

UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS
CARRERA DE SOFTWARE



TEMA:

IDENTIFICACIÓN DE MALEZAS EN CULTIVOS DE MAÍZ Y/O PAPA A TRAVÉS DE IMÁGENES DE UN DRON, UTILIZANDO LA ARQUITECTURA DE LA RED NEURONAL FASTER R-CNN.

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

Autor:

Alex Israel Lanchimba Ashqui

Director:

PhD. Iván Danilo García Santillán

Ibarra, 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:	1725604563		
APELLIDOS Y NOMBRES:	Lanchimba Ashqui Alex Israel		
DIRECCIÓN:	Cotopaxi - Toacaso		
EMAIL:	ailanchimbaa@utn.edu.ec		
TELÉFONO FIJO:		TELÉFONO MÓVIL:	0995065906

DATOS DE LA OBRA	
TÍTULO:	Identificación de malezas en cultivos de maíz y/o papa a través de imágenes de un dron, utilizando la arquitectura de la red neuronal Faster R-CNN.
AUTOR (ES):	Alex Israel Lanchimba Ashqui
FECHA DE APROBACIÓN: DD/MM/AAAA	30/07/2024
PROGRAMA:	<input checked="" type="checkbox"/> PREGRADO <input type="checkbox"/> POSGRADO
TÍTULO POR EL QUE 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:

Alex Israel Lanchimba Ashqui
1725604563

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. Alex Israel Lanchimba Ashqui portador de la cedula de ciudadanía número 1725604563, ha trabajado en el desarrollo del proyecto de grado "Identificación de malezas en cultivos de maíz y/o papa a través de imágenes de un dron, utilizando la arquitectura de la red neuronal Faster R-CNN." 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

Este trabajo va dedicado a mi familia, en especial a mi querida madre por ser mi apoyo e inspiración de alcanzar nuevos logros, por enseñarme el valor del esfuerzo y dedicación.

A mi abuelita, que siempre creyó en mí y me inspiro a alcanzar mis sueños, cuya ausencia física es apaciguada por sus valores y fortaleza. Eres la estrella que sigue brillando en mi vida, iluminando cada paso de mi camino. Este trabajo es un testimonio de tu amor eterno y de las valiosas lecciones que me dejaste. Gracias por todo, abuelita.

Alex Israel Ashqui

AGRADECIMIENTO

Quiero expresar mi más profunda gratitud, el apoyo incondicional de mi familia, a mis padres Nelson y Gladys por su amor incondicional y sus consejos que me ayudaron a salir adelante, a mi hermana Diana quien ha sido fuente de inspiración para nuevos retos y mantener disciplina y determinación.

Mis agradecimientos para la Universidad Técnica del Norte, y a todos los docentes y amigos que formaron parte de mi formación académica. Por brindarme conocimientos esenciales y potenciar mis habilidades, por ayudarme a construir mi carrera y crecer profesionalmente.

Un agradecimiento especial a mis mentores PhD. García Santillán Iván Danilo y al PhD. Pusedá Chulde Marco Remigio por su asesoramiento, su compromiso, su experiencia y habilidades puesto en la realización de esta investigación, su entusiasmo y dedicación me han impulsado a seguir aprendiendo y superar nuevos desafíos en el ámbito laboral.

Alex Israel Ashqui

TABLA DE CONTENIDO

DEDICATORIA	IV
AGRADECIMIENTO	V
TABLA DE CONTENIDO.....	VI
ÍNDICE DE FIGURAS.....	XII
ÍNDICE DE TABLAS	XVI
RESUMEN	XX
ASBTRACT	XXII
INTRODUCCIÓN.....	1
TEMA.....	1
PROBLEMA	1
ANTECEDENTES.....	1
SITUACIÓN ACTUAL	1
PROSPECTIVA.....	2
PLANTEAMIENTO DEL PROBLEMA	2
OBJETIVOS	3
Objetivo General.....	3
Objetivos Específicos.....	3
ALCANCE	4
METODOLOGÍA.....	7
JUSTIFICACIÓN.....	8
CAPITULO I	10
1.1 FUNDAMENTACIÓN TEÓRICA.....	10
1.1.1 Cultivos	10

1.1.1.1	Clasificación de cultivos	10
1.1.1.2	Maíz.....	11
1.1.1.3	Papa	12
1.1.2	Malezas.....	13
1.1.2.1	Características.....	13
1.1.2.2	Especies de malezas más comunes en el Ecuador ...	13
1.1.2.3	Malezas en cultivos de maíz en el Ecuador	15
1.1.2.4	Malezas en cultivos de papa en el Ecuador.....	16
1.1.3	Dispersión de malezas	17
1.1.3.1	Dispersión con acción del hombre	17
1.1.3.2	Dispersión sin acción del hombre.....	18
1.1.4	Control de malezas.....	19
1.2	AGRICULTURA DE PRECISIÓN	20
1.2.1	Características	20
1.2.2	Sistemas de control	21
1.2.3	Aplicación en la agricultura	21
1.2.4	Dron.....	22
1.2.4.1	Tipos de drones para cultivos.....	23
1.2.4.2	Condiciones de vuelo	24
1.3	INTELIGENCIA ARTIFICIAL.....	24
1.3.1	Redes neuronales convolucionales	25
1.3.2	Modelos de aprendizaje automático	26
1.3.3	Arquitectura Faster R-CNN.....	28
1.3.4	Backbone ConvNet.....	30
1.3.4.1	Red preentrenada VGG 19	30

1.3.5	Region Proposal Network (RPN).....	31
1.3.6	Red de Clasificación y Regresión	32
1.4	METODOLOGÍA DE DESARROLLO	35
1.4.1	Metodología en cascada.....	35
1.4.2	ISO/IEC/IEEE 29148:2018.....	37
1.5	APLICACIÓN WEB.....	38
1.5.1	Detalles del sistema.....	38
1.5.2	Lenguaje de programación	39
1.6	TRABAJOS RELACIONADOS.....	41
1.7	PREGUNTAS CIENTÍFICAS.....	44
CAPITULO II.....		46
2	DESARROLLO DEL PROYECTO	46
2.1	RED NEURONAL ARTIFICIAL	46
2.1.1	Metodología en cascada.....	46
2.1.2	Herramientas de desarrollo.....	47
2.1.2.1	Dron Dji Mavic 2 PRO.....	48
2.1.2.2	Google Colab.....	50
2.1.2.3	Roboflow	50
2.1.2.4	Ngrok.....	50
2.2	METODOLOGÍA DE CASCADA BAJO LA NORMA ISO/IEC/IEEE 29148:2018.	51
2.2.1	Análisis.....	51
2.2.1.1	Historias de usuario	- 3 -
2.2.2	Diseño.....	- 7 -
2.2.3	Implementación.....	- 8 -
2.2.3.1	Preprocesamiento de datos	- 8 -

2.2.3.2	Elaboración del dataset.....	- 13 -
2.2.3.3	Verificación de la anotación de las imágenes	- 15 -
2.2.3.4	Set de entrenamiento y evaluación del modelo	- 15 -
2.2.3.5	Análisis y carga de datos del dataset.....	- 16 -
2.2.3.6	Entrenamiento del modelo	- 17 -
2.2.3.7	Evaluación del modelo.....	- 18 -
2.2.4	Verificación	- 19 -
2.2.4.1	Diseño de la base de datos.....	- 20 -
2.2.4.2	Desarrollo Backend.....	- 21 -
2.2.4.3	Desarrollo Frontend	- 21 -
2.2.4.4	Verificación de resultados	- 21 -
2.2.4.5	Despliegue de la aplicación	- 25 -
2.2.5	Mantenimiento.....	- 26 -
CAPITULO III.....		- 28 -
3	ANÁLISIS DE RESULTADOS	- 28 -
3.1	MÉTRICAS DEL MODELO FASTER R-CNN.....	- 28 -
3.1.1	Línea de tiempo del modelo entrenado	- 28 -
3.1.1.1	Fase 1 (Dataset #1 “Sin Balancear”).....	- 28 -
3.1.1.2	Fase 2 (Dataset #2 “Balanceado”)	3
3.1.2	Fases de entrenamiento.....	1
3.1.2.1	Perdida de caja.....	1
3.1.2.2	Perdida de clasificación.....	1
3.1.2.3	Classification Accuracy	2
3.1.2.4	Perdida General del modelo	3
3.1.3	Fase de validación.....	3

3.1.4	Fase de Resultados.....	4
3.1.4.1	IoU (Interseccion over Union).....	4
3.1.4.2	Precisión	5
3.1.4.3	Recall.....	6
3.1.4.4	mAP	7
3.2	COMPARACIÓN DEL MODELO CON MÉTODOS TRADICIONALES.....	8
3.2.1	Inferencias y resultados	8
3.2.1.1	Prueba 1 de inferencia.....	9
3.2.1.2	Prueba 2 de inferencia.....	10
3.2.1.3	Prueba 3 de inferencia.....	11
3.2.1.4	Prueba 4 de inferencia.....	12
3.2.1.5	Prueba 5 de inferencia.....	13
3.2.2	Métodos tradicionales.....	14
3.2.3	Uso del modelo de detección de malezas con Dron	14
3.2.4	Comparativa	15
3.3	PRUEBAS ESTADÍSTICAS	16
3.3.1	T-Student en tiempos de detección de malezas.....	16
3.3.2	T-Student en detección de malezas con Faster R-CNN y drones	18
3.3.3	T-Student en detección de papas con Faster R-CNN vs expertos.....	21
3.3.4	T-Student en detección de plantas con Faster R-CNN vs expertos.....	24
3.4	NIVEL DE INFESTACIÓN.....	27
3.5	DISCUSIONES.....	29

3.6	CONCLUSIONES.....	33
3.7	RECOMENDACIONES.....	35
	BIBLIOGRAFIA.....	36

ÍNDICE DE FIGURAS

Figura 1 Árbol de problemas	3
Figura 2 Arquitectura Faster R-CNN.....	5
Figura 3 Tecnologías de desarrollo.....	6
Figura 4 Arquitectura Faster R-CNN.....	6
Figura 5 Diagrama de flujo de metodología	8
Figura 6 Dispersión de maleza con maquinaria.....	17
Figura 7 Dispersión por mezcla de semillas.....	18
Figura 8 Dispersión por alimentación de ganado	18
Figura 9 Dispersión de otras especies.....	19
Figura 10 Aplicaciones de la inteligencia artificial	25
Figura 11 Red neuronal convolucional	26
Figura 12 Detalle de la estructura VGG19	31
Figura 13 RPN Y ROI Pooling	32
Figura 14 Region Proposal Network	33
Figura 15 Diagrama de metodología en cascada.....	37
Figura 16 Dron Dji Mavic 2 PRO	48

Figura 17 Recursos Colab PRO.....	50
Figura 18 Sobre población de maleza	56
Figura 19 Imagen dañada.....	56
Figura 20 Imagen con desenfoque	56
Figura 21 Interferencias con árbol y arbustos.....	- 2 -
Figura 22 Diseño del aplicativo	- 7 -
Figura 23 Altura de vuelo en el cultivo.....	- 8 -
Figura 24 Recorrido del Dron en el cultivo de papas	- 9 -
Figura 25 Perímetro de vuelo del Dron.....	- 9 -
Figura 26 Imágenes con las condiciones más favorables	- 11 -
Figura 27 Vista previa de las etiquetas del dataset.....	- 13 -
Figura 28 Estado del conjunto de datos pertenecientes al Dataset #1 “Sin Balancear”	- 14 -
Figura 29 Estado del conjunto de datos pertenecientes al Dataset #2 “Balanceado”	- 14 -
Figura 30 Formato de etiqueta Faster R-CNN.....	- 15 -
Figura 31 Test Split.....	- 16 -
Figura 32 Resultados de las experimentaciones en el modelo.....	- 19 -

Figura 33 Arquitectura de la aplicación web	- 19 -
Figura 34 BD de Comprobador	- 20 -
Figura 35 BD de Analizador.....	- 20 -
Figura 36 Procesar imagen de validación	- 22 -
Figura 37 Resultados de validación	- 23 -
Figura 38 Resultado luego de procesar imagen de análisis.....	- 23 -
Figura 39 Resultado de análisis	- 24 -
Figura 40 Registro de resultados anteriores	- 24 -
Figura 41 Eliminar registro	- 25 -
Figura 42 Túnel de conexión entre el servidor local y la URL publica de Ngrok	- 26 -
Figura 43 Despliegue del aplicativo web	- 26 -
Figura 44 Regresión Loss.....	1
Figura 45	2
Figura 46 Classification Acurracy.....	2
Figura 47 General Loss.....	3
Figura 48 IoU vs Epochs	5
Figura 49 Gráfica Precision vs Epochs.....	6

Figura 50	Grafica Recall vs Epochs.....	7
Figura 51	Grafica mAP vs Epochs	8
Figura 52	Resultado de inferencia Prueba 1.....	9
Figura 53	Resultados de inferencia Prueba 2.....	10
Figura 54	Resultados de inferencia Prueba 3.....	11
Figura 55	Resultados de inferencia Prueba 4.....	12
Figura 56	Resultados de inferencia Prueba 5.....	13

ÍNDICE DE TABLAS

Tabla 1 Clasificación de cultivos.....	10
Tabla 2 Morfología de la planta de maíz.....	11
Tabla 3 Malezas más comunes en el Ecuador	14
Tabla 4 Malezas en cultivos de maíz	15
Tabla 5 Maleza en cultivos de papa.....	16
Tabla 6 Recolección de datos.....	20
Tabla 7 Tecnologías clave en la evolución de la agricultura de precisión.....	21
Tabla 8 Tipo de drones para los cultivos	23
Tabla 9 Arquitecturas CNN.....	27
Tabla 10 Modelos de aprendizaje automáticos.....	28
Tabla 11 Versiones de Faster R-CNN.....	29
Tabla 12 Librerías en el desarrollo del proyecto	40
Tabla 13 Trabajos relacionados.....	41
Tabla 14 Herramientas de desarrollo	47
Tabla 15 Especificaciones técnicas de la Cámara	48
Tabla 16 Especificaciones técnicas del Dron Mavic2 Pro.....	49

Tabla 17 Tipos de maleza en cultivos de maíz y/o papa	51
Tabla 18 Condiciones de vuelo.....	53
Tabla 19 Fechas en las que se capturaron las imágenes en los terrenos elegidos	54
Tabla 20 Número de imágenes útiles resultantes.....	55
Tabla 21 Imágenes utilizables de todos los terrenos.....	- 2 -
Tabla 22 Estimación relacionada con el intervalo de días	- 3 -
Tabla 23 Lista de historias de usuario.....	- 4 -
Tabla 24 Procesar imagen de validación.....	- 4 -
Tabla 25 Resultados de validación.....	- 5 -
Tabla 26 Procesar imagen de validación.....	- 5 -
Tabla 27 Listar los resultados de análisis	- 5 -
Tabla 28 Eliminar registro de imagen.....	- 6 -
Tabla 29 Número de imágenes capturadas por fechas en los terrenos	- 10 -
Tabla 30 Colores por clase para las malezas	- 12 -
Tabla 31 Parámetros de red neuronal Faster R-CNN	- 16 -
Tabla 32 Librerías utilizadas en el modelo Faster R-CNN.....	- 17 -
Tabla 33 Experimentaciones de la Fase 1, sin balanceo de clases	1

Tabla 34 Experimentaciones de la Fase 2, con balanceo de clases	4
Tabla 35 Resultado de inferencia Prueba 1.	9
Tabla 36 Resultados de inferencia Prueba 2.	10
Tabla 37 Resultados de inferencia Prueba 3.	11
Tabla 38 Resultados de inferencia Prueba 4.	12
Tabla 39 Resultados de inferencia Prueba 5.	13
Tabla 40 Tiempos de detección de malezas	15
Tabla 41 Resultados Media y Varianza en tiempos de detección.....	17
Tabla 42 Prueba T-Student en tiempos de detección	17
Tabla 43 Correlación de Pearson en tiempos de detección	17
Tabla 44 Muestra de comparación del modelo vs expertos	18
Tabla 45 Resultados Media y Varianza de Dron + Faster R-CNN.....	20
Tabla 46 T-Student Dron + Faster R-CNN	20
Tabla 47 Correlación de Pearson Faster R-CNN.....	20
Tabla 48 T-Student en detección de papas con Faster R-CNN vs expertos. 21	
Tabla 49 Resultados Media y Varianza en detección de papas con Faster R-CNN vs expertos	23

Tabla 50 Prueba T-Student en detección de papas con Faster R-CNN vs expertos.....	23
Tabla 51 Resultado de correlación en detección de papas con Faster R-CNN vs expertos.....	24
Tabla 52 Comparación de modelo Faster R-CNN vs expertos.	24
Tabla 53 Resultados Media y Varianza	26
Tabla 54 Prueba T de Student	26
Tabla 55 Correlación de Pearson	27
Tabla 56 Niveles de afectación de los terrenos	28
Tabla 57 Comparación de resultados con modelos de predicción.....	30

RESUMEN

La identificación de malezas en la agricultura de precisión ha hecho uso de los avances tecnológicos. La capacidad de identificar malezas se considera crucial, aporta significativamente a los agricultores que se dedican a realizar controles en los cultivos, ya que al retener malezas junto a las plantas compiten por espacio y recursos, afectando el desarrollo de la planta y la calidad de sus frutos.

La iniciativa del proyecto es automatizar la identificación y cuantificación de malezas, por lo que se propone crear una aplicación web utilizando la arquitectura Faster R-CNN con Backbone VGG19. Las imágenes para su entrenamiento serán adquiridas mediante un dron. Esto ayudará a minimizar el tiempo que conlleva recorrer los terrenos propuestos.

En el primer capítulo se muestra el estudio literario de los diferentes tipos de cultivos, las características de las malezas, su dispersión y propuestas para mitigar basados en trabajos relacionados, también qué tipos de parámetros y técnicas se emplean para solucionar la propuesta de este proyecto. Se establecen comparaciones de algoritmos para responder a preguntas de investigación propuestas por el director del trabajo.

En el segundo capítulo se muestra la recolección de los datos y el preprocesamiento de estos, la elección de Faster R-CNN como algoritmo para el desarrollo del proyecto, también se muestra la construcción del aplicativo web y las diferentes experimentaciones realizadas para mejorar los resultados de predicción, además la intervención de la metodología en cascada e implementación de la norma ISO/IEC/IEEE 29148:2018 propuesta.

En el tercer capítulo se muestran los resultados obtenidos de los diferentes modelos experimentados, se hace énfasis en la comparación de las versiones de modelos experimentales, y mediante métricas de validación analizar su eficacia. Se emplea un análisis estadístico descriptivo para confirmar la mejora en la eficiencia del proceso de identificar y cuantificar malezas.

Finalmente, en la sección de discusión, se comparan los hallazgos obtenidos de nuestra investigación con otras propuestas de investigación relacionadas a la detección de objetos y el impacto de nuestra aplicación web en la gestión agrícola.

ASBSTRACT

Weed identification in precision agriculture has made use of technological advances. The ability to identify weeds is considered crucial, it contributes significantly to farmers who are dedicated to carry out controls on crops, since by retaining weeds next to the plants they compete for space and resources, affecting the development of the plant and the quality of its fruits.

The project initiative is to automate the identification and quantification of weeds, so it is proposed to create a web application using the Faster R-CNN architecture with Backbone VGG19. The images for training will be acquired using a drone. This will help to minimize the time involved in traversing the proposed terrains.

The first chapter shows the literature study of the different types of crops, the characteristics of weeds, their dispersion and proposals to mitigate based on related works, also what types of parameters and techniques are used to solve the proposal of this project. Comparisons of algorithms are established to answer research questions proposed by the director of the work.

The second chapter shows the data collection and preprocessing of these data, the choice of Faster R-CNN as the algorithm for the development of the project, also shows the construction of the web application and the different experiments carried out to improve the prediction results, in addition to the intervention of the cascade methodology and implementation of the proposed ISO/IEC/IEEE 29148:2018 standard.

The third chapter shows the results obtained from the different experimented models, emphasis is made on the comparison of the experimental model versions, and by means of validation metrics analyze their effectiveness. A descriptive statistical analysis is used to confirm the improvement in the efficiency of the process of identifying and quantifying weeds.

Finally, in the discussion section, the findings obtained from our research are compared with other research proposals related to object detection and the impact of our web application in agricultural management.

INTRODUCCIÓN

Tema

Identificación de malezas en cultivos de maíz y/o papa a través de imágenes de un dron, utilizando la arquitectura de la red neuronal Faster R-CNN.

Problema

Antecedentes

La agricultura es una actividad que se practica a nivel mundial dentro de diversos ecosistemas, con el fin de producir y ofertar alimentos para los seres vivos (humanos y animales). Requiere de recursos como suelo, agua, temperatura, luminosidad, materia orgánica, entre los principales elementos. Con estos recursos se pueden realizar diversos cultivos para los seres humanos y como alimento para los animales. En el proceso de producción los cultivos se ven amenazados por arvenses, plagas y enfermedades que afectan la productividad y el rendimiento en las cosechas (María Guadalupe de Los Santos Zavala, 2023).

Se ha determinado que en el mundo se pierden miles de toneladas de alimentos por causas diversas; entre las cuales las “malezas” constituyen un factor que incide en la pérdida de dichos alimentos. La presencia de malezas es inevitable sin embargo la concentración directa en los cultivos por agua, luz y nutrimentos, obstaculizan el crecimiento y desarrollo de estos, las malezas no afectan de la misma forma a todos los cultivos, su competencia por lo general se determinan en el estado de desarrollo inicial, por lo que los cultivos son más vulnerables al ataque de plagas e infecciones por enfermedades (Barbaś & Sawicka, 2020), también cabe recalcar que las malezas pueden obstaculizar las labores de cosecha y cultivo.

Situación Actual

Actualmente la innovación tecnológica ha provocado un cambio en el mundo, con ello varios países se han visto en la obligación de adaptarse a nuevas tecnologías con el fin de aumentar su línea de producción y conservar su calidad reduciendo

drásticamente los problemas convencionales de maleza, plagas y enfermedades (Alarcão Júnior & Nuñez, 2023). En el Ecuador contar con innovación tecnológica para la agricultura suele resultar costoso y no rentable debido a que existe mano de obra barata que permite ejecutar tareas y realizar labores manuales de sembrío, monitoreo, extracción y cosecha del producto, el problema en la mayoría de los sectores agrícola se debe a los recursos y a su falta de conocimiento en las áreas tecnológicas, así como en el mantenimiento de software, equipos mecánicos y eléctricos (Ekos, 2022).


Prospectiva

La elaboración de este proyecto tiene como finalidad reducir el tiempo que se necesita para identificar las malezas de manera convencional en cultivos de maíz y/o papas, los resultados obtenidos nos permitirá tomar decisiones para controlar las malezas sin dañar el cultivo y optimizar recursos.

Planteamiento del problema

La propuesta de investigación propone automatizar la detección de malezas en cultivos de la granja experimental "La Pradera", cede de la Universidad técnica del Norte con el fin de solucionar el problema en la identificación y cuantificación de malezas existentes en los campos de cultivos de maíz y/o papa, con la finalidad de minimizar tiempos, evitar su sobrecrecimiento y aplicar un adecuado tratamiento para combatir la maleza, así como se muestra en la Figura 1.

Figura 1
Árbol de problemas



Nota. *Elaboración propia.*

Objetivos

Objetivo General

Identificar y cuantificar malezas en los cultivos de maíz y/o papas a través de imágenes de un dron utilizando la arquitectura de red neuronal convolucional Faster R-CNN.

Objetivos Específicos

1. Elaborar un marco teórico sobre detección de tipos de maleza en cultivos maíz y/o papa utilizando redes neuronales convolucionales.
2. Desarrollar un aplicativo web que utilice la arquitectura Faster R-CNN para identificar y cuantificar malezas en los cultivos de maíz y/o papas basados en el estándar ISO/IEC/IEEE 29148:2018.
3. Validar los resultados de la propuesta utilizando métricas de inteligencia artificial y estadística descriptiva.

Alcance

El proyecto de investigación tiene como fin desarrollar un aplicativo web que identifique y cuantifique la maleza existente en los cultivos de maíz y/o papa, a través de la arquitectura Faster R-CNN en diferentes cultivos de la zona norte del país. Este proyecto servirá como aporte para futuras investigaciones referentes al estudio de la inteligencia artificial relacionada con redes convolucionales que estén basadas en la arquitectura Faster R-CNN. Este proyecto aplicará la metodología en cascada junto al estándar de la ISO/IEC/IEEE 29148:2018 (Llanque, 2022).


Para la construcción del marco teórico, se realizará una investigación de la literatura sobre redes neuronales convolucionales y su interacción con la agricultura a partir de datos bibliográficos de la Universidad Técnica de Norte y artículos científicos, que tendrá como objetivo responder las siguientes preguntas planteadas por el director del proyecto de tesis, PhD. Iván Danilo García Santillán; que se detallan a continuación.

1. ¿Qué drones y cámaras están usando para la tarea de detección automática de malas hierbas?
2. ¿Cuál es la altura y velocidad adecuada del dron para capturar imágenes y regiones de interés (ROIs) de alta resolución (px/cm)?
3. ¿Qué espacio de color y formato de imágenes resulta adecuado?
4. ¿En qué bandas de espectro electromagnético (visible, infrarrojo, ultravioleta) están trabajando)?
5. ¿Qué cultivos y tipos de malezas se están detectando y dónde?
6. ¿Qué conjunto de datos se encuentran disponibles públicamente para el entrenamiento de un modelo DL (Deep Learning)?
7. ¿Cómo crear y anotar un conjunto de datos propio?
8. ¿Qué arquitectura de CNN se usan para la detección automática de malas hierbas?
9. ¿Qué hardware específico o servicios en la nube resulta adecuado para entrenar modelos de DL?
10. ¿Qué métricas y gráficas se usan para validar el rendimiento de los modelos de DL?

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

Para el desarrollo del proyecto de investigación se entrenará una red neuronal convolucional empleando el lenguaje de programación Python con los framework Tensorflow y Keras. Para obtener las imágenes de los cultivos de maíz y/o papa, se contará con un dispositivo aéreo no tripulado “dron” DJI Mavic 2 Pro, el que recopilará al menos 50 imágenes como mínimo desde el aire específicamente en la región Sierra al norte del país, se evaluara un máximo de 3 tipos de maleza de los cultivos de maíz y/o papa, cabe mencionar que la etiqueta de imágenes se lo realizara manualmente utilizando una herramienta de software libre “Roboflow”, una vez obtenidas las imágenes de los cultivos se entrenará una red neuronal convolucional como primera etapa con la propuesta (RPN) que procesara las imágenes utilizando un extractor de características con regiones de interés (ROIs) mientras que en la segunda etapa se utilizara una red de detección para clasificar y localizar objetos “Malezas” en cada región de las imágenes (Microsoft, Microsoft, 2022), como se muestra en la Figura 2.

Figura 2
Arquitectura Faster R-CNN



Nota. *Towards Data Science* (Ananth, 2019)

Para la construcción del aplicativo web, se desarrollará con MERN Stack, el que consta de un entorno JavaScript de diferentes componentes de código abierto: MongoDB, Express, React y Node como se muestra en la Figura 3, contará con un dominio el cual estará almacenado en un Hosting compartido, finalmente los datos

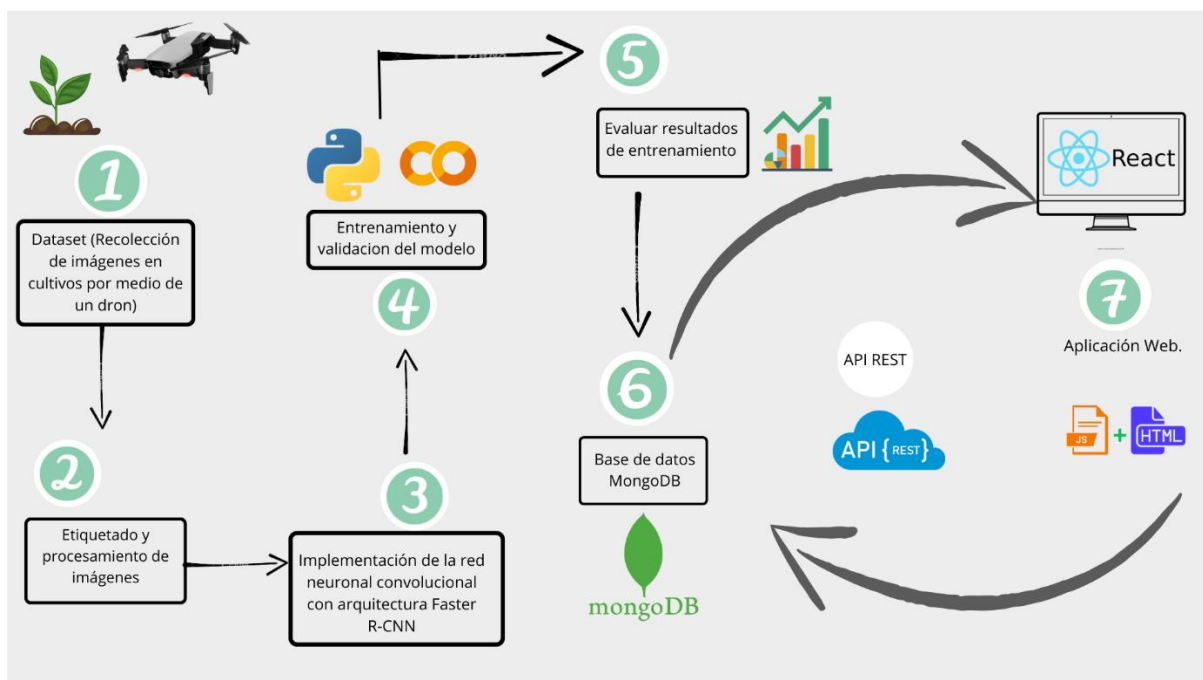
obtenidos en la investigación serán almacenados respectivamente en la base de datos que será consumida a través de una API REST, como se muestra en la Figura 4.

Figura 3
Tecnologías de desarrollo

Desarrollo	Tecnologías
Back-End	Python, Editor de Código (Visual Studio Code), Google Colab, MongoDB, Hosting compartido.
Front-End	Framework React, JavaScript, HTML.

Nota. *Elaboración propia.*

Figura 4
Arquitectura Faster R-CNN



Nota. *Elaboración propia.*

Metodología

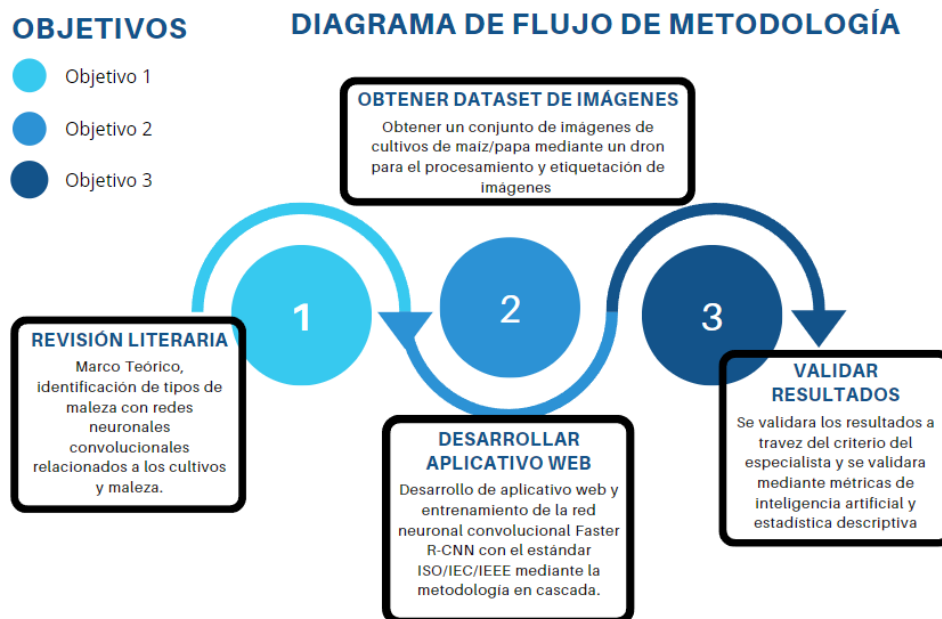
El proyecto de investigación se desarrollará en la región Sierra de la provincia de Imbabura específicamente en la sede de la Universidad Técnica del Norte “La Pradera” en los cultivos de maíz y/o papa.

Para el cumplimiento del primer objetivo en la presente propuesta de investigación, se llevará a cabo una revisión de la literatura referente a la detección de tipos de maleza en los cultivos de maíz y/o papas relacionadas con redes neuronales convolucionales, se utilizará trabajos bibliográficos de la universidad Técnica del Norte, así como fuentes bibliográficas publicados a nivel nacional como internacional.

Para el segundo objetivo se desarrollará un aplicativo web que utilice la arquitectura Faster R-CNN para identificar y cuantificar las malezas, dicho desarrollo se basará en el estándar ISO/IEC/IEEE 29148:2018, contará con la metodología basada en cascada ideal para describir los procesos del ciclo de vida en el desarrollo de software. Con la ayuda de un dron se recopilará un dataset de mínimo 50 imágenes de cultivos de maíz y/o papa de la granja “La Pradera” para lo cual se provee identificar como máximo 3 tipos de malezas en los cultivos en etapa inicial de crecimiento. La etiqueta de imágenes se realizará de forma manual utilizando una herramienta de software libre, posteriormente las imágenes serán entrenadas bajo la red convolucional Faster R-CNN.

Finalmente, para el tercer objetivo se validará los resultados a través del criterio de un especialista por lo que permitirá realizar ajustes necesarios, se usará métricas de inteligencia artificial y estadística descriptiva, como se presenta en la Figura 5.

Figura 5
Diagrama de flujo de metodología



Nota. Elaboración propia.

Justificación

El proyecto de investigación está orientado hacia los objetivos ODS (Objetivos de Desarrollo Sostenible) sugerido por la ONU y UNESCO: INDUSTRIA, INNOVACIÓN E INFRAESTRUCTURAS (ONU, 2015), el literal 9.5 plantea: “Aumentar la investigación científica y mejorar la capacidad tecnológica de los sectores industriales de todos los países, en particular los países en desarrollo, entre otras cosas fomentando la innovación y aumentando considerablemente, de aquí a 2030, el número de personas que trabajan en investigación y desarrollo por millón de habitantes y los gastos de los sectores público y privado en investigación y desarrollo”.(ONU, 2015)

Justificación Institucional. - El proyecto pretende ayudar en la identificación y cuantificación de maleza en los cultivos de maíz y/o papa de la región sierra del norte del país, por lo que ayudara a optimizar tiempos en la identificación de maleza y optar por un tratamiento adecuado para cada cultivo, así cumpliendo con la

expectativa de la institución en facilitar la organización de actividades académicas y científicas de los docentes y estudiantes (Almuiñas Rivero et al., 2021)

Justificación Social. - El proyecto de investigación contribuirá al desarrollo sostenible y al bienestar de la sociedad, esto incluye en la producción de alimentos seguros y nutritivos, la conservación al medio ambiente y al desarrollo económico rural será de gran aporte para garantizar la seguridad alimentaria a través de buenas decisiones para combatir las malezas adecuadamente sin contaminar y conservar la calidad del producto (Latindex Catálogo & Hugo Fernández-Bedoya, 2020).

Justificación Teórica. - Este proyecto de investigación contará con un marco teórico sobre los tipos de malezas y su identificación en los cultivos de maíz y/o papa, además contará con una línea investigación sobre redes neuronales convolucionales que beneficiará con información y conocimientos previos para la correcta elaboración del proyecto de titulación (IBM, 2021).

Justificación Tecnológica. - Este proyecto de investigación mantiene relevancia sobre la tecnología actual y herramientas de desarrollo de código abierto, que permita experimentar con teorías y modelos de inteligencia artificial, Machine Learning, Deep Learning, para identificar maleza en los cultivos de maíz y/o papa a través de imágenes de un dron utilizando la arquitectura de red neuronal convolucional Faster R-CNN con tecnologías MERN Stack (IBM, 2021).

CAPITULO I

Marco Teórico

1.1 Fundamentación teórica

1.1.1 Cultivos

Los cultivos agrícolas son plantas cultivadas con propósito específico para producir alimentos. Son esenciales en la agricultura y abarcan diversas especies vegetales, desde cereales hasta frutas, verduras, legumbres y hierbas medicinales. Los agricultores los seleccionan, plantan, manejan y cosechan de manera meticulosa para satisfacer las necesidades alimenticias, económicas y comerciales. En esencia, los cultivos son la base de la subsistencia y la economía en muchas comunidades (Bonilla Bolaños et al., 2019).

1.1.1.1 Clasificación de cultivos

La variedad de cultivos varía de acuerdo con los propósitos de producción agrícola, puede variar según los siguientes criterios, como el clima, el suelo, el ciclo del cultivo, la región geográfica y el propósito del cultivo (Jazmín, 2017), así como se muestra en la Tabla 1.

Tabla 1
Clasificación de cultivos

Clasificación de Cultivo	
Cultivos temporales	Son cultivos con tiempos de crecimiento menores a un año.
Cultivos permanentes	Son cultivos con tiempo de crecimiento mayores a un año.
Cultivos sucesivos	Son cultivos temporales que crecen más de una vez en la misma tierra y época del año.

Cultivos intercalados	Son cultivos temporales plantados entre las filas de otro cultivo.
Cultivos de cobertura	Son cultivos temporales que crecen de forma sistemática en un campo o lote.

Nota. Estudio del Efecto del Hidrogel en Diferentes Tipos de Cultivos (Jazmín, 2017).

1.1.1.2 Maíz

La producción de maíz en el Ecuador es aproximadamente de 500000 ha, siendo el único cultivo sembrado a nivel nacional, se destaca que la mayoría de los productores son pequeños agricultores con superficies de 1 a 5 ha (Edwin Stalin et al., 2021). El nombre científico del maíz es *Zea mays* L., su importancia se debe a que suministra elementos nutritivos al hombre y animales (Cardoza, 2006). La morfología del maíz es un aspecto fundamental para comprender su desarrollo y manejo agronómico, a continuación, se presentan algunas características morfológicas del maíz como se ve en la Tabla 2.

Tabla 2
Morfología de la planta de maíz

Morfología del maíz	
Sistema radicular	Son las raíces fibrosas, las raíces seminales nutren a la planta en sus primeras etapas, mientras que las raíces adventicias se desarrollan a partir de la corona. Su función es nutrir y anclar al suelo para proporcionar estabilidad.
Tallo	Es el soporte de la planta, mantiene forma cilíndrica y leñosa, compuesta por nudos y entrenudos, puede presentar pocas y muchas ramas. En promedio se observa hoja por cada 14 nudos.
Hojas	Presentan modificaciones de cotiledones, están constituidas por vaina, cuello y lamina, siendo esta última una banda delgada y angosta. Las hojas también pueden

tener un ápice agudo y mostrar diferencias en el envés y haz de la hoja.

Sistema Floral

Se encuentran en la parte basal de los entrenudos desarrollados de tallo. Estos ovarios, una vez polinizados se convierten en granos.

Nota. Evaluación de las características morfológicas y agronómicas del cultivo de maíz (Orihuela Martínez, 2009).

1.1.1.3 Papa

Su nombre científico es *Solanum tuberosum*, la papa es el principal ingreso económico para los agricultores de la zona andina, en Ecuador la mata de papa se desarrolla en terrenos irregulares con pendientes pronunciadas de hasta 45 grados y una altitud de 2400 a 3800 m s.n.m. Las provincias que destacan en producción son: Carchi, Pichincha, Tungurahua, Chimborazo y Cotopaxi (Pumisacho et al., 2002). Su importancia se debe a la gran demanda, para el año de 2018 aportó con el 9% del PIB nacional, para la provincia de Imbabura se obtuvo, 20041 toneladas métricas en venta (Salazar & César Muñoz, 2022).

La papa es una planta dicotiledónea, su crecimiento puede ser rastrero o erecto, formado por tallos gruesos y leñosos con entrenudos cortos, su morfología se ve afectada a factores ambientales como la temperatura, humedad, fertilidad del suelo entre otras (INIAP, 2002). Presenta una raíz axonomorfa con ramificaciones laterales, mientras que el caso del tubérculo-semilla son raíces adventicias que va en la base de cada brote, en el tallo procede de tubérculo-semilla conforma de estolones, pueden llegar a crecer hasta 1 metro, los tallos pueden desarrollar flores. Las hojas están formadas de folíolos ovales unidos al peciolo central, son de color verde con un aspecto velloso en su superficie. Las flores son de forma estrellada, de color blanco, rosa o morado, son las responsables de la reproducción y formación de semillas. El tubérculo es un tallo subterráneo modificado que almacena nutrientes, pueden variar en tamaño y color según la variedad, pueden ser de pulpa blanca, amarilla o morada (Inostroza F. et al., 2009).

1.1.2 Malezas

La maleza o malas hierbas son plantas indeseables que interfieren de manera negativa con los cultivos, restan a las plantas agua, nutrientes, luz, entorpecen el crecimiento normal de los cultivos provocando pérdidas, para Moreno (2021), Las malezas o malas hierbas son aquellas plantas indeseables que compiten con los cultivos por nutrientes esenciales para desarrollarse, por tanto, es necesario realizar controles adecuados que permitan disminuir su infestación". Podemos decir que las malezas provocan pérdidas en los cultivos, generan más costos de producción, es necesario su control y erradicación para generar cultivos de calidad.

1.1.2.1 Características

La maleza son plantas que se caracterizan por su alto nivel de supervivencia en cualquier tipo de suelo, son resistentes a las medidas de control (fumigación, herbicidas, plaguicidas, entre otros), depredan los nutrientes, agua y luz que sirven para los cultivos, además presentan un crecimiento agresivo.

En general, la gran mayoría de las características de una planta que contribuyen a una alta capacidad de colonización y competitividad se corresponden con las exhibidas por las malezas, y en un grado mucho mayor que el exhibido por las especies cultivadas (Leguizamón, 2000).

Se enfatiza que la principal característica es la depredación de recurso que sirven para los cultivos, entorpeciendo el correcto crecimiento de las plantas, también la maleza no tiene un uso alimenticio o valor económico, ZORZOLI (2019).

1.1.2.2 Especies de malezas más comunes en el Ecuador

En Ecuador la diversidad de malezas afecta considerablemente a la productividad agrícola, por lo que representa un gran desafío identificar y controlar su impacto (Jaramillo-Díaz N. Y Quizhpe-Coronel, 2019), a continuación, se detalla las malezas más comunes que existe en Ecuador como se muestra en la Tabla 3.

Tabla 3*Malezas más comunes en el Ecuador*

Nombre científico	Nombre común	Principales Provincias
Chenopodium murale L.	Palitaria.	Loja, Imbabura y Pichincha.
Dysphania ambrosioides.	Paico.	Azuay, Cañar, Carchi, Chimborazo, Cotopaxi.
Sisymbrium irio.	Moztazilla.	Pichincha, Imbabura, Carchi, Chimborazo, Cotopaxi.
Ageratum conyzoides L.	Hierva de chivo.	Azuay, Cañar, Carchi, Chimborazo, Tungurahua, Pichincha, Imbabura.
Baccharis latifolia.	Chilca.	Azuay, Bolívar, Cañar, Carchi, Chimborazo, Cotopaxi.
Bidens pilosa L.	Guichingue.	Loja, Azuay, Tungurahua, Pichincha, Galápagos, Esmeraldas.
Galinsoga quadriradiata.	Pacunga.	Cañar, Chimborazo, Tungurahua, Imbabura.
Senecio vulgaris L.	Lechuguilla.	Loja, Imbabura y Pichincha.
Taraxacum officinale	Diente de león.	Loja, Azuay, Cotopaxi, Pichincha, Imbabura y Carchi.
Drymaria cordata.	Golondrina.	Loja, Tungurahua, Cotopaxi, Pichincha, Imbabura.
Rumex obtusifolius L.	Lengua de vaca.	Loja, Azuay, Cañar, Carchi, Chimborazo, Imbabura, Manabí, Napo, Pastaza, Pichincha y Tungurahua.
Melilotus albus Medik.	Alfalfilla blanca.	Loja, Azuay, Carchi, Bolívar, Imbabura, Tungurahua, Pichincha
Melilotus indicus.	Alfalfilla amarilla.	Azuay, Chimborazo, Imbabura, Loja, Pichincha y Tungurahua.
Juncus microcephalus Kunth.	Esparto.	Azuay, Cañar, Tungurahua, Pichincha, Imbabura, Carchi, Morona Santiago, Napo
Pennisetum clandestinum.	Kikuyo.	Loja, Azuay, Cañar, Carchi, Chimborazo, Imbabura, Manabí, Napo, Pastaza, Pichincha y Tungurahua.

Nota. Arvenses asociadas a cultivos y pastizales del Ecuador (Jaramillo-Díaz N. Y Quizhpe-Coronel, 2019).

1.1.2.3 Malezas en cultivos de maíz en el Ecuador

Las malezas en cultivos de maíz son consideradas un problema debido a su competencia de nutrientes y resistencia agroquímica, en la Tabla 4 presentamos las malezas más destacadas en cultivos de maíz.

Tabla 4
Malezas en cultivos de maíz

Tipo de Hoja	Nombre científico	Nombre común
Ancha.	Galinsopa spp.	Abuelaquihua.
Ancha.	Spergula arvensis.	Alfarillo.
Ancha.	Escleranthus anus.	Alpatezera.
Ancha.	Lupinus pubescens.	Ashpachocho.
Ancha.	Chenopodium spp.	Ashpaquínoa.
Ancha.	Amaranthus spp.	Bledo.
Ancha.	Silene gallica.	Forastera.
Ancha.	Veronica pérsica.	Golondrina.
Ancha.	Plantago lanceolata	Llantén.
Ancha.	Rumex crispus	Pacta.
Ancha.	Bidens humilis.	Pacunga.
Ancha.	Stellaria media.	Pajarera.
Ancha.	Ipomea spp.	Porotillo.
Ancha.	Raphanus raphanistrum.	Rábano.
Ancha.	Medicago hispida.	Trebol carretón.
Ancha.	Lepidium bipinnatifidum.	Tzetzera
Ancha.	Brassica campestris.	Nabo.
Delgada	Cynodon dactylon.	Cabrestillo.
Delgada	Cyperus spp.	Coquito.
Delgada	Poa annua.	Poa.
Delgada	Grammineace.	Saraquihua.
Delgada	Pennisetum clandestinum.	Kikuyo.

Nota. Control de malezas de la sierra (Francisco Gabela & Julio Cárdenas, 1979).

1.1.2.4 Malezas en cultivos de papa en el Ecuador

Las malezas que destacan en cultivos de papas en Ecuador se detallan en la siguiente Tabla 5.

Tabla 5
Maleza en cultivos de papa

Tipo de Hoja	Nombre científico	Nombre común
Ancha.	<i>Spergula arvensis</i> L.	Alfarillo.
Ancha.	<i>Scleranthus annuus</i> L.	Alpatereza.
Ancha.	<i>Amaranthus</i> spp.	Bledo.
Ancha.	<i>Polygonum aviculare</i> L.	Cien nudos.
Ancha.	<i>Polygonum nepalense</i> .	Corazón herido (oreja del diablo).
Ancha.	<i>Polygonum segesum</i> H.B.K.	Duraznillo.
Ancha.	<i>Silene gallica</i> L.	Forastera.
Ancha.	<i>Galinsoga ciliata</i> (Raf.) Blade.	Hierba de cuy.
Ancha.	<i>Gflinsonga parviflora</i> Cav.	Sin especificar.
Ancha.	<i>Plansago lanceolaria</i> L.	Llantén.
Ancha.	<i>Malvastrum peruvianum</i> (L.) Gray.	Malva blanca.
Ancha.	<i>Malva silvestris</i> L.	Malva morada.
Ancha.	<i>Sinapsis nigra</i> L.	Mostaza.
Ancha.	<i>Brassica napus</i> L.	Nabo.
Ancha.	<i>Rumex crispus</i> L.	Pacta.
Ancha.	<i>Rumex acerosella</i> L.	Pactilia.
Ancha.	<i>Stellaria media</i> (L.) Cyrill.	Pajarera.
Ancha.	<i>Lepidium chinichicara</i> .	Quimbilla.
Ancha.	<i>Raphanus raphanistrum</i> L.	Rábano.
Ancha.	<i>Taraxacum officinale</i> Weber in Wiggers.	Taraxaco.
Ancha.	<i>Lepidium bipinnatifidum</i> Desv.	Tze-Tzera.
Ancha.	<i>Veronica persica</i> Por.	Verónica.
Delgada	Gramínea	Cabrestillo.

Delgada

Pennisetum clandestinum Hochst ex Kikuyo.
Chiov.

Nota. Manual de control de malezas en papa (Cárdenas Granja, 1987).

1.1.3 Dispersión de malezas

Como se lo menciono anteriormente una de las características de las malezas es su rápida propagación esto se debe a su capacidad de producir gran cantidad de semillas para su supervivencia, esta peculiaridad provoca que su control y erradicación de los cultivos sea compleja, es imprescindible que se genere estrategias para no perder de vista el rápido crecimiento de la maleza, cuidando de esta manera los cultivos (Moncayo Bajaña, 2024).

1.1.3.1 Dispersión con acción del hombre

1. **Máquinas y equipos:** La maquinaria es el principal medio de propagación, son portadoras de semillas o partes de malezas trasportadas a diferentes cultivos como se muestra en la Figura 6 (Rubione & Wojszko, 2021).

Figura 6

Dispersión de maleza con maquinaria



Nota. Manejo de malezas en la agricultura orgánica (Rosales, 2007).

2. **Mezcla de semillas:** La semilla proviene de zonas con malezas resistentes y probablemente se mezclen en los campos, llegando a que germinen y comience una nueva infestación en el cultivo, como se muestra en la Figura 7 (Rubione & Wojszko, 2021).

Figura 7

Dispersión por mezcla de semillas



Nota. Propagación de malezas (Rubione & Wojszko, 2021).

3. **Ganadería y alimento de ganado:** Se encuentra en el estiércol, es un mecanismo de propagación resistente, pueden sobrevivir en el tracto digestivo de los animales y germinar después de que el animal defeca, como se muestra en la Figura 8 (Rubione & Wojszko, 2021).

Figura 8

Dispersión por alimentación de ganado



Nota. Alimento para el ganado (MAG, 2024).

1.1.3.2 Dispersión sin acción del hombre

4. **Dispersión por el viento:** La propagación ocurre cuando la planta termina su ciclo, se secan y son arrastradas por el viento a cortas y largas distancias (Rubione & Wojszko, 2021).
5. **Dispersión de otras especies:** Es un mecanismo de propagación transportados a través de animales que son nómadas conformadas principalmente por aves y roedores, la semilla de maleza puede resistir al tracto

intestinal y cambios bruscos de temperatura, como se muestra en la Figura 9 (Saska, Werf, Vries, & Westerman, 2008).

Figura 9

Dispersión de otras especies



Nota. Alimentación de palomas (Katuwal et al., 2022).

1.1.4 Control de malezas

Para el control de malezas debe realizarse de manera integral, combinando diferentes métodos para alcanzar un control sostenible, alguno de los métodos más utilizados dentro de la agricultura para el control de maleza son los siguientes:

1. **Métodos culturales:** Es un conjunto de prácticas que se basan en el manejo de agroecosistema para prevenir el crecimiento y desarrollo de las malezas, este método es sostenible y amigable con el medio ambiente (González & Franco, 2000).
2. **Métodos químicos:** Se basa en la aplicación de herbicidas de forma selectiva para eliminar y controlar el desarrollo de malezas en los cultivos, este método se utiliza contra malezas que tienen mayor resistencia y características especiales (Suquilanda, 2019).
3. **Métodos biológicos:** Consiste en la utilización de organismos vivos, como insectos hongos, bacterias o nematodos para eliminar el crecimiento de malezas en los cultivos, se basa en los principios de la ecología y la interacción entre diferentes especies y mantener un equilibrio natural y sostenible, este método permite mayor control para evitar daños colaterales a otras plantas (Suquilanda, 2019).

1.2 Agricultura de precisión

La agricultura es la actividad humana que tiene como objetivo producir alimentos orgánicos, a través de distintos procedimientos que tratan la tierra para la siembra, cultivo y cosecha, (Sarandón, 2020) menciona que la agricultura consiste en la modificación de ecosistemas naturales y transformarlos en agroecosistemas. Por lo que la agricultura de precisión utiliza tecnología avanzada como sistemas de información geográficos (SIG) y sistemas de posicionamiento (GPS), para encontrar soluciones, herramientas y prácticas modernas (ISPAG, 2019).

1.2.1 Características

La agricultura de precisión ha permitido la recopilación, análisis y aplicación de la información para mejorar la gestión más precisa en la producción de cultivos, el desarrollo y la adopción de prácticas y tecnologías, se pueden dividir en tres etapas principales (Ramos Hernández et al., 2021).

1. **Recolección e ingreso de datos:** En esta etapa radica en recopilar datos precios y relevantes sobre el estado de los cultivos y el suelo, se logra con las siguientes herramientas tecnológicas como se detalla en la Tabla 6 (Brenes et al., 2020).

Tabla 6
Recolección de datos

Recolección de datos	
Sensores remotos	Satélites, drones y cámaras aéreas
Sensores de campo	Medidores de humedad, sondas de suelo, Conductividad eléctrica del suelo y radiación solar.
Sensores en maquinaria	Maquinaria agrícola en general: tractores, cosechadoras, etc.

Nota. (Brenes et al., 2020)

2. **Interpretación de la información:** Los datos obtenidos son analizados y procesados, se usan de herramientas tecnológicas, estadísticas entre otros

softwares, dicha información permite identificar problemas específicos en el terreno (Felipe & González, 2022).

3. **Aplicación diferencial de insumos:** Finalmente analizados los datos, se puede proponer distintas soluciones para solucionar el conflicto que existe en el terreno, se aplican métodos de control de malezas convencionales, químicos o biológicos (Felipe & González, 2022).

A lo largo de los años ha evolucionado las tecnologías para el área agrícola, las cinco tecnologías clave que ha impulsado la agricultura de precisión son las siguientes que se muestran en la Tabla 7.

Tabla 7

Tecnologías clave en la evolución de la agricultura de precisión.

Tecnologías clave en AP	
GPS	Permite la localización precisa en el campo
SIG	Facilita la integración y análisis de datos espaciales
Percepción remota	Proporciona información detallada sobre los cultivos
Tecnologías de dosis variable	Permite la aplicación precisa de insumos
Análisis de datos georreferenciados	Ayuda a identificar patrones en la producción agrícola

Nota. (Bongiovanni et al., 2006).

1.2.2 Sistemas de control

Los sistemas de control se caracterizan por una serie de lineamientos y procedimientos para influir en el funcionamiento de los procesos de producción, en los cultivos o la agricultura se utiliza estos mecanismos para optimizar recursos, potenciar cultivos y sus cosechas (Viera-Arroyo et al., 2020). Su finalidad es ahorrar en costos de personal y de recursos energéticos.

1.2.3 Aplicación en la agricultura

La aplicación de la tecnología en la agricultura tiene ventajas, permite obtener información completa sobre el estado de los cultivos, controlar plagas, maleza o

enfermedades de las plantas, (Pino et al., 2019) menciona que, dentro de la agricultura, requiere información experimentada para cuantificar y toma decisiones al momento, siembra, fertilización, riego y cosecha. La utilización de estas nuevas tecnologías en las técnicas de siembra optimiza los procesos de cultivo, siembra y cosecha.

Como parte de estas nuevas tecnologías se utiliza drones para el mapeo de las áreas de cultivo lo que permite obtener datos que posteriormente serán utilizados por los agricultores para la eliminación de plagas, fumigación, fortaleciendo a las plantas, entre otras acciones, los drones poseen sensores capaces de identificar los problemas antes mencionados (Brenes et al., 2020).

Entre las aplicaciones más generalizadas de los drones en la agricultura se encuentran: manejo eficiente del agua, tratamientos localizados de herbicidas, el uso adecuado de fertilizantes, detección temprana de enfermedades y plagas en cultivos, supervisión de áreas fumigadas, indicadores de calidad en cultivos, generación de inventarios de cultivos, control de subvenciones agrarias, conteo de plantas y peritación de cultivos (León Rodríguez et al., 2023)

Los drones permiten un gran abanico de posibilidades para el agro, fortalece los procesos de cultivo y siembra, abarata costos, posibilita la detección de plagas y maleza, se reinventa la manera de administrar los campos de cultivo, es una herramienta que beneficia a los agricultores (Pino et al., 2019)

1.2.4 Dron

Es un vehículo aéreo no tripulado, autónomo, (VANT por sus siglas en español). Manejados mediante un control remoto (tipo joystick), ayudado por aplicaciones para smartphones o tablets, equipados con cámaras y sensores para tomar fotos y videos (León Rodríguez et al., 2023).

Además, para lograr que los sistemas agrícolas funcionen correctamente se apoyan en las nuevas tecnologías, como por ejemplo la utilización de drones para la obtención de datos y sensores ópticos hiperespectrales que capturen imágenes en RGB (rojo, verde, azul) de alta resolución (Del Cerro et al., 2021), así permite a los

agricultores llevar un control y tomar las medidas necesarias para mejorar los cultivos (Viera-Arroyo et al., 2020).

1.2.4.1 Tipos de drones para cultivos

Los drones son considerados una herramienta innovadora para el control y monitoreo de plantaciones, que ofrecen varios tipos de drones según la utilidad necesaria como se muestra en la Tabla 8 (Vargas-Ramírez & Paneque-Gálvez, 2019).

Tabla 8

Tipo de drones para los cultivos

Drones ganaderos	Permiten obtener información de los procesos ganaderos, además del porcentaje de carbono en los pastizales.
Drones de agricultura de precisión	Están equipados con sensores especiales que permiten recabar información como: mapeo, requerimientos de los cultivos, estado del ganado y cosecha, conteo de plantas.
Drones para fumigar o pulverizar	Este tipo de drones permiten llegar a áreas de difícil acceso para realizar procesos de fumigación, son eficientes porque se utilizan las cantidades exactas de plaguicidas y herbicidas bajando el riesgo de envenenamiento por estos químicos.
Drones para fertilizar	Permiten cubrir las necesidades de las plantas de forma precisa, aumentado el rendimiento, productividad y la calidad de los cultivos.
Drones para sembrar	Permiten sembrar de una manera rápida, pueden sembrar semillas de manera autónoma de manera programada por un territorio específico, realizan el trabajo de 10 personas.

Nota. Revista ingeniería agrícola (Agrícola, 2021) .

1.2.4.2 Condiciones de vuelo

Los drones han sido utilizados para el monitoreo en la agricultura de precisión, tiene la capacidad de sobrevolar espacios aéreos con parámetros específicos de manera precisa, usualmente los drones sobrevuelan alturas a partir del ciclo de la planta, es decir, si la planta está en sus etapas de crecimiento se puede parametrizar desde 1 metro de altura y así sucesivamente, todo esto dependerá del ciclo de la planta, en los desplazamientos de plantaciones su rango alcanza hasta los 30 metros de altura (Martins et al., 2023). Para realizar detecciones de plantas pequeñas (plantas de cultivos, malezas) se recomienda una altura de vuelo menor para obtener mejor detalle de todas las plantas involucradas y preservar la calidad de la imagen (Xie et al., 2022).

Para la velocidad de desplazamiento en los campos de cultivos, es recomendable realizar varias pruebas de vuelo para evaluar la captura de datos, la calidad de imagen entre otros factores, mediante una experimentación de buscar la relación que existe entre la velocidad del dron y el número de vuelos en lectura de etiquetas se determinó que el desplazamiento del dron horizontalmente de 2,2; 1,7 y 1,1 metros por segundo, obtuvieron resultados favorables tomando en cuenta que no afecto a la cantidad de etiquetas escaneadas (Quino et al., 2021).

1.3 Inteligencia artificial

Las redes neuronales artificiales (RNA) tratan de imitar las funciones de las redes neuronales biológicas humanas, esto significa que su comportamiento se parece a las funciones cerebrales de un ser humano (Universidad de la Frontera Chile, 2013), La red neuronal es un modelo computacional inspirado en las neuronas del ser humano, por tanto, se crea solucionar problemáticas complejas y tener la capacidad de aprender y proponer criterios a problemáticas en diferentes trabajos como se muestra en la Figura 10.

Figura 10

Aplicaciones de la inteligencia artificial




Nota. Ejemplos donde podría utilizarse la inteligencia artificial (Rouhiainen, 2018).

1.3.1 Redes neuronales convolucionales

Es el subconjunto de aprendizaje automático y son la base de los algoritmos de aprendizaje profundo, están construidas por nodos, poseen una capa de entrada, una o más capas ocultas y una capa de salida, cada nodo conecta con otro nodo, está conformado por un peso y un umbral, si la salida de un nodo excede un cierto umbral, el nodo se activa y enviará datos a la siguiente capa de la red, de lo contrario los datos no se envían. Existen varios tipos de redes neuronales que se pueden utilizar para diferentes casos de uso, las más recurrentes se usan en el procesamiento de lenguaje natural, reconocimiento de voz, mientras que las redes neuronales convolucionales se usan en tareas de clasificación y visión por computadora, como se muestra en la Figura 11 (IBM, 2024).

Figura 11
Red neuronal convolucional



Nota. Extracción de funciones: reconocimiento facial (Kontsev, 2021).

Actualmente, las CNN proporcionan un enfoque más escalable para tareas de clasificación de imágenes y reconocimiento de objetos mediante el uso de principios de álgebra lineal, estas redes pueden ser hoy computacionalmente intensivas y requieren unidades de procesamiento de gráficos (GPU) para entrenar los modelos de aprendizaje automático (IBM, 2024).

1.3.2 Modelos de aprendizaje automático

Son sistemas que se han creado para reconocer y aprender de forma automática ciertos patrones, crea algoritmos que posteriormente serán utilizados para obtener información de esos datos (Microsoft Learn, 2024).

En la agricultura de precisión la detección de malezas gestiona aspectos críticos para garantizar la productividad y sostenibilidad de cultivos, en las diferentes redes neuronales existentes se puede aprovechar la capacidad del aprendizaje profundo para extraer características de imágenes permitiendo la identificación precisa y eficiente de plantas y malezas, las CNN cuenta con diversos tipos de arquitecturas asociados con la detección de malezas como se muestra en la Tabla 9.

Tabla 9
Arquitecturas CNN

Yolo (You Only Look)	Su característica principal es la detección de objetos en tiempo real de alta precisión, su aplicación puede ser utilizada para vigilancia, conducción autónoma y detección de objetos en video.
Fast R-CNN	Su característica principal se basa en identificar la región de propuesta y clasificarlas, es capaz de detectar múltiples objetos de diferentes clases en una sola pasada, hoy se puede aplicar para vigilancia y seguridad, automatización industrial, reconocimiento de objetos.
Faster R-CNN	Su característica principal es la detección de objetos mediante la generación de regiones de interés, esto mejora la eficiencia y la precisión, esta arquitectura nos permite optimizar recursos y facilita la escalabilidad.
Mask R-CNN	Es una red profunda diseñada para la detección de objetos y segmentación de imágenes, hoy no solo puede identificar los objetos en una imagen, sino segmentar cada objeto individualmente, posee flexibilidad y precisión, sus aplicaciones se utiliza en reconocimiento de objetos en imágenes médicas, análisis de vídeo y reconocimiento y clasificación de objetos en imágenes.
SSD	Su característica principal es la detección de objetos en tiempo real, detecta con alta precisión y rapidez en una sola pasada, posee variedad de tamaños de filtros para detectar diferentes escalas, su aplicación puede ser utilizada en detección de peatones y vehículos, seguimiento de objetos en tiempo real, detección en defectos de líneas, realidad aumentada y virtual (Sun et al., 2021).

Nota. Revisión del aprendizaje profundo (Alzubaidi et al., 2021)

A continuación, podemos ver algunos de los modelos de aprendizaje automático más utilizados en la detección de objetos (Maciej Serda et al., 2021), como se muestra en la Tabla 10.

Tabla 10
Modelos de aprendizaje automáticos

Aprendizaje Supervisado	Representa una técnica de aprendizaje en la que se entrena un modelo utilizando un conjunto de datos, durante el entrenamiento el modelo se ajusta mediante parámetros para aprender una función, consta de presencia de datos etiquetados por lo que permite al modelo aprender y realizar comparaciones de predicciones con salidas reales, cuando se haya finalizado se puede realizar predicciones precisas sobre la nueva instancia de datos que no formaron parte del conjunto de entrenamiento original (van Engelen & Hoos, 2020).
Aprendizaje no supervisado	Representa una técnica donde el modelo se entrena sin etiquetas de salida, su característica principal es encontrar patrones, estructuras o relaciones intrínsecas en los datos mediante técnicas de agrupamiento, hoy se utiliza en aplicaciones como segmentación de clientes análisis de redes sociales y detección de fraudes (Glielmo et al., 2021).

Nota. Técnicas de aprendizaje automático (Maciej Serda et al., 2021).

1.3.3 Arquitectura Faster R-CNN

Se compone de la familia de redes convolucionales basadas en regiones R-CNN, permite significativamente la precisión y la velocidad de tareas en detección de objetos, comparte características convolucionales hoy de una imagen completa con la red de detección lo que permite propuestas de regiones sin mayor esfuerzo (Adejojo, 2023).

La arquitectura Faster R-CNN es una red neuronal diseñada para la detección y localización precisa de objetos en imágenes, se utiliza una combinación de técnicas

de convolución y región proposal para lograr una detección eficiente y precisa, Hernández (2020) sostiene que “El modelo Fast R-CNN es una evolución del modelo R-CNN, que trata de solucionar algunos de los problemas antes indicados y que eran la causa de su alto tiempo de entrenamiento y detección de objetos” (Romero, 2022), esto significa mejora los sistemas de R-CNN y Fast R-CNN, mejorando significativamente su velocidad y precisión en la detección de objetos.

Entre las versiones de Faster R-CNN que se ha implementado para mejorar su rendimiento tenemos las siguientes, como se muestra en la Tabla 11.

Tabla 11
Versiones de Faster R-CNN

Versiones de Modelos		
Versión	Año	Desarrollador
Faster R-CNN con VGG-16	2015	Shaoqing Ren, Kaiming He, Ross B. Girshick y Jian Sun.
Faster R-CNN con VGG-19	-	Shaoqing Ren, Kaiming He, Ross B. Girshick y Jian Sun.

Nota. Elaboración propia.

El comienzo de la arquitectura Faster R-CNN con VGG-16 fue presentada por (Ren et al., 2015), ellos combinaron el RPN y Fast R-CNN en una sola red, para el modelo VGG-16 presento una velocidad de fotogramas de 5 fps en una GPU, a comparación de ILSVRC y COCO 2015, Faster R-CNN obtiene mejores resultados en varias pruebas (Omiotek & Zhunisova, 2024).

(Nawaz et al., 2023) explica que el Backbone VGG-19 tiene 19 capas con pesos (16 capas convolucionales y 3 capas conectadas), aprovecha la capacidad de esta red para extraer características complejas en clasificación de enfermedades de plantas, presentando mejor precisión y utilizando más recursos.

La arquitectura Faster R-CNN se compone de tres componentes principales:

1.3.4 Backbone ConvNet


Esta parte de la red se encarga de extraer características de alto nivel de la imagen de entrada. Puede utilizar redes convolucionales preentrenadas como VGG16, VGG19 o ResNet como base, capturando características generales y abstractas de la imagen (Omiotek & Zhunissova, 2024)

En el artículo de (Hindarto et al., 2023) menciona la comparación de la eficacia en la clasificación de insectos sobre plantas en modelos VGG16 y VGG19, dentro de la experimentación se determinó que el modelo VGG19 logro una mejor precisión y un valor de perdida considerable, ya que mitigo de manera eficaz los errores de predicción durante la fase de entrenamiento, por lo que concluye que el modelo VGG19 demuestra estabilidad de precisión en la clasificación en patrones complejos de datos y demuestra valores de perdidas bajas.

1.3.4.1 Red preentrenada VGG 19

Hoy la red VGG19 hoy se encarga de extraer características de la imagen a través de capas convolucionales y de Pooling, mientras que el RPN se encarga de proponer regiones candidatas que puedan contener objetos de interés. El VGG19 se compone de 16 capas convolucionales y 3 capas totalmente conectadas como se muestra en la Figura 12 (Sahoo et al., 2024), estas capas tienen filtros de tamaño de $3 * 3$ y utilizan la función de activación ReLU para incorporar la no linealidad en la red, esta red sí caracteriza por ser profunda, al combinar VGG19 con el módulo R-CNN que incluye una región proporsal network (RPN) y región based CNN, permite de esta manera aprender características complejas en conjunto de datos de imágenes de manera precisa y eficiente (Baussard et al., 2020).

Figura 12
Detalle de la estructura VGG19




Nota. (Das et al., 2019).

1.3.5 Region Proposal Network (RPN)

El RPN examina las características extraídas por el Backbone ConvNet y genera propuestas de regiones que tienen una alta probabilidad de contener objetos. Estas propuestas se generan utilizando anclas (anchors) que son regiones de diferentes escalas y aspectos en la imagen, como se muestra en la Figura 13. El RPN clasifica las propuestas como objeto o fondo y ajusta las coordenadas de las regiones propuestas para mejorar la precisión de detección (Yelisetty, 2020).

Figura 13
RPN Y ROI Pooling




Nota. Understanding Faster R-CNN (Yelisetty, 2020).

1.3.6 Red de Clasificación y Regresión

En esta etapa, las propuestas generadas por el RPN se utilizan para realizar la clasificación y refinamiento de la localización de los objetos (Menacho, 2014). Las propuestas se pasan a través de una red de clasificación para determinar la clase a la que pertenecen, esta red se basa en una arquitectura convolucional Resnet o VGG, con datos preentrenados como ImageNet, se utiliza una salida Softmax que asigna probabilidades a cada clase, la y clase con la probabilidad más alta se dice que es la predicción final para esa región, mientras que en la regresión se realiza para ajustar las coordenadas de las cajas delimitadoras que rodean los objetos detectados, la salida de esta red consiste en cambios en la posición de la caja delimitadora en desplazamiento y escalado, como se muestra en la Figura 14 (Karmarkar, 2018).

Figura 14
Region Proposal Network



Nota.(Yelisetty, 2020).

Ventajas de la arquitectura Faster R-CNN

1. La arquitectura Faster R-CNN es la evolución de sus arquitecturas, que ha demostrado ser altamente preciso en detectar objetos, su estructura nos permite obtener una precisión óptima en múltiples objetos y la asignación de clases correctas (Jiehua Cai, 2023).
2. La implementación de la arquitectura funciona de manera eficiente y beneficia en cuanto en recursos de hardware, por lo que es ideal para aplicaciones que contengan grandes cantidades de datos y aplicaciones en tiempo real (Microsoft, Object detection using Faster R-CNN, 2022).

Desventajas de la arquitectura Faster R-CNN

1. Complejidad en módulos de generación de propuestas (RPN) para proponer regiones, aumentando la complejidad del modelo (Karmarkar, 2020).

2. Requiere grandes cantidades de datos para un entrenamiento efectivo, se puede considerar la recopilación y etiquetado de datos pueden ser costosos y laborioso (Xiang, Lv, Guo, Wang, & El Saddik, 2018)

Cuando aplicar la arquitectura Faster R-CNN

Las redes neuronales profundas se utilizan cada vez más para resolver problemas de visión por computadora, como la identificación y el seguimiento de personas a través de redes de cámaras. Se realiza una revisión de los principales algoritmos de seguimiento y detección de objetivos basados en redes profundas que permitirán la formación de una arquitectura para sistemas inteligentes de videovigilancia. Los algoritmos de una sola etapa son significativamente más rápidos que los algoritmos basados en propuestas regionales, destacándose SSD, y los algoritmos de seguimiento fuera de línea tienen mayor precisión en comparación con los algoritmos en línea, destacando a DeepSort como el más efectivo (Sánchez, 2020).

Aplicaciones de la arquitectura Faster R-CNN

Detección de caries: Mediante la obtención de imágenes y placas dentales, que permita predecir el número y la ubicación de lesiones de caries basándose en películas periapicales (Yuang Zhu, 2022).

Análisis médicos: A través de datos obtenidos mediante pruebas de análisis de sangre, obtener valores de precisión que permitan evidenciar la precisión del diagnóstico, por lo que permite dar una respuesta a los medicamentos que necesita el paciente (Fanyi Zeng, 2023).

Detección de vehículos: Se realiza vigilancia inteligente cuando se trata de escenarios y seguimiento a gran escala con el fin de mejorar características de vehículos en movimiento (Xiang, Lv, Guo, Wang, & El Saddik, 2018).

Para la implementación de la red neuronal Faster R-CNN, se consideró los siguientes parámetros e hiperparámetros, como se muestra en la Tabla 12.

1.4 Metodología de desarrollo

La metodología de desarrollo de software es el marco de trabajo que proporciona las estructuras y procesos utilizadas para el desarrollo de sistemas de software. Los procesos involucrados abarcan escenarios desde la definición de requerimientos hasta el mantenimiento de proyectos de software (Morales-Carrillo et al., 2022).

Una de las características principales es entender las necesidades del proyecto con el objetivo hoy que nuestro entorno sea una ventaja competitiva y aumentar la productividad y saber las necesidades del cliente en el menor tiempo posible, las metodologías representan una solución a los problemas que requieren una respuesta inmediata, la metodología tradicional hoy tiene un enfoque estructurado y secuencial el desarrollo y la gestión de proyectos de software con periodos de tiempo a corto y largo plazo, mientras que la metodología ágil se adapta de manera más eficiente a un proyecto determinado (Desarrollo De Software & Gabriel Pacienza, 2015).

1.4.1 Metodología en cascada

La metodología en cascada es un enfoque tradicional para el desarrollo de software que implica una secuencia lineal ordenada de fases en la que cada fase ha de llevarse a cabo y completarse antes de que comience la siguiente. El modelo destaca por su estructura muy rígida y bien definida, lo que se adapta bien a los proyectos en los que los requisitos son claros y no se prevé que cambien mucho durante el desarrollo (Flores-Cerna et al., 2022). Bajo este concepto, el proceso de desarrollo se compone de las siguientes fases, como se muestran a continuación y en la Figura 15.

Análisis: Este es el proceso de planificación inicial se recopilan tanta información como sea posible para garantizar el éxito del proyecto. Dado que en esta fase se toma en cuenta los requisitos del proyecto y se define todo detalladamente antes de comenzar. Este proceso de planificación es una etapa crítica de la metodología en cascada y, por lo tanto, la mayor parte del tiempo del proyecto se dedica a la planificación (Laoyan, 2022).

Diseño: Dentro de este proceso se establece la arquitectura de software, las especificaciones generales que se lleva a cabo como: herramientas, lenguaje de programación, estructura de datos, software y otros aspectos técnicos que se usara para el desarrollo óptimo del software (Morales et al., 2018).

Implementación: Dentro de este proceso se toma en cuenta los puntos anteriores y se interpreta la fase de diseño para codificarlo, se puede incluir múltiples fases dentro de este proceso como: módulos, pruebas unitarias y la integración del código, con la finalidad de obtener un producto de software final (Ionos, 2019).

Verificación: Dentro de este proceso se concluye con la fase de implementación de software, respectivamente inicia la fase de pruebas, donde se lleva a cabo pruebas para garantizar que el software funcione previo a los objetivos establecidos de las fases anteriores, esto implica pruebas de integración, pruebas de sistema y aceptación del cliente (Ionos, 2019).

Mantenimiento: Dentro de este proceso final es importante garantizar la estabilidad y seguridad de software, por lo que realizan varios controles a través del tiempo con el objetivo de identificar y corregir errores, realizar reajustes y mejoras del software y actualizaciones de versiones previas a las herramientas utilizadas durante el proceso de elaboración del software, es importante llevar documentación y registros de control sobre los cambios realizados para facilitar futuras actualizaciones (Atlassian, 2023).

Figura 15
Diagrama de metodología en cascada



Nota. (IONOS, 2019)

1.4.2 ISO/IEC/IEEE 29148:2018

La norma se define como la construcción de requisitos de un proyecto, establece procesos y prácticas para la gestión de proyectos de software, la norma define los conceptos y términos relacionados con la ingeniería de requisitos y proporciona varias soluciones a errores e interpretación, ambigüedades, reduce el costo y riesgo del desarrollo de software y mantenimiento de requisitos del software, La norma proporciona un marco estructurado para la gestión de proyectos con la finalidad de mejorar la calidad de los requisitos a lo largo del ciclo de vida del desarrollo del software (Januarita & Prabowo, 2020). Para el proceso estructural del desarrollo del ciclo de vida del software se considera de acuerdo con la norma ISO/IEC/IEEE que incluye:

1. **Levantamiento de requisitos:** Se realiza la recolección de los requisitos como puede ser de los stakeholders, especialistas y personal involucrado en el área, utilizando entrevistas para comprender las necesidades y el alcance del proyecto, también se crea un documento en el que se especifica los requisitos funcionales y no funcionales de acuerdo con la norma (ISO/IEC/IEEE 29148:2018, 2018).
2. **Diseño del sistema:** Se diseña en base a la arquitectura del sistema, lo que deberá cumplir los requisitos previos, así también los

componentes del sistema incluyendo diagramas, modelos que complementen al desarrollo (ISO/IEC/IEEE 29148:2018, 2018).

3. **Implementación:** Se realiza el desarrollo del código fuente según los estándares del levantamiento de requisitos y de diseño, si existen diferentes tecnologías se integran para asegurar su proceso a las siguientes fases (ISO/IEC/IEEE 29148:2018, 2018).
4. **Pruebas:** Se realizan pruebas unitarias correspondientes a las fases anteriores que cumpla con los requisitos especificados, dependerá del tipo de desarrollo de software para realizar diferentes pruebas como, por ejemplo: pruebas de sistemas, pruebas de aceptación (ISO/IEC/IEEE 29148:2018, 2018).
5. **Despliegue:** Se instala el producto final en un entorno de producción local o de nube, también se realiza una verificación de los requisitos cumplan con el producto final (ISO/IEC/IEEE 29148:2018, 2018).
6. **Mantenimiento:** Se realiza la corrección de algún error que sé de en la fase de despliegue, se considera dar solución a cualquier problema sea de hardware o de software, de no existir errores, la verificación de actualizaciones y mejoras en componentes o herramientas es esencial para el funcionamiento (ISO/IEC/IEEE 29148:2018, 2018).

1.5 Aplicación web

1.5.1 Detalles del sistema

El proyecto de desarrollo permitirá realizar la detección de malezas a través de una recolección de imágenes realizadas por un dron, por consiguiente se realizará la construcción de un aplicativo web utilizando como base la arquitectura Faster R-CNN, mediante la investigación literaria se pretende realizar modificaciones al modelo con el fin de obtener mejores resultados en la predicción, la aplicación web contendrá el modelo preentrenado que se usara para evaluar la densidad de malezas existente en los cultivos. A continuación, se muestra el proceso para llevar a cabo el proyecto:

1. Recolectar imágenes utilizando el dron en los cultivos, posterior se realizará un preprocesamiento de las imágenes obtenidas, donde manualmente se filtra imágenes que no cumplan con los requisitos para ser etiquetadas.
2. Mediante un software libre (Roboflow) se realiza el proceso de etiquetar cada una de las imágenes, se asignan clases para cada una de las malezas, terminado este proceso obtendremos un dataset malezas que se utilizara para el entrenamiento del modelo.
3. Una vez obtenido el modelo de entrenamiento con mejor precisión Faster R-CNN, se comenzará a construir el aplicativo web en base a su metodología normas establecidas, el despliegue se realizará en la plataforma Ngrok, a través de un túnel desde el servidor hacia un subdominio público generado automáticamente.
4. Por otro lado, se incorporará nuevas imágenes en el aplicativo para ser procesadas por el modelo final, dentro de este proceso se muestra un registro que contendrá la cuantificación de malezas.
5. Por último, se calculará la densidad de las malezas dentro de la imagen y determinará la eficiencia y beneficios frente a métodos tradicionales.

1.5.2 Lenguaje de programación

El lenguaje de programación para la construcción del aplicativo web que se va a utilizar es Python, este lenguaje de programación consta de una sintaxis sencilla que facilita el desarrollo de aplicaciones en diversas áreas técnicas y científicas, la gran cantidad de bibliotecas y framework disponibles permite abordar problemas complejos en tareas de aprendizaje automático (Hao & Ho, 2019). Dentro de sus aplicaciones se utilizará en el procesamiento de lenguaje natural, visión por computador, análisis predictivo, automatización y robótica, debido a su compatibilidad con bibliotecas como Tensorflow, keras, entre otras (Saabith et al., 2019). A continuación, se detalla en la Tabla 12 alguna de las librerías que se utilizara en el desarrollo del modelo.

Tabla 12
Librerías en el desarrollo del proyecto

Librería	Concepto
Matplotlib.pyplot	<p>Propósito: Se utiliza para la visualización de imágenes y gráficos</p> <p>Función: Permite mostrar imágenes, gráficos de barras, curvas de precisión-Recall, y otras visualizaciones útiles durante el proceso de entrenamiento y evaluación.</p>
Pandas	<p>Propósito: Es una librería para manipulación y análisis de datos.</p> <p>Función: Puede ser utilizada para organizar y estructurar datos, como, por ejemplo, para manejar información relacionada con el rendimiento del modelo</p>
Numpy	<p>Propósito: Es una librería fundamental para computación numérica en Python.</p> <p>Función: Facilita operaciones matriciales y manipulación de datos, lo cual es esencial para el preprocesamiento de imágenes y la gestión de tensores en el contexto de redes neuronales.</p>
Tensorflow	<p>Propósito: Es una librería de código abierto para aprendizaje automático y redes neuronales</p> <p>Función: Se utilizan para implementar y entrenar la arquitectura Faster R-CNN</p>
Tensorflow.keras.layers	<p>Propósito: proporciona capas de red neural que son fundamentales para construir modelos de manera eficiente.</p> <p>Función: proporciona herramientas para la construcción y entrenamiento de modelos de aprendizaje profundo.</p>
PIL	<p>Propósito: Es una librería para el procesamiento de imágenes.</p> <p>Función: Funciones: Puede ser usada para cargar, manipular y convertir imágenes a formatos compatibles con TensorFlow.</p>
Cv2(OpenCV)	<p>Propósito: Es una librería de visión por computadora.</p> <p>Función: Se utiliza para cargar, preprocesar y manipular imágenes. En el contexto de Faster R-CNN, podría utilizarse para operaciones como cambio de tamaño, normalización, etc.</p>

Seaborn **Propósito:** Es una librería de visualización de datos basada en matplotlib.

Función: Facilita la creación de gráficos estadísticos y puede ser utilizada para visualizar métricas de rendimiento y otros datos relevantes.

Nota. (Saabith et al., 2020)

1.6 Trabajos relacionados

Tabla 13

Trabajos relacionados

Num.	Objeto	Título	Tipo de modelo
1	Maíz y/o papa	Desarrollo de algoritmos de procesamiento de imágenes agrícolas obtenidas por drones para la detección de plantas faltantes en cultivos de maíz	Técnica de visión por computador
2	Maíz y/o papa	Construir un sistema de visión por computadora para detección de maleza y líneas de cultivo usando imágenes provenientes de un dron	Faster R-CNN
3	Tomate riñón	Visión por computador para reconocimiento de malezas en cultivos de tomate riñón de invernadero, mediante redes neuronales	Faster R-CNN
4	Aguacates	Clasificación de aguacates basado en visión por Computador	Faster R-CNN
5	Maíz y/o papas	Control de maleza mediante la robótica	Técnicas de inteligencia artificial
6	Palma	Sistema de visión por computadora para identificación de palma amazónica y el estado de madurez de sus frutos mediante navegación aérea no tripulada UAV.	Mask R-CNN/ COCO Faster R-CNN
7	Peatones	Detección de peatones en la noche usando Faster R-CNN e imágenes infrarrojas	Faster R-CNN

Nota. Recopilación de trabajos relacionados.

1. El autor (Moreira Ramos, 2022) en su trabajo titulado “Desarrollo de algoritmos de procesamiento de imágenes agrícolas obtenidas por drones para la detección de plantas faltantes en cultivos de maíz” se enfoca en la detección de plantas faltantes en el cultivo de maíz, el objetivo de su trabajo de investigación fue el desarrollo de algoritmos utilizando la técnica de visión por computador para detectar estas plantas faltantes mediante la utilización de drones, además se empleó la metodología de cascada, también se determinó que el algoritmo funcionaba correctamente, por otra parte, la investigación propuesta se enfoca a la identificación de malezas en los cultivos de maíz y/o papa utilizando una red neuronal convolucional
2. El autor Robayo (2020) en su trabajo de investigación titulado “Construir un sistema de visión por computadora para detección de maleza y líneas de cultivo usando imágenes provenientes de un dron” establece técnicas de visión mediante computadoras con el propósito de identificar la maleza en los campos de cultivos, para este propósito se utilizó el software DroneDeploy, mientras que en la investigación propuesta se enfoca a identificar maleza utilizando la red neuronal convolucional Faster R-CNN en cultivos de maíz y/o papa.
3. El autor Moncayo (2021) en su proyecto de investigación titulado “Visión por computador para reconocimiento de malezas en cultivos de tomate riñón de invernadero, mediante redes neuronales” propone un sistema de detección de malezas en los cultivos de invernadero de tomate riñón, para cumplir su objetivo planteo un sistema de reconocimientos de imagen a través de redes neuronales, estas imágenes se procesaron con el Software Labellm, por otra parte en el presente trabajo de investigación se enfoca en etiquetar y entrenar imágenes en cultivos de maíz y/o papa con redes neuronales convolucionales “Faster R-CNN”.
4. El autor Pasuy (2019) en su trabajo de investigación titulado “Clasificación de aguacates basado en visión por Computador” tiene como objetivo la clasificación de los aguacates mediante visión por computadora, además con este método pretende innovar la forma de clasificación, para esto propone el preprocesamiento de imagen, análisis de tamaño en pixeles, análisis de color en rojo, verde y azul (RGB), análisis de color en

luminosidad, entre otros parámetros, a diferencia del presente trabajo de investigación que se enfoca en la identificación de maleza utilizando el algoritmo Faster R-CNN y su recopilación de imágenes por medio de un dron.

5. Los autores Espinoza et al, (2021) en su investigación titulada “Control de maleza mediante la robótica” tienen como objetivo una revisión bibliográfica de las nuevas tecnologías robóticas para la detección y eliminación de la maleza, por medio de intervenciones químicas, térmicas y eléctricas, por otra parte este trabajo de investigación se enfoca en identificar y cuantificar las malezas existentes en cultivos de maíz y/o papa en granjas de la Universidad Técnica del Norte.
6. El autor (Rodríguez et al., 2022a) menciona en su trabajo titulado “Sistema de visión por computadora para identificación de palma amazónica y el estado de madurez de sus frutos mediante navegación aérea no tripulada UAV”, se centra en el uso de aeronaves no tripuladas para identificar palma en la amazonia en el estado de madurez de sus frutos, utilizando diversas herramientas de visión por computadora, basados en radiaciones fotosintéticas y el estado del fruto. Compone de un proceso de obtención de imágenes y un preprocesamiento de imágenes en modelos con los siguientes resultados: Mask R-CNN /COCO un 98% precisión mientras que en Faster R-CNN obtuvo un 81% (Marin et al., 2022).
7. En el artículo titulado “Detección de peatones en la noche usando Faster R-CNN e imágenes infrarrojas”, el autor (Galarza Bravo & Flores, 2018) presenta un sistema de detección de peatones en la noche, algoritmo que desempeña la arquitectura Faster, utiliza imágenes de infrarrojo lejano, detecta en múltiples escalas mediante (ROI) en peatones a corta y larga distancia, el modelo utiliza un Backbone VGG16, dentro de los resultados se demostró una precisión en la identificación de peatones del 89.85% con una tasa de error de 16%.

1.7 Preguntas científicas

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

Las herramientas que se emplearon para el siguiente proyecto son: Dron Dji Mavic 2 PRO y la cámara integrada, su vuelo consta de rotores y de ala fija.

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

Según varios trabajos relacionados la altura apropiada depende del tipo de aplicación que se vaya a trabajar, para detectar objetos se recomienda desde 5 hasta 15 metros de altura, en cuanto a su velocidad de vuelo se recomienda entre 1 hasta 4 m/s.

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

(Rodríguez et al., 2022b) recomienda que el espacio sea en RGB, utilizando en formato de PNG, JPEG.

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

La cámara del dron captura imágenes con espectro visible en una calidad de 4K.

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

Los cultivos donde se recolectaron las imágenes corresponden a cultivos de papas con presencia de las siguientes malezas: Lengua de vaca, Kikuyo, diente de león y otros. Las imágenes se obtuvieron de los siguientes sectores: San Gabriel, Cuesaca, El Ángel y Cotacachi.

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

Entre los conjuntos públicos disponibles se encuentran los siguientes: Kaggle, LabelMe, UCI Machine Learning Repository, Berkeley DeepDrive, Data.Gov.

¿Cómo crear y anotar un conjunto de datos propio?

Conlleva un proceso de preprocesamiento de datos, el cual se conforma de 2 etapas, la primera consta en recopilar las imágenes mediante un dron en cultivos previos a parámetros estipulados (Etapa de crecimiento de la planta, tipo de cultivo, altura), para la etapa 2 se realiza una revisión manual a manera de filtro donde cumplan parámetros óptimos, finalmente se utiliza un software libre (Roboflow) para etiquetar imágenes por clases y áreas específicas de interés (Bounding Box).

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

Las arquitecturas más utilizadas en la detección de maleza son: Faster R-CNN, Mask R-CNN y YOLOv8

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

El autor (Hwang, 2018) menciona que en el hardware la calidad de los materiales de los chips y semiconductores influyen en el desempeño para el entrenamiento de los modelos, la potencia computacional basada en unidades de procesamiento gráfico, mientras que en servicios de nube con mayor impacto son: AWS, Azure, Google Colab Pro.

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

Las métricas más comunes para validar el rendimiento corresponden a precisión, Recall, mAP, matriz de confusión, mientras que para las gráficas se usa la curva ROC, curva PR, luO.

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

Para obtener mejores resultados, existen varias técnicas que se aplican en el ajuste de parámetros e hiperparámetros, preprocesamiento de datos, aumento de datos de entrenamiento.

CAPITULO II

2 Desarrollo del proyecto

2.1 Red neuronal artificial

En el proceso del desarrollo se ha planteado como objetivo desarrollar un aplicativo web que utilice la arquitectura Faster RCNN como modelo central de la investigación, que propone detectar malezas en las diferentes imágenes, que el proceso de detección sea preciso y eficiente (Seemakurthy et al., 2023). A continuación, se detalla las distintas fases del desarrollo del aplicativo web, además los motivos detrás de la elección en la arquitectura y sus diferentes experimentaciones a través de desafíos para lograr obtener mejores resultados a nivel de la red neuronal convolucional.

2.1.1 Metodología en cascada

Para el desarrollo de este proyecto se desarrollará un software que permita la identificación de malezas en cultivos de maíz y/o papas bajo la metodología en cascada, que se enfoca en el desarrollo secuencial y lineal de manera que sea una estructura clara para entender el desarrollo del proyecto.

Análisis: Se muestra la definición, planificación y análisis de los requisitos, también de ser necesario se establece propuestas al cliente (Senarath, 2021).

Diseño: Se realiza la construcción de la arquitectura del software como la interfaz del usuario Backend – Frontend, base de datos y herramientas que permitan desarrollar el software (Senarath, 2021).

Implementación: Se realiza la traducción del diseño al lenguaje de programación definido en la fase anterior, se toma en cuenta los componentes del software como los módulos (Senarath, 2021).

Verificación: Se realizan pruebas unitarias, las que permite corroborar que el software cumpla con la calidad como producto final (Senarath, 2021).

Mantenimiento: Se contempla en la etapa de producción, se corrigen errores, mejorar la funcionalidad existente y actualizaciones de parches en librerías y seguridad (Senarath, 2021).

2.1.2 Herramientas de desarrollo

Para el desarrollo del proyecto de investigación se utilizó varias herramientas en diferentes fases. Para abordar este desafío se utilizó herramientas especializadas que permitan capturar, procesar y analizar los datos de manera eficiente, bajo este contexto se menciona las herramientas para el desarrollo del proyecto, como se detalla a continuación en la Tabla 14.

Tabla 14

Herramientas de desarrollo

Herramienta	Función
Dron Mavic2 Pro	Vehículo aéreo no tripulado empleado en la recolección de imágenes en cultivos de maíz y/o papas.
Python	Lenguaje de programación de alto nivel para el desarrollo de aplicaciones de inteligencia artificial y aprendizaje automático.
Colab Pro	Plataforma para el entrenamiento del modelo de aprendizaje automático.
Roboflow	Plataforma de preparación y gestión de datos de visión por computador para etiquetar, procesar y distribuir conjunto de datos de imágenes.
Ngrok	Plataforma que nos permite crear un túnel desde un servidor local a un subdominio público.
ISO/IEC/IEEE 29148:2018	Norma que define los procesos de ingeniería de requisitos en el ciclo de vida del software.

Nota. Elaboración propia.

2.1.2.1 Dron Dji Mavic 2 PRO

En el desarrollo de la investigación se contará con un vehículo aéreo no tripulado, el Dron Dji Mavic 2 PRO, es una herramienta versátil que realiza tomas de alta calidad, una de sus características destaca en volar con gran precisión en espacios reducidos, como se muestra en la Figura 16, se puede utilizar para Fotografías y videos con una perspectiva única en el aire, inspecciones industriales, mapeo y topografía, vigilancia y seguridad (DJI, 2024).

Figura 16
Dron Dji Mavic 2 PRO



Nota. (DJI, 2024).

A continuación, se detalla las especificaciones técnicas de la Cámara del Dron, como se muestra en la Tabla 15 y también las especificaciones técnicas del Dron, como se muestra en la Tabla 16 (DJI, 2024).

Tabla 15
Especificaciones técnicas de la Cámara

Componente	Información
Sensor	1" CMOS
Lente	Píxeles efectivos: 20 millones
Tamaño de imagen fija	FOV: alrededor de 77 ° 5472x3648
Resolución de video	4K: 3840x2160 24/25/30p 2.7K: 2688x1512 24/25/30/48/50/60p FHD: 1920x1080 24/25/30/48/50/60/120p
Tasa de bits de video máxima	100Mbps
Sistema de archivos compatible	FAT32 (≤ 32 GB) exFAT (> 32 GB)

Formato de foto	JPEG / DNG (RAW)
Formato de video	MP4 / MOV (MPEG-4 AVC/H.264, HEVC/H.265)

Nota. Especificaciones tomadas del sitio web de DJI (DJI, 2024).

Tabla 16
Especificaciones técnicas del Dron Mavic2 Pro


Componente	Información
Peso al despegar	907 g
Dimensiones	Doblada: 214 x 91 x 84 mm (largo x ancho x alto)
	Desplegado: 322 x 242 x 84 mm (largo x ancho x alto)
Distancia diagonal	354 mm
Velocidad máxima de ascenso	5 m / s (modo S) 4 m / s (modo P)
Velocidad máxima de descenso	3 m / s (modo S) 3 m / s (modo P)
Velocidad máxima (cerca del nivel del mar, sin viento)	72 km / h (modo S)
Altitud máxima de despegue	6000 m
Tiempo máximo de vuelo (sin viento)	31 minutos (a una velocidad constante de 25 km / h)
Tiempo máximo de vuelo estacionario (sin viento)	29 minutos
Distancia máxima de vuelo (sin viento)	18 km (a una velocidad constante de 50 kph)
Resistencia máxima a la velocidad del viento	29–38 km / h
Frecuencia de operación	2.400 - 2.483 GHz 5.725 - 5.850 GHz
	Vertical: ± 0,1 m (cuando el posicionamiento visual está activo)
Rango de precisión de desplazamiento	± 0,5 m (con posicionamiento GPS)
	Horizontal: ± 0,3 m (cuando el posicionamiento visual está activo)
	± 1,5 m (con posicionamiento GPS)
Almacenamiento interno	8GB

Nota. Especificaciones tomadas del sitio web de DJI (DJI, 2024).

2.1.2.2 Google Colab

Para el desarrollo del modelo, se usará la plataforma de Google Colab como entorno de entrenamiento y validación de la red neuronal convolucional Faster R-CNN, ya que cuenta con facilidad de uso y accesibilidad a recursos gratuitos de hardware, así como el soporte de bibliotecas como TensorFlow, Keras, Pythorch y OpenCV, para potenciar los recursos en GPU, CPU y memoria RAM, se optó por utilizar la versión de paga (Colab PRO), como se muestra en la Figura 17 (Google, 2024).

Figura 17
Recursos Colab PRO



Nota. Datos obtenidos con la suscripción de Google Colab PRO (Google, 2024).

2.1.2.3 Roboflow

Para el proceso de etiquetar imágenes se consideró utilizar Roboflow, ya que su plataforma nos permite realizar trabajos colaborativos entre diferentes usuarios, cuenta con una interfaz amigable y fácil de usar, nos permite generar, procesar y distribuir conjuntos de datos masivos en diferentes extensiones para varios modelos de inteligencia artificial (Roboflow, 2024).

2.1.2.4 Ngrok

Esta plataforma nos permite crear un túnel seguro desde nuestro servidor local a un subdominio público, de esta manera se podrá acceder a la aplicación web, una de las ventajas más relevantes es compartir el trabajo en un entorno local sin la necesidad de configurar y desplegar un servidor (Ngrok, 2024).

2.2 Metodología de cascada bajo la norma ISO/IEC/IEEE 29148:2018

2.2.1 Análisis


Para el desarrollo del proyecto se llevó a cabo identificar las necesidades de usuario y la solución a la cuantificación de tipos de maleza en los campos de cultivos de maíz y/o papa, se obtuvo la recolección de requisitos con las expectativas del usuario final, que se detallan a continuación:









1. Preprocesamiento de imágenes.
2. Clases asignadas para malezas.
3. Validación del dataset.
4. Tamaño de imagen para procesar la detección.
5. Registro de imágenes procesadas.
6. Cuantificación de malezas.

Previo se realizó la investigación literaria en detección de malezas en diferentes campos de cultivos con el fin de recopilar un conjunto local de datos. Este procedimiento es crucial para asegurar que el proyecto cumpla las expectativas del usuario final y pueda procesar imágenes en diferentes tamaños, se tomó como referencia ciertas malezas que son originarias de la sierra ecuatoriana en la zona norte del País, como se muestra en la Tabla 17. Se consideró trabajar con al menos 3 tipos de maleza como se especificó en el alcance del proyecto, también se agregó una categoría de clase “otras” para referirnos otras malezas existentes en los campos de cultivo.

Tabla 17

Tipos de maleza en cultivos de maíz y/o papa

Nombre Común	Nombre científico	Numero asignado de clase	Ejemplar 1	Ejemplar 2
Diente de león.	Taraxacum officinale.	0		

Kikuyo.	Pennisetum clandestinum.	1		
Lengua de vaca.	Rumex obtusifolius L.	2		
Otras. (Alfalfilla, verbenita, mostaza)		3		
Papa.	Solanum tuberosum	4		

Nota. Elaboración propia.

El desarrollo de este proyecto inicia con la recolección de imágenes en diferentes terrenos de la zona norte del País, que cumplan ciertas condiciones para asegurar que los datos obtenidos sean apropiados para obtener mejores resultados, como se detalla a continuación:

1. Tipo de terreno plano

(Vargas et al., 2017) concluye que para determinar la confiabilidad del levantamiento del dron para capturar imágenes puede variar dependiendo el modelo del dron, el entorno y el objetivo, por lo que menciona que la altura recomendada es de 10 a 15 metros de altura.

2. Las plantas en el cultivo deben estar en las primeras etapas de crecimiento

En el artículo publicado por IAgric (Ríos, 2021), manifiesta que en los estudios realizados para el control de cultivos se emplean drones como

tecnología innovadora para cubrir grandes extensiones de terrenos, y detectar incidencias de plagas, enfermedades y malezas en los cultivos, para el monitoreo óptimo se toma en cuenta el análisis de suelo como las siembras por lo que las tareas ejecutadas por drones se realizan en etapa de fenología (etapa del ciclo de desarrollo).

A partir de las condiciones es necesario fijar parámetros de ingreso para el desplazamiento del dron sobre los campos de cultivos, los parámetros propuestos cumplen valores en referencia a investigaciones previas y trabajos relacionados a la obtención de imágenes con vehículos aéreos no tripulados, se toma en cuenta los valores cercanos a las especificaciones técnicas del dron que se va a utilizar en el proyecto, obteniendo los siguientes parámetros como se detalla en la Tabla 18.

Tabla 18
Condiciones de vuelo

Parámetro	Valor
Altura de vuelo.	9 metros.
Velocidad de vuelo.	1 metro/segundo.
Resolución de imagen.	5472 x 3648 píxeles.
Resolución de video.	3840x2160 pixeles.
Tiempo entre captura de cada imagen.	4 segundos.

Nota. Elaboración propia

Dadas las condiciones y parámetros anteriores se planificó el traslado a diferentes sitios de la provincia del Ibarra y Carchi, con el propósito de recopilar imágenes para formar un conjunto de datos, para que exista un registro de los sitios explorados, se obtuvo la siguiente información, como se muestra en la Tabla 19.

Tabla 19*Fechas en las que se capturaron las imágenes en los terrenos elegidos*

Terreno	Coordenada	Fecha	Etapas de crecimiento
Terreno 1 - San Gabriel, comunidad de Chutan Bajo (Propiedad del padre del Ing. PUSDÁ).	77°51'03"W.	20/05/2023.	20 días aprox.
	77°51'03"W.	28/05/2023.	28 días aprox.
	77°51'03"W.	04/06/2023.	35 días aprox.
Terreno 2 - San Gabriel (Propiedad anónima).	77°48'403"W.	04/06/2023.	28 días aprox.
Terreno 3 – Cuesaca, Avenida de la Prehistoria (Propiedad del tío del estudiante Kevin Vinuesa).	77°52'40"W.	17/06/2023.	30 días aprox.
Terreno 4 - El Ángel, barrio San Vicente (Propiedad anónima).	0°38'21"N.	16/12/2023.	30 días aprox.
Terreno 5 - El Ángel, barrio San Vicente (Propiedad anónima).	77°55'59"W.	16/12/2023.	20 días aprox.
Terreno 6 - El Ángel, barrio San Vicente (Propiedad anónima).	77°55'59"W.	16-12-2023.	30 días aprox.
Terreno 7 - El Ángel, barrio San Vicente (Propiedad anónima).	0°38'13"N.	16-12-2023.	15 días aprox.
Terreno 8 – Cotacachi, comunidad Tunibamba de Bellavista (Propiedad del estudiante Luis Perugachi.)	0°19'00.1"N 78°15'56.2"W	11/05/2024	15 – 20 días aprox.
Terreno 8 – Cotacachi, comunidad Tunibamba de Bellavista (Propiedad del estudiante Luis Perugachi.)	0° 19'00.1"N 78°15'56.2"W	17/05/2024	20 – 25 días aprox.

Nota. Elaboración propia.

Se recopiló 2 conjuntos de datos, el primer conjunto se obtuvo de los terrenos 1 al 7 lo que llamaremos como conjunto A, el proceso de obtención de imágenes se realizó mediante una ráfaga de fotografías en una resolución de (5472 x 3648) píxeles, mientras que el segundo conjunto se obtuvo del terreno

8 lo que llamaremos conjunto B, el proceso de obtención se realizó mediante un video con una resolución de (3840x2160) píxeles, para obtener las imágenes se realizó un proceso de captura de fotogramas con la finalidad de obtener imágenes fijas.

Para la construcción del conjunto de datos se aplicó el siguiente criterio de eliminación, obteniendo los siguientes resultados como se detalla en la Tabla 20.

1. Imágenes que en su nomenclatura no eran múltiplos de 3.
2. Imágenes que carecen de presencia de malezas.
3. Imágenes con sobrepoblación de maleza.
4. Imágenes dañadas o que presenten desenfoque.

Tabla 20
Número de imágenes útiles resultantes

Criterio de eliminación	Número de imágenes resultantes(4K)
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.

También se detalla el número de imágenes pertenecientes a cada terreno que serán utilizadas en la siguiente fase, como se muestra en la Tabla 21. A partir del proceso de filtro, se descartaron imágenes aplicando el criterio de eliminación, entre las siguientes imágenes descartadas tenemos varios ejemplos que se detallan en las Figuras 18 al 21.

Figura 18
Sobre población de maleza




Nota. Elaboración propia

Figura 19
Imagen dañada



Nota. Elaboración propia.

Figura 20
Imagen con desenfoque



Nota. Elaboración propia.

Figura 21

Interferencias con árbol y arbustos



Nota. elaboración propia.

Tabla 21

Imágenes utilizables de todos los terrenos

Terreno	Coordenada	Número de imágenes capturadas	Número de imágenes utilizables
Terreno 1 - San Gabriel, comunidad de Chutan Bajo.	77o51'03"W.	539. 409. 926.	0. 0. 0.
Terreno 2 - San Gabriel.	77o48'403"W	197.	55.
Terreno 3 - Cuesaca, Avenida de la Prehistoria.	77o52'40"W.	209.	0.
Terreno 4 - El Ángel, barrio San Vicente.	0o38'21"N.	61.	19.
Terreno 5 - El Ángel, barrio San Vicente.	77o55'59"W	28.	9.
Terreno 6 - El Ángel, barrio San Vicente.	77o55'59"W.	53.	17.
Terreno 7 - El Ángel, barrio San Vicente.	0o38'13"N.	25.	8.
Terreno 8 – Cotacachi, comunidad Tunibamba de Bellavista.	0 ° 19'00.1"N 78°15'56.2"W	400.	400.
Total.		2847.	508.

Nota. Elaboración propia.

.Historias de usuario

En el desarrollo del proyecto surge la necesidad de crear una aplicación web especializada en el procesamiento de imágenes aéreas capturadas por drones, con el objetivo de identificar y cuantificar malezas en campos de cultivo mediante la arquitectura Faster R-CNN, la aplicación facilitará la identificación y cuantificación de malezas por clase, además de mostrar el nivel de infestación de la imagen (Senarath, 2021). La aplicación web se centrará en proporcionar una experiencia de usuario simplificada, presentando solo dos pantallas clave: una para validar etiquetas y otra para procesar imágenes, facilitando así la toma de decisiones informadas y la gestión efectiva sobre los cultivos (Han et al., 2018).

- **Técnica de estimación:** Para llevar a cabo las historias de usuario aplicaremos una técnica de estimación T-Shirt para indicar un lapso en el desarrollo de las historias, que serán valoradas de XS hasta XL, como se detalla en la Tabla 22 (Guillermo et al., 2019).

Tabla 22

Estimación relacionada con el intervalo de días

Tamaño	Días
XS	0-1
S	2-6
M	7-13
L	14-20
XL	21-100

Nota. elaboración propia.

- **Prioridad:** Es la perspectiva del usuario para determinar los requisitos del proyecto, se toma en cuenta los diferentes niveles mediante el uso de la escala de Likert, por lo tanto, se evalúa la importancia de cada historia en un nivel de 1 a 5, donde 1 indica un nivel bajo y 5 un nivel alto. A continuación, se detalla la lista en la Tabla 23.

Tabla 23*Lista de historias de usuario*

ID	Título	Prioridad	Estimación
HU-01	Procesar imagen de Validación	4	S
HU-02	Listar los resultados de la Validación	2	S
HU-03	Procesar imagen de Análisis	5	S
HU-04	Listar los resultados de Análisis	2	S
HU-05	Eliminar registro de imágenes	2	XS

Nota. Elaboración propia.

- **Despliegue de historias de usuarios**

Cada historia de usuario es una pequeña porción funcional del producto que aporte valor tangible al usuario final, por lo tanto, se detalla cada una como se muestra en las Tablas 24 al 28.

Tabla 24*Procesar imagen de validación*

Procesar imagen de validación	
ID: HU-01	Dependencia: Ninguna
Prioridad: 4	Estimación: S
Descripción: Como rol de usuario deseo procesar una imagen de validación en la aplicación para validar las etiquetas de malezas detectas.	
Prueba de aceptación:	
<ol style="list-style-type: none"> 1. En la pantalla principal, debería haber una opción clara para cargar una imagen de validación. 2. La aplicación debería procesar la imagen utilizando la arquitectura Faster R-CNN para detectar el número de aciertos y errores en la imagen 3. Se debería presentar una interfaz que muestre las detecciones resaltadas. 	

Nota. Elaboración propia.

Tabla 25
Resultados de validación

Listar los resultados de la Validación	
ID: HU-02	Dependencia: HU-01
Prioridad: 2	Estimación: S
Descripción: Como rol de usuario deseo tener la capacidad de ver una lista de los resultados de la validación de las imágenes procesadas y validar la precisión del modelo.	
Prueba de aceptación:	
<ol style="list-style-type: none">1. La aplicación debería proporcionar una sección donde se muestre el historial de imágenes de validación procesadas.2. Cada entrada en la lista debería mostrar información relevante, como el nombre, resolución de la imagen, numero de malezas detectadas, validación (Aciertos y Errores) y el porcentaje de aciertos.	

Nota. Elaboración propia.

Tabla 26
Procesar imagen de validación

Procesar imagen de análisis	
ID: HU-03	Dependencia: Ninguna
Prioridad: 5	Estimación: S
Descripción: Como rol de usuario deseo poder cargar una imagen, luego se pueda analizar y como resultado identifique la maleza existente en la imagen.	
Prueba de aceptación:	
<ol style="list-style-type: none">1. En la pantalla principal, debería haber una opción clara para cargar una imagen para analizar.2. La aplicación deberá procesar la imagen utilizando la arquitectura Faster R-CNN para detectar y cuantificar las malezas.3. Se deberá presentar una interfaz que muestre las detecciones resaltadas por cada clase de malezas	

Nota. Elaboración propia.

Tabla 27*Listar los resultados de análisis*

Listar los resultados de análisis	
ID: HU-04	Dependencia: HU-03
Prioridad: 2	Estimación: S
Descripción: Como rol de usuario deseo tener la capacidad de ver una lista de los resultados de análisis para realizar un seguimiento de las imágenes procesadas y evaluar la presencia de malezas en los campos de cultivo.	
Prueba de aceptación:	
1. La aplicación debería proporcionar una sección donde se liste el historial de imágenes de análisis procesadas.	
2. Cada entrada en la lista debería mostrar información relevante, como el nombre, la resolución de la imagen, el número de malezas por clase, número de malezas totales y el nivel de infestación existente.	

Nota. Elaboración propia.

Tabla 28*Eliminar registro de imagen*

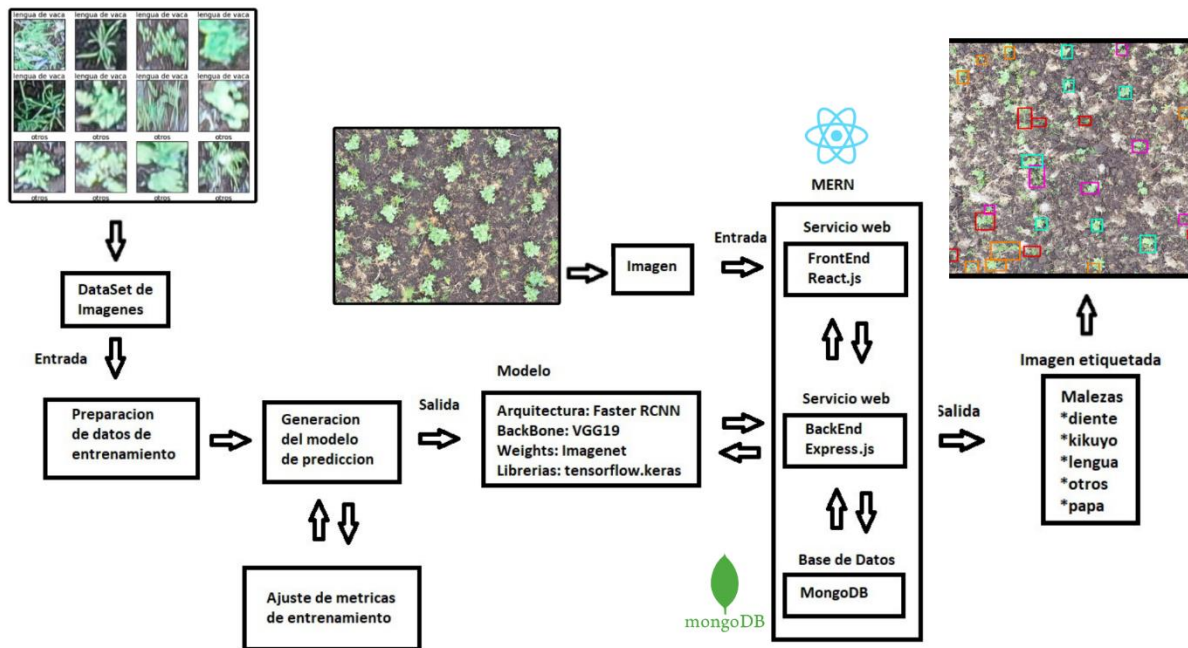
Eliminar registro de imagen	
ID: HU-05	Dependencia: HU-02, HU-04
Prioridad: 2	Estimación: XS
Descripción: Como usuario deseo eliminar registros de imágenes procesadas para gestionar y mantener limpio el historial de resultados.	
Prueba de aceptación:	
1. En la sección de resultados de validación y análisis, debería haber una opción para eliminar un registro específico.	
2. La aplicación deberá proporcionar una confirmación antes de eliminar el registro para evitar incidentes.	
3. Después de eliminar el registro, la lista de resultados deberá actualizarse automáticamente.	

Nota. Elaboración propia.

2.2.2 Diseño

A partir de la fase de análisis y todos los parámetros establecidos, en esta etapa se inicia la construcción del aplicativo web para la identificación de malezas. Cabe mencionar que en esta fase se centra en la transformación de los requisitos definidos por la fase de análisis con el objetivo de mantener una estructura técnica y visual, como se muestra en la Figura 22. El diseño del aplicativo no solo se enfoca en la eficiencia de la red neuronal, sino también en la usabilidad y experiencia para el usuario (Han et al., 2018), garantizando que los usuarios puedan interactuar de manera intuitiva al procesar la imagen y visualizar los resultados del análisis.

Figura 22
Diseño del aplicativo



Nota. Elaboración propia.

Dentro de la aplicación contará con una interfaz web que conste de 2 páginas, la primera el usuario podrá realizar la validación del dataset obtenido, mientras que la segunda se realiza el análisis de la imagen, la capa de administración consumirá la capa de microservicios para eliminar el registro de datos.

La aplicación se conecta con el módulo de procesamiento de imágenes, cabe mencionar que detrás de varias experimentaciones en la arquitectura Faster R-CNN se elegirá el mejor modelo, para ello se tomará en cuenta los resultados de las métricas en cuanto a precisión, rendimiento, y tiempo. Dentro de la arquitectura Faster R-CNN se usará el Backbone VGG19 y pesos de ImageNet, el propósito de la aplicación es realizar la identificación y cuantificación de malezas existentes en los campos de cultivos de maíz y/o papa.

2.2.3 Implementación

2.2.3.1 Preprocesamiento de datos

Para adquirir los datos de este proyecto se llevó a cabo mediante un proceso sistemático, su finalidad es automatizar la información recopilada, esto permite analizar, así como dar soluciones de forma inmediata, se identificó como máximo 4 tipos de malezas, tomando en cuenta las más sobresalientes dentro del cultivo, las plantas deberán estar en una etapa inicial de crecimiento (Carrera, 2023), se realizó varias muestras de (2 a 5 semanas aproximadamente), se tomó como referencia información de trabajos relacionados con varias propuestas de altura, la altura que se consideró es de 9 metros debido a las especificaciones y componentes del dron como se muestra en la Figura 23 (Castello et al., 2018).

Figura 23

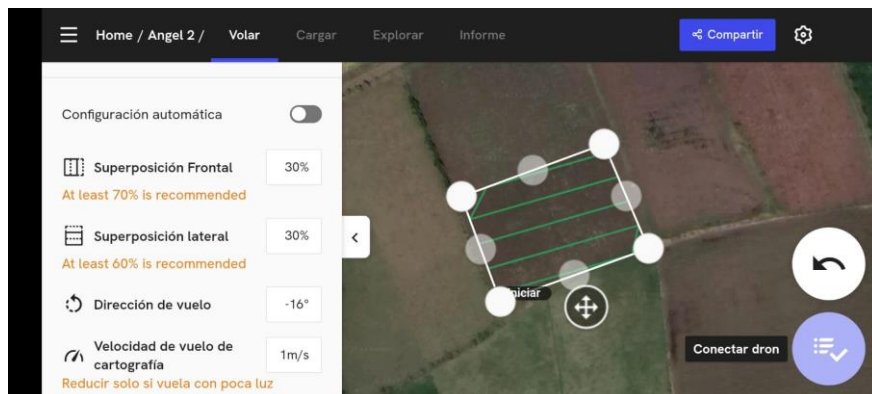
Altura de vuelo en el cultivo



Nota. Fotografía obtenida del terreno #3

Se realizó varios desplazamientos programados en los cultivos con una configuración automática mediante el uso de la aplicación DroneDeploy como se muestra en la Figura 24, y sus desplazamientos recorridos como se muestra en la Figura 25, este proceso se aplicó para todos los terrenos mencionados (Joyce et al., 2018).

Figura 24
Recorrido del Dron en el cultivo de papas



Nota. Elaboración propia.

Figura 25
Perímetro de vuelo del Dron



Nota. Elaboración propia.

A continuación, en la Tabla 29 se detalla el conjunto de datos que pertenece cada terreno, el número de imágenes obtenidos por fecha y hora.

Tabla 29*Número de imágenes capturadas por fechas en los terrenos*

Conjunto de datos	Terreno	Fecha	Hora	Número de imágenes
A	Terreno 1 - San Gabriel, comunidad de Chutan Bajo, 77°51'03"W (Propiedad del padre del Ing. PUSDÁ).	20/05/202 3.	9:10 - 9:55.	539.
		28/05/202 3.	10:07 - 10:42.	409.
		04/06/202 3.	11:25 - 12:38.	926.
	Terreno 2 - San Gabriel, 77°48'40"W. (Propiedad anónima).	04/06/202 3.	14:12 - 14:20.	197.
	Terreno 3 - Cuesaca, Avenida de la Prehistoria, 77°52'40"W. (Propiedad del tío del estudiante Kevin Vinuesa).	17/06/202 3.	8:58 - 9:20.	209.
	Terreno 4 - El Ángel, barrio San Vicente, 0°38'21"N (Propiedad anónima).	16/12/202 3.	10:23 - 10:28.	61.
	Terreno 5 - El Ángel, barrio San Vicente, 77°55'59"W (Propiedad anónima).	16/12/202 3.	10:52 - 10:55.	28.
	Terreno 6 - El Ángel, barrio San Vicente, 77°55'59"W (Propiedad anónima).	16/12/202 3.	11:18 - 11:25.	53.
B	Terreno 7 - El Ángel, barrio San Vicente, 0°38'13"N (Propiedad anónima).	16/12/202 3.	11:51 - 11:55.	25.
		Terreno 8 - Cotacachi, comunidad Tunibamba de Bellavista (Propiedad del estudiante Luis Perugachi.)	11/05/202 4	09:56 - 10:35
		17/05/202 4	09:39 - 10:20	

Nota. Elaboración propia.

Después de haber aplicado el criterio de eliminación, obtenemos varias imágenes que son favorables para el proceso de etiquetado, como se muestra en la Figura 26.

Figura 26
Imágenes con las condiciones más favorables



Nota. Elaboración propia.

Bajo este proceso se obtuvo el conjunto de datos A y B, cabe mencionar que ambos conjuntos fueron obtenidos con diferentes técnicas y en diferentes resoluciones, la propuesta es mantener una similitud de resolución entre ambos conjuntos, por tanto, se pretende agrupar para formar un Dataset robusto.

Esto es posible de realizar con la herramienta Roboflow, ya que nos permite separar y unir conjuntos de datos de diferentes proyectos bajo el mismo formato de archivo, mediante esta técnica de agrupación se formó un Dataset con 2847 imágenes con una resolución de (2736 x 1824) píxeles, este Dataset servirá para realizar experimentaciones en el entrenamiento de la red neuronal, a partir del Dataset obtenido se consideró realizar un balance de clases que consiste en eliminar la imagen completa, reduciendo el mayor número de etiquetas por clase, por

consiguiente obtenemos 2 conjuntos de datos que lo llamaremos de la siguiente manera:






Conjunto de datos

- Dataset # 1: Dataset Original “Sin balancear”
- Dataset # 2: “Balanceado”

Mediante la herramienta “Roboflow” se busca realizar la etiqueta de malezas por Bounding Box, se podrá definir los límites de un objeto dentro de una imagen (Xia et al., 2017), este proceso es indispensable, ya que proporcionará información sobre el contenido de las imágenes, de esta manera el modelo podrá extraer características específicas para reconocer y clasificar objetos como se muestra en la Figura 27 (Algan & Ulusoy, 2021). Cada una de las plantas del cultivo pertenecerá a una clase con un color específico para identificar las plantas y malezas, este color se mantendrá para visualización de métricas y distintivo de las etiquetas en la aplicación web, como se muestra en la Tabla 30

Tabla 30

Colores por clase para las malezas

Color	Nombre de Etiqueta
#FF8000 	Diente-de-leon
#EB0000 	Kikuyo
#00FFCE 	Lengua de vaca
#FF00D8 	Otros
#8622FF 	papa

Nota. Elaboración propia.

Figura 27

Vista previa de las etiquetas del dataset



Nota. Imagen capturada de la plataforma (Roboflow, 2024).

2.2.3.2 Elaboración del dataset


Se generó una versión de conjunto de datos sin parámetro alguno o preprocesamiento previo, para evitar pérdidas de información al recortar las imágenes con la herramienta Roboflow, ya que al mantener un preprocesamiento la herramienta realiza una compresión de hasta el 40%. Dichos cambios se realizaron en cada una de las experimentaciones de la red neuronal convolucional, partiendo de investigaciones y trabajos relacionados en la detección de objetos, se puede concluir que es recomendable realizar el entrenamiento con tamaños de 600 entre 1200 píxeles permitiendo mantener el equilibrio entre la precisión y el rendimiento, la arquitectura Faster R-CNN con Backbone VGG19 nos permite manejar imágenes de diferentes tamaños, también permite la posibilidad de no realizar ninguna redimensión de la imagen y utilizar la imagen original de cada conjunto de dataset (De et al., 2021), sin embargo, para un óptimo rendimiento se realizará cortes en las imágenes con diferentes tamaños propuestos a partir de 400x400; 600x600; 800x800; 1280x1280 píxeles.

Dentro de la herramienta Roboflow, en la sección de Dataset Health Check, se puede ver a detalle el número de etiquetas por clase de cada dataset, al contar con 2

conjuntos de datos a continuación se muestra el detalle del estado de datos del dataset #1 como se ve en la Figura 28 y el estado de datos del dataset #2, como se muestra en la Figura 29.

Figura 28


Estado del conjunto de datos pertenecientes al Dataset #1 “Sin Balancear”



Nota. Resultado obtenido del proyecto UTN (Roboflow, 2024).

Figura 29

Estado del conjunto de datos pertenecientes al Dataset #2 “Balanceado”



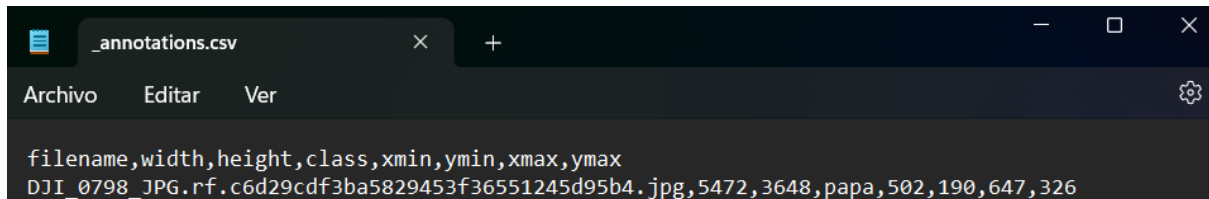
Nota. Resultado obtenido del proyecto UTN (Roboflow, 2024).

Para exportar el dataset, Roboflow tiene compatibilidad con varios formatos, en este proyecto se trabajará con el formato CSV (Tensorflow Object Detector), nos

permite que las etiquetas de cada clase (papa y/o maíz, maleza) y coordenadas del Bounding Box sea útil para entrenar el modelo, el archivo CSV contine columnas de 'filename', 'width', 'height', 'class', 'xmin', 'ymin', 'ymax', como se muestra en la Figura 30 (Howal et al., 2020).

Figura 30

Formato de etiqueta Faster R-CNN



```
filename,width,height,class,xmin,ymin,xmax,ymax
DJI_0798.JPG.rf.c6d29cdf3ba5829453f36551245d95b4.jpg,5472,3648,papa,502,190,647,326
```

Nota. Datos obtenidos de la exportación de dataset de la herramienta Roboflow.

2.2.3.3 Verificación de la anotación de las imágenes

Dentro del proceso, para obtener un dataset robusto y confiable se considera realizar la verificación de los datos obtenidos, dentro de esta evaluación se consideró utilizar el método de auto-consistencia o self consistency check, el autor (Zhai et al., 2023) hace uso de este método para verificar las anotaciones de su Dataset, por lo que ayuda a reducir errores y aumentar la confiabilidad de los datos obtenidos. Aplicando el mismo método se realizó el entrenamiento del modelo con el conjunto de entrenamiento y validación, se toma como referencia que al entrenar con el conjunto de validación se causa un sobreajuste a los valores representativos en las primeras épocas por lo que su precisión tiende a un valor de 100%, esto indicara que cada etiqueta corresponde a su clase respectivamente.

2.2.3.4 Set de entrenamiento y evaluación del modelo

Para implementar el modelo, se utilizó Google Colab PRO como plataforma de entrenamiento, en el dataset se llevó a cabo la separación del conjunto de entrenamiento del 80% y un conjunto de validación del 20%, como se muestra en la Figura 31, dichos porcentajes son comunes en el aprendizaje automático, y una buena práctica para el entrenamiento del modelo y validación de este. Durante el


entrenamiento se establecerá un conjunto de parámetros como se muestra en la Tabla 31, al finalizar el entrenamiento se realizará la verificación con imágenes que no pertenecen al dataset.

Tabla 31
Parámetros de red neuronal Faster R-CNN

Parámetros
Tamaño de imagen
Tamaño de lote (Batch size)
Numero de épocas
Rango de rotación
Desplazamiento
Escalado
Ajuste de brillo
Función de perdida

Nota. (Yan et al., 2021)

Figura 31
Test Split



Nota. Datos obtenidos en (Roboflow, 2024).

2.2.3.5 Análisis y carga de datos del dataset

Se implementará diferentes librerías que se utilizó en el modelo Faster R-CNN, como se detalla en la Tabla 32.

Tabla 32*Librerías utilizadas en el modelo Faster R-CNN*

Librería	Características
Matplotlib.pyplot	Permite mostrar imágenes, gráficos de barras, curvas de precisión-Recall, entre otras visualizaciones.
Pandas	Permite organizar y estructurar datos, como, por ejemplo, para manejar información relacionada con el rendimiento del modelo.
Numpy	Facilita operaciones matriciales y manipulación de datos
TensorFlow	Se utilizan para implementar y entrenar la arquitectura Faster R-CNN.
Tensorflow. keras. layers	Proporciona herramientas para la construcción y entrenamiento de modelos de aprendizaje profundo.
PIL	Puede ser usada para cargar, manipular y convertir imágenes a formatos compatibles con TensorFlow.
Cv2(OpenCV)	Permite cargar, preprocesar y manipular imágenes. En el contexto de Faster R-CNN, se puede utilizar para operaciones como cambio de tamaño, normalización, etc.
Seaborn	Facilita la creación de gráficos estadísticos y puede ser utilizada para visualizar métricas de rendimiento y otros datos relevantes.

Nota. Elaboración propia.

2.2.3.6 Entrenamiento del modelo

Para entrenar el modelo se necesita considerar una serie de aspectos que influyen directamente en su rendimiento y capacidad de recursos, en esta sección se realizó diversas experimentaciones, desde la configuración de la arquitectura, pasando por varios cambios de parámetros y empleando técnicas de aumento de datos para mejorar la robustez del modelo, a continuación, se presentan las siguientes propuestas de los modelos entrenados:

2.2.3.6.1 Modelo de experimentación Faster R-CNN-01 (ADAM vs SGD)

En este modelo se realizó una comparativa entre el optimizador ADAM Y SGD con la finalidad de experimentar que optimizador podría llegar a ser más preciso y eficiente en el entrenamiento y rendimiento del modelo (Trujillo González & Martínez Valderrama, 2022), en este modelo se consideró adaptar la tasa de aprendizaje de forma dinámica para cada parámetro, esto nos conduce a una convergencia más rápida con la posibilidad de que requiera más tiempo de entrenamiento, los cambios en el sobreajuste y los pesos.

2.2.3.6.2 Modelo de experimentación Faster R-CNN-02 (Escala de grises)

En este modelo se consideró experimentar bajo la técnica de escala de grises, ya que reduce la complejidad de los datos al eliminar la información de color, con esto se podría mejorar significativamente el rendimiento y eficacia del modelo para la identificación de malezas que presenten condiciones de baja luminosidad (Jiang et al., 2021).

2.2.3.6.3 Modelo de experimentación Faster R-CNN-03 (Data Augmentation)

En este modelo se consideró experimentar el aumento de datos a partir de los existentes, mediante parámetros como escalados, rotación, desplazamiento, ajuste de brillo, esto permite aumentar el conjunto de datos y mejorar la capacidad del modelo en identificar y aprender nuevos patrones, esto resulta en un modelo más robusto con la posibilidad de ofrecer mejores resultados (Huang et al., 2019).

2.2.3.7 Evaluación del modelo

En cada versión del modelo se tomó parámetros que ayuden a mejorar la precisión y el rendimiento, se consideró entrenar el modelo con el dataset #1

empleando recortes de 400x400 píxeles y las mismas condiciones paramétricas para cada experimentación para determinar un punto de partida y realizar nuevas modificaciones de parámetros, mediante esta experimentación se obtuvo los siguientes resultados, como se muestra en la Figura 32.

Figura 32
Resultados de las experimentaciones en el modelo

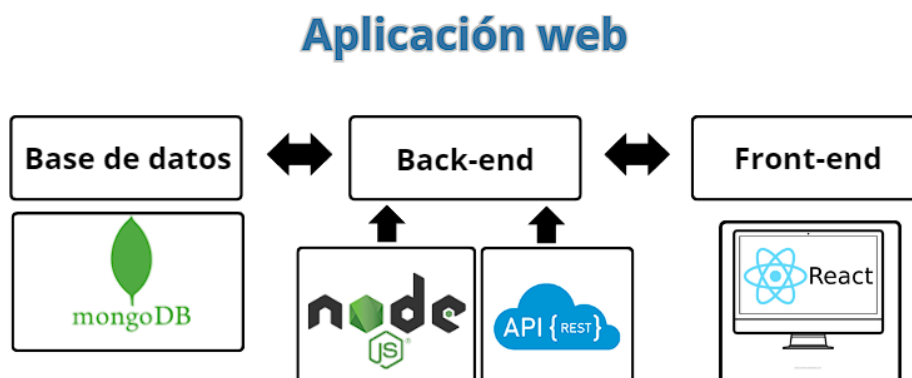
Modelo	Precisión	Recall	Hiperparámetros cambiados					Recursos	
			Tamaño de imagen	Batch Zise	Épocas	Optimizador	Tiempo	GPU 40%	RAM 83.5%
SGD	0.538888	0.530718	400x400	16	30	SGD	10'16"	16.9%	37.3%
ADAM	0.640000	0.658356	400x400	16	30	ADAM	11'45"	16.7%	36.7%
GRISES	0.588333	0.591834	400x400	16	30	ADAM	9'21"	16.7%	37.0%
DATA AUGMENTATION	0.649560	0.662012	400x400	16	30	ADAM	14'26"	32.9%	78.2%

Nota. Elaboración propia.

2.2.4 Verificación

Para sobrellevar la experiencia con los usuarios, se tomó en cuenta varios factores como la accesibilidad, interfaz de usuario, procesamiento, tiempo de respuesta, visualización de resultados y facilidad de integración, para ello se ha dividido en tres módulos principales para garantizar el uso adecuado del software, como se muestra en la Figura 33.

Figura 33
Arquitectura de la aplicación web



Nota. Elaboración propia

Para el desarrollo del aplicativo web se trabajó con la propuesta inicial Stack MERN, este grupo nos permite construir un aplicativo moderno y escalable, combinando tecnologías como MongoDB para la base de datos, Express.js para el servidor Backend, React.js para la interfaz de usuario del Frontend y node.js como entorno de ejecución del servidor.

2.2.4.1 Diseño de la base de datos

Para la construcción de la base de datos se consideró los requerimientos del sistema, la herramienta que se utilizó es MongoDB v6.0.13, para listar los registros del aplicativo se crean rutas y controladores, lo que permitirá realizar operaciones CRUD y peticiones desde los componentes de React, a continuación, se muestra las colecciones obtenidas en las Figuras 34 y 35.

Figura 34
BD de Comprobador



Nota. Elaboración propia.

Figura 35
BD de Analizador



Nota. Elaboración propia.

2.2.4.2 Desarrollo Backend

Para la conexión de base de datos, se creó un String de conexión que se vincula automáticamente con MongoDB, posterior se creó un esquema de datos en Models, para la entrada y salida de la base de datos, luego en Controllers se configuró los métodos para el consumo del API REST, entre el manejo de peticiones tenemos el uso de HTTP (POST, GET, UPDATE Y PUT) que recibe el parámetro de la imagen y lo almacena en el servidor. Parte del Backend tenemos el modelo Faster R-CNN con Data Augmentation como modelo preentrenado que se encarga del procesamiento de las imágenes, el modelo se comunica mediante las rutas node.js que pasa a través del API REST, finalmente se conecta con la base de datos a través de controladores y módulos dando como resultado una ruta donde se almacenan las imágenes procesadas.

2.2.4.3 Desarrollo Frontend

Para el desarrollo del Frontend se utilizó la biblioteca de JavaScript React.js, esta librería nos permite crear interfaces de manera eficiente, también nos permite construir y reutilizar componentes que se involucren con el desarrollo web o móvil, dichos componentes se pueden gestionar de manera dinámica (Naiki et al., 2019), de tal forma ofrece un rendimiento optimizado gracias a su representación virtual de la estructura de interfaces.

Los componentes modulares de interfaz utilizados son HTML, CSS y JavaScript, se añade una configuración en el proxy para redirigir solicitudes entre el Backend y Frontend utilizando la librería Fetch.

2.2.4.4 Verificación de resultados

En esta sección se verificará los resultados tomando en cuenta las fases anteriores de la metodología en cascada, a continuación, se presentan los resultados de funcionamiento del aplicativo web con base en las historias de usuario planteadas.

1. **Procesar imagen de validación:** Nos permite cargar imágenes para comprobar que existen etiquetas en las imágenes, como se muestra en la Figura 36.


Figura 36
Procesar imagen de validación



Nota. Elaboración propia.

2. **Listar los resultados de validación:** Muestra los resultados de la validación de imágenes y un resumen de aciertos y errores por cada clase y una métrica general de aciertos, como se muestra en la Figura 37.


Figura 37
Resultados de validación

RESUMEN										
Imagen		Clases					Validación			Borrar Registro
Nombre	Resolución	Diente de león	Kikuyo	Lengua de vaca	Papa	Otros	Aciertos	Errores	Porcentaje de aciertos	
DJI_0680.JPG.rf.63ec374ce8ea2a8eea0385c902f05a10.jpg	2736x1824	0/0	0/0	11/56	118/222	0/0	129	149	46.40	

Nota. Elaboración propia.

- 3. Procesar imagen de análisis:** Tiene la capacidad de cargar e identificar plantas y malezas de una imagen, como se muestra en la Figura 38.



Figura 38
Resultado luego de procesar imagen de análisis



Nota. Elaboración propia.

- 4. Listar los resultados de análisis:** Muestra los resultados del análisis previamente procesado, como la detección de malezas por clase, cuantificación de malezas y el porcentaje de infestación, como se muestra en la Figura 39.























Figura 39
Resultado de análisis

Imagen		Clases							Porcentaje de infestación	Opciones
Nombre	Resolución	Diente de león	Kikuyo	Lengua de vaca	Papa	Otros	Total de malezas			
DJI_0680_JPG.jpg.rf.63ec374ce8ea2a8eea0385c902f05a10.jpg	2736x1824	5	3	2	36	6	16	30.76 %	 	

Nota. Elaboración propia.

5. Visualizar resultados anteriores: Permite a los usuarios ver los registros de resultados anteriores, como se muestra en la Figura 40.

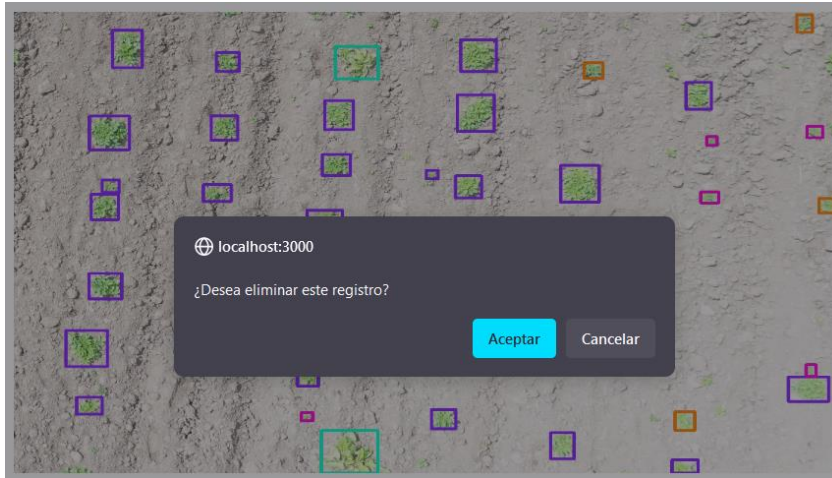
Figura 40
Registro de resultados anteriores

RESUMEN										
Imagen		Clases							Porcentaje de infestación	Opciones
Nombre	Resolución	Diente de león	Kikuyo	Lengua de vaca	Papa	Otros	Total de malezas			
DJI_0680_JPG.jpg.rf.63ec374ce8ea2a8eea0385c902f05a10.jpg	2736x1824	5	3	2	36	6	16	30.76 %	 	
DJI_0684_JPG.jpg.rf.6fc9f9e6394d2f8179d7127fcb6469a2.jpg	2736x1824	5	0	3	29	6	14	32.55 %	 	
00372.jpg.rf.ec2cfa96c1948427d79cc73aa6238bfb.jpg	1920x1920	39	1	1	4	17	58	93.54 %	 	
00280.jpg.rf.aa372f8eb2b744af90c97af2c6d237d8.jpg	1920x1920	73	7	3	0	17	100	100.0 %	 	
DJI_0979_JPG.jpg.rf.77f01ad9918ea84e8d3c4c76da81b978.jpg	2736x1824	55	10	18	11	16	99	90.0 %	 	
DJI_0936_JPG.jpg.rf.f302343a6255f71c74158398e83779e1.jpg	2736x1824	29	18	3	5	20	70	93.33 %	 	
DJI_0955_JPG.jpg.rf.8a8470f536e8e3ccbada437b8c17c758.jpg	2736x1824	37	21	4	4	24	86	95.55 %	 	
00066.jpg.rf.9ba76fff5d5517f4d34467617bfa630a.jpg	1920x1920	4	1	1	47	12	18	27.69 %	 	
00001.jpg.rf.4eb9f03b71387aa769c099d2c2c2f747.jpg	1920x1920	1	1	0	61	0	2	3.174 %	 	
00011.jpg.rf.9da66c01a45641352c60dcdad404e13d.jpg	1920x1920	9	3	21	66	25	58	46.77 %	 	
00352.jpg.rf.b3a704162e3798923df4633633b0f004.jpg	1920x1920	39	0	0	0	8	47	100.0 %	 	

Nota. Elaboración propia.

6. Eliminar registro de imagen: Nos permite eliminar registros anteriores previo al proceso, en las pantallas de validación y análisis, como se muestra en la Figura 41.

Figura 41
Eliminar registro



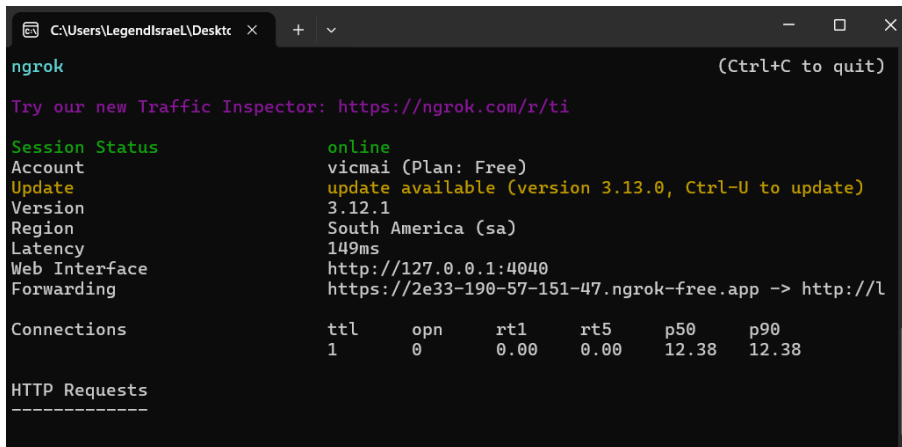
Nota. Elaboración propia.

2.2.4.5 Despliegue de la aplicación

El aplicativo web se desplegará en la plataforma Ngrok, esta plataforma nos permite soportar cargas de trabajo que requieren características especiales de rendimiento, procesamiento gráfico adicional de un servidor local (Ngrok, 2024). Para el despliegue de la aplicación es necesario que la aplicación web se encuentre funcionando correctamente de manera local e ingresar con el token de autenticación de su cuenta creada en Ngrok y crear un túnel de conexión entre el servidor local y la dirección pública de Ngrok como se muestra en la Figura 42.

Figura 42

Túnel de conexión entre el servidor local y la URL publica de Ngrok



```
ngrok (Ctrl+C to quit)
Try our new Traffic Inspector: https://ngrok.com/r/ti

Session Status      online
Account             vicmai (Plan: Free)
Update              update available (version 3.13.0, Ctrl-U to update)
Version             3.12.1
Region              South America (sa)
Latency             149ms
Web Interface        http://127.0.0.1:4040
Forwarding           https://2e33-190-57-151-47.ngrok-free.app -> http://l

Connections
  ttl   opn   rt1   rt5   p50   p90
  1     0    0.00  0.00  12.38 12.38

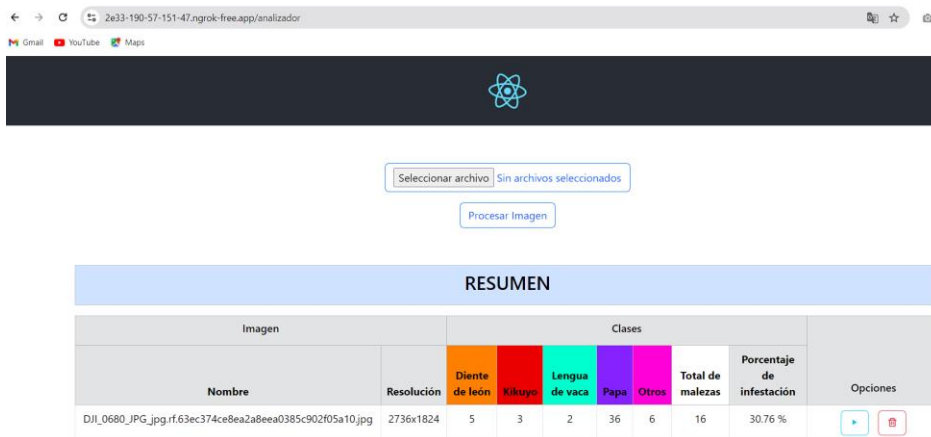
HTTP Requests
-----
```

Nota. Imagen obtenida de la consola de Ngrok (Ngrok, 2024).

Una vez establecida la conexión podemos dirigirnos al URL e ingresar desde cualquier navegador web y hacer uso del analizador de imágenes para identificar malezas, como se muestra en la Figura 43.

Figura 43

Despliegue del aplicativo web



Nota. Imagen obtenida del despliegue en Ngrok (Ngrok, 2024).

2.2.5 Mantenimiento

Para el desarrollo del proyecto se puede considerar varios puntos para garantizar que la aplicación continúe funcionando de manera óptima y cumpla con las expectativas de los usuarios, entre los puntos a destacar se propone lo siguiente.

- **Actualización:** Es importante mantener actualizado las dependencias y bibliotecas utilizadas, esto nos permitirá aprovechar las últimas características, mejorar de seguridad y correcciones de errores.
- **Respaldos y recuperación de datos:** Implementar un plan de respaldo de la aplicación web, dataset, modelo preentrenado y recuperación de datos solidos para garantizar la integridad y disponibilidad de los datos en la aplicación web.
- **Mejoras funcionales:** Considerar mejoras en la experiencia de usuario y tendencias recientes relacionadas con técnicas de aprendizaje automático, corrección de errores reportados por usuarios.

Para verificar la norma ISO/IEC/IEEE 29148:2018, se puede evidenciar el proceso de desarrollo del aplicativo web, se detalla a través de la metodología en cascada, que cumple con lo establecido desde la fase de análisis hasta la fase de mantenimiento del producto final.

CAPITULO III

3 Análisis de resultados

La detección de maleza en cultivos de maíz y/o papas es un desafío crucial para garantizar la salud y el rendimiento óptimo de los cultivos. Bajo este contexto, las redes neuronales convolucionales han emergido como una herramienta prometedora para abordar este problema de manera eficiente, están diseñadas para procesar datos de manera similar al sistema visual humano, lo que hace particularmente efectivas en tareas de visión por computadora, como la detección de objetos en imágenes (Ríos, 2021).

3.1 Métricas del modelo Faster R-CNN

3.1.1 Línea de tiempo del modelo entrenado

En el proceso, se realizó varios entrenamientos del modelo, donde se ha podido incorporar varios parámetros e hiperparámetros con el objetivo de mejorar los resultados del modelo por defecto, de tal forma nos permitió obtener un modelo inicial y un final para realizar varias comparaciones en cuanto a su precisión y rendimiento. Para el entrenamiento del modelo se consideró experimentar con los Datasets obtenidos, para la obtención de los resultados se dividió en 2 fases.

3.1.1.1 Fase 1 (Dataset #1 “Sin Balancear”)

Dentro de la Fase 1 se utilizará el concepto de trabajar con todas las imágenes obtenidas de los terrenos, bajo esta experimentación no se contempla el balance de clases, ya que se pretende evaluar el modelo mediante métricas de detección de objetos y observar su comportamiento en cuanto a precisión y rendimiento (RAM y GPU), a continuación, se detalla en la Tabla 33 los resultados obtenidos de esta primera Fase.

Tabla 33*Experimentaciones de la Fase 1, sin balanceo de clases*

Versión del modelo	Precisión	Recall	mAP	IOU	Hiperparámetros cambiados					Recursos	
					Tamaño de imagen	Batch Size	Épocas	Optimizador	Tiempo	GPU 40 Gigas	RAM 83.5 Gigas
1	0.512527555	0.506547899	0.506547079	0.661	400x400	32	30	ADAM	16'24"	32.9 GB	77.3 GB
2	0.536934522	0.516578964	0.516578963	0.656	400x400	16	30	ADAM	15'36"	32.9 GB	77.3 GB
3	0.508767863	0.490259763	0.490259101	0.643	400x400	8	30	ADAM	18'22"	32.9 GB	65.3 GB
4	0.521259870	0.501457853	0.501457323	0.657	400x400	2	30	ADAM	22'50"	32.9 GB	65.3 GB
5	0.546447995	0.523079936	0.523079745	0.708	400x400	16	50	ADAM	26'50"	35.9 GB	65.3 GB
6	0.553698715	0.520143685	0.520143458	0.644	600x600	32	30	ADAM	16'30"	32.9 GB	81.5 GB
7	0.568657258	0.559637425	0.559637066	0.650	600x600	16	30	ADAM	19'14"	32.9 GB	73.3 GB
8	0.593395875	0.585259222	0.585259140	0.628	600x600	8	30	ADAM	20'42"	32.9 GB	73.3 GB
9	0.540589302	0.536587007	0.536587331	0.633	600x600	2	30	ADAM	31'09"	32.9 GB	77.3 GB
10	0.581458730	0.577854209	0.577854367	0.681	600x600	16	50	ADAM	42'18"	35.9 GB	73.3 GB
11	0.614717668	0.601382114	0.601380910	0.655	800X800	32	30	ADAM	17'15"	39.1 GB	81.5 GB

12	0.603691472	0.597812357	0.597812963	0.651	800X800	16	30	ADAM	22'02"	39.1 GB	73.3 GB
13	0.595327926	0.573690050	0.573690784	0.643	800X800	8	30	ADAM	21'28"	35.9 GB	52.0 GB
14	0.613775380	0.600048927	0.600048357	0.648	800X800	2	30	ADAM	25'33"	32.9 GB	73.3 GB
15	0.604698701	0.599896482	0.599896900	0.649	800X800	16	50	ADAM	42'59"	39.1 GB	81.5 GB
16	--	--	--	--	1080X1080	32	30	ADAM	--	SOBREPASO	SOBREPASO
17	--	--	--	--	1080X1080	16	30	ADAM	--	SOBREPASO	SOBREPASO
18	0.583651236	0.558454108	0.558454968	0.610	1080X1080	8	30	ADAM	44'36"	39.1 GB	81.5 GB
19	0.598355641	0.569651482	0.569651055	0.622	1080X1080	2	30	ADAM	58'26"	39.1 GB	81.5 GB
20	0.583154558	0.563578520	0.563578997	0.660	1080X1080	8	50	ADAM	40'12"	37.9 GB	81.5 GB

Nota. Datos obtenidos de diferentes experimentaciones con la arquitectura Faster R-CNN con Dataset sin balancear.

Una vez obtenidos los resultados, se puede evaluar el rendimiento del modelo, para elegir un modelo óptimo se consideró las métricas principales de la Tabla 33, las métricas utilizadas para determinar el rendimiento del modelo son: entrenamiento, validación y resultados finales, se incluye la precisión, Recall y mAP.

3.1.1.2 Fase 2 (Dataset #2 “Balanceado”)

Dentro de la Fase 2 se realizó un equilibrio de clases del Dataset original contemplando el mayor número de etiquetas de las clases, se pretende evaluar el modelo mediante métricas de detección de objetos y observar su comportamiento en cuanto a precisión y rendimiento (RAM y GPU), a continuación, se detalla en la Tabla 34 los resultados obtenidos de esta segunda Fase.

Tabla 34*Experimentaciones de la Fase 2, con balanceo de clases*

Versión del modelo	Precisión	Recall	mAP	IOU	Hiperparámetros cambiados					Recursos	
					Tamaño de imagen	Batch Size	Épocas	Optimizador	Tiempo	GPU 40 Gigas	RAM 83.5 Gigas
1	0.596425168	0.577978169	0.577978186	0.541	400x400	32	20	ADAM	15'18"	35.9 GB	77.3 GB
2	0.616684962	0.589412801	0.589412780	0.656	400x400	16	30	ADAM	14'25"	35.9 GB	77.3 GB
3	0.585087651	0.562426197	0.562426211	0.443	400x400	8	10	ADAM	15'08"	35.9 GB	77.3 GB
4	0.591285970	0.571487365	0.571487988	0.617	400x400	2	40	ADAM	20'14"	35.9 GB	77.3 GB
5	0.617896521	0.592008965	0.592002571	0.628	400x400	16	50	ADAM	25'36"	35.9 GB	65.3 GB
6	0.583386432	0.56753263	0.564753158	0.650	600x600	32	50	ADAM	16'15"	32.9 GB	81.5 GB
7	0.568796521	0.558563412	0.558563755	0.549	600x600	16	20	ADAM	15'42"	32.9 GB	77.3 GB
8	0.594675169	0.586951129	0.586951136	0.639	600x600	8	30	ADAM	19'52"	32.9 GB	77.3 GB
9	0.546116929	0.534204912	0.534204940	0.632	600x600	2	10	ADAM	29'33"	32.9 GB	73.3 GB
10	0.587836902	0.572583570	0.57258994	0.651	600x600	16	40	ADAM	41'00"	35.9 GB	73.3 GB
11	0.713072495	0.697603252	0.697601856	0.759	800X800	32	30	ADAM	18'45"	35.9 GB	81.5 GB

12	0.700282108	0.693462334	0.693463037	0.639	800X800	16	20	ADAM	19'36"	35.9 GB	77.3 GB
13	0.690580394	0.667214815	0.667214825	0.514	800X800	8	10	ADAM	19'56"	35.9 GB	52.0 GB
14	0.711979441	0.696056755	0.696056094	0.751	800X800	2	50	ADAM	20'45"	35.9 GB	73.3 GB
15	0.701450493	0.695879919	0.695880404	0.753	800X800	16	40	ADAM	38'05"	39.1 GB	81.5 GB
16	--	--	--		1080X1080	32	10	ADAM	--	SOBREPASO	SOBREPASO
17	--	--	--		1080X1080	16	20	ADAM	--	SOBREPASO	SOBREPASO
18	0.5536421036	0.541687249	0.541687928	0.571	1080X1080	8	30	ADAM	46'38"	39.1 GB	81.5 GB
19	0.5489247896	0.540105037	0.540105885	0.549	1080X1080	2	40	ADAM	52'36"	39.1 GB	81.5 GB
20	0.5387965321	0.524986512	0.524986357	0.569	1080X1080	8	50	ADAM	44'14"	39.1 GB	81.5 GB

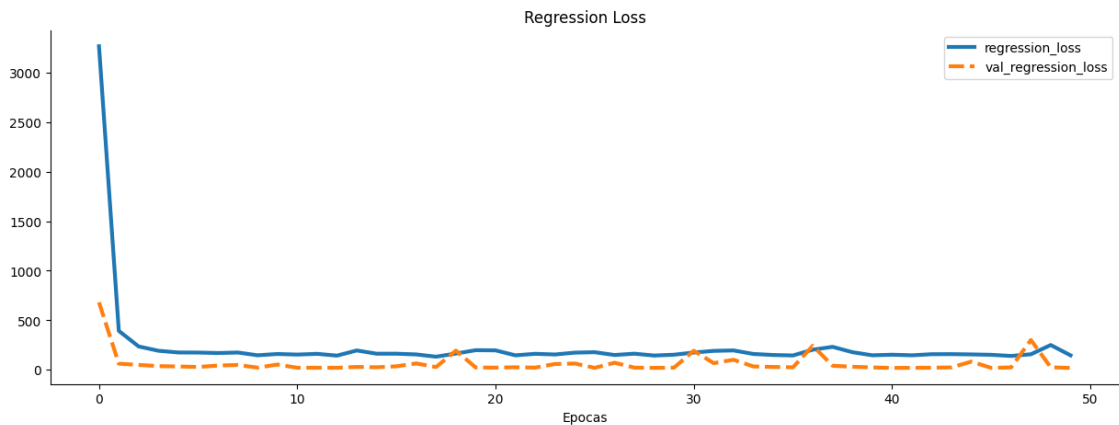
Nota. Datos obtenidos de diferentes experimentaciones con la arquitectura Faster R-CNN con Dataset balanceado.

3.1.2 Fases de entrenamiento

3.1.2.1 Perdida de caja

Muestra que tan bien predice el modelo la ubicación y el tamaño de las cajas limitadoras de las malezas. En la gráfica se puede apreciar como en la fase inicial el modelo aprende a detectar correctamente los bordes de las cajas limitadoras en las primeras épocas para los datos de entrenamiento mientras que con los datos de validación aumenta conforme avanzan las épocas del entrenamiento, como se muestra en la Figura 44.

Figura 44
Regresión Loss




Nota. Elaboración propia.

3.1.2.2 Perdida de clasificación

Muestra la precisión con la que el modelo distingue las malezas de otros objetos, en este caso la planta de papa. Además, se puede observar que la velocidad de aprendizaje es mayor en las primeras épocas del entrenamiento lo cual indica que el modelo aprende de manera eficaz como distinguir y clasificar correctamente las plantas que poseen características distintas, y que tarda más en distinguir las plantas que tiene un parecido en color y forma, como se muestra en la Figura 45.

Figura 45

Classification Loss




Nota. Elaboración propia

3.1.2.3 Classification Accuracy

Precisión en la clasificación: muestra la precisión media de la predicción de las diferentes categorías de las plantas. En la Figura 46 se puede observar cómo los valores para el set de entrenamiento, así como los valores para el set de validación se encuentran muy cercanos, con lo que se observa que no existe ni overfitting ni underfitting, con lo que se puede concluir que el modelo está aprendiendo y no memorizando.

Figura 46

Classification Accuracy

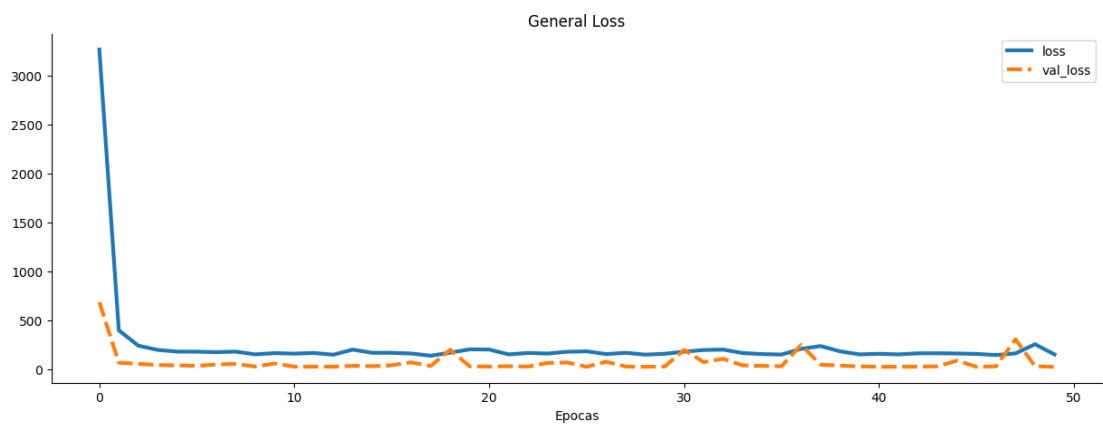


Nota. Elaboración propia.

3.1.2.4 Perdida General del modelo

Muestra la precisión de la detección de los bordes de las cajas limitadoras, así como también la precisión de la clasificación, al mantenerse combinadas las pérdidas se puede apreciar como aprenden conjuntamente detección y clasificación y como su velocidad de aprendizaje disminuye al transcurrir las épocas, como se muestra en la Figura 47.

Figura 47
General Loss



Nota. Elaboración propia.

Estas métricas nos permitieron ajustar los parámetros del modelo, estos cambios nos permitieron enfocarnos en identificar las malezas con mejores resultados, reduciendo el consumo de recursos computacionales y así también reduciendo el tiempo de entrenamiento.

3.1.3 Fase de validación

En la fase de validación, se tomaron en cuenta las métricas de pérdida, pero en un conjunto de datos que no se utilizó en el entrenamiento, el objetivo de esta prueba fue para comprobar si el modelo final era capaz de generalizar su aprendizaje a nuevas situaciones (Flores-Calero et al., 2022), con ello podríamos evitar el sobreajuste del modelo y asegurar que el modelo sea capaz de identificar patrones correctamente de malezas en nuevas imágenes.

3.1.4 Fase de Resultados

En la fase de resultados, se tomó en cuenta las métricas como precisión, el Recall, el mAP, IoU, matriz de confusión, para determinar la efectividad del modelo al clasificar las plantas detectadas.

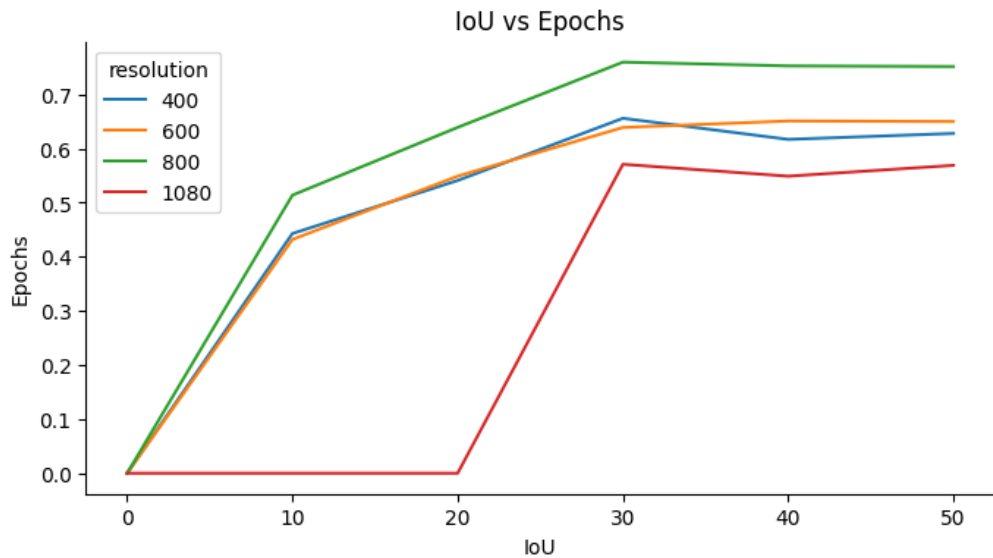
3.1.4.1 IoU (*Interseccion over Union*)

Esta métrica se calcula dividiendo el área de superposición entre la caja delimitadora de predicción y la caja delimitadora real (Etiqueta original) por el área de la unión de ambas cajas (Torres-López et al., 2024), su fórmula es la siguiente:

$$IoU = \frac{\text{Área de intersección}}{\text{Área de union}}$$

Para determinar la exactitud de los bordes de las cajas que encierran a las plantas detectadas. En la gráfica se puede apreciar como el modelo aprende a detectar correctamente los bordes de las cajas limitadoras en las primeras épocas y la precisión aumenta conforme avanzan las épocas del entrenamiento, como se muestra en la Figura 48.

Figura 48
IoU vs Epochs



Nota. Elaboración propia.

3.1.4.2 Precisión


Mientras el modelo tenga un índice alto de precisión, se puede decir que el modelo tiene un buen desempeño en identificar correctamente las malezas, minimizando la identificación incorrecta de objetos que no son malezas (Davis & Goadrich, 2006). La gráfica elaborada presenta el cambio en la precisión obtenida para los diferentes modelos según la variación de sus hiperparámetros la cual presenta mejores valores para la versión de 800x800, como se muestra en la Figura 49.

Para obtener la precisión se utiliza la siguiente fórmula en donde:

- **Verdaderos positivos (VP):** Los casos en donde el modelo predijo como positivos y que en realidad son positivos.
- **Falsos positivos (FP):** Los casos en donde el modelo predijo como positivos, pero en realidad son negativos.

$$\text{Precisión} = \frac{\text{Verdaderos positivos (VP)}}{\text{Verdaderos positivos (VP)} + \text{Falsos positivos (FP)}}$$

Figura 49
Gráfica Precision vs Epochs



Nota. Elaboración Propia.

3.1.4.3 Recall

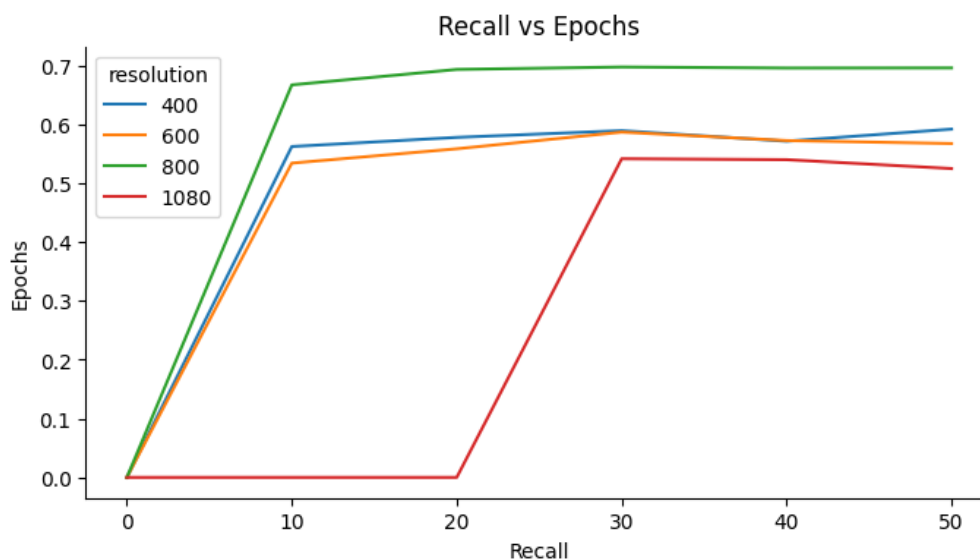
Es una métrica de medición que se utiliza para medir la capacidad del modelo de identificar las instancias positivas, en este caso identificar la mayoría de las malezas presentes en la imagen (Torgo & Ribeiro, 2009), el Recall se calcula con la siguiente formula en donde:

- **Verdaderos positivos (VP):** Son los casos que el modelo predijo correctamente como positivos
- **Falsos negativos (FN):** Son los casos que el modelo predijo incorrectamente como negativos, pero en realidad son positivos

$$Recall = \frac{Verdaderos\ positivos\ (VP)}{Verdaderos\ positivos\ (VP) + Falsos\ negativos\ (FN)}$$

La gráfica elaborada presenta el cambio en la Recall(sensibilidad) obtenida para los diferentes modelos según la variación de sus hiperparametros la cual presenta mejores valores para la versión de 800x800, como se muestra en la Figura 50.

Figura 50
Grafica Recall vs Epochs

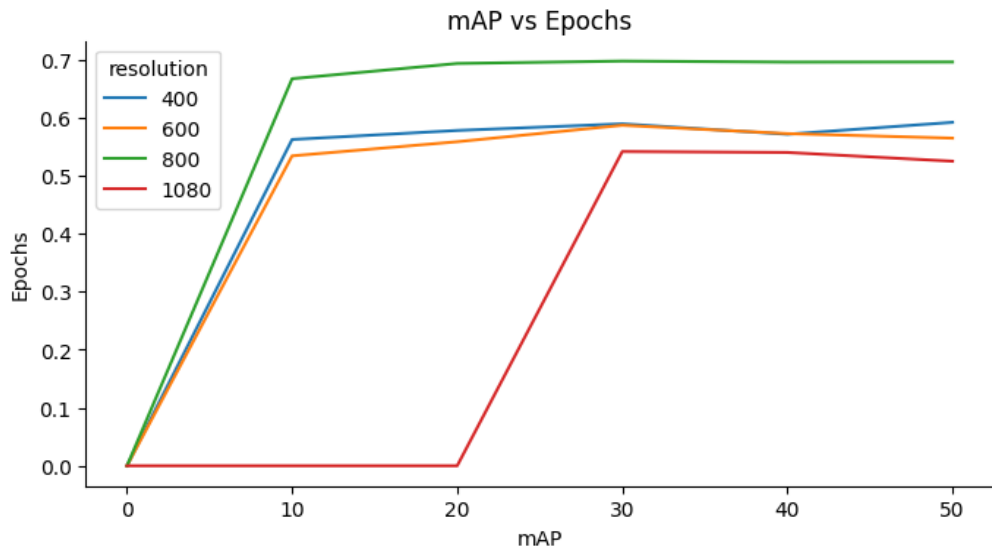


Nota. Elaboración propia.

3.1.4.4 mAP

Las métricas de precisión y Recall son importantes para determinar la efectividad del modelo en la identificación correcta de malezas y en minimizar los falsos positivos, mientras tanto con la métrica mAP se pudo evaluar la precisión y el Recall en varios umbrales de confianza, como resultado se pudo ver el rendimiento del modelo en diferentes condiciones, con esto se puede confirmar la aplicabilidad del modelo en la detección de malezas en diferentes entornos (Zapeta Hernández et al., 2022). La gráfica muestra el cambio en el mAP para los diferentes modelos según la variación de sus hiperparametros, la cual presenta mejores valores para la versión de 800x800, como se muestra en la Figura 51.

Figura 51
Grafica mAP vs Epochs



Nota. Elaboración propia.

3.2 Comparación del modelo con métodos tradicionales

Se realiza una comparación con el método tradicional que son aplicados por agricultores en la detección de malezas en diversas plantaciones, en este caso las plantaciones de papa y el método propuesto por uso de drones utilizando la arquitectura Faster R-CNN alojado en una aplicación web.

3.2.1 Inferencias y resultados

En el desarrollo del proyecto y tras haber realizado las experimentaciones correspondientes se entrenó y desplegó el aplicativo web, se realizó interpretaciones en algunas imágenes del dataset, se dibujaron recuadros limitadores correspondientes a las etiquetas de la imagen y se comparó con la interpretación realizada por el aplicativo web.

3.2.1.1 Prueba 1 de inferencia

En la Tabla 35 se detalla el resultado de inferencia realizada por un agricultor frente a los resultados obtenidos por el aplicativo web, también se muestra la comparativa de la experimentación en la Figura 52.

Tabla 35
Resultado de inferencia Prueba 1.

Imágenes etiquetadas	Imágenes con inferencia (Etiquetas correctas)	Resultado Modelo vs Imágenes etiquetadas
Diente de león:0	Diente de león:1	# etiquetas adicionales correctas
Kikuyo:0	Kikuyo:4	7
Lenguas de vaca:0	Lenguas de vaca:2	# etiquetas adicionales incorrectas
Otros:0	Otros:0	
Papa:104	Papa:99	4
Plantas totales:104	Plantas totales:115	

Nota. Elaboración propia.

Figura 52
Resultado de inferencia Prueba 1.



Nota. Elaboración propia.

3.2.1.2 Prueba 2 de inferencia

En la Tabla 36 se detalla el resultado de inferencia realizada por un agricultor frente a los resultados obtenidos por el aplicativo web, también se muestra la comparativa de la experimentación en la Figura 53.

Tabla 36
Resultados de inferencia Prueba 2.

Imágenes etiquetadas	Imágenes con inferencia (Etiquetas correctas)	Resultado Modelo vs Imágenes etiquetadas
Diente de león:0	Diente de león:19	# etiquetas adicionales correctas
Kikuyo:0	Kikuyo:1	5
Lenguas de vaca:0	Lenguas de vaca:1	# etiquetas adicionales
Otros:0	Otros:30	incorrectas
Papa: 191	Papa:147	3
Plantas totales:191	Plantas totales:198	

Nota. Elaboración propia.

Figura 53
Resultados de inferencia Prueba 2.



Nota. Elaboración propia.

3.2.1.3 Prueba 3 de inferencia


En la Tabla 37 se detalla el resultado de inferencia realizada por un agricultor frente a los resultados obtenidos por el aplicativo web, también se muestra la comparativa de la experimentación en la Figura 54.

Tabla 37
Resultados de inferencia Prueba 3.

Imágenes etiquetadas	Imágenes con inferencia (Etiquetas correctas)	Resultado Modelo vs Imágenes etiquetadas
Diente de leon:0	Diente de leon:0	# etiquetas adicionales correctas
Kikuyo:0	Kikuyo:1	5
Lenguas de vaca:0	Lenguas de vaca:7	# etiquetas adicionales incorrectas
Otros:0	Otros:0	
Papa:112	Papa:102	4
Plantas totales:112	Plantas totales:121	

Nota. Elaboracion propia.

Figura 54
Resultados de inferencia Prueba 3.



Nota: Elaboración propia.

3.2.1.4 Prueba 4 de inferencia

En la Tabla 38 se detalla el resultado de inferencia realizada por un agricultor frente a los resultados obtenidos por el aplicativo web, también se muestra la comparativa de la experimentación en la Figura 55.

Tabla 38
Resultados de inferencia Prueba 4.

Imágenes etiquetadas	Imágenes con inferencia (Etiquetas correctas)	Resultado Modelo vs Imágenes etiquetadas
Diente de leon:0	Diente de leon:5	# etiquetas adicionales correctas
Kikuyo:0	Kikuyo:3	3
Lenguas de vaca:11	Lenguas de vaca:9	# etiquetas adicionales incorrectas
Otros:0	Otros:0	
Papa:40	Papa:38	1
Plantas totales:51	Plantas totales:55	

Nota. Elaboración propia.

Figura 55
Resultados de inferencia Prueba 4.



Nota. Elaboración propia.

3.2.1.5 Prueba 5 de inferencia


En la Tabla 39 se detalla el resultado de inferencia realizada por un agricultor frente a los resultados obtenidos por el aplicativo web, también se muestra la comparativa de la experimentación en la Figura 56.

Tabla 39
Resultados de inferencia Prueba 5.

Imágenes etiquetadas	Imágenes con inferencia (Etiquetas correctas)	Resultado Modelo vs Imágenes etiquetadas
Diente de leon:6	Diente de leon:8	# etiquetas adicionales correctas
Kikuyo:64	Kikuyo:79	25
Lenguas de vaca:0	Lenguas de vaca:12	# etiquetas adicionales incorrectas
Otros:13	Otros:10	
Papa:0	Papa:8	9
Plantas totales:83	Plantas totales:117	

Nota. Elaboración propia.

Figura 56
Resultados de inferencia Prueba 5.



Nota. Elaboración propia.

Una vez obtenidas estas pruebas y comparaciones entre distintas imágenes se pudo observar que en cultivos donde existen mayor índice de plantas de papa y

lengua de vaca, la eficiencia del modelo incrementa debido a que existe un mayor contraste de color tanto entre las plantas, así como con el suelo; por otra parte, donde existe Kikuyo y diente de león la precisión baja de forma leve debido a la superposición de las distintas plantas. La precisión de la detección se relaciona con el contraste de colores, en imágenes en las que las plantas se encuentran espaciadas el color del suelo aumenta considerablemente, mientras que en imágenes en las que plantas se encuentran muy juntas o el suelo está seco, la precisión disminuye. Por otra parte, la precisión en la clasificación al depender de la precisión de la detección, mientras más acertada sea el área detectada la precisión de la clasificación aumenta como es esperado.

3.2.2 Métodos tradicionales

Estos métodos utilizados por agricultores consisten en realizar varios desplazamientos a pie a través del cultivo, con la finalidad de realizar una estimación visual de la presencia de malezas, este método es subjetivo y varía dependiendo el tipo de cultivo, su región geográfica, clima y experiencia del agricultor, dicho método permite calcular significativamente, sin embargo, existe posibilidad de estropear las plantas del cultivo para estimar.

3.2.3 Uso del modelo de detección de malezas con Dron

El uso de un vehículo aéreo no tripulado posee un proceso práctico en estimar las malezas dentro del cultivo, para realizar la detección de maleza inicia con un proceso de planificación, posterior se ejecuta el recorrido del dron permitiendo de esta forma capturar imágenes de los cultivos, con las imágenes recolectadas se cargan al aplicativo web Faster R-CNN para la cuantificación y detección de malezas existentes en la imagen. Por otro lado, este método nos permite cubrir grandes áreas en un tiempo reducido, también configurar parámetros de vuelos como su velocidad y altura, permitiendo una visión amplia y personalizada del estado del cultivo con respecto a las malezas.

3.2.4 Comparativa

Se realizó una comparativa entre el método tradicional para detección de malezas en cultivos de papa y el método tecnológico de uso del dron con aplicativo web Faster R-CNN, dentro de esta comparativa se tomó los siguientes parámetros: extensión del terreno, el tiempo total de detección de malezas.

Para la identificación de malezas con el método tradicional mostro limitaciones con respecto a las dimensiones y a la forma de desplazamiento en el terreno, se consideró que el agricultor tarda aproximadamente 5 segundos por metro cuadrado para analizar el cultivo, mientras para el modelo con el dron se consideró el tiempo de desplazamiento del terreno 1m/s por m^2 más el tiempo del procesamiento de las imágenes. A continuación, se detallan los siguientes resultados como se muestra en la Tabla 40.

Tabla 40
Tiempos de detección de malezas

Identificación del Terreno	Extensión (m²)	Método	Tiempo total (Minutos)	Diferencia (Minutos)
Terreno 1	800	Tradicional (Visual)	66'00''	35'12''
		Dron + Faster R-CNN	30'48''	
Terreno 2	650	Tradicional (Visual)	54'00''	25'56''
		Dron + Faster R-CNN	28'04''	
Terreno 3	730	Tradicional (Visual)	60'00''	30'35''
		Dron + Faster R-CNN	29'25''	
Terreno 4	500	Tradicional (Visual)	41'35''	16'01''
		Dron + Faster R-CNN	25'34''	
Terreno 5	1600	Tradicional (Visual)	133'20''	89'29''

		Dron + Faster R-CNN	43'51"	
Terreno 8	500	Tradicional (Visual)	41'35"	16'01"
		Dron + Faster R-CNN	25'34"	

Nota. Elaboración propia.

3.3 Pruebas estadísticas

3.3.1 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 Faster R-CNN con drones.

Desarrollo

Se utilizó la prueba T-Student, de las muestras relacionadas y el coeficiente de Pearson obteniendo 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 + Faster R-CNN.
- **H1:** Si hay inferencia estadísticamente significativa en el tiempo de detección entre el método tradicional entre el uso del método Dron + Faster R-CNN.

Resultados clave

En la Tabla 41 se detalla los resultados obtenidos de media y varianza con respecto a los tiempos de detección, por otro lado, en la Tabla 42 se detalla

el resultado obtenido de la prueba T-Student con respecto a los tiempos de detección, finalmente en la Tabla 43 se detalla los resultados obtenidos por la correlación de Pearson.

Tabla 41

Resultados Media y Varianza en tiempos de detección

Estadística	Método tradicional	Uso de Faster R-CNN y Dron
Media (Minutos)	61.83	29.72
Varianza (minutos)	1539.8	60.88

Nota. Elaboración propia.

Tabla 42

Prueba T-Student en tiempos de detección

Estadística	Valor
Media (Minutos)	110.23
Varianza (minutos)	0.406

Nota. Elaboración propia.

Tabla 43

Correlación de Pearson en tiempos de detección

Estadística	Valor
Coeficiente r	0.9998

Nota. Elaboración propia.

Conclusión

Los datos muestran una diferencia significativa en los tiempos de inspección a favor del uso de Faster R-CNN y dron ($t = 110.23$, $p = 0.406$). La alta correlación ($r = 0.9998$) indica una relación muy fuerte entre los tamaños de terreno inspeccionados con ambos métodos y la cantidad de plantas existentes. Los resultados justifican la implementación del método Faster R-CNN con drones por su mayor eficiencia.

3.3.2 T-Student en detección de malezas con Faster R-CNN 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 44.

Tabla 44

Muestra de comparación del modelo vs expertos

Nombre del Archivo	Cantidad de Malezas Etiquetas	Cantidad de Malezas Predichas
DJI_0664_JPG_jpg	36	25
DJI_0748_JPG_jpg	11	3
DJI_0721_JPG_jpg	105	53
DJI_0746_JPG_jpg	26	5
DJI_0821_JPG_jpg	48	13
DJI_0019_JPG_jpg	74	28
DJI_0743_JPG_jpg	40	4
DJI_0812_JPG_jpg	38	11
DJI_0955_JPG_jpg	102	38
DJI_0054_JPG_jpg	180	98
DJI_0979_JPG_jpg	29	22
00058_jpg	0	5
00094_jpg	0	0
00357_jpg	51	16
00387_jpg	74	41
00043_jpg	126	20
00112_jpg	0	0
00246_jpg	32	21
00055_jpg	40	25
00352_jpg	45	34
00001_jpg	2	0
00066_jpg	7	4

00280_jpg	79	32
00372_jpg	46	26

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 modelo Faster R-CNN + Dron.

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

En la Tabla 45 se detalla los resultados obtenidos de media y varianza con respecto a los tiempos de detección, por otro lado, en la Tabla 46 se detalla el resultado obtenido de la prueba T-Student con respecto a los tiempos de detección, finalmente en la Tabla 47 se detalla los resultados obtenidos por la correlación de Pearson.

Tabla 45*Resultados Media y Varianza de Dron + Faster R-CNN*

Estadística	Anotaciones Manuales	Detección Faster R- CNN
Media (Cantidad de malezas)	49.625	21.83
Varianza (Cantidad de malezas ²)	1895.651	456.22

Nota. Elaboración propia.**Tabla 46***T-Student Dron + Faster R-CNN*

Estadística	Valor
Valor t	8.204
Valor p	0.087
Valor (α)	0.05

Nota. Elaboración propia.**Correlación de Pearson**

Valores de correlación de Pearson

- **Muy débil:** 0.00 a 0.19
- **Débil:** 0.20 a 0.39
- **Moderada:** 0.40 a 0.59
- **Fuerte:** 0.60 a 0.79
- **Muy fuerte:** 0.80 a 1.00

Tabla 47*Correlación de Pearson Faster R-CNN*

Estadística	Valor
Coeficiente r	0.8681

Nota. Elaboración propia.**Conclusión**

La regla de decisión

Si $p - \text{value} (0.087) > 0.05$ entonces no se rechaza H_0 .

Este resultado indica que no hay una diferencia estadísticamente significativa entre las cantidades de malezas y lo que hemos supuesto como papas. El valor p es mayor que 0.05, lo que sugiere que el modelo ha otorgado buenos resultados, los cuales se pueden comparar a un experto en el área. La correlación entre las dos variables es 0.8681, lo que indica una muy fuerte correlación positiva. Esto sugiere que a medida que aumenta la cantidad de malezas etiquetadas, también tiende a aumentar la cantidad de malezas predichas por el modelo, y viceversa.

3.3.3 T-Student en detección de papas con Faster R-CNN vs expertos

Datos

Para realizar la comparación se hizo uso de la cantidad de etiquetas de papa correctas realizadas por el modelo Faster R-CNN y la cantidad de etiquetas de papa realizadas manualmente como se observa en la Tabla 48.

Tabla 48

T-Student en detección de papas con Faster R-CNN vs expertos.

Nombre del Archivo	Cantidad de papas Etiquetas	Cantidad de papas Predichas
DJI_0664_JPG_jpg	46	34
DJI_0748_JPG_jpg	40	33
DJI_0721_JPG_jpg	266	145
DJI_0746_JPG_jpg	132	72
DJI_0821_JPG_jpg	341	115
DJI_0019_JPG_jpg	0	0
DJI_0743_JPG_jpg	220	95
DJI_0812_JPG_jpg	175	83
DJI_0955_JPG_jpg	0	1
DJI_0054_JPG_jpg	0	0
DJI_0979_JPG_jpg	0	0
00058_jpg	104	99

00094_.jpg	180	156
00357_.jpg	13	2
00387_.jpg	15	3
00043_.jpg	159	79
00112_.jpg	161	159
00246_.jpg	0	0
00055_.jpg	118	90
00352_.jpg	6	1
00001_.jpg	104	99
00066_.jpg	91	70
00280_.jpg	14	4
00372_.jpg	14	0

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 Faster R-CNN + 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 Faster R-CNN + Dron, se hizo uso de las fórmulas estándar para la prueba T-Student y la correlación de Pearson.

Resultados clave

En la Tabla 49 se detalla los resultados obtenidos de media y varianza con respecto a los tiempos de detección, por otro lado, en la Tabla 50 se detalla el resultado obtenido de la prueba T-Student con respecto a los tiempos de detección, finalmente en la Tabla 51 se detalla los resultados obtenidos por la correlación de Pearson.

Tabla 49

Resultados Media y Varianza en detección de papas con Faster R-CNN vs expertos

Estadística	Anotaciones Manuales	Detección Faster R-CNN
Media (Cantidad de malezas)	91.625	55.833
Varianza (Cantidad de malezas ²)	8915.817	2969.472

Nota. Elaboración propia.

Tabla 50

Prueba T-Student en detección de papas con Faster R-CNN vs expertos.

Estadística	Valor
Valor t	8.072
Valor p	0.051
Valor (α)	0.05

Nota. Elaboración propia.

Correlación de Pearson

Valores de correlación de Pearson

- **Muy débil:** 0.00 a 0.19
- **Débil:** 0.20 a 0.39
- **Moderada:** 0.40 a 0.59
- **Fuerte:** 0.60 a 0.79

- **Muy fuerte:** 0.80 a 1.00

Tabla 51

Resultado de correlación en detección de papas con Faster R-CNN vs expertos.

Estadística	Valor
Coeficiente r	0.8646

Nota. Elaboración propia.

Conclusión

La regla de decisión

Si $p - \text{value} (0.051) > 0.05$ entonces no se rechaza H_0 .

Este resultado indica que no hay una diferencia estadísticamente significativa entre las cantidades de papas etiquetadas y lo que el modelo ha clasificado como papas. El valor p es mayor que 0.05, lo que sugiere que el modelo ha otorgado buenos resultados, los cuales se pueden comparar a un experto en el área. La correlación entre las dos variables es 0.8646, lo que indica una muy fuerte correlación positiva. Esto sugiere que a medida que aumenta la cantidad de papas etiquetadas, también tiende a aumentar la cantidad de papas predichas por el modelo, y viceversa.

3.3.4 T-Student en detección de plantas con Faster R-CNN vs expertos

Datos

Para la comparación se utilizó la cantidad de etiquetas de plantas correctas realizadas por el modelo Faster R-CNN y la cantidad de etiquetas de plantas realizadas manualmente como se observa en la Tabla 52.

Tabla 52

Comparación de modelo Faster R-CNN vs expertos.

Nombre del Archivo	Cantidad de plantas Etiquetas	Cantidad de plantas Predichas
---------------------------	--	--

DJI_0664_JPG_jpg	222	142
DJI_0748_JPG_jpg	51	36
DJI_0721_JPG_jpg	371	198
DJI_0746_JPG_jpg	196	77
DJI_0821_JPG_jpg	300	128
DJI_0019_JPG_jpg	74	18
DJI_0743_JPG_jpg	260	99
DJI_0812_JPG_jpg	213	94
DJI_0955_JPG_jpg	102	68
DJI_0054_JPG_jpg	180	98
DJI_0979_JPG_jpg	88	67
00058_jpg	104	99
00094_jpg	180	156
00357_jpg	74	48
00387_jpg	90	41
00043_jpg	285	99
00112_jpg	161	159
00246_jpg	70	48
00055_jpg	158	115
00352_jpg	51	34
00001_jpg	104	99
00066_jpg	98	74
00280_jpg	94	32
00372_jpg	60	34

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 Faster R-CNN + 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 Faster R-CNN + Dron, se hizo uso de las fórmulas estándar para la prueba T-Student y la correlación de Pearson.

Resultados clave

Tabla 53
Resultados Media y Varianza

Estadística	Método tradicional	Uso de Faster R-CNN y Dron
Media (Cantidad de malezas)	149.416	85.958
Varianza (Cantidad de malezas ²)	7516.076	2111.206

Nota. Elaboración propia.

Tabla 54
Prueba T de Student

Estadística	Valor
Valor t	5.917
Valor p	0.059
Valor (α)	0.05

Nota. Elaboración propia

Correlación de Pearson

Valores de correlación de Pearson

- **Muy débil:** 0.00 a 0.19
- **Débil:** 0.20 a 0.39
- **Moderada:** 0.40 a 0.59
- **Fuerte:** 0.60 a 0.79
- **Muy fuerte:** 0.80 a 1.00

Tabla 55
Correlación de Pearson

Estadística	Valor
Coeficiente r	0.7837

Nota. Elaboración propia

Conclusión

La regla de decisión

Si $p - \text{value} (0.059) > 0.05$ entonces no se rechaza H_0 .

Este resultado indica que no hay una diferencia estadísticamente significativa entre las cantidades de plantas etiquetadas y lo que el modelo ha predicho. El valor p es mayor que 0.05, lo que sugiere que el modelo ha otorgado buenos resultados, los cuales se pueden comparar a un experto en el área. La correlación entre las dos variables es 0.7837, lo que indica una fuerte correlación positiva. Esto sugiere que a medida que aumenta la cantidad de plantas etiquetadas, también tiende a aumentar la cantidad de plantas predichas por el modelo, y viceversa.

3.4 Nivel de infestación

Para medir el nivel de infestación se consideró lo siguiente: dentro del método tradicional se puede evidenciar variabilidad y subjetividad para ello se ha considerado la experiencia y percepción del agricultor, mientras que en el uso de drones y el modelo Faster R-CNN proporciona resultados más objetivos y consistentes para la detección de malezas, ya que tiene la capacidad de procesar gran cantidad de

imágenes y clasificar malezas de forma automatizada, para calcular el nivel de infestación se utilizó la siguiente fórmula:

- IIM= Índice de infestación de malezas
- NMI=Número de malezas por imagen
- NTPI=Número total de plantas por imagen

$$IIM = \left(\frac{NMI}{NTPI \text{ (Malezas+papas)}} \right) \times 100$$

Bajo nivel de infestación: El IIM de hasta 20% podría considerarse bajo, considerando que las malezas están presentes, pero probablemente no afecten significativamente el desarrollo del cultivo.

Medio nivel de infestación: EL IIM de 20% a 50% podría considerarse medio, contemplando que las malezas podrían estar empezando a competir con el cultivo por recursos y podrían afectar significativamente al cultivo si no se maneja correctamente.

Alto nivel de infestación: El IIM de 50% a 100% podría considerarse alto, contemplando que existe una fuerte competencia con el cultivo y un posible un impacto en el desarrollo de las plantas de papa.

A continuación, se detalla los resultados de infestación por cada terreno, como se detalla en la Tabla 56.

Tabla 56
Niveles de infestación de los terrenos

Identificación del Terreno	Extensión (m ²)	Método	Nivel de afectación
Terreno 1	800	Tradicional (Visual)	Bajo
		Dron + Faster R-CNN	Medio
Terreno 2	650	Tradicional (Visual)	Bajo
		Dron + Faster R-CNN	Bajo

Terreno 3	730	Tradicional (Visual)	Medio
		Dron + Faster R-CNN	Alto
Terreno 4	500	Tradicional (Visual)	Alto
		Dron + Faster R-CNN	Alto
Terreno 5	1600	Tradicional (Visual)	Alto
		Dron + Faster R-CNN	Medio
Terreno 8	500	Tradicional (Visual)	Alto
		Dron + Faster R-CNN	Medio

Nota. Elaboración propia.

3.5 Discusiones

En la propuesta de la arquitectura Faster R-CNN para la identificación de malezas en cultivos de maíz y/o papa se consideró utilizar el modelo predeterminado de la versión Faster R-CNN año 2015, esta versión fue el punto de partida para realizar comparaciones con otras versiones de otros autores, la mayoría de los trabajos relacionados manejan conjuntos de datos robustos, ya que tiende a dar mejores resultados.

En este proyecto se obtuvo 2 conjuntos de datos, ambos fueron obtenidos de diferente manera, considerando que teníamos datos diferentes se propone unir ambos conjuntos de datos para tener diversidad de ejemplares en perspectivas diferentes (Insfrán et al., 2024), por tanto, se considera entrenar el modelo con el Dataset original y crear un nuevo Dataset aplicando una técnica de balance de clases, para este proceso se eliminó imágenes completas para evitar pérdida de información sobre las clases excesivas.

El resultado de experimentaciones sobre el Dataset original no fue tan satisfactorio, se puede ver los resultados en la Tabla 33, mostraron métricas bajas a

comparaciones de otros modelos de detección de objetos, también se añade que al contar con datos desbalanceados puede crear confusiones dando prioridad a la clase con más anotaciones, mientras que para la experimentación con el Dataset balanceado se pudo notar un cambio significativo en las métricas, esto se debe a que cuando las clases mantienen equilibrio de anotaciones ayuda a mejorar la sensibilidad y la precisión del modelo, por ende bajo el entrenamiento del modelo obliga a aprender y a distinguir todas las clases por igual, esto es apropiado para que el modelo pueda reconocer y aprender patrones significativos y no solo se limite a memorizar. De esta experimentación contemplando los resultados de la Tabla 34 y bajo el análisis de las métricas se puede decir que las versiones con mejores resultados fueron las que tenían un recorte de 800x800 y entre las más destacadas por sus valores fue la versión del modelo # 11 y se interpretó sus valores en entrenamiento como en validación. Para realizar una comparativa acertada se realizó una recopilación de artículos científicos que tengan métricas similares a la arquitectura Faster R-CNN para ser comparadas, como se muestra en la Tabla 57.

Tabla 57

Comparación de resultados con modelos de predicción

Modelo	Backbone	Precisión	Recall	IoU	mAP	Referencia
FASTER R-CNN	VGG19	0.71	0.69	0.75	0.69	Modelo resultante
FASTER R-CNN	PROPOSED FRAMEWORK	0.81	--	--	--	(Moustafa et al., 2024)
SSD	PROPOSED FRAMEWORK	0.74	--	--	--	(Moustafa et al., 2024)
FASTER R-CNN, FPN	RESTNET18	0.91	--	0.95	--	(Lyu et al., 2024)
SQUEEZENET	FIRE MODULES	0.65	0.85	--	--	(Zhang et al., 2024)
VGG16	--	0.70	0.87	--	--	(Zhang et al., 2024)
FASTER R-CNN	--	0.83	0.77	0.59	0.75	(Sumit et al., 2024)

FAST R-CNN	--	0.78	0.72	0.52	0.74	(Sumit et al., 2024)
MASK R-CNN	--	0.86	0.80	0.63	0.82	(Sumit et al., 2024)

Nota. Datos obtenidos de artículos científicos

Análisis de resultados

- Los modelos que conforman la Tabla 57 sus experimentaciones se basan en detección de objetos, fueron entrenados con diversos conjuntos de dataset, bajo esta comparativa se puede discutir que la arquitectura Faster R-CNN, FPN al tener valores altos tiene mayor efectividad, se debe a que presenta desvanecimiento del gradiente, permitiendo que los datos fluyan por las capas sin presentar perdida significativa de información, por otro lado, también presenta en su arquitectura Feature Pyramid Network (FPN) que genera características a múltiples resoluciones en diferentes niveles, mientras que en nuestro modelo no presenta (FPN) y está limitado a detectar objetos de diferentes tamaños y escalas de imagen complejas. Aun así, nuestro modelo en comparación al resto de modelos podemos decir que no fue el peor, ya que de cierta forma compite con la arquitectura VGG16.
- Tomando en cuenta que las arquitecturas SSD y SQUEEZENET son ideales para detección de objetos en tiempo real, su efectividad con base a las métricas es bastante buenas, ya que estos modelos no requieren una propuesta de región separada como Faster R-CNN, por tanto, obtienen valores más precisos y en menor tiempo.

Recolección del dataset

- Dentro de la recolección del conjunto de datos se pudo notar varias inconsistencias, una de ellas es el tipo de terreno, existen terrenos que contaban con papas, pero no cumplía con las condiciones necesarias para volar el dron, muchas veces eran inclinados, al sobrevolar el terreno íbamos

a presentar inconsistencias en la altura y provocando un desenfoque en la cámara al intentar mantener la altura programada.

- La sobrepoblación de malezas existentes en los terrenos, esto nos dificultaría la toma de muestras y la identificación de estas. La maleza al estar una encima de otra causaría confusión con otras plantas, ya que para este trabajo se utilizará la técnica de Bounding box.
- Luego de experimentar distintas circunstancias de vuelo lo mejor será combinar diversas modificaciones cuanto a su vuelo y su velocidad de vuelo, de cierta forma lograr condiciones favorables para obtener imágenes de calidad y sin desenfoque.

Implicaciones para Faster R-CNN / VGG19

- Una de las implicaciones de la arquitectura se debe a los requerimientos computacionales ya que, al intentar entrenar con un conjunto de datos masivo, el consumo de Memoria RAM y la GPU limitando el proceso de entrenamiento, esto implicaría dar por terminar la ejecución.
- Otra de las implicaciones es que existe en el modelo es su sensibilidad a la resolución de las imágenes, ya que puede afectar considerablemente a la identificación de objetos y presentar valores erróneos, por tanto, es necesario mantener filtros para mejorar el conjunto de datos y obtener un dataset legible.

3.6 CONCLUSIONES

- El modelo Faster R-CNN obtuvo una precisión del 0.71 como se muestra en la Tabla 34, se concluye que este resultado es considerado bueno y confiable en honor a las métricas obtenidas y las pruebas de validación en comparación con otros modelos de detección de objetos.
- La revisión literaria nos ha permitido crear un marco teórico robusto en relación de la agricultura y la tecnología, mediante esta revisión se logró entender los retos que manejaba la problemática, estudiar el comportamiento de las malezas, sus tipos y forma de propagación nos daba a entender que tipos de técnicas se puede emplear y que parámetros serán necesarios cambiarlos. Las preguntas de investigación llevo a buscar propuestas para solventar inquietudes como: las condiciones de vuelo, el desplazamiento del dron y la calidad de imagen, también era importante determinar que tipos de métricas se podía utilizar enfocado a nuestra problemática y arquitectura.
- Se desarrolló un aplicativo web utilizando el conjunto Stack MERN basada en la norma ISO/IEC/IEEE 29148:2018, esta norma propone seguir un proceso de ciclo del software, en consecuencia, la metodología en cascada se adapta correctamente porque sigue el desarrollo del software de manera secuencial, por otro lado se realizó una serie de experimentaciones en la arquitectura Faster R-CNN, se obtuvo la mejor versión validada por métricas que posterior fue anclado al aplicativo web para identificar malezas, el aplicativo web cubrió con todo el proceso de la norma y con su objetivo principal, el identificar y cuantificar las malezas de una imagen, al finalizar el proceso la aplicación muestra el total de número de malezas y el porcentaje de infestación de la imagen analizada.
- Después de validar los resultados de la propuesta se utilizó métricas de inteligencia artificial, se ha encontrado que la propuesta cumple con los objetivos esperados. Las métricas de precisión, Recall, mAP, IoU indican un desempeño robusto, lo que da mayor confiabilidad en la predicción referente a versiones anteriores, el mejor modelo se obtuvo de realizar las experimentaciones con el Dataset Equilibrado, el modelo favorecido con el resultando fue la versión #11 con una precisión de 0.71%, un mAP del 0.69%,

IoU del 0.75%. La estadística descriptiva utilizada muestra una distribución coherente de los datos y una baja variabilidad, lo que refuerza la confiabilidad de los resultados. Se realizó una comparativa entre varios modelos de detección de objetos de artículos científicos y se concluyó que el modelo de esta investigación tiene buenos resultados, también se realizó pruebas de T-Student, Correlación de Pearson que nos ayudaron contemplar el factor tiempo empleado así, si es factible o no el uso del aplicativo web, después de analizar los resultados estadísticos se puede concluir que no influye tanto subjetivamente, pero si influye en la reducción del tiempo, por tanto facilitara el trabajo de identificar al agricultor.

- Dentro de la propuesta ha sido satisfactoria el despliegue y el uso del aplicativo web cumpliendo con los requisitos esperados de la norma ISO/IEC/IEEE 29148:2018 de acuerdo con lo planificado.

3.7 RECOMENDACIONES

- Se recomienda que para futuras investigaciones se considere cambiar a una altura menor de vuelo del dron o considerar equipar el dron con una cámara con mejores características para este tipo de prácticas, esto beneficiara a la calidad de la imagen y evitar distorsión de las malezas y plantas en tempranas etapas de crecimiento.
- Se recomienda el uso de alternativas computaciones de alto rendimiento, como supercomputadoras para efectuar el entrenamiento de varias imágenes con múltiples clases, es posible que ni los recursos de paga (Google Colab PRO) sean suficientes para cubrir la demanda de datos en el entrenamiento, esto permitirá optimizar tiempo y realizar varias experimentaciones y trabajos de procesamiento simultáneos.
- Se recomienda incrementar el número de imágenes en el dataset, balancear las clases y verificar las etiquetas, mientras se agregue mayor número de imágenes para el entrenamiento, el modelo tendrá la capacidad de aprender nuevos patrones y mejorar significativamente su precisión.

BIBLIOGRAFIA

Adejo, O. (18 de 08 de 2023). Kanaries. Obtenido de Desplegando la arquitectura y eficiencia de Fast y Faster R-CNN para la detección de objetos: <https://docs.kanaries.net/es/topics/Python/fast-rcnn>

Aldana, Y. A. (2020). Drones y procesamiento de imágenes, una alternativa a la erradicación de malezas.

Ananth, S. (09 de 2019). Faster R-CNN for object detection. Obtenido de <https://towardsdatascience.com/faster-r-cnn-for-object-detection-a-technical-summary-474c5b857b46>

Atlassian. (2023). Atlassian. Obtenido de <https://www.atlassian.com/agile/project-management/waterfall-methodology>

Cardoza, C. G. (2006). El maíz: origen, composición química y morfología. Posgrado de Biomedicina Molecular, Escuela Nacional de Medicina y Homeopatía.

Dicyt. (30 de 05 de 2019). Drones para saber dónde aplicar herbicidas y combatir malezas. Obtenido de <https://www.dicyt.com/noticias/drones-para-saber-donde-aplicar-herbicidas-y-combatir-malezas>

DJI. (2024, 02 23). Retrieved from <https://www.dji.com/global/support/product/mavic-2>

Ekos. (08 de 02 de 2022). EKOS. Obtenido de Tecnologías destacadas en el sector agrícola: <https://ekosnegocios.com/articulo/tecnologias-destacadas-en-el-sector-agricola>

- Gómez, G. (02 de 09 de 2022). Infocampo. Obtenido de Infocampo:
<https://www.infocampo.com.ar/malezas-los-drones-marcan-un-camino-hacia-mas-eficiencia-y-menos-costos/>
- Huang-Nan, M. C. (20 de 09 de 2022). Image segmentation using transfer learning and Fast R-CNN for diabetic foot wound treatments. Obtenido de <https://doi.org/10.3389/fpubh.2022.969846>
- IBM. (07 de 08 de 2021). El modelo de redes neuronales. Obtenido de IBM:
<https://www.ibm.com/docs/es/spss-modeler/saas?topic=networks-neural-model>
- INIAP. (2002). El cultivo de la papa en Ecuador. Instituto Nacional de Investigaciones Agropecuarias, 224.
- Innova, G. (13 de 05 de 2016). Geo Innova. Obtenido de https://geoinnova.org/blog-territorio/drones-agricultura-una-herramienta-clave/?psafe_param=1&gad=1
- Ionos. (11 de 03 de 2019). IONOS. Obtenido de Digital guide:
<https://www.ionos.es/digitalguide/paginas-web/desarrollo-web/el-modelo-en-cascada/>
- Jarmin, S. (12 de 2020). Integration of the waterfall model with ISO/IEC/IEEE 29148:2018 for the development of military defense system. Obtenido de [10.1109/TLA.2020.9400437](https://doi.org/10.1109/TLA.2020.9400437)
- Jazmín, A. C. (2017). UNIVERSIDAD TÉCNICA DE COTOPAXI. Guía fotográfica de las plantas útiles de la familia.

Karmarkar, T. (05 de 2020). Region Proposal Network (RPN) — Backbone of Faster R-CNN. Obtenido de <https://doi.org/10.1016/j.compag.2020.105791>

Laoyan, S. (22 de 07 de 2022). Asana. Obtenido de <https://asana.com/es/resources/waterfall-project-management-methodology>

Li, B. (12 de 2022). Automatically classifying non-functional requirements using deep neural network. Obtenido de ScienceDirect: <https://doi.org/10.1016/j.patcog.2022.108948>

Llanque, A. (05 de 2022). ReCIBE. Obtenido de <http://recibe.cucei.udg.mx/index.php/ReCIBE/article/view/242>

MAG. (2024). Ministerio de Agricultura y Ganadería. Obtenido de El ensilaje garantiza el alimento para el ganado: <https://www.agricultura.gob.ec/el-ensilaje-garantiza-el-alimento-para-el-ganado/>

Mariño, G. (2020). Prototipo de aplicación móvil para la optimización de rutas mediante mecanismos de inteligencia artificial. Obtenido de unab: <http://hdl.handle.net/20.500.12749/14342>

Mateo Gašparović, M. Z. (06 de 2020). An automatic method for weed mapping in oat fields based on UAV imagery. Obtenido de Computers and Electronics in Agriculture: <https://doi.org/10.1016/j.compag.2020.105385>

Menacho, C. (2014). Universidad Nacional Agraria La Molina. Obtenido de Modelos de regresión lineal con redes neuronales: <https://doi.org/10.21704/ac.v75i2.961>

Microsoft. (13 de 10 de 2022). Microsoft. Obtenido de Detección de objetos mediante R-CNN más rápida: <https://learn.microsoft.com/es-es/cognitive-toolkit/object-detection-using-faster-r-cnn>

Microsoft. (13 de 10 de 2022). Object detection using Faster R-CNN. Obtenido de <https://learn.microsoft.com/en-us/cognitive-toolkit/object-detection-using-faster-r-cnn>

Revistaseguridad360. (03 de 01 de 2022). Obtenido de <https://revistaseguridad360.com/destacados/drones-para-agricultura/>

Ríos-Hernández, R. (2021). Use of Drones or Unmanned Aerial Vehicles in Precision Agriculture.

Rivera, M. G. (2022). Factores que afectan a la producción agrícola. Factores que afectan a la producción agrícola.

Roma. (2018). Transformar la alimentación y la agricultura para alcanzar los ODS.

Romero, J. J. (2022). Universidad Nacional de Educación a Distancia. Obtenido de Creación de una red neuronal artificial para predecir el comportamiento de las plataformas MOOC sobre la agenda 2030 y los objetivos para el desarrollo sostenible: <https://orcid.org/0000-0003-1375-2028>

Rosales. (2007). Manejo de Malezas en la agricultura Orgánica. Intagri, 5. Obtenido de Intagri: <https://www.intagri.com/articulos/agricultura-organica/manejo-de-malezas-en-la-agricultura-organica>

- Rubione, C., & Wojszko, A. (2021). Maleza en Foco. Obtenido de Propagación: <https://www.malezaenfoco.com/resistencia-a-herbicidas/como-se-propagan-las-malezas-resistentes-a-los-herbicidas/>
- Saska, Werf, V. D., Vries, D., & Westerman. (2008). Spatial and temporal patterns of carabid activity-density in cereals do not explain levels of predation on weed seeds. *Bulletin of Entomological Research*.
- Wang, C. (2019). Pulmonary Image Classification Based on Inception-v3 Transfer Learning Model. Obtenido de <https://ieeexplore.ieee.org/document/8861312>
- Zambrano, T. (01 de 2020). La inteligencia artificial en la calidad del software: una revisión sistemática de la literatura. Obtenido de <https://doi.org/10.47230/unsum-ciencias.v4.n1.2020.208>
- School, T. (2021, 30 agosto). Los antecedentes de la inteligencia artificial. Tokio School. <https://www.tokioschool.com/noticias/antecedentes-inteligencia-artificial/> Aprendizaje automático: Qué es y por qué es importante.
- (2020). SAS. https://www.sas.com/es_mx/insights/analytics/machine-learning.html
- Chávez, R. Z. D. L. (2020, 7 agosto). Desarrollo de una aplicación para generar ritmos de batería a través de técnicas relacionadas con aprendizaje automático. Repositorio digital. <http://www.dspace.uce.edu.ec/handle/25000/21447>
- Robayo Ordoñez, A. (2022). Construcción De Un Sistema De Visión Por Computadora Para La Detección De Maleza Y Líneas De Cultivo Utilizando Imágenes Provenientes De Un Dron.

Society, S. S. E. S. C. of the I. C. (2011). ISO/IEC/IEEE 29148:2011(E), Systems and software engineering — Life cycle processes — Requirements engineering. 1–94.

<http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=6146379%0Apapers3://publication/uuid/00C781D8-399B-46C0-B2A1-6EC531E373CC>

Robayo, A. (2022). Construcción de un sistema de visión por computadora para la detección de maleza y líneas de cultivo utilizando imágenes provenientes de un Dron. <http://repositorio.utn.edu.ec/handle/123456789/11950>

G., G. & J., A. P. (2019). Identification of plant leaf diseases using a nine-layer deep convolutional neural network. *Computers & Electrical Engineering*, 76, 323-338. <https://doi.org/10.1016/j.compeleceng.2019.04.011>

Ozguven, M. M. & Adem, K. (2019). Automatic detection and classification of leaf spot disease in sugar beet using deep learning algorithms. *Physica A: Statistical Mechanics and its Applications*, 535, 122537. <https://doi.org/10.1016/j.physa.2019.122537>

Mocayo, K. (2021). Visión por computador para reconocimiento de malezas en cultivos de tomate riñón de invernadero, mediante redes neuronales. <http://repositorio.utn.edu.ec/handle/123456789/11567>

García, I. (2018). Métodos de visión por computador para detección automática de líneas de cultivo curvas/rectas y malas hierbas en campos de maíz - E-Prints Complutense. <https://eprints.ucm.es/id/eprint/49697/>

- Castani, S., & Quintanilla, A. (2019). Aplicación de sensores remotos en la detección y evaluación de plagas y enfermedades en la vegetación. <http://www.aet.org.es/congresos/viii/alb16.pdf>
- Chiluisa González, G. D. (2021). Detección de enfermedades en plantas de tomate a través del análisis computacional de sus hojas (Bachelor's thesis).
- IB, S., Antonio, R., & Almorox, J. A. (1999). Aplicación de sensores remotos en la detección y evaluación de plagas y enfermedades en la vegetación. Teledetección. Av. Apl, 64-67. <https://www.redalyc.org/pdf/612/61222101.pdf>
- Trujillo, L. M. L., Cuartas, L. M. B., & Cardona, C. J. M. (2009). Detección de *Trichinella spiralis* en cerdos faenados en dos plantas de beneficio en el municipio de bello. Revista CES Medicina Veterinaria y Zootecnia, 4(2), 47-56.
- Sullca, C., Molina, C., Rodríguez, C., & Fernández, T. (2019). Detección de enfermedades y plagas en las hojas de arandanos utilizando técnicas de inteligencia artificial. *Perspectiv@s*, 15(15), 32-39
- Michart, P. (2022, 13 octubre). Detección de objetos mediante Fast R-CNN - Cognitive Toolkit - CNTK. Microsoft Learn. <https://learn.microsoft.com/es-es/cognitive-toolkit/object-detection-using-faster-r-cnn>
- Acosta Henríquez, G. F., & Mendoza Torres, C. M. (2017). Aplicaciones de los drones en la agricultura. https://repositoriounicaes.catolica.edu.sv/jspui/bitstream/123456789/199/1/25_dronesAN17.pdf
- Banchero, S., Fernández, J. F., Tonin Monzón, F., Giordano, L. A., Marrone, A., Lulic, M., & Tolosa, G. H. (2020). Modelos para aprendizaje automático en tiempo

real sobre entornos de big data. In XXII Workshop de Investigadores en Ciencias de la Computación (WICC 2020, El Calafate, Santa Cruz).

Crespo, C. (2020). ¿Cuál fue el origen de la agricultura? National Geographic. <https://www.nationalgeographic.es/historia/2022/01/cual-fue-el-origen-de-la-agricultura>

Edgar Steven Moreno Campuzano, E. S. (2021). Manejo de poblaciones de malezas resistentes a herbicidas (Bachelor's thesis, BABAHOYO: UTB, 2021). <http://dspace.utb.edu.ec/bitstream/handle/49000/9205/E-UTB-FACIAG-ING%20AGRON-000292.pdf?sequence=1&isAllowed=y>

Espinoza-Hernández, J., Juárez-González, C., Mota-Delfín, C., & Romantchik-Kriuchkova, E. (2021). Control de maleza mediante la robótica. Ingeniería Agrícola, 11(4). <https://www.redalyc.org/journal/5862/586268743008/586268743008.pdf>

Fernández, A. O. N. (2021). Redes Neuronales. https://ofeliayorquesta.com/articulos/Redes_Neuronales_001.pdf

García Alcalá, I. S. (2020). PROCESAMIENTO DIGITAL DE IMÁGENES UTILIZANDO REDES NEURONALES PARA IDENTIFICAR LA SIGATOKA NEGRA EN EL CULTIVO DEL PLÁTANO. <https://rinacional.tecnm.mx/bitstream/TecNM/1499/3/ISIS%20SIMONARA%20GARC%C3%8DA%20ALCAL%C3%81%20-TEISIS.pdf>

García, Z. (2006). Agricultura, expansión del comercio y equidad de género. FAO. <https://biblioteca.semarnat.gob.mx/janium/recursos/224844/Contenido/K%20documentos%20de%20 analisis/43%20Agricultura,%20expasion%20del%20comercio.pdf>

Hernández Carrascosa, P. (2020). Evaluación de técnicas de detección de dorsales en competiciones deportivas (Bachelor's thesis). <https://accedacris.ulpgc.es/handle/10553/77916>

- Huang, H. N., Zhang, T., Yang, C. T., Sheen, Y. J., Chen, H. M., Chen, C. J., & Tseng, M. W. (2022). Image segmentation using transfer learning and Fast R-CNN for diabetic foot wound treatments. *Frontiers in Public Health*, 10, 969846. <https://www.frontiersin.org/articles/10.3389/fpubh.2022.969846/full>
- Karmarkar, T. (2018). Regional Proposal network (RPN)—Backbone of Faster R-CNN. Aug, 18, 6.
- Leguizamón, E. (2000). Las malezas y el agroecosistema. Cátedra de Malezas, Facultad de, 1-9. https://www.researchgate.net/profile/Eduardo-Leguizamon-2/publication/242391146_LAS_MALEZAS_Y_EL_AGROECOSISTEMA/links/56018ad308aed98518276b52/LAS-MALEZAS-Y-EL-AGROECOSISTEMA.pdf
- Maestre Betolaza, X. (2021). Implementación de redes neuronales en plataformas hardware para su aplicación en ingeniería eléctrica. https://addi.ehu.es/bitstream/handle/10810/54026/TFM_XabierMaestreBetolaza.pdf?sequence=1
- Mendoza, S. H., & Avila, D. D. (2020). Técnicas e instrumentos de recolección de datos. *Boletín científico de las ciencias económico administrativas del ICEA*, 9(17), 51-53. <https://repository.uaeh.edu.mx/revistas/index.php/icea/article/view/6019/7678>
- Mendoza, Z. A., & Díaz, N. J. Arvenses asociadas a cultivos y pastizales del Ecuador. https://www.researchgate.net/profile/Zhofre-Aquirre/publication/334331146_Arvenses_asociadas_a_cultivos_y_pastizales_del_Ecuador/links/5d250b24a6fdcc2462d05cea/Arvenses-asociadas-a-cultivos-y-pastizales-del-Ecuador.pdf
- Microsoft. (13 de 10 de 2022). Microsoft. Obtenido de Detección de objetos mediante R-CNN más rápida: <https://learn.microsoft.com/es-es/cognitive-toolkit/object-detection-using-faster-r-cnn>
- Moncayo Suárez, K. F. (2021). Visión por computador para reconocimiento de malezas en cultivos de tomate riñón de invernadero, mediante redes neuronales (Bachelor's thesis).

<http://repositorio.utn.edu.ec/bitstream/123456789/115678/04%20RED%20265%20TRABAJO%20GRADO.pdf>

Morales, M., & Mideros, A. (2021). Análisis de la pobreza multidimensional en los hogares de la agricultura familiar campesina en el Ecuador, 2009-2019. *Revista Economía*, 73(118), 7-21.
<https://dialnet.unirioja.es/servlet/articulo?codigo=8270392>

Moreira Ramos, R. D. (2022). Desarrollo de algoritmos de procesamiento de imágenes agrícolas obtenidas por drones para la detección de plantas faltantes en cultivos de maíz (Bachelor's thesis).

Mota-Delfín, C., Espinoza-Hernández, J., Romantchik-Kriuchkova, E., & Juárez-González, C. (2021). Control de maleza mediante la robótica. *Revista Ingeniería Agrícola*, 11(4), 54-67.
<https://www.redalyc.org/journal/5862/586268743008/586268743008.pdf>

Pasuy Quevedo, P. A. (2019). Clasificación de aguacates basado en visión por Computador (Bachelor's thesis).
<http://repositorio.utn.edu.ec/handle/123456789/9364>

Pino, E. (2019). Los drones una herramienta para una agricultura eficiente: un futuro de alta tecnología. *Idesia (Arica)*, 37(1), 75-84.
<https://www.scielo.cl/pdf/idesia/v37n1/0718-3429-idesia-00402.pdf>

Pozo, M. (2021). Estudio del efecto del hidrogel en diferentes tipos de cultivos de importancia económica.
<https://repositorio.upse.edu.ec/bitstream/46000/6304/1/UPSE-TIA-2021-0036.pdf>

REAL ACADEMIA ESPAÑOLA: Diccionario de la lengua española, 23.^a ed., [versión 23.6 en línea]. <<https://dle.rae.es>> [14 de septiembre del 2023].

Ríos-Hernández, R. (2021). Uso de los Drones o Vehículos Aéreos no Tripulados en la Agricultura de Precisión. *Revista Ingeniería Agrícola*, 11(4), 75-84.

Rivero Calera, J. (2012). Sistema de control agrícola. <https://openaccess.uoc.edu/bitstream/10609/14603/7/jriverocaTFC0612presentacio.pdf>

Robayo Ordoñez, A. (2022). Construcción de un sistema de visión por computadora para la detección de maleza y líneas de cultivo utilizando imágenes provenientes de un Dron (Bachelor's thesis). <http://repositorio.utn.edu.ec/handle/123456789/11950>

Rouhiainen, L. (2018). Inteligencia artificial. Madrid: Alienta Editorial. https://static0planetadelibroscom.cdnstatics.com/libros_contenido_extra/40/39308_Inteligencia_artificial.pdf

Salas, C., & Jesus, A. (2021). Entrenando una red neuronal Mask R-CNN con imágenes sintéticas para la detección y segmentación de objetos en imágenes reales de maquinaria. http://54.213.100.250/bitstream/20.500.12590/16982/1/CERPA_SALAS_ALO_NEU.pdf

Sarandón, S. J. (2020). El papel de la agricultura. <https://library.fes.de/pdf-files/bueros/mexiko/16550.pdf>

Wadsworth, J. (1997). Análisis de sistemas de producción animal: Tomo 1. las bases conceptuales. FAO Animal Production and Health Paper.

ZORZOLI, F. Malezas resistentes y/o tolerantes1. https://www.researchgate.net/profile/Wilson-Picado/publication/353764586_Revolucion_Verde_Tercer_Mundo_1941-2020/links/611017ff1e95fe241abaf094/Revolucion-Verde-Tercer-Mundo-1941-2020.pdf#page=649