

Haciendo uso de la métrica para evaluar la característica de adecuación funcional, se obtiene el siguiente resultado:

$$\chi = \frac{\sum_{i=1}^n x_i}{n}$$
$$x = \frac{0.9 + 0.9 + 0.9}{3}$$
$$x = 0,9$$

La métrica de calidad indica que el 90% de las funciones del proyecto cumplen con los estándares de calidad, situando al proyecto en una categoría de alta calidad. Solo un pequeño 10% de las funciones no alcanzan la calidad deseada.

#### DISCUSIÓN

La discusión tratada en este proyecto pone a la arquitectura EfficientDet para detección de malezas en comparativa con otras arquitecturas existentes y que se encuentran en la literatura actual, en la tabla 33 se organiza las arquitecturas para mejor comparativa en donde se tiene la arquitectura, la referencia de donde obtuvimos los datos y métricas como precisión y recall.

**Tabla 33** *Discusión EfficientDet con otras arquitecturas*

| Arquitectura | Referencia                           | Precision % | Recall % |
|--------------|--------------------------------------|-------------|----------|
| VGG16        | (Wu et al., 2023)                    | 93.2        | 93.4     |
| ResNet-50    | (Manikandakumar & Karthikeyan, 2022) | 96.88       | -        |
| GoogLeNet    | (Wu et al., 2023)                    | 93.5        | 93.6     |

|              |                          |      |       |
|--------------|--------------------------|------|-------|
| Desenet-121  | (Wu et al., 2023)        | 94.3 | 94.2  |
| Mask R-CNN   | (Soltane & Laouar, 2023) | 90.2 | 88.6  |
| YOLOv5       | (Soltane & Laouar, 2023) | 91.7 | 90.5  |
| EfficientDet | -                        | 64.1 | 63.46 |

*Nota.* Elaboración propia.

La tabla 33 proporciona una comparación de las métricas de rendimiento de varias arquitecturas de CNN en la tarea de detección de malezas, como destacadas tenemos las métricas de precisión y recall.

#### **Rendimiento General**

- Las arquitecturas VGG16, ResNet-50, GoogLeNet y Densenet-121 dan métricas de precisión y recall superiores al 93%. En el caso de ResNet-50 alcanza una precisión del 96.88%, lo que demuestra su alta capacidad para identificar malezas en las imágenes.
- Mask R-CNN y YOLOv5 tienen métricas levemente inferiores en comparación con ResNet-50 y Densenet-121 mostrando una precisión del 90.2% y 91.7% y un recall de 88.6% y 90.5% respectivamente, lo que indica un rendimiento sólido.

#### **Desempeño de EfficientDet**

EfficientDet alcanza una precisión del 64.1% y un recall del 63.46%. Estas métricas son significativamente más bajas en comparación con el resto de arquitecturas presentadas en la comparativa, lo que sugiere que EfficientDet no es tan eficaz en la detección de malezas en este contexto específico.

Las posibles causas del bajo rendimiento que presenta la arquitectura puede incluir un entrenamiento insuficiente del modelo, la necesidad de un ajuste más fino de los

hiperparámetros, mayor variedad de clases en el dataset e incluso que las características del dataset no se adaptan bien a la arquitectura EfficientDet.

### **Análisis de Resultados**

- Las arquitecturas ResNet-50 y Densenet-121 muestran una alta precisión y recall, lo que indica su efectividad en la detección de malezas. Esto podría atribuirse a su capacidad para extraer características robustas y detalladas de las imágenes, permitiendo una clasificación más precisa.
- Mask R-CNN y YOLOv5, no alcanzan el nivel de ResNet-50 y Densenet-121, pero aún así ofrecen un rendimiento sólido, especialmente en la detección en tiempo real, lo cual es beneficioso en aplicaciones de agricultura de precisión.

### **Implicaciones para EfficientDet**

- El rendimiento inferior de EfficientDet sugiere la necesidad de investigar más a fondo las causas detrás de estos resultados. Podría ser útil ajustar el preprocesamiento del dataset, incrementar el tamaño del dataset de entrenamiento o utilizar técnicas de data augmentation para mejorar las métricas del modelo.
- Otra estrategia podría ser combinar EfficientDet con otros métodos o modelos para mejorar su rendimiento. Como por ejemplo, usar EfficientDet como backbone para la abstracción de características y luego refinar la clasificación con una arquitectura más robusta como ResNet-50.

## **CONCLUSIONES**

- El buscar trabajos relacionados con el énfasis del proyecto de detección de malezas dio un resultado favorable en todo el proceso de desarrollo, dio un panorama más amplio de toda la temática, desde las arquitecturas más usadas para este tipo de proyectos, los hiperparámetros que mejor resultados dan y en el caso particular del proyecto dieron información relevante para la creación de un propio dataset para el entrenamiento, desde la altura del dron en la que se puede obtener imágenes, el formato de los datos, la velocidad del dron en la obtención de las imágenes y demás, en el caso de EfficientDet se obtuvo información de los pesos preentrenados para cada versión de la arquitectura que va de acorde con las dimensiones del input.

- Para el despliegue del modelo se hace uso de Gradio, una herramienta open source que facilita la difusión de trabajos relacionados con la ciencias de datos, el cual es excelente para la metodología KDD que es usada en este proyecto de visión por computador, se usa Gradio por ser una herramienta integrada a Python con interfaces sencillas que se presentan al público final, permitiendo la carga de imágenes, ejecución del modelo y la visualización de los resultados de manera más interactiva.
- EfficientDet muestra un rendimiento inferior en esta comparación, lo que resalta la necesidad de hacer más investigación y experimentación para mejorar su eficacia en la detección de malezas. La combinación de distintas técnicas y la optimización más rigurosa del modelo y dataset podrían llevar a obtener mejoras significativas en las métricas que se están usando en el proyecto.
- Las pruebas realizadas a la arquitectura EfficientDet muestran el trayecto que se tuvo en todo el proceso de entrenamiento, esto ayudó a escoger de mejor manera los hiperparámetros con los cuales entrenar, con esto comenzar con un modelo base de la red y así hacer uso del modelo seleccionado en el despliegue del modelo para ser puesto al uso de terceros como muestra la metodología KDD en la fase de difusión.
- El proyecto trabajo en el documento cumple con 9 de 10 requisitos que usamos para cuantificar el porcentaje de la calidad del software, con el uso de la ISO 25010 como guía para el desarrollo de la encuesta que se realiza al director del proyecto y la ISO 25023 como herramienta para cuantificar el porcentaje de los resultados que se obtienen con la encuesta realizada. Con todo esto el resultado dado en el proyecto fue de un 90%, un valor alto que se vio afectado en un 10% por el no cumplimiento de un requerimiento.

### **RECOMENDACIONES**

- Se debe explorar más y cada vez documentación más actualizada, al tener en cuenta el auge de herramientas con IA se hace más visible la publicación de nuevas herramientas e información que es de utilidad para este tipo de trabajos, por lo que es recomendable usar literatura de al menos 3 años de antigüedad, pues existen varios modelos publicados que al ser estudiados y puestos en práctica cumplen con

métricas altas, además de dar nuevos enfoques que pueden ayudar a la resolución de problemas que tienen relación con nuestro proyecto.

- Para tener mejores resultados se recomienda tener un dataset robusto, como este proceso lleva mucho tiempo existen varias técnicas que cumplen el propósito como el de data augmentation, en ese caso en particular se recomienda hacer rotaciones en ángulos rectos por el motivo que al usar otros valores en las rotaciones los píxeles se ven promediados en las esquinas de las imágenes lo que hace que la imagen pierda información que es de valor.
- La utilización de entornos de desarrollo como Google Colab o Kaggle ahorran mucho tiempo en la inicialización de proyectos, con la incorporación de herramientas dan más ayuda para entender los recursos que se usan, en el caso de Google Colab se recomienda usar la versión de paga, pues incluyen GPUs más potentes, actuales y ayudan con más tiempo de procesamiento en el entrenamiento, con todo esto se puede acelerar de manera considerable el tiempo, dando más oportunidad a experimentaciones.
- Tener un buen plan de seguimiento para la obtención de datos para la formación del dataset, al ser un conjunto de datos de campos de cultivos, existe la problemática del tiempo, pues la mayoría de terrenos son trabajados y sus propietarios no pueden permitir el crecimiento de malezas en exceso, ni dejar sin tratarlos por varios días, por lo cual al se dificulta la obtención de malezas, es recomendable tener un plan B para tratar este tipo de problemas.

## BIBLIOGRAFÍA

- Abid, A., Abdalla, A., Abid, A., Khan, D., Alfozan, A., & Zou, J. (2019). *Gradio: Hassle-Free Sharing and Testing of ML Models in the Wild*. <http://arxiv.org/abs/1906.02569>
- Aggarwal, V., Ahmad, A., Etienne, A., & Saraswat, D. (2022). *4Weed Dataset: Annotated Imagery Weeds Dataset*. <http://arxiv.org/abs/2204.00080>
- Berzal, F. (2018). *Redes Neuronales & Deep Learning* (F. B. Berzal, Ed.).
- Cárdenas, J. (1987). *Manual de Control de Malezas en Papa*.
- Chollet, F. (2017). Xception: Deep Learning with Depthwise Separable Convolutions. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1800–1807.
- Couto, R. S., Cruz, P., Campista, M. E. M., & Costa, L. H. M. K. (2023). Using Public Datasets to Train O-RAN Deep Learning Models. *International Conference on 6G Networking, 6GNet 2023*. <https://doi.org/10.1109/6GNET58894.2023.10317705>
- Cumbal, C. (2022). *Análisis de imágenes de radiografías de la columna vertebral para calcular el ángulo de desviación en pacientes que padecen escoliosis utilizando técnicas de IA*.
- Dairath, M. H., Akram, M. W., Mehmood, M. A., Sarwar, H. U., Akram, M. Z., Omar, M. M., & Faheem, M. (2023). Computer vision-based prototype robotic picking cum grading system for fruits. *Smart Agricultural Technology*, 4, 100210. <https://doi.org/10.1016/j.atech.2023.100210>
- DroneDeploy, Inc. (2024). *Drone & Plataforma de mapeo UAV | DroneDeploy*. <https://prod.dronedeploy.com/es-mx/>
- Finger, R., Swinton, S. M., El Benni, N., & Walter, A. (2019). Precision Farming at the Nexus of Agricultural Production and the Environment. *Annual Review of Resource Economics*. <https://doi.org/10.1146/annurev-resource-100518>
- Google. (2024, July 24). *Colab pricing*. <https://research.google.com/colaboratory/intl/es/faq.html>
- Guo, X., Ge, Y., Liu, F., & Yang, J. (2023). Identification of maize and wheat seedlings and weeds based on deep learning. *Frontiers in Earth Science*, 11. <https://doi.org/10.3389/feart.2023.1146558>

- Haq, S. I. U., Tahir, M. N., & Lan, Y. (2023). Weed Detection in Wheat Crops Using Image Analysis and Artificial Intelligence (AI). *Applied Sciences (Switzerland)*, 13(15). <https://doi.org/10.3390/app13158840>
- HLEG. (2019). *A Definition Of AI: Main Capabilities And Disciplines*. <https://ec.europa.eu/digital-single->
- IBM. (2021, August 17). *El modelo de redes neuronales*. <https://www.ibm.com/docs/es/spss-modeler/saas?topic=networks-neural-model>
- ISO 25010. (2022). <https://iso25000.com/index.php/normas-iso-25000/iso-25010>
- ISO 25010. (2024). *ISO 25010*. <https://iso25000.com/index.php/normas-iso-25000/iso-25010>
- Jain, S. (2023). *DeepSeaNet: Improving Underwater Object Detection using EfficientDet*. <https://arxiv.org/abs/2306.06075v2>
- Jeong, C. (2024). *Fine-tuning and Utilization Methods of Domain-specific LLMs*.
- Jiménez López, A. F., Camargo Pico, D. A., & García Ramírez, D. Y. (2020). Sistema Inteligente para el manejo de Malezas en el cultivo de Piña con Conceptos de Agricultura de Precisión. *Ciencia y Agricultura*, 17(3), 122–136. <https://doi.org/10.19053/01228420.v17.n3.2020.10830>
- Kim, Y. H., & Park, K. R. (2022). MTS-CNN: Multi-task semantic segmentation-convolutional neural network for detecting crops and weeds. *Computers and Electronics in Agriculture*, 199. <https://doi.org/10.1016/j.compag.2022.107146>
- Lin, Q., Ye, G., Wang, J., & Liu, H. (2022). *RoboFlow: a Data-centric Workflow Management System for Developing AI-enhanced Robots*. <https://sites.google.com/u.northwestern.edu/roboflow>
- Liu, B. (2023). An automated weed detection approach using deep learning and UAV imagery in smart agriculture system. *Journal of Optics (India)*, 53(3), 2183–2191. <https://doi.org/10.1007/S12596-023-01445-X/METRICS>
- Liu, Y., Wang, Y., Wang, S., Liang, T., Zhao, Q., Tang, Z., & Ling, H. (2019). *CBNet: A Novel Composite Backbone Network Architecture for Object Detection*. <http://arxiv.org/abs/1909.03625>

- Ma, F., Ye, M., Luo, J., Xiao, C., & Sun, J. (2021). Advances in Mining Heterogeneous Healthcare Data. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 4050–4051. <https://doi.org/10.1145/3447548.3470789>
- Manikandakumar, M., & Karthikeyan, P. (2022). Weed Classification Using Particle Swarm Optimization and Deep Learning Models. *Computer Systems Science and Engineering*, 44(1), 913–927. <https://doi.org/10.32604/csse.2023.025434>
- Martínez, J. M. (2021). *Desarrollo de una Arquitectura Eficiente Orientada a Microservicios con API REST Utilizando la Calidad Externa de las Normas ISO/IEC 25023*.
- Melgar-García, L., Gutiérrez-Avilés, D., Godinho, M. T., Espada, R., Brito, I. S., Martínez-Álvarez, F., Troncoso, A., & Rubio-Escudero, C. (2022). A new big data triclustering approach for extracting three-dimensional patterns in precision agriculture. *Neurocomputing*, 500, 268–278. <https://doi.org/10.1016/j.neucom.2021.06.101>
- Naciones Unidas. (2022). *Sustainable Development Goal 9: Industria, innovación e infraestructura | Naciones Unidas en Ecuador*. <https://ecuador.un.org/es/sdgs/9>
- Nagreacha, K. (2023). *Systems for Parallel and Distributed Large-Model Deep Learning Training*. <http://arxiv.org/abs/2301.02691>
- Nigro, H. O., Xodo, D., Corti, G., & Terren, D. (2004). *KDD (Knowledge Discovery in Databases): Un proceso centrado en el usuario*.
- Ortega, B. A. (2024). *Detección automática de malezas en plantaciones de maíz y/o papa utilizando imágenes adquiridas por dron y red neuronal Convolutacional Yolo*.
- Padilla, R., L. Netto, S., & da Silva, A. B. (2020, July 1). *A Survey on Performance Metrics for Object-Detection Algorithms*.
- Padmapriya, G., Santhosh Kumar, B., Kavitha, M. N., & Vennila, V. (2021). WITHDRAWN: Deep convolutional neural network for real time object detection using tensor flow. *Materials Today: Proceedings*. <https://doi.org/10.1016/j.matpr.2021.02.671>
- Pathmudi, V. R., Khatri, N., Kumar, S., Abdul-Qawy, A. S. H., & Vyas, A. K. (2023). A systematic review of IoT technologies and their constituents for smart and sustainable agriculture applications. *Scientific African*, 19. <https://doi.org/10.1016/j.sciaf.2023.e01577>

- Raja, R., Slaughter, D. C., Fennimore, S. A., & Siemens, M. C. (2023). Real-time control of high-resolution micro-jet sprayer integrated with machine vision for precision weed control. *Biosystems Engineering*, 228, 31–48. <https://doi.org/10.1016/j.biosystemseng.2023.02.006>
- Sharma, S., & Kumar, S. (2022). The Xception model: A potential feature extractor in breast cancer histology images classification. *ICT Express*, 8(1), 101–108. <https://doi.org/10.1016/j.ict.2021.11.010>
- Singh, S. P., Kumar, A., Yadav, N., & Awasthi, R. (2018). Data mining: Consumer behavior analysis. *2018 3rd IEEE International Conference on Recent Trends in Electronics, Information and Communication Technology, RTEICT 2018 - Proceedings*, 1917–1921. <https://doi.org/10.1109/RTEICT42901.2018.9012300>
- Soltane, M., & Laouar, M. R. (2023). Weeds Detection Using Mask R-CNN and Yolov5. *Communications in Computer and Information Science*, 1941 CCIS, 223–233. [https://doi.org/10.1007/978-3-031-46338-9\\_17](https://doi.org/10.1007/978-3-031-46338-9_17)
- Subeesh, A., Bhole, S., Singh, K., Chandel, N. S., Rajwade, Y. A., Rao, K. V. R., Kumar, S. P., & Jat, D. (2022). Deep convolutional neural network models for weed detection in polyhouse grown bell peppers. *Artificial Intelligence in Agriculture*, 6, 47–54. <https://doi.org/10.1016/j.aiia.2022.01.002>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2015). *Rethinking the Inception Architecture for Computer Vision*. <http://arxiv.org/abs/1512.00567>
- Tan, M., Pang, R., & Le, Q. V. (2019). *EfficientDet: Scalable and Efficient Object Detection*. <http://arxiv.org/abs/1911.09070>
- Timarán Pereira, S. R., Hernández Arteaga, I., Caicedo Zambrano, S. J., Hidalgo Troya, A., & Alvarado Pérez, J. C. (2016). Descubrimiento de patrones de desempeño académico con árboles de decisión en las competencias genéricas de la formación profesional. In *Descubrimiento de patrones de desempeño académico con árboles de decisión en las competencias genéricas de la formación profesional*. Universidad Cooperativa de Colombia. <https://doi.org/10.16925/9789587600490>

- Vecchio, Y., Di Pasquale, J., Del Giudice, T., Pauselli, G., Masi, M., & Adinolfi, F. (2022). Precision farming: what do Italian farmers really think? An application of the Q methodology. *Agricultural Systems*, 201. <https://doi.org/10.1016/j.agsy.2022.103466>
- Wang, P., Tang, Y., Luo, F., Wang, L., Li, C., Niu, Q., & Li, H. (2022). Weed25: A deep learning dataset for weed identification. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.1053329>
- Wu, Y., He, Y., & Wang, Y. (2023). Multi-Class Weed Recognition Using Hybrid CNN-SVM Classifier. *Sensors*, 23(16). <https://doi.org/10.3390/s23167153>
- Xu, Y., Zhai, Y., Zhao, B., Jiao, Y., Kong, S., Zhou, Y., & Gao, Z. (2021). Weed recognition for depthwise separable network based on transfer learning. *Intelligent Automation and Soft Computing*, 27(3), 669–682. <https://doi.org/10.32604/IASC.2021.015225>
- Zhai, Y., Luan, T., Doermann, D., & Yuan, J. (2023). *Towards Generic Image Manipulation Detection with Weakly-Supervised Self-Consistency Learning*.

## ANEXOS

### Apéndice A: Encuesta sobre Exactitud Funcional



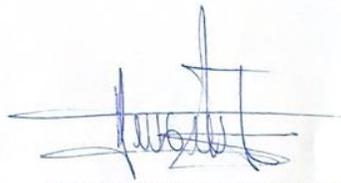
UNIVERSIDAD TÉCNICA DEL NORTE  
FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS  
CARRERA DE SOFTWARE  
ENCUESTA – EXACTITUD FUNCIONAL

Para la validación de los resultados de la tesis "Detección automática de malezas en cultivos de maíz y/o papa utilizando imágenes adquiridas por drones empleando la arquitectura de red neuronal convolucional Xception" realizada por Lema Dias Kevin Johao, se presenta la siguiente encuesta respecto a la exactitud funcional. Esta encuesta consta de una sola pregunta.

1. Marque con un visto las funciones implementadas en base a los requerimientos que sí cumplen con la exactitud requerida por el director.

| Número | Requerimientos  | Cumplimiento |
|--------|---|--------------|
| 1      | Investigar la literatura acerca de redes neuronales.  | ✓            |
| 2      | Investigar los parámetros en las cuales se puedan obtener imágenes propias para un dataset. | ✓            |
| 3      | Seguimiento de cultivos y malezas en terrenos.  | ✓            |
| 4      | Crear un propio dataset.  | ✓            |
| 5      | Adquirir imágenes de cultivos desde un dron.  | ✓            |
| 6      | Adquirir imágenes de malezas desde un dron.   | ✓            |
| 7      | Implementar una cnn para la detección de malezas.   | ✓            |
| 8      | Usar la arquitectura Xception para la detección de malezas.                                 | ✗            |

|    |  |   |
|----|--|---|
| 9  | Crear una bitácora en las salidas de campo para tomas de imágenes con el dron. | ✓ |
| 10 | Validar los resultados con métricas adecuadas para detección de objetos.       | ✓ |



-----  
DIRECTOR DE TESIS

PhD. Iván Danilo García Santillán

## Apéndice B: Encuesta sobre Pertinencia Funcional



UNIVERSIDAD TÉCNICA DEL NORTE  
FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS  
CARRERA DE SOFTWARE  
ENCUESTA – PERTINENCIA FUNCIONAL

Para la validación de los resultados de la tesis "Detección automática de malezas en cultivos de maíz y/o papa utilizando imágenes adquiridas por drones empleando la arquitectura de red neuronal convolucional Xception" realizada por Lema Dias Kevin Johao, se presenta la siguiente encuesta respecto a la pertinencia funcional. Esta encuesta consta de una sola pregunta.

1. Marque con un visto las funciones implementadas en base a los requerimientos que sean percibidas como idóneas.

| Número | Requerimientos  | Cumplimiento |
|--------|---|--------------|
| 1      | Investigar la literatura acerca de redes neuronales.  | ✓            |
| 2      | Investigar los parámetros en las cuales se puedan obtener imágenes propias para un dataset. | ✓            |
| 3      | Seguimiento de cultivos y malezas en terrenos.  | ✓            |
| 4      | Crear un propio dataset.  | ✓            |
| 5      | Adquirir imágenes de cultivos desde un dron.  | ✓            |
| 6      | Adquirir imágenes de malezas desde un dron.   | ✓            |
| 7      | Implementar una cnn para la detección de malezas.   | ✓            |
| 8      | Usar la arquitectura Xception para la detección de malezas.                                 | ✓            |

|    |  |   |
|----|--|---|
| 9  | Crear una bitácora en las salidas de campo para tomas de imágenes con el dron. | ✓ |
| 10 | Validar los resultados con métricas adecuadas para detección de objetos.       | ✓ |



-----  
DIRECTOR DE TESIS

PhD. Iván Danilo García Santillán