



**UNIVERSIDAD TÉCNICA DE COTOPAXI**  
**FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS.**  
**CARRERA DE INGENIERÍA EN INFORMÁTICA Y SISTEMAS**  
**COMPUTACIONALES.**

**PROYECTO DE INVESTIGACIÓN**

**“APLICACIÓN MÓVIL PARA CLASIFICACIÓN AUTOMÁTICA DE MALAS  
HIERBAS EN IMÁGENES USANDO APRENDIZAJE PROFUNDO”**

Proyecto de Titulación presentado previo a la obtención del Título de Ingenieras en Informática y Sistemas Computacionales.

**Autores:**

Casa Lema Mercedes Azucena.

Tumbaco Sango Jenny Celia.

**Tutor:**

Ing. Mtr. Cantuña Flores Karla Susana.

LATACUNGA-ECUADOR

FEBRERO 2020

## DECLARACIÓN DE AUTORÍA

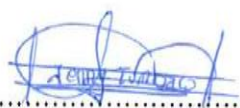
Nosotros, Casa Lema Mercedes Azucena y Tumbaco Sango Jenny Celia, declaramos ser autor (a) del presente proyecto de investigación: **“APLICACIÓN MÓVIL PARA CLASIFICACIÓN AUTOMÁTICA DE MALAS HIERBAS EN IMÁGENES USANDO APRENDIZAJE PROFUNDO”**, siendo Ing. Mtr. Cantuña Flores Karla Susana tutor del presente trabajo; y eximo expresamente a la Universidad Técnica de Cotopaxi y a sus representantes legales de posibles reclamos o acciones legales.

Además, certifico que las ideas, conceptos, procedimientos y resultados vertidos en el presente trabajo investigativo, son de mi exclusiva responsabilidad.



.....

Casa Lema Mercedes Azucena  
C.I. 050413999-9



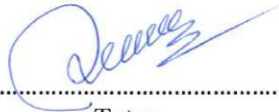
.....

Tumbaco Sango Jenny Celia  
C.I. 050413908-0

### **AVAL DEL TUTOR DE PROYECTO DE TITULACIÓN**

En calidad de Tutor del Trabajo de Investigación sobre el título: **“APLICACIÓN MÓVIL PARA CLASIFICACIÓN AUTOMÁTICA DE MALAS HIERBAS EN IMÁGENES USANDO APRENDIZAJE PROFUNDO”**, de Casa Lema Mercedes Azucena, Tumbaco Sango Jenny Celia, de la carrera **INGENIERÍA EN INFORMÁTICA Y SISTEMAS COMPUTACIONALES**, considero que dicho Informe Investigativo cumple con los requerimientos metodológicos y aportes científico-técnicos suficientes para ser sometidos a la evaluación del Tribunal de Validación de Proyecto que el Consejo Directivo de la Facultad **DE CIENCIAS DE LA INGENIERÍA Y APLICADAS** de la Universidad Técnica de Cotopaxi designe, para su correspondiente estudio y calificación.

Latacunga, febrero del 2020.



.....  
Tutor

Ing. Mtr. Cantuña Flores Karla Susana.


### **APROBACIÓN DEL TRIBUNAL DE TITULACIÓN**

En calidad de Tribunal de Lectores, aprueban el presente Informe de Investigación de acuerdo a las disposiciones reglamentarias emitidas por la Universidad Técnica de Cotopaxi, y por la **FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS**; por cuanto, el o los postulantes: Casa Lema Mercedes Azucena, Tumbaco Sango Jenny Celia con el título de Proyecto de titulación: **“APLICACIÓN MÓVIL PARA CLASIFICACIÓN AUTOMÁTICA DE MALAS HIERBAS EN IMÁGENES USANDO APRENDIZAJE PROFUNDO”** han considerado las recomendaciones emitidas oportunamente y reúne los méritos suficientes para ser sometido al acto de Sustentación de Proyecto.

Por lo antes expuesto, se autoriza realizar los empastados correspondientes, según la normativa institucional.

Latacunga, 06 de febrero del 2020.

Para constancia firman:

  
Lector 1 (Presidente)

Nombre: Ing. Mg. Cadena Moreano José Augusto  
CC: cc: 050155279-8

  
Lector 2

Nombre: Ing. Mg. Alban Taipe Mayra Susana  
CC: 050231198-8

  
Lector 3

Nombre: Ing. Mg. Rodríguez Bárcenas Gustavo  
cc: 1757001357



UNIVERSIDAD  
TÉCNICA DE  
COTOPAXI



## CERTIFICADO

Yo, Cantuña Flores Karla Susana docente de la Carrera Sistemas de Información Certifico que las señoritas **Casa Lema Mercedes Azucena**, con cedula No 050413999-9 y **Tumbaco Sango Jenny Celia**, con cedula No 0504139080, participaron en el proyecto de investigación formativa en el tema **“APLICACIÓN MÓVIL PARA CLASIFICACIÓN AUTOMÁTICA DE MALAS HIERBAS EN IMÁGENES USANDO APRENDIZAJE PROFUNDO”** desde el 05 de octubre hasta el 10 de enero del 2020.

Ing.Mtr. Cantuña Flores Karla Susana  
Tutor de Titulación  
CC: 0502305113

Latacunga - Ecuador

Av. Simón Rodríguez s/n Barrio El Ejido / San Felipe. Tel: (03) 2252346 - 2252307 - 2252205

## **AGRADECIMIENTO**

En primer lugar, doy gracias a Dios por haber guiado mi camino, brindar sabiduría y cumplir un sueño más en mi vida, por la salud, por la familia que me ha dado.

Mi gratitud muy especial a mis padres y hermanas quienes siempre confiaron en mí y supieron darme palabras de aliento para seguir siempre adelante.

A mi esposo por el apoyo incondicional que me ha proporcionado día a día en las buenas y en las malas y a mis hijos por ser angelitos que con su sonrisa lo cambia todo.

Mi querida institución “Universidad Técnica de Cotopaxi” por haber abierto las puertas para prepararme y ser profesional y a la vez a mis queridos maestros brindarme sus conocimientos.

De manera especial a mi tutora quien con sus palabras conocimientos y apoyo supo guiar en el desarrollo de la investigación.

*Mercedes Azucena Casa Lema.*

## **DEDICATORIA**

La presente investigación dedico primeramente a Dios por dar sabiduría y guiarme en los momentos más difíciles que se ha presentado y guiar a pesar de ello.

A mi esposo Edgar Sango a mi hija Leydi Sango, Emily Sango por ser lo motivos más importantes en mi vida para lograr este objetivo y de esta manera ser una profesional de manera grata, gracias a todos por brindar, cariño, paciencia, esfuerzo, ánimo para que valga la pena.

A mis padres Milton Casa y Inés Lema quienes me brindaron su comprensión amor, consejos y además de ello educarme con sus valores y sus principios en la cual me convirtió una persona humilde y sencilla.

*Mercedes Azucena Casa Lema.*

## **AGRADECIMIENTO**

Quiero en primer lugar agradecer a Dios, por brindarme la sabiduría y fortaleza necesaria para cumplir una meta más en vida, a mis padres por ser mi fuerza, mi inspiración porque todo lo que soy se los debo a ellos, a mis hermanos por su incondicional apoyo que me brindaron para seguir luchando por mis sueños, a toda mi familia que siempre me brindaron su incondicional apoyo y sobre todo a mi mis dos grandes amores que son mi esposo e hijo por ser el motor de mi vida, mi inspiración y mi motivo para seguir adelante que siempre estuvieron dispuestos a acompañarme cada larga y agotadoras noche.

Agradezco inmensamente mi tutora de titulación Ing. Mtr. Karla Susana Cantuña Flores, que con su apoyo, paciencia y dedicación se logró desarrollar satisfactoriamente el proyecto de investigación e incluso a mis docentes quienes aportaron con sus conocimientos durante toda mi vida universitaria.

*Jenny Celia Tumbaco Sango.*

## **DEDICATORIA**

Dedico este proyecto de investigación a mis padres Luis Tumbaco y María Sango, quienes me dieron la vida, su confianza, su apoyo incondicional y sobre todo por sus sabios consejos de lucha y dedicación durante toda mi vida universitaria.

A mis hermanos Javier, Erika, Cinthia, Paúl, Magali y Evelyn y como olvidar de mi segunda madre Rosa Yugcha quienes me han apoyado y motivado a seguir luchando por mis sueños a pesar de las dificultades que se presenta cada día, por sus palabras de aliento y su cariño incondicional que permitieron cumplir una etapa grande en mi vida, agradezco de todo corazón por ese apoyo y cariño.

Finalmente quiero dedicar mi proyecto de investigación con todo mi amor a mis dos grandes amores Geovanny y José Luis, que son mi inspiración mi fuerza y mi vida entera, por apoyarme en las buenas y en las malas, por creer en mi capacidad, por esa fuerza que cada día me ofrecen para luchar por mis sueños y por el amor puro y sincero que me brindan cada instante de mi vida, mil gracias y como no dedicar a la memoria de Papito Feliciano, porque fue una gran persona hoy te dedico mi esfuerzo siempre te tengo presente en mi mente y corazón, mil gracias por todo el apoyo y afecto incondicional.

*Jenny Celia Tumbaco Sango.*

## **UNIVERSIDAD TÉCNICA DE COTOPAXI**

### **FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS**

**TITULO:** “APLICACIÓN MÓVIL PARA CLASIFICACIÓN AUTOMÁTICA DE MALAS HIERBAS EN IMÁGENES USANDO APRENDIZAJE PROFUNDO.”

**Autores:** Casa Lema Mercedes Azucena.

**Tumbaco Sango Jenny Celia.**

### **RESUMEN**

Las malas hierbas en el campo, son consideradas como un gran problema para los cultivos, causan efectos negativos que rivalizan con las plantas de maíz en su desarrollo quitándoles todos los elementos nutrientes, donde el agricultor utiliza cualquier herbicida para eliminar estas malas hierbas aplicando en todo el cultivo. Por tal razón, se considera importante que este problema se tratado. Una de las soluciones para atenuar esta problemática podría ser mediante el uso de técnicas de aprendizaje profundo que permita obtener una aplicación móvil con información para minimizar o eliminar las malas hierbas en el cultivo de maíz en base al herbicida correcto. La revisión de la literatura permitió determinar estudios similares para la clasificación de malas hierbas en el cultivo a través técnicas empleadas para clasificar de forma automática. Sin embargo, las técnicas propuestas por los investigadores tienen limitados el uso de técnicas de aprendizaje automático. Por consiguiente, se propone un modelo clasificador basado en técnicas de aprendizaje profundo para la clasificación de las malas hierbas en imágenes. Como resultado se obtiene una aplicación móvil desarrollada bajo tecnología de última generación desarrollada para beneficio de los agricultores, Herbario institucional, estudiantes y profesores de áreas relacionadas en la Universidad Técnica de Cotopaxi. La metodología utilizada para el desarrollo del proyecto de investigación fueron las Redes Neuronales Convolucionales, empleando la metodología CRISP-DM que corresponde a la descripción de las fases. Además, se utilizará el lenguaje de programación Android Studio y la plataforma Custum Vision permitiendo emplear algoritmos de aprendizaje, con la biblioteca Tensorflow de código abierto capaz de construir redes neuronales, utilizada para la detección de objetos personas, animales, plantas y lugares. El modelo generado fue evaluado logrando una precisión de 97.8%, un recall de 97.3% y un A.P de 97.8%, permitiendo obtener resultados óptimos en la clasificación de malas hierbas de forma automática.

**Palabras claves:** Clasificación de malas hierbas, aprendizaje profundo, redes neuronales convolucionales, CRISP-DM, tensorflow.

**TECHNICAL UNIVERSITY OF COTOPAXI**  
**FACULTY OF ENGINEERING AND APPLIED SCIENCES.**

**TITLE: “MOBILE APPLICATION FOR AUTOMATIC CLASSIFICATION OF BAD HERBS IN IMAGES USING DEEP LEARNING.”**

**Authors: Casa Lema Mercedes Azucena.**  
**Tumbaco Sango Jenny Celia.**

**ABSTRACT**

Weeds in the field, are considered a major problem for crops, cause negative effects that rival the corn plants in their development by removing all the nutrient elements, where the farmer uses any herbicide to eliminate these weeds by applying in all The crop For this reason, it is considered important that this problem be treated. One of the solutions to mitigate this problem could be through the use of deep learning techniques that allow obtaining a mobile application with information to minimize or eliminate weeds in the corn crop based on the correct herbicide. The literature review allowed to determine similar studies for the classification of weeds in the crop through techniques used to classify automatically. However, the techniques proposed by the researchers have limited use of machine learning techniques. Therefore, a classification model based on deep learning techniques for the classification of weeds in images is proposed. As a result, a mobile application developed under the latest technology developed for the benefit of farmers, institutional herbarium, students and professors of related areas at the Technical University of Cotopaxi is obtained. The methodology used for the development of the research project was the Convolutionary Neural Networks, using the CRISP-DM methodology that corresponds to the description of the phases. In addition, the Android Studio programming language and the Custum Vision platform will be used allowing learning algorithms to be used, with the Tensorflow open source library capable of building neural networks, used for the detection of people, animals, plants and places. The generated model was evaluated achieving an accuracy of 97.8%, a recall of 97.3% and an A.P of 97.8%, allowing optimum results in the classification of weeds automatically.

**Keywords:** Weed classification, deep learning, convolutional neural networks, CRISP-DM, tensorflow.



Universidad  
Técnica de  
Cotopaxi

CENTRO DE IDIOMAS

## *AVAL DE TRADUCCIÓN*

En calidad de Docente del Idioma Inglés de la Carrera de Pedagogía de los idiomas nacionales y extranjeros de la Universidad Técnica de Cotopaxi; en forma legal **CERTIFICO** que: La traducción del resumen del proyecto de investigación al Idioma Inglés presentado por las señoritas Egresadas de la Carrera de **INGENIERÍA EN INFORMÁTICA Y SISTEMAS COMPUTACIONALES** de la **FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS, CASA LEMA MERCEDES AZUCENA Y TUMBACO SANGO JENNY CELIA**, cuyo título versa **“APLICACIÓN MÓVIL PARA CLASIFICACIÓN AUTOMÁTICA DE MALAS HIERBAS EN IMÁGENES USANDO APRENDIZAJE PROFUNDO”**, lo realizaron bajo mi supervisión y cumple con una correcta estructura gramatical del idioma.

Es todo cuanto puedo certificar en honor a la verdad y autorizo a las peticionarias hacer uso del presente certificado de la manera ética que estimaren conveniente.

Latacunga, Febrero del 2020,

Atentamente,

.....  
**Lic. Msc. José Ignacio Andrade.**  
**C.C. 0503101040**  
**DOCENTE DE UTC**



## ÍNDICE GENERAL

DECLARACIÓN DE AUTORÍA .....	ii
AVAL DEL TUTOR .....	iii
APROBACIÓN DEL TUTOR DE TITULCIÓN.....	iv
AGRADECIMIENTO .....	vi
DEDICATORIA .....	vii
RESUMEN.....	x
ABSTRACT .....	xi
ÍNDICE GENERAL .....	xiii
ÍNDICE DE TABLAS .....	xviii
ÍNDICE DE FIGURAS .....	xix
1.- INFORMACIÓN GENERAL .....	1
2. JUSTIFICACIÓN DEL PROYECTO.....	2
3. BENEFICIARIOS DEL PROYECTO.....	3
4. PROBLEMA DE INVESTIGACIÓN.....	3
5. OBJETIVOS.....	5
5.1. Objetivo general. ....	5
5.2. Objetivos específicos. ....	5
6. ACTIVIDADES Y SISTEMA DE TAREAS EN RELACIÓN A LOS OBJETIVOS PLANTEADOS. ....	5
7. FUNDAMENTACIÓN CIENTÍFICO TÉCNICA. ....	6
7.1. Antecedentes. ....	6
7.2. Bases teóricas. ....	7
7.2.1. Aprendizaje automático. ....	7
7.2.1.1. Tareas de aprendizaje automático. ....	8
Clasificación binaria .....	8

Clasificación multiclase .....	9
Regresión.....	9
Agrupación en clústeres .....	9
Detección de anomalías.....	9
Clasificación .....	10
7.2.2. Aprendizaje profundo. ....	10
7.2.3. Redes neuronales. ....	11
7.2.4. Redes neuronales convolucionales (CNN).....	12
7.2.4.1. Arquitecturas de redes neuronales convolucionales.....	13
Letnet .....	13
Alexnet .....	14
Resnet o red resisual .....	14
Vgg net .....	15
7.2.6. Técnica de evaluación.....	15
Validación cruzada. ....	15
7.2.7. PLATAFORMA DE APRENDIZAJES .....	16
7.2.7.1. Custom Vision.....	16
¿Qué hace Custom Vision? .....	16
Clasificación y detección de objetos.....	17
Mejoramiento .....	17
Lo que incluye .....	17
7.2.8. Aplicaciones móviles. ....	17
7.2.8.1. Sistemas operativos para dispositivos móviles. ....	17
7.2.9. Android Studio .....	18
7.2.9.1. Arquitectura de Android Studio .....	18
7.2.9.2. Ventajas de Android Studio .....	19
7.2.10. Tensorflow.....	19

7.2.11. Las malas hierbas.....	19
7.2.12. Localización de las malas hierbas.....	20
7.2.13. Identificación de malas hierbas en la agricultura. ....	21
7.2.14. Estado del arte de sistemas usados para la clasificación de malas hierbas. ....	21
7.2.15. El maíz en el Ecuador .....	22
7.2.16. Principales malas hierbas en maíz.....	23
Abutilon (Abutilon the ophrasti). ....	23
Ambrosia Artemisiifolia.....	23
Cadillo (Xanthium) .....	24
Chenopodium Album.....	24
Erodium Cicutarium.....	25
Galinsoga Parviflora .....	25
Los bledos (Amaranthus) .....	26
Raphanus Raphanistrum.....	26
Urtica urens .....	27
Tomatito (Solanum) .....	27
7.2.17. Herbicida .....	28
Tipo de tratamiento.....	28
7.2.18. Tipos de herbicidas. ....	29
Ambrosia Artemisiifolia.....	29
Chenopodium Album.....	30
Erodium Cicutarium.....	30
Galinsoga Parviflora .....	30
Raphanus Raphanistrum.....	31
Urtica urens .....	31
8. VALIDACIÓN DE LAS PREGUNTAS CIENTÍFICAS O HIPÓTESIS. ....	32
8.1. FORMULACIÓN DEL PROBLEMA.....	32

8.2. HIPÓTESIS.....	32
9. METODOLOGÍAS Y DISEÑO EXPERIMENTAL.....	32
9.1.1. Tipos de investigación. ....	32
9.1.1.1. Investigación mixta.....	32
9.1.1.2. Investigación cuantitativa.....	32
9.1.1.3. Investigación cualitativa.....	32
9.1.1.4. Investigación bibliográfica. ....	33
9.1.1.5. Investigación de campo. ....	33
9.1.1.6. Investigación explicativa. ....	33
9.2. Métodos teóricos. ....	34
9.2.1. Hipotético deductivo. ....	34
9.2.2. Método no experimental. ....	34
9.4.1. Técnicas de investigación. ....	34
9.4.1. Fichaje .....	34
9.4.2. Observación. ....	35
9.5. Instrumentos de investigación. ....	35
9.5.1. Ficha bibliográfica .....	35
9.5.2. Guía de observación. ....	35
9.6. Métodos específicos.....	36
9.6.1. Plan de proyecto.....	36
9.6.2. Desarrollo de la Aplicación Móvil.....	41
9.6.3. Metodología CRISP-DM.....	45
Fase de comprensión de negocio .....	45
Fase de comprensión de los datos.....	46
Fase de preparación de datos.....	46
Fase de modelo .....	46
Fase de evaluación .....	47

Fase de distribución .....	47
9.6.2. Gráfica del proceso.....	48
10. ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS.....	49
10.1. Metodología CRISP-DM. ....	49
10.1.1. Fase de compresión de negocio .....	49
10.1.2. Fase de compresión de datos.....	50
10.1.3. Fase de descripción de datos.....	51
10.1.4. Fase de modelo.....	51
10.1.5. Fase de evaluación. ....	52
10.1.6. Fase de distribución.....	54
10.1.6.1. Manual de usuario. ....	55
10.2. Discusión de resultados.....	57
11. IMPACTOS (TÉCNICOS, SOCIALES, AMBIENTALES O ECONÓMICOS). ....	58
11.1. IMPACTO SOCIAL.....	58
11.2. IMPACTO TÉCNICO. ....	58
11.3. IMPACTO AMBIENTAL .....	58
12. PRESUPUESTO PARA LA PROPUESTA DEL PROYECTO .....	58
12.1. GASTOS DIRECTOS. ....	58
12.2. GASTOS INDIRECTOS. ....	59
12.3. GASTOS APROXIMADOS. ....	59
13. CONCLUSIONES Y RECOMENDACIONES. ....	60
13.1. CONCLUSIONES.....	60
13.2. RECOMENDACIONES. ....	60
15. ANEXOS.....	65
15.1. Anexo 1: Hoja de vida autor 1.....	65
15.2. Hoja de vida autor 2.....	66
15.2. Anexo 3: Clasificación de las 6 especies de malas hierbas. ....	67

## ÍNDICE DE TABLAS

Tabla 1: Tareas de los objetivos planteados.....	5
Tabla 2: Caso de uso clasificador.....	37
Tabla 3: Caso de uso generar información.....	38
Tabla 2: Caso de Prueba 1.....	40
Tabla 3: Caso de Prueba 2.....	40
Tabla 4: Informen de pruebas.....	41
Tabla 5: Cantidad de imágenes.....	51
Tabla 6: Gastos directos.....	58
Tabla 7: Gastos indirectos.....	59
Tabla 8: Gastos indirectos.....	59

## ÍNDICE DE FIGURAS

Figura 1: Esquema de una red neuronal.....	11
Figura 2: Esquema de la red neuronal convolucionales.....	12
Figura 3: Arquitectura de LeNet5.....	13
Figura 4: Arquitectura de AlexNet.....	14
Figura 5: Arquitectura de ResNet.....	15
Figura 6: Técnica de validación cruzada.....	16
Figura 7: Abutilon.....	23
Figura 8: Ambrosia Artemisiifolia.....	24
Figura 9: Xanthium.....	24
Figura 10: Chenopodium Album.....	25
Figura 11: Erodium Cicutarium.....	25
Figura 12: Galinsoga Parviflora.....	26
Figura 13: Amaranthus.....	26
Figura 14: Raphanus Raphanistrum.....	27
Figura 15: Urtica urens.....	27
Figura 16: Tomatito.....	28
Figura 17: Tipo de tratamiento.....	28
Figura 18: Tipo de tratamiento.....	37
Figura 19: Diagrama de secuencia clasificar.....	39
Figura 20: Diagrama de secuencia generar información.....	39
Figura 21.- Activity_principal.....	42
Figura 22: Activity_camara.....	42
Figura 23: Activity_principal.....	43
Figura 25.- Clase OverlayView.....	43
Figura 24: Activity_información.....	44
Figura 26.- Modelo CRISP-DM.....	45
Figura 27: Proceso de clasificación.....	48
Figura 28.- Plan de proyecto.....	50
Figura 29: Resultados del modelo.....	52

Figura 30: Resultados de <i>Urtica Urens</i> .....	53
Figura 31: Resultados de <i>Raphanus Raphanistrum</i> . ....	53
Figura 32: Resultados de <i>Galinsoga Parviflora</i> .....	53
Figura 33: Resultados de <i>Ambrosia Artemisiifolia</i> . ....	53
Figura 34: Resultados del modelo .....	54
Figura 35: Resultados de <i>Eradium Citutarium</i> .....	54
Figura 36.-Venta principal. ....	55
Figura 37: Clasificación. ....	56
Figura 38: Mala hierba. ....	57

## **1.- INFORMACIÓN GENERAL**

### **Título del Proyecto:**

Aplicación móvil para clasificación automática de malas hierbas en imágenes usando aprendizaje profundo.

**Fecha de inicio:** Septiembre 2019.

**Fecha de finalización:** Febrero 2020.

**Lugar de ejecución:** Barrio El Ejido, Parroquia Eloy Alfaro, Cantón Latacunga, Universidad Técnica de Cotopaxi.

**Facultad que auspicia:** Ciencias de la Ingeniería y Aplicadas.

### **Carrera que auspicia:**

Ingeniería en Informática y Sistemas Computacionales.

**Proyecto de investigación vinculado:** Análisis de imágenes en tiempo real de especies de malas hierbas ecuatorianas en cultivos de maíz sobre dispositivos móviles.

### **Equipo de Trabajo:**

**Tutor de Titulación:** Ing. Mtr. Karla Susana Cantuña Flores.

**Estudiantes:** Mercedes Azucena Casa Lema.

Jenny Celia Tumbaco Sango.

**Área de Conocimiento:** Ciencias.

**Sub-área:** Informática.

**Línea de investigación:** Tecnologías de la Información y Comunicación (TIC'S).

**Sub líneas de investigación de la Carrera:** Inteligencia Artificial e Inteligencia de Negocios.

## **2. JUSTIFICACIÓN DEL PROYECTO.**

En el sector agrícola las malas hierbas son muy importantes ya que a nivel mundial han venido proliferando, evolucionando de manera continua a la par de los cultivos. Por ello, muchas especies de malas hierbas han desarrollado características que les permiten adaptarse al cultivo que acompañan: germinan exactamente en la misma época, crecen al mismo ritmo camuflándose en el interior del cultivo (como el ejemplo de la parábola de la cizaña) y llegan a la maduración al mismo tiempo (F.Quintanilla, 2017).

Por otro lado, en la actualidad las malas hierbas constituyen una serie de amenazas biológicas capaces de causar pérdidas económicas en la agricultura produciendo diversos daños. Éstas pueden afectar directamente, a los animales que las consumen y combaten con otras plantas particularmente con los cultivos por el espacio, la luz, el agua y los nutrientes y en consecuencia reduce el rendimiento de los cultivos. Sin embargo, desde el punto de vista del manejo y control la identificación de las malas hierbas se lo debe ejecutar en los primeros estadios de desarrollo. En cuanto, al control en fases tempranas se realiza para disminuir los daños que estas puedan ocasionar, mientras más jóvenes son las especies que se quieren controlar menos problemático resulta su manejo y control en el campo (L.O, 2019).

Por tal razón, al identificar las malas hierbas se podrá conocer su origen, las especies a las que pertenecen, el herbicida que corresponde aplicar a la mala hierba y por tanto echar de la mano de la tecnología para desarrollar herramientas que sirvan de apoyo a los agricultores en las labores diarias del campo. La identificación de malas hierbas en imágenes dotará los conocimientos necesarios para tomar acciones oportunas en los cultivos.

Por otro lado Sara Herrero (2014) manifiesta que la herramientas tecnológicas para efectuar las labores diarias en el campo: AIMBRA es una herramienta que se utiliza para una rápida y precisa determinación de 156 especies diferentes de malas hierbas, con el apoyo de las fotos e imágenes que identifica las malas hierbas basándose en varios órganos de la planta, las especies de malas hierbas se describen a detalle y se muestran en diferentes fases de desarrollo germinación, hojas, tallos, flores. Esta aplicación beneficia a los cultivos del campo y a los agricultores quienes trabajan en el sector. (Ortega, 2014).

Pl@ntNet es una aplicación para la recopilación, anotación y recuperación de imágenes para ayudar en la identificación de plantas. Esta herramienta reconoce las imágenes de las malas

hierbas mediante el tallo y las hojas de la planta. El uso del aprendizaje profundo permitirá una adecuada identificación de las malas hierbas más importantes de cultivo de maíz en el campo. La presente investigación pretende obtener un modelo clasificador de especies de malas hierbas en situaciones reales del campo a través de una plataforma de Custom Vision, además, se pretende que la herramienta desarrollada sea utilizada como referente para la identificación de especies vegetales e información del tipo de herbicida que corresponde a cada especie de mala hierba que maneja el agricultor o herbario de la Universidad Técnica de Cotopaxi.

### **3. BENEFICIARIOS DEL PROYECTO.**

Este proyecto contribuirá en el cumplimiento de uno de los objetivos del proyecto “clasificación automática de malas hierbas en imágenes usando aprendizaje profundo”.

Los beneficiarios directos del proyecto son: los agricultores y botánicos.

Los beneficiarios indirectos son: Herbario institucional, estudiantes y profesores de áreas relacionadas en la Universidad Técnica de Cotopaxi.

### **4. PROBLEMA DE INVESTIGACIÓN.**

Las malas hierbas constituyen una serie de amenazas biológicas capaces de causar erosión excesiva, asociada a la pérdida de nutrientes de agua de luz, en el cual son el enemigo natural número uno para los agricultores, muchas de ellas son resistentes a la acción de uno o varios herbicidas a nivel del Ecuador y Latinoamérica. Dada la tasa anual de incremento a la resistencia se calcula en el año 2014, hasta 38 millones de hectáreas de campo de cultivo que han sufrido con esta infestación de malas hierbas. (Deere, 2014).

Por otra parte, las malas hierbas reducen más la producción de cultivos con una mayor inversión económica para su control de enfermedades, insectos, plagas quien dificulta las cosechas reduciendo la calidad de las semillas cultivadas, rebajando su valor comercial hacia los consumidores en los mercados internacionales (Mendiola, 2011).

Estas especies vegetales en los cultivos han generado pérdidas muy grandes en estos casos son generales, ocasionado la abundancia de las malas hierbas del 23% al 40% en cultivo de trigo y maíz respectivamente en España, por su lugar han variado los daños de cultivo enormemente (Quintanilla, 2017).

La diversidad de flora que incide en la producción del cultivo de estas especies de malezas dominantes la cual no son idóneas, determinan la identificación de las especies predominantes dentro del ecosistema ya que se encuentra en la ciudad de Quevedo (Ecuador) con resultados

señalados en diferentes áreas monitoreadas se encontraron más de 55 especies destacándose como la Compositae, Poaceae con mayor presencia alta la cual estas fueron las dicotiledóneas y monocotiledóneas (Vera, 2018).

No obstante en cultivos extensivos o zonas de monocultivo es a veces difícil desechar ya que estas desempeñan un papel importante en el agro sistema y son el principal soporte de la diversidad biológica en los campos de cultivo donde proporciona valiosos servicios ecológicos para diferentes siembras, por tanto es necesario el manejo de herbicidas y la cantidad que lo va a utilizar evitando el desarrollo de resistencias de estas especies vegetales de toda la biodiversidad (Escorial, 2017).

Por otro lado, los herbicidas representan casi el 50% de los pesticidas utilizados en la agricultura ya que han ocasionado problemas ambientales, como la contaminación del suelo y malezas con factores de resistencia de estos matorrales de hoja ancha de plantas monocotiledóneas de tallo y hojas alternas como vigencia del 85% de resistencia estas siempre se han aplicado en etapas tempranas de desarrollo dependiendo al clima que se encuentra por lo tanto, al utilizar un o varios herbicidas depende que sea formado como complemento en un manejo integrado de malezas (Allan, 2016).

A pesar que mal uso de herbicidas pone en riesgo la salud humana, animal, y sobre todo el suelo que queda parte de sus componentes y nutrientes ahí, esto menciona un informe de la organización de las naciones unidas ya que revelo anualmente mueren 200mil personas envenenadas por el uso inadecuado de pesticidas y herbicidas. En Ecuador (2017), el centro de información y asesoramiento toxicológico evidencio en un estudio que los plaguicidas y herbicidas son causantes de intoxicación hacia las personas, en estos casos a un van en aumento por la inadecuada utilización de químicos a los productos (Coloma, 2017).

En la actualidad las malas hierbas son plantas no deseadas tales como: *Chenopodium álbum*, *Ambrosia Artemisiifolia*, *Urtica Urens*, *Rapahus Rapanistrum*, *Eradium Cicutarium*, *Galinsoga Parviflora*, dichas especies existen en los cultivos de maíz en donde no son reconocidos sus características y el tipo herbicidas para cada una de estas especies, dando como consecuencia que las personas utilizan los herbicidas para todo el cultivo sin tomar en cuenta que existen herbicidas para cada tipo de especie de mala hierba, poniendo en riesgo las planta de maíz, por ende en los últimos años se ha utilizado fertilizantes para todo tipo de planta en el cultivo de maíz. Por lo tanto, se considera importante diseñar una aplicación móvil que permitirá clasificar

las imágenes de malas hierbas en tiempo real, proporcionando información de las características y el herbicida que corresponde a cada especie clasificada, con el fin de mejorar el suelo donde es cultivado y la producción del maíz.

## 5. OBJETIVOS.

### 5.1. Objetivo general.

Diseñar una aplicación móvil de especies de malas hierbas en imágenes a través del uso de clasificadores empleando técnicas de aprendizaje profundo para la identificación en cultivo de maíz.

### 5.2. Objetivos específicos.

- Revisar minuciosamente la literatura mediante diferentes fuentes bibliográficas para conocer las concepciones teóricas de la clasificación de malas hierbas en el cultivo de maíz.
- Generar un clasificador de especies de malas hierbas en imágenes mediante técnica de aprendizaje profundo para la identificación de dichas malas hierbas.
- Evaluar el clasificador de especies de malas hierbas en el cultivo de maíz mediante el lenguaje de programación Android Studio para obtener un clasificador óptimo y preciso.

## 6. ACTIVIDADES Y SISTEMA DE TAREAS EN RELACIÓN A LOS OBJETIVOS PLANTEADOS.

### SISTEMA DE TAREAS EN RELACIÓN A LOS OBJETIVOS PLANTEADOS.

**Tabla 1:** Tareas de los objetivos planteados.

<b>Objetivo</b>	<b>Actividad (tareas)</b>	<b>Resultado de la actividad</b>	<b>Medios de verificación</b>
Revisar minuciosamente la literatura mediante diferentes fuentes bibliográficas para conocer las concepciones teóricas de la clasificación de malas hierbas en el cultivo de maíz.	<ol style="list-style-type: none"> <li>1. Recopilación de fuentes bibliográficas primaria y secundaria por lo menos 5 años atrás.</li> <li>2. Selección de diferentes fuentes</li> </ol>	<ol style="list-style-type: none"> <li>1. Banco de Datos de fuentes bibliográficas primarias y secundarias.</li> <li>2. Banco de Datos de fuentes bibliográficas</li> </ol>	Técnica: Fichaje Instrumento: Ficha bibliográfica.

	bibliográficas primaria y secundaria. <b>3.</b> Análisis y revisión de las fuentes bibliográficas primaria y secundaria.	primarias y secundarias. <b>3.</b> Banco de Datos de fuentes bibliográficas.	
Generar un clasificador de especies de malas hierbas en imágenes mediante técnica de aprendizaje profundo para la identificación de dichas malas hierbas.	<b>1.</b> Etiquetado de imágenes. <b>2.</b> Aplicación de técnicas de aprendizaje profundo.	<b>1.</b> Base de datos de imágenes etiquetadas. <b>2.</b> Informe de clasificador.	Técnica: Observación Instrumento: Fotografías y guía de observación.
Evaluar el clasificador de especies de malas hierbas en el cultivo de maíz en mediante el lenguaje de programación Android Studio para obtener un modelo óptimo y preciso.	<b>1.</b> Desarrollo de la Aplicación Móvil	<b>2.</b> Aplicación Móvil.	Manual de Usuario

Fuente: Equipo de trabajo.

## 7. FUNDAMENTACIÓN CIENTÍFICO TÉCNICA.

### 7.1. Antecedentes.

El continuo auge de la tecnología ha permitido la automatización de muchos procesos de forma eficaz, la mayoría de los sistemas que brindan estos servicios son desarrollados en un ambiente informático, hoy en día enfrentamos al gran desafío de ser constantemente más competitivos de ofrecer un servicio con un alto nivel de calidad, lo cual sin duda trae consigo grandes retos tecnológicos incluso en el campo de la agricultura. (Martínez, 2015).

El maíz conocido como también *zea mays* es uno de los cultivos más tradicional de la Sierra ecuatoriana, debido a la gran superficie sembrada y el papel que cumple en la seguridad y

soberanía alimentaria, por ende, constituye un componente importante en la dieta tanto de la población. Sin embargo, en la actualidad existe en los cultivos de maíz severas infestaciones de las hierbas, por lo tanto, se puede mencionar que las malas hierbas compiten con los cultivos, especialmente por el agua, luz y todos los nutrientes del suelo, de igual manera dificulta las labores culturales, en la cual reduce la eficiencia de la fertilización, disminuyendo el rendimiento severamente. (Peñaherrera, 2011).

Tradicionalmente, las tareas agrícolas se basan en la aplicación de técnicas en toda la superficie del terreno. Pensemos por ejemplo en la aplicación de herbicida en un campo de cultivo con el fin de eliminar las malas hierbas existentes en el campo para favorecer el crecimiento y desarrollo del cultivo. (Martínez, 2015). Centrándonos en el tratamiento de eliminación de las malas hierbas en campos de cultivo, es cierto, que se debería aplicar un tratamiento más agresivo en aquellas zonas con más alta densidad que en las zonas con menor densidad, incluso no realizar ningún tipo de tratamiento si la densidad de malas hierbas es muy baja o incluso nula.

La identificación de zonas con ciertas densidades de cultivo para la detección automática de malas hierbas ha sido una grande tarea desalentadora, puesto a la gran cantidad que existe de variables, causando dificultad de adaptar las técnicas a la realidad. Sin embargo, estudios demuestran el potencial de la visión artificial como una herramienta útil que a futuro mejorara la competencia con respecto a la agricultura y evitando ser afectados en el retraso de la producción del cultivo. (Betancourt, 2014).

Según Zheng y col. (2010), resulta difícil separar las diferentes texturas de las imágenes en color que contiene cultivos y malas hierbas, debido a que son imágenes de exterior donde las condiciones de iluminación son muy cambiantes en cortos intervalos de tiempo e incluso las sombras de las plantas pueden influir directamente dificultando una correcta clasificación o discriminación de tales texturas. (Callejo, 2016).

## **7.2. Bases teóricas.**

### **7.2.1. Aprendizaje automático.**

El aprendizaje automático es un tipo de inteligencia artificial que proporciona a las computadoras la capacidad de aprender, sin ser programadas y estas pueden cambiar cuando se exponen a nuevos datos, el proceso de aprendizaje automático es similar a la minería de datos para encontrar los patrones, sin embargo en lugar de extraer los datos para la comprensión

humana como es el caso de las aplicaciones de minería de datos el aprendizaje automático utiliza esos datos para detectar patrones en los datos y ajustar las acciones del programa en consecuencia se clasifican como supervisado o no supervisados. (Caparrini, 2017).

**Aprendizaje supervisado:** Establece una correspondencia entre entradas y las salidas deseadas del sistema donde la base de conocimientos del sistema está formada por ejemplos etiquetados, es decir, ejemplos de los que sabemos su clasificación correcta.

**Aprendizaje no supervisado:** donde el proceso de modelado se lleva a cabo sobre un conjunto de ejemplos formados únicamente por entradas al sistema, sin conocer su clasificación correcta por lo que se busca que el sistema sea capaz de reconocer patrones para poder etiquetar las nuevas entradas. También se ocupa del desarrollo de sistemas computacionales diseñados con el propósito de aprender y adaptarse a partir de los datos (Caparrini, 2017).

Por otra parte Machine Learning (aprendizaje automático) es una técnica de análisis de datos que enseña a los ordenadores a hacer lo que resulta natural para las personas, en este método se calcula para aprender información directamente de los datos ya que los algoritmos mejora su rendimiento de forma adaptable en este caso presenta dos tipos de técnicas aprendizaje supervisado, que entrega un modelo con datos de entrada y salida conocidos para que pueda predecir salidas futuras mientras el aprendizaje no supervisado encuentra patrones ocultos en los datos de entrada (Gusmán, 2019).

También estas técnicas están basadas sobre un modelo específico o sobrentendido, que posibilita a categorizar los patrones analizados una de ellas se caracteriza en esquemas de datos etiquetados para entrenar el modelo de comportamiento, siendo este un procedimiento que demanda recursos, basados en aprendizaje automático como en algunos de ellos son las redes neuronales, algoritmos genéticos agrupamiento y detección (Rivero, 2014).

#### **7.2.1.1. Tareas de aprendizaje automático.**

La siguiente lista describe las diferentes tareas de aprendizaje automático que puede elegir y algunos casos de uso comunes.

##### **Clasificación binaria**

Esta tarea se usa para predecir a cuál de los de las dos clases (categorías) pertenece una instancia de datos. La entrada de un algoritmo de clasificación es un conjunto de ejemplos con etiqueta, donde cada etiqueta es un número entero de 0 o 1. El resultado de un algoritmo de clasificación

binaria es un clasificador, que puede usar para predecir la clase de nuevas instancias sin etiqueta.

### **Clasificación multiclase**

Una tarea de aprendizaje automatizado supervisado que se usa para predecir la clase (categoría) de una instancia de datos. La entrada de un algoritmo de clasificación es un conjunto de ejemplos con etiqueta. Cada etiqueta se inicia normalmente como texto. Luego se ejecuta mediante TermTransform, que lo convierte al tipo de clave (numérico). El resultado de un algoritmo de clasificación es un clasificador, que puede usar para predecir la clase de nuevas instancias sin etiqueta.

### **Regresión**

Una tarea de aprendizaje automatizado supervisado que se usa para predecir el valor de la etiqueta a partir de un conjunto de características relacionadas. La etiqueta puede tener cualquier valor real y no proviene de un conjunto finito de valores como en las tareas de clasificación. Los algoritmos de regresión modelan la dependencia de la etiqueta de sus características relacionadas para determinar cómo cambiará la etiqueta a medida que varíen los valores de las características. La entrada de un algoritmo de regresión es un conjunto de ejemplos con etiquetas de valores conocidos. El resultado de un algoritmo de regresión es una función, que puede utilizar para predecir el valor de etiqueta para cualquier nuevo conjunto de características de entrada.

### **Agrupación en clústeres**

Una tarea de aprendizaje automático no supervisado que se usa para agrupar instancias de datos en clústeres que contienen características similares. La agrupación en clústeres también se puede utilizar para identificar relaciones en un conjunto de datos que podrían no detectarse lógicamente mediante la exploración o la simple observación. Las entradas y salidas de un algoritmo de agrupación en clústeres dependen de la metodología elegida. Puede tomar un enfoque de distribución, centroide, de conectividad o de densidad. ML.NET admite actualmente un enfoque basado en centroide mediante la agrupación en clústeres K-Means.

### **Detección de anomalías**

Esta tarea crea un modelo de detección de anomalías mediante el uso de análisis de componentes principales (PCA). La detección de anomalías basada en PCA le permite generar un modelo en escenarios donde resulta sencillo obtener datos de entrenamiento de una clase,

como transacciones válidas, pero difícil obtener muestras suficientes de las anomalías de destino.

### **Clasificación**

Una tarea de clasificación construye un clasificador a partir de un conjunto de ejemplos etiquetados. Este conjunto de ejemplos consta de grupos de instancias que se pueden puntuar con un criterio determinado. Las etiquetas de clasificación son {0, 1, 2, 3, 4} para cada instancia. El clasificador está entrenado para clasificar nuevos grupos de instancias con puntuaciones desconocidas para cada instancia.

#### **7.2.2. Aprendizaje profundo.**

Deep Learning conocido más como aprendizaje profundo, lleva a cabo un proceso de Machine Learning que se caracteriza en una red neuronal artificial que se compone de un número de niveles jerárquicos. Es un concepto que nace de una idea simular el funcionamiento del cerebro humano, tomando en cuenta que se aplica en diferentes campos de la ciencia y de la ingeniería como el reconocimiento de voz o la clasificación de imágenes de una forma automática, basándose en técnicas como el aprendizaje profundo que tiene como funcionalidad procesar datos en tiempo real con una precisión y eficacia y a una alta velocidad. Sin embargo, el aprendizaje profundo logra identificar patrones que extraen características de datos complejos sin la participación alguna del ser humano, del mismo modo, que dicha técnica se convierte en una herramienta de gran importancia para el análisis de grandes datos o Big Data. (Bah, Dericquebourg, Hafiane, & Canals, 2019).

Por otra parte, aprendizaje profundo es un sub componente de aprendizaje automático, que se le considera también como redes neuronales profundas e incluso es un aspecto de la inteligencia artificial que se ocupa de emular el enfoque de aprendizaje que los seres humanos utilizan para obtener algunos tipos de conocimientos. También aprendizaje profundo comprende una estructura compleja de algoritmos que intenta modelar abstracciones de alto nivel, en su forma más simple, el aprendizaje profundo puede considerarse como una forma de automatizar en análisis predictivo. (Yu, Sharpe, Schumann, & Boyd, 2019). También Deep Learning se considera un área de mayor desarrollo, lo mismo que utiliza algoritmos multinivel para generar distintos niveles de abstracción de la información. Algunos ejemplos de aplicaciones son: el reconocimiento de imágenes, voz, predicción de tendencias digitales, entre otros. (Rodríguez, 2018).

### 7.2.3. Redes neuronales.


Las redes neuronales son procesos de un modelo no lineal sofisticadas que permite modelar funciones complejas, de igual modo que las redes neuronales suelen aplicarse a los problemas de predicción, clasificación o diferentes campos como son las finanzas, la psicología cognitiva/neurociencia, la medicina, la ingeniería y la física. Las redes neuronales se emplean cuando se conoce la naturaleza exacta de la relación entre los valores de entrada y salida. (Timón, 2017).

#### Capas de una red neuronal

Se caracterizan por una serie de neuronas organizadas en diferentes capas, según el funcionamiento de cada una de ellas, como se muestra en la Figura 1 se puede observar tres tipos de capas.

- **Capa de entrada:** Esta capa de entrada es la que se encarga de recibir los datos para el análisis correspondiente.
- **Capa oculta:** los mismos que pasan por el medio de la “capa oculta”, la que se encarga de procesar y realizar cálculos internos, estas capas pueden estar interconectadas en diversas formas.
- **Capa de salida:** esta capa es la que se encarga de recibir los resultados finales. (Estradas, 2017).

**Figura 1:** Esquema de una red neuronal.



**Fuente:** (Estradas, 2017).

Las redes neuronales tratan sobre el funcionamiento de la neurona biológica y del funcionamiento de la sinapsis humana. Este tipo de redes son un modelo de aprendizaje y de procesamiento automático, es decir se refiere a un sistema de interconexión entre neuronas que colaboran entre sí para promover un estímulo de salida. (Gutiérrez, 2016)

Las redes neuronales se emplean cuando se desconocen de la naturaleza exacta de la relación entre los valores de entrada y salida, una característica fundamental de las redes neuronales es

que aprenden la relación que tienen los valores de entrada y salida a través del entrenamiento. (Espino, 2017).

### Niveles o capas de una red neuronal.

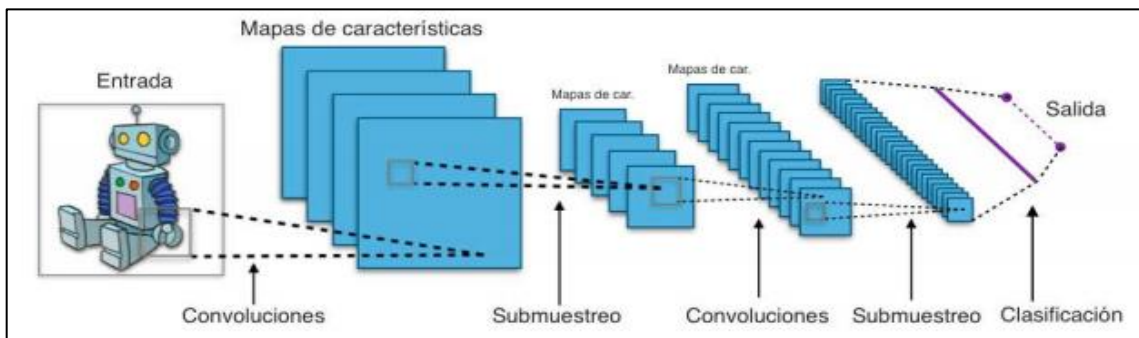
La distribución de neuronas dentro de la red, se efectúa formando niveles o capas con un número específico de las neuronas en cada una de ellas, es por eso que se puede identificar tres tipos de capas como son:

- **De entrada:** Esta capa recibe directamente toda la información de las fuentes externas de la red.
- **Ocultas:** Son internas a la red, lo cual no tienen ninguna relación directo con el medio exterior, el número de niveles ocultos puede estar entre 0 o cualquier número indefinido. Las neuronas de las capas ocultas pueden estar interconectadas de diversas formas, lo cual establece junto con su número, las diferentes topologías de redes neuronales.
- **De salidas:** Transfieren la información de la red hacia el exterior. (Matich, 2001)

#### 7.2.4. Redes neuronales convolucionales (CNN).

Las redes neuronales convolucionales nacen de la necesidad de procesar imágenes de forma efectiva y eficiente, por otra parte, son algoritmos más populares de Deep Learning que son variante del perceptron multicapa, utilizadas para el reconocimiento de objetos en imágenes. Las CNN son particularmente apropiadas para aplicaciones en las que los datos se encuentran en forma de una rejilla, con matrices, en la Figura 2 se muestra la arquitectura básica de un CNN el principal objetivo es manejar los datos que representan los píxeles en forma de volúmenes y no como vectores, debido a esto es que son utilizadas en aplicaciones que utilizan visión artificial, tales como pueden ser el reconocimiento de objetos en imágenes como se mencionó anteriormente, clasificación de imágenes o video, segmentación, descripción de escenas, seguimiento de objetos en videos y mucho más. (Rigoberto, 2018) .

**Figura 2:** Esquema de la red neuronal convolucionales.



**Fuente:** (Durán, 2017).

Las redes neuronales convolucionales se definen como un grupo de neuronas que reaccionan en función de estímulo, esta red neuronal proviene de la familia de Deep Learning específicamente diseñada para aprender y describir características de dichas imágenes, donde están incorporando operaciones no lineales de manipulación de imágenes. Además, las redes convolucionales están diseñadas suponiendo que la entrada a la red es una imagen, lo cual permite codificar ciertas propiedades en la arquitectura, en donde permitirá ganar y reducir la cantidad de parámetros usando en la red. (Durán, 2017)


#### 7.2.4.1. Arquitecturas de redes neuronales convolucionales.

Las redes neuronales profundas y el aprendizaje profundo son algoritmos poderosos donde a la vez una parte de su éxito radica en el cuidadoso diseño de la arquitectura de las redes neuronales. Según el orden cronológico existen diversos tipos de arquitecturas:

##### Letnet

La arquitectura LeNet es una CNN básica que fue empleada para el reconocimiento de dígitos escritos. Una variante muy exitosa es la LetNet5 se caracteriza por tener cinco pasos, como se muestra la Figura 3, la implementación de esta arquitectura da una precisión de clasificación de aproximadamente el 99,2% con una tasa de error del 0,8% (Badra, 2018).

**Figura 3:** Arquitectura de LeNet5



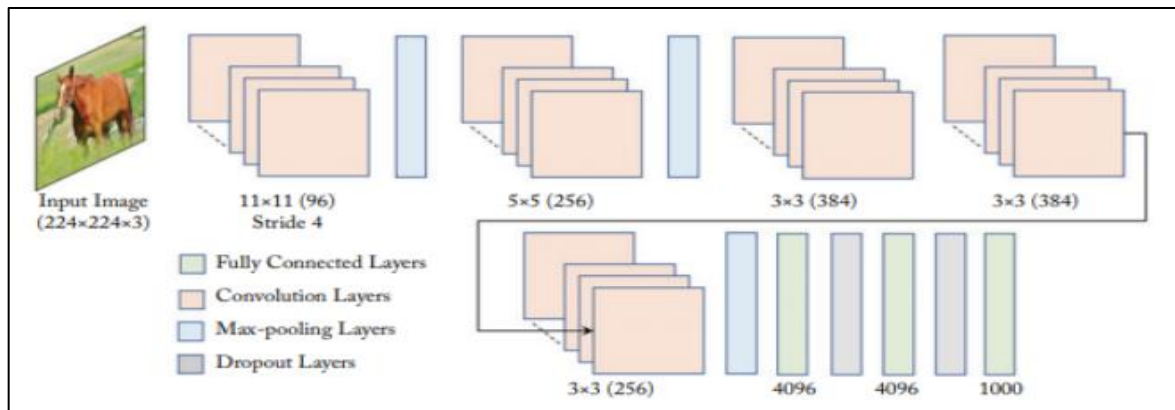
**Fuente:** (Badra, 2018).

Esta red es una de la primera red neuronal convolucional apareció en 1994, dicha red determina que las características de la imagen se distribuyen en toda la imagen, mientras que las convoluciones son una forma eficaz de extraer características similares. LetNet5 demostró que no se debería utilizar la primera capa, por el simple hecho de que las imágenes están altamente correlacionadas y el uso de píxeles individuales en arquitecturas CNN. (Valderrama, 2017). LaNet5 suele ser un conjunto de capas de convolucion aplicadas de una o más capas que se encuentran completamente contactadas, donde dichas capas pueden tener una capa de normalización y una capa de agrupación.

## Alexnet

Arquitectura que llevó al resurgimiento de las redes neuronales profundas en el campo de la visión por computadora como se muestra en la Figura 4. (Badra, 2018). AlexNet es una versión más profunda y mucho más grande que LetNet que se emplea para aprender objetos más complejos.(Valderrama, 2017).

**Figura 4:** Arquitectura de AlexNet.

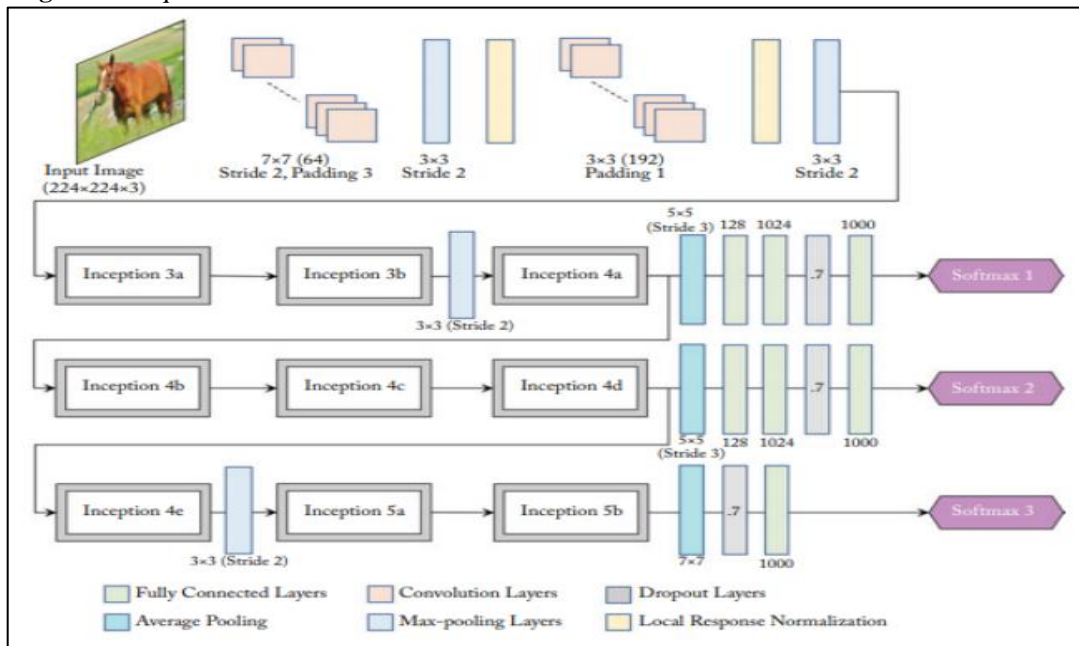


**Fuente:** (Badra, 2018).

La entrada a AlexNet es una imagen RGB de tamaño 256x256, lo que significa que todas las imágenes del conjunto de entrenamiento y todas las imágenes de prueba debe tener un tamaño de 256x256, donde se debe lograr la dimensión más pequeña, tomando en cuenta de que si la imagen no es de la medida mencionada anteriormente se debe convertirse a la medida correcta antes de ser usada para entrenar en la red. Cabe recalcar que AlexNet es una arquitectura para cualquier tarea de detección de objetos, donde puede tener enormes aplicaciones en el sector de visión artificial. (Han, Zhong, Cao, & Zhang, 2017).

## Resnet o red residual

Esta red fue creada por Microsoft que se caracteriza por saltarse las conexiones que permite entender fácilmente arquitecturas de CNN muy profundas como se muestra en la Figura 5. (Badra, 2018). ResNet o Red Residual tiene como propósito alimentar la salida de dos capas convolucionales sucesivas, para luego pasar la entrada a la capa siguiente, además dicha red se utiliza una capa de agrupación más de una capa de una función exponencial normalizada como clasificador final. (Valderrama, 2017).

**Figura 5:** Arquitectura de ResNet.

Fuente: (Badra, 2018).

## Vgg net

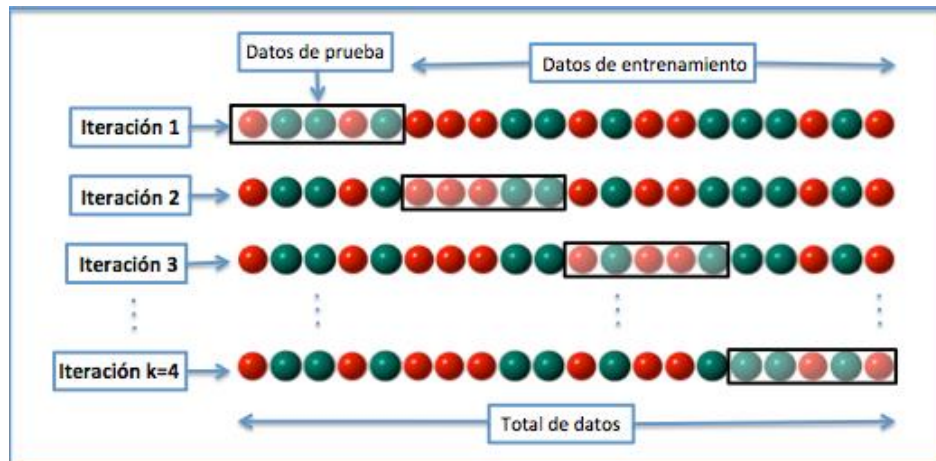
Esta arquitectura es la que utilizó por primera vez los filtros  $3 \times 3$  que son mucho más pequeños en cada uno de las capas convolucionales, una de las grandes ventajas fue la percepción de la convolucion múltiple, para representar características complejas. Los VGG usan tamaños de características grandes en muchas capas y por lo tanto es bastante costoso en tiempo de ejecución. (Valderrama, 2017).

### 7.2.6. Técnica de evaluación

#### Validación cruzada.

Validación cruzada o cross-validation es una técnica diseñada para modelos de regresión y predicción, donde utiliza  $k$ -iteraciones, la cual consiste en dividir el conjunto de datos en  $k$  subconjuntos. Uno de los subconjuntos se utiliza como datos de validación y el resto ( $k-1$ ) como datos de entrenamiento. El proceso de validación cruzada es repetido durante  $k$  iteraciones, con cada uno de los posibles subconjuntos de datos de validación (ver Figura 6). Principalmente se las utiliza para estimar con que precisión un modelo predictivo se desempeña en la práctica. (Parra, 2019).

**Figura 6:** Técnica de validación cruzada.



**Fuente:** (Parra, 2019).

Por otro lado la validación cruzada es una técnica que se utiliza para evaluar los resultados de un análisis estadístico y garantizar que son independientes de la partición entre los datos de entrenamiento y prueba, por la cual dicha técnica se utiliza en entornos donde el objetivo principal es la predicción y se quiere estimar como de preciso es un modelo que se llevará a cabo a la práctica, se puede mencionar que esta técnica es muy utilizada en proyectos de inteligencia artificial para validar modelos generados. (Ochoa, 2019).

## 7.2.7. PLATAFORMA DE APRENDIZAJES

### 7.2.7.1. Custom Vision

La plataforma de Custom Vision permite crear, implementar y mejorar sus propios clasificadores de imágenes. Un clasificador de imágenes es un servicio de IA que aplica etiquetas (que representan clases) a las imágenes, en función de sus características visuales.

#### ¿Qué hace Custom Vision?

Custom Vision utiliza un algoritmo de aprendizaje automático para aplicar etiquetas a las imágenes. El usuario, el desarrollador, debe enviar grupos de imágenes que presenten y carezcan de las características en cuestión. El desarrollador etiqueta las imágenes en el momento de la presentación. Luego, el algoritmo se entrena con estos datos y calcula su propia precisión probándose en esas mismas imágenes. Una vez que se entrena el algoritmo, puede probarlo, volver a entrenarlo y eventualmente usarlo para clasificar nuevas imágenes de acuerdo con las necesidades de su aplicación. También puede exportar el modelo en sí para su uso sin conexión.

### **Clasificación y detección de objetos.**

La funcionalidad de visión personalizada se puede dividir en dos características. La clasificación de imagen aplica una o más etiquetas a una imagen. La detección de objetos es similar, pero también devuelve las coordenadas en la imagen donde se pueden encontrar las etiquetas aplicadas.

### **Mejoramiento**

El servicio Custom Vision está optimizado para reconocer rápidamente las principales diferencias entre las imágenes, por lo que puede comenzar a crear prototipos de su modelo con una pequeña cantidad de datos. 50 imágenes por etiqueta son generalmente un buen comienzo. Sin embargo, el servicio no es óptimo para detectar diferencias sutiles en las imágenes (por ejemplo, detectar grietas o abolladuras menores en escenarios de garantía de calidad).

### **Lo que incluye**

El servicio Custom Vision está disponible como un conjunto de SDK nativos, así como a través de una interfaz basada en la web en la página de inicio de Custom Vision. Puede crear, probar y entrenar un modelo a través de cualquiera de las interfaces o usar ambos juntos.

### **7.2.8. Aplicaciones móviles.**

Las tecnologías móviles y su continuo avance están propiciando una nueva generación de aplicaciones, estas son las denominadas aplicaciones móviles o app es simplemente un programa informático o software desarrollado para ser ejecutada en diferentes dispositivos móviles, permitiendo al usuario realizar varias tareas, a la misma vez permite acceder desde cualquier lugar o momento, tomar en cuenta que existe dos categorías en las que se puede clasificar las aplicaciones móviles: aplicaciones nativas son desarrolladas específicamente para un tipo de dispositivo y las aplicaciones web se ejecuta en servidores que pueden desarrollar en Java Script, CSS. (Enriquez & Casas, 2014).

#### **7.2.8.1. Sistemas operativos para dispositivos móviles.**

Es una capa compleja entre hardware y el usuario, facilitando al usuario o al programador las herramientas e interfaces apropiadas para desarrollar las tareas informáticas evitándole de los complicados procesos necesarios para llevarlas a cabo de acuerdo con los dispositivos móviles desde reproductores de audio, navegadores de GPS, donde existen multitud de opciones, las

cuales son BlackBerry OS, Windows Mobile, y Android. (Baz, Ferreira, Álvarez, & García, 2011).

### **7.2.9. Android Studio**

Android Studio es un entorno de desarrollo integrado (IDE) que básicamente está diseñado para teléfonos móviles, que permite programar crear aplicaciones, proporcionando todas las interfaces necesarias para desarrollar de manera fácil aplicaciones que accedan a las funciones del teléfono, tomando en cuenta que Android es un sistema de código abierto, que se programa principalmente en Java y su núcleo se basa en Linux, es por eso que gracias a la existencia de esta herramienta de programación existen cientos de miles de aplicaciones disponibles que facilita y mejora la experiencia del usuario. (Brazzero, 2019).

Además, Android también posee bibliotecas que son escritas en lenguaje C, en la cual incluye un emulador de dispositivos, así como las herramientas necesarias para la depuración de la memoria y el análisis del rendimiento del software. Cabe recalcar que la diferencia de otros sistemas operativos es que cualquier persona con conocimientos de programación pueda crear nuevas aplicaciones o a su vez pueda incluir o modificar sus propios sistemas, dado que Android es de código abierto en un ambiente del lenguaje Java fácil. (Sanz, 2016).

#### **7.2.9.1. Arquitectura de Android Studio**

##### **Aplicaciones**

Las aplicaciones incluyen un cliente de correo electrónico, contactos, navegador mapas, calendario entre otros, tomando en cuenta que todas las aplicaciones están escritas en lenguaje de programación Java. (Clavijo, 2017).

##### **Marco de trabajo de aplicaciones**

En este caso los programadores tienen acceso completo los mismos APIs de framework usados por las aplicaciones, tomando en cuenta que están diseñadas para cualquier aplicación, los mismos que permiten a los usuarios remplazar varios componentes. (Clavijo, 2017)

##### **Bibliotecas**

Android contiene un conjunto de bibliotecas C/C++ usadas por varios componentes del sistema, los mismos que se exponen a los desarrolladores a través del marco de trabajo de aplicaciones de Android, estas bibliotecas son las bibliotecas de gráficos, 3D y SQLite. (Clavijo, 2017).

## **Runtime de Android**

Incluye bibliotecas que proporciona todas las funciones disponibles en bibliotecas para el lenguaje Java, tomando en cuenta que cada Android corresponde a cada proceso a cada instancia de la máquina virtual que se basa en registros y por el compilador de Java. (Clavijo, 2017)

### **7.2.9.2. Ventajas de Android Studio**

- Android es de código abierto en donde cualquier persona puede realizar una aplicación web o móvil.
- El sistema Android es capaz de hacer funcionar varias aplicaciones e incluso se encarga de dejar en modo de suspensión cuando lleva un periodo determinado de inactividad.
- La mayor ventaja de Android es carga con mayor rapidez una aplicación abierta como podría ser en Google Maps.
- Android es un código abierto, libre, cómodo en costo y gusto. (Clavijo, 2017).

### **7.2.10. Tensorflow**

Es una librería de código abierto capaz de realizar operaciones (numéricas, computación) usando el flujo de datos en un grafo. En este grafo se muestra, los nodos que representan las operaciones mientras tanto que las aristas también representan (tensores) como estructuras de datos (Rios, 2016).

### **7.2.11. Las malas hierbas**

Las malas hierbas se le define también como hierbas molestas y difíciles de eliminar dentro de cualquier cultivo, en donde estas absorben el agua y los nutrientes de las buenas plantas para que las semillas no germinen o las plantas de semillero no puedan acceder a la luz suficiente y con el tiempo pueda morir algunas de estas plantas, las malas hierbas son muy competitivas que en realidad asesinan a las plantas deseables ocasionando que estas plantas se dispersan por todo el cultivo, causando enfermedades al paso del tiempo (Dorado, 2014).

Las malas hierbas son un gran problema para los cultivos, originando daños de varias formas ya que intervienen en el cultivo y en las actividades agrícolas, también compiten con los cultivos por el espacio, luz, agua y potencialmente los nutrientes que pueden ser albergado de enfermedades y plagas que crecen junto a la planta. (Taberner, 2013).

Estas especies de plantas adaptables invaden y prosperan en hábitats alterando de una forma u otra, estas son manejadas por el ser humano y que en un cierto espacio y tiempo intervienen en

diferentes campos donde se desarrollan estas malas hierbas como son las tierras de cultivo, pastizales, bosques, jardines, reservas naturales etc. estas especies vegetales son dominadas y resistentes en su habilidad especial para beneficiarse en el campo (Castro, 2017).

También las malas hierbas causan mayores pérdidas o daños en la agricultura las plagas y enfermedades de las plantas cultivadas y representan una barrera más importante para la producción de alimentos y el desarrollo económico de muchas regiones del mundo. Se ha considerado como uno de los principales responsables de cuantiosas pérdidas causadas por estas en el rendimiento de los cultivos ya que esta lucha de plantas buenas y las malas hierbas.

### **7.2.12. Localización de las malas hierbas**

El manejo de las malas hierbas dentro de los sistemas de agricultura precisión tiene numerosas especificidades que lo diferencian del control de las mismas, con el cultivo en primer lugar, se debe considerar, que diversos tipos de plantas aumentan con mayor fuerza los rebrotes, durante el periodo de barbecho (labrado) suelen estar presentes en el momento de la siembra. (Sánchez, 2014).

Las malas hierbas van orientadas aquellas zonas de cultivo que lo necesitan y sus tipos de herbicida que lo requieran para cada grupo de malas hierbas dependiendo si son monocotiledóneas o dicotiledóneas (Sánchez, 2014).

Por otra parte el desarrollo de una especie de mala hierba está condicionado por su capacidad de competición con las buenas hierbas en muchos casos es variable en la función de las características casuales que son ofrecidas durante su desarrollo vegetativo para las malas hierbas no habiendo una constante que permita indicar las características del manejo de suelo, influyendo en su manifestación en el campo que van en aumento (G.M, 2015).

Se podría considerar cuatro parámetros implicados en el manejo de los cultivos.

1. Monitorización que se basa en la detección y mapeo de variables que determine a cada momento de infestaciones y presencias de malas hierbas en todo el campo.
2. La toma de decisiones y elaboración del mapa de tratamiento en función del mapa obtenido que da como resultados a las decisiones que lo han manejado en diferentes cultivos.
3. Actuación en el campo y la ejecución del manejo localizado que se ha decidido.
4. Evaluación de la rentabilidad económica y medioambiental de las operaciones realizadas en cultivos.

### **7.2.13. Identificación de malas hierbas en la agricultura.**

En la agricultura las malas hierbas se las localizan con exactitud mediante imágenes de líneas principales de cultivo que facilita la tarea de discriminación y detección con medios accesibles, tomando en cuenta que con el avance de la tecnología existen drones quien con su estructura aeronáutica de seguridad visualiza cada una de las especies vegetales en el campo. (Barreiro, 2014)

En la actualidad se ha desarrollado tecnologías muy avanzadas para identificar y localizar, especies vegetales en este caso los drones son utilizados para la identificación en imágenes capturadas dentro del campo, sin embargo, es imprescindible el acceso rápido y eficiente a una información amplia y fiable para una mejor decisión, la sociedad con el tiempo debe renovarse a la agricultura para que pueda adaptarse a distintos escenarios y resolver los diferentes problemas de las malas hierbas, al utilizar las TIC (Tecnologías de información y comunicación) permite mejorar la capacidad y especificar la recolección de datos de pequeños agricultores facilitando la información amplia y beneficios alrededor de los agricultores quienes están dedicados a la agricultura (Herrero, 2014).

La identificación temprana de las malas hierbas es prioritaria en la actualidad en cualquier parte del mundo, se está volviendo más importante debido a las nuevas circunstancias como la resistencia de herbicidas en el campo, en primer factor es evitar la competencia con el cultivo o en cualquier ambiente que se encuentra ya que se produce en las primeras semanas de convivencia con las demás plantas limitando la calidad y el factor económico que perjudica a los agricultores comprando más fertilizantes para el campo. (Sousa, 2017).

### **7.2.14. Estado del arte de sistemas usados para la clasificación de malas hierbas.**

Mads Dyrmann realizó estudios sobre las especies de malezas que se presentan a diario en los campos agrícolas. En dicho estudio se presenta el método que es capaz de reconocer especies de plantas en imágenes mediante el uso de una red neuronal convolucional, por otra parte la red está construida desde cero y ha sido probada en un total de 10.413 imágenes que contienen 22 especies de malezas y cultivos en las primeras etapas de crecimiento contienen variaciones con respecto a iluminación y resolución de suelo para estas 22 especies, la red puede lograr una precisión de clasificación del 86,2%. (Dyrmann, Karstoft, & Midtiby, 2016)

Ignacio Heredia discute el potencial de aplicar técnicas de aprendizaje profundo para la clasificación de plantas, por ende, muestra que la clasificación de plantas usando la arquitectura

de red convolucional de última generación como ResNet50 logrando mejoras significativas en precisión, comparación para la aplicación de clasificación de plantas en conjunto de pruebas, que están compuestas por miles de etiquetas de especies diferentes. (Heredia, n.d.)

Jana Müllerová, Jan Pergl y Petr Pysek realizaron un estudio para evaluar las invasiones de plantas las que representan una amenaza no solo a la biodiversidad, a pesar de los esfuerzos que realizan para controlar y erradicar especies invasoras, su amenaza crece es por ello que han utilizado técnicas que permite un monitoreo rápido, preciso que proporcione información sobre la estructura especialmente de las plantas invasoras, implementando estrategias eficientes, una de ellas es la evolución por teledetección de un especie invasora *Heracleum mantegazzianum* (gigante hogweed) integrando diferentes fuentes de datos, resoluciones espaciales, espectrales y técnica de procesamiento de imágenes. Para evaluar su potencial, en cuanto al monitoreo de la especie hogweed en base al uso de píxeles y análisis de imagen basado en objetos (OBIA, jerárquico automatizado, iterativo y basado en reglas). Realizando una evaluación de precisión basada en puntos y cuadrículas. El análisis de los datos de VHR permitió el monitoreo de Hogweed con altas precisiones de clasificación medidas independientemente de la resolución espectral de los datos, siempre y cuando los datos provengan de la especie en período de floración. (Müllerová, Pergl, & Py, 2013)

Stefan Paulus, Jan Dupuis, Katrin Mahlein y Heiner Kuhlmann realiza un estudio basado en histograma de características de superficie del campo y de la robótica donde se adaptó a escaneos de láser en primer plano las plantas, donde las características de puntos geométricos locales describen características de clase, que se utilizaron para distinguir entre diferentes órganos de plantas. Este enfoque ha sido probado en varias especies de plantas. Tallos y hojas en base a una clasificación con una precisión de hasta el 98%. El método propuesto se transfirió con éxito a las escalas láser 3D de trigo plantas para estimación de rendimiento. Las espigas se separaron con una precisión del 96% de otros órganos de la planta. (Paulus, Dupuis, Mahlein, & Kuhlmann, 2013).

#### **7.2.15. El maíz en el Ecuador**

El maíz es una planta de fácil desarrollo y de producción de forma anual, perteneciente al género de las Zeas (comprende varias especies de gramíneas de origen americano) de nombre científico *Zea Mays* (maíz), familia de las gramíneas. El maíz amarillo duro (tipo cristiano) que se produce en Ecuador es de excelente calidad tanto para la elaboración de alimentos, balanceados

como para las industrias que cumple un componente básico en la población ecuatoriana (Yáñez, 2013)

Todas las plantas de maíz se desarrollan de la misma manera y el tiempo que se demora en su crecimiento ya se en etapas de progreso y estas pueden variar dependiendo del tipo de maíz y la fecha de siembra, es de 215 a 270 días desde la siembra hasta la cosecha (Yáñez, 2013).

De la misma forma existen diferentes tipos de maíz en la sierra ecuatoriana depende de las costumbres y gustos del agricultor. La planta de maíz ha venido formando parte de la producción agrícola del país juega un rol importante en la alimentación indígena y campesina, ya que preserva su importancia como elemento ritual y festivo. (Geonanny, 2016).

#### **7.2.16. Principales malas hierbas en maíz**

Las principales malas hierbas que compiten en los cultivos de maíz y ponen en riesgo el desarrollo y germinación de la planta son:

##### **Abutilon (Abutilon the ophrasti).**

Es fácilmente identificable por tener hojas con un tacto característico, como el terciopelo de porte vegetativo muy desarrollado tiene gran capacidad de producir semillas durante un periodo extenso, esta planta se dispersa alrededor de todas las plantas que se encuentran en todo el campo como se muestra en la Figura 7. (Dorado, 2017).

**Figura 7:** Abutilon



**Fuente:** (Dorado, 2017)

##### **Ambrosia Artemisiifolia**

Este tipo de mala hierba se le conoce con un nombre común que es Ambrosia, que es una especie anual que por lo general germina a finales de la primavera y se desarrolla durante la época de verano, que se puede encontrar en cultivos arados, dicha mala hierba se caracteriza por tener un tallo dividido con pelos separados, especialmente en la parte superior, mientras

que las hojas tienen 3 lóbulos como se muestra en la Figura 8. (Quiroz García, Laplace, Rodríguez, & Laplace, 2011).

**Figura 8:** Ambrosia Artemisiifolia.



**Fuente:** (Quiroz García, Laplace, Rodríguez, & Laplace, 2011).

### **Cadillo (Xanthium)**

Es fácilmente identificable por sus frutos con zarcillos adaptados para pegarse a la piel de los animales y así facilitar su dispersión, dicha planta suele encontrarse en diversos lugares del maíz, como se muestra en la Figura 9. (Dorado, 2017).


**Figura 9:** Xanthium.



**Fuente:** (Dorado, 2017).

### **Chenopodium Album**

Es una mala hierba que comúnmente también se lo conoce como cenizo blanco, dicha planta es de primavera y verano que por lo general crece de manera abundante en climas templados o fríos. (Andújar, 2017). Esta especie se caracteriza por sus hojas simples de forma triangulares, harinosas, por otra parte, Chenopodium Album también posee flores pequeñas y verdosas, con un tallo grueso, como se muestra en la Figura 10, que pueden medir hasta 0,40 – 1,50 metros de altura, muchas veces se puede confundir con otras especies del mismo género, este tipo de mala hierba es de casi todos los cultivos extensivos, en huertos, jardines. (Quiroz García et al., 2011).

**Figura 10:** *Chenopodium Album*.

Fuente: (Andújar, 2017).

### ***Erodium Cicutarium***

Es una mala hierba que comúnmente se le llama Alfiler de pastor, que se caracteriza por ser cotiledóneas asimétricas que mide de unos 4-7 mm, sus hojas son verdaderas alternas, ovales, a menudo el tallo y las hojas toman un color rojizo, *Erodium Cicutarium* se puede confundir con otras de la misma especie en especial con la *Erodium Moschatum*, a continuación, se muestra la Figura 11. En estado de plántula cotiledones asimétricas y divididas en lóbulos, así como también las plantas adultas en floración, dicha planta se presenta en cultivos donde frecuentemente se hallan otras especies de malas hierbas, el monte, etc. (Recasens J. a., 2009).

**Figura 11:** *Erodium Cicutarium*

Fuente: (Recasens J. a., 2009)

### ***Galinsoga Parviflora***

Esta mala hierba se le considera como hierba pajarito, que se caracteriza por ser parte de cotiledones oval, con un tallo con pelos y glándulas, que posee hojas ovales, donde pueden contener de 40 o más flores como se muestra en la Figura 12. (Recasens J. a., 2009).

**Figura 12:** Galinsoga Parviflora.



**Fuente:** (Recasens, 2009).

### **Los bledos (Amaranthus)**

Esta planta pertenece a un género problemático debido a su metabolismo y capacidad para producir semillas y la tolerancia a ciertos herbicidas, por ende son varias las especies que se presentan como malas hierbas en el cultivo de maíz estas crecen y se reproducen muy rápidamente, como se muestra en la Figura 13. (Dorado, 2017).

**Figura 13:** Amaranthus.




**Fuente:** (Dorado, 2017).

### **Raphanus Raphanistrum**

Esta planta se le considera comúnmente como Rábano silvestre por lo general crece en invierno, esta mala hierba es principal y muy frecuente en todo tipo de cultivos, que se caracteriza por los cotiledones que tienen la forma entre acorazonada que puede alcanzar una altura de 1,5 m, con un tallo erecto, ramificados gruesos, estas son cubiertas de cerdas, cuando son maduros los tallos son semi-leñosos como se muestra en la Figura 14. Dicha planta es similar a las otras especies similares, pero se distingue por sus primeras hojas que son dentadas. (Díaz, 2017).

**Figura 14:** Raphanus Raphanistrum.



Fuente: (Díaz, 2017)

### **Urtica urens**

Esta mala hierba es muy conocida por la mayoría de los agricultores con un nombre muy común ortiga menor, que germina en las épocas de otoño e invierno, por ende, se le considera como una mala hierba que no tiene muchos beneficios, posee características como una plántula erecta, con tallos prismáticos y hojas opuestas, con una longitud de 4- mm de longitud, con pelos erizados como se muestra en la Figura 15. (Recasens J. a., 2009).

**Figura 15:** Urtica urens



Fuente: (Recasens, 2009).

### **Tomatito (Solanum)**

Tomatito es una mala hierba que se caracteriza por emerger durante todo el ciclo de cultivo, escapando así a los métodos de control de malas hierbas las especies más frecuentes de este género a nivel nacional afectando toneladas de siembra, como se muestra en la Figura 16. (Dorado, 2017).

**Figura 16:** Tomatito


**Fuente:** (Dorado, 2017).

### 7.2.17. Herbicida

Un herbicida son sustancias químicas empleadas capaces de destruir o impedir el crecimiento de las malas hierbas en los cultivos. Los mismos que generan su efecto letal actuando sobre un sitio primario de acción y generando una serie de efectos secundarios y terciarios que conlleva a la muerte de la planta. Tomando en cuenta que El modo de acción de un herbicida consiste en la secuencia de eventos que provocan los herbicidas en las plantas desde que se absorben hasta la eventual muerte de las mismas, mientras que el mecanismo o sitio de acción es el sitio que es afectado por el herbicida. Por ende, los herbicidas pueden clasificarse en familias de acuerdo a características comunes entre ellos. (Zubizarreta, 2014).

### Tipo de tratamiento

Atendiendo al momento de aplicación del herbicida en relación al estado del cultivo se diferencian los siguientes tratamientos como se muestra en la Figura 17:

**Figura 17:** Tipo de tratamiento

**Fuente:** (Garnica, 2009).

**Pre-siembra**

Se denomina así a la aplicación del herbicida antes de la siembra, con su incorporación mediante una labor mecánica inmediatamente para evitar su degradación, tomando en cuenta que en la actualidad no resulta frecuente. (Garnica, 2009)

**Pre-emergencia**

Consiste en aplicar el herbicida después de sembrar el maíz y antes de su germinación, esta práctica es la aplicación más común en este cultivo por los agricultores. (Garnica, 2009).

**Post-emergencia**

Cuando la aplicación del herbicida es posterior a la germinación del cultivo y de las malas hierbas se denominan tratamientos de post-emergencia. Algunos herbicidas típicos de pre-emergencia también pueden aplicarse con las malas hierbas recién nacidas, en lo que se denomina post-emergencia precoz. La post-emergencia propiamente dicha es una práctica dirigida al control de las malas hierbas en estado de plántula más o menos desarrollada que han escapado a una aplicación de presiembra o preemergencia, aunque en muchas zonas ha sustituido a estas. (Garnica, 2009).

**7.2.18. Tipos de herbicidas.****Ambrosia Artemisiifolia****Herbicida Atectra**

Es un herbicida selectivo y post-emergente soluble en agua que se recomienda para usarse en maíz y sorgo. El ingrediente activo de Atectra, actúa al contacto con la maleza y es absorbido por hojas, tallo y raíces translocándose dentro de la planta y provocando su muerte dentro de los siete días siguientes a la aplicación. (BASF, 2017) .

**Volumen de aplicación**

Realizar la aplicación, con un volumen de agua de 450-550 L/ha.

**Preparación.**

Agregue agua al tanque de mezclado hasta las  $\frac{3}{4}$  partes de su capacidad, luego agregue la cantidad necesaria de Atectra y llene el tanque a su capacidad mantenimiento una agitación constante. (BASF, 2017).

**Chenopodium Album****Herbicida Atectra BV**

Es un herbicida postemergente que controla malezas de hoja ancha. Su formulación presenta una nueva sal de Dicamba DGA (dicamba diglycolamine) con una volatilidad diez veces menor que la formulación tradicional de la sal DMA conocida en el mercado. (BASF, 2017).

**Volumen de aplicación**

Realizar la aplicación, con un volumen de agua de 0,15 a 0,5 l/ha

**Preparación.**

Atectra BV debe ser aplicado con agua. Para preparar la mezcla, llenar el depósito de la pulverizadora con agua hasta la mitad o  $\frac{3}{4}$  partes de su capacidad, luego agregar el producto Atectra BV con el agitador en marcha, que deberá estar en constante movimiento durante toda la aplicación. Completar el depósito con agua. (BASF, 2017).

**Erodium Cicutarium****Herbicida Atectra BV**

Es un herbicida postemergente que controla malezas de hoja ancha. Su formulación presenta una nueva sal de Dicamba DGA (dicamba diglycolamine) con una volatilidad diez veces menor que la formulación tradicional de la sal DMA conocida en el mercado. (BASF, 2017).

**Volumen de aplicación**

Realizar la aplicación, con un volumen de agua de 0,15 a 0,5 l/ha

**Preparación.**

Atectra BV debe ser aplicado con agua. Para preparar la mezcla, llenar el depósito de la pulverizadora con agua hasta la mitad o  $\frac{3}{4}$  partes de su capacidad, luego agregar el producto Atectra BV con el agitador en marcha, que deberá estar en constante movimiento durante toda la aplicación. Completar el depósito con agua. (BASF, 2017).

**Galinsoga Parviflora****Herbicida Basagran 60**

Es un herbicida de contacto para aplicar en post-emergencia, que se descompone en el suelo y no deja residuos que puedan afectar a futuros cultivos. Es una herramienta para el control de malezas, que posee amplitud de cultivos registrados y control tanto en malezas de hoja ancha. (BASF, 2017).

**Volumen de aplicación**

Realizar la dosis: 1,2 - 1,6 l/ha

**Preparación.**

Después que todas las malezas hayan emergido, ya que Basagran 60 no posee efecto residual en el suelo. Cuando las malezas son pequeñas (hasta 5 cm) y están en activo crecimiento. En no menos de 250 litros de agua por ha. Basagran 60 actúa por contacto, por lo tanto, es necesario mojar bien las hojas y tallos de las malezas. Alta luminosidad y temperatura favorecen la acción de Basagran 60, mientras que el tiempo fresco la retarda. Lluvias posteriores a 8 horas de la aplicación no afectan la actividad del producto. Adicionar coadyuvante Citowett Plus a razón de 0,15porc. (150 cm<sup>3</sup>/100 lts de caldo) lo cual aumenta la efectividad del tratamiento. Se debe escardillar luego de la aplicación, nunca antes de esta labor. Inmediatamente después de la aplicación de Basagran 60 se puede sembrar o implantar cualquier tipo de cultivo. (BASF, 2017).

**Raphanus Raphanistrum****Herbicida Atectra BV**

Es un herbicida postemergente que controla malezas de hoja ancha. Su formulación presenta una nueva sal de Dicamba DGA (dicamba diglycolamine) con una volatilidad diez veces menor que la formulación tradicional de la sal DMA conocida en el mercado (BASF, 2017).

**Volumen de aplicación**

Realizar la aplicación, con un volumen de agua de 0,15 a 0,5 l/ha.

**Preparación.**

Atectra BV debe ser aplicado con agua. Para preparar la mezcla, llenar el depósito de la pulverizadora con agua hasta la mitad o  $\frac{3}{4}$  partes de su capacidad, luego agregar el producto Atectra BV con el agitador en marcha, que deberá estar en constante movimiento durante toda la aplicación. Completar el depósito con agua. (BASF, 2017).

**Urtica urens****Herbicida Pivot.**

Es un herbicida selectivo con acción residual, en aplicaciones postemergentes en los cultivos de soja, maní, alfalfa, arveja, maíz resistente a imidazolinonas (identificado en la bolsa de semilla con el logo CLEARFIELD), y en aplicaciones preemergentes en el cultivo de proto. Luego de la aplicación de PIVOT, las malezas susceptibles detienen su crecimiento, dejando de competir con el cultivo; la muerte de las mismas puede demorar 3 a 4 semanas. (BASF, 2017).

**Volumen de aplicación**

Realizar la aplicación de 0.8 litros/ha de pivot por ha (hectáreas).

**Preparación.**

Llene el tanque de la pulverizadora hasta la mitad o las tres cuartas partes con agua limpia. Con el agitador en funcionamiento, vierta la cantidad recomendada de herbicida PIVOT al tanque del pulverizador. Luego complete el tanque con agua. Si las malezas han emergido añada un tensioactivo no iónico a la concentración de 0,25% de principio activo en el volumen total (250 gramos de principio activo cada 100 litros de agua). (BASF, 2017).

**8. VALIDACIÓN DE LAS PREGUNTAS CIENTÍFICAS O HIPÓTESIS.****8.1. FORMULACIÓN DEL PROBLEMA.**

¿Qué técnicas de aprendizaje profundo permiten la clasificación automática de malas hierbas en imágenes?

**8.2. HIPÓTESIS.**

El uso de las redes neuronales convolucionales permite la clasificación automática de malas hierbas en imágenes de cultivos de maíz.

**9. METODOLOGÍAS Y DISEÑO EXPERIMENTAL****9.1.1. Tipos de investigación.****9.1.1.1. Investigación mixta**

La investigación mixta permite combinar los métodos cuantitativos y cualitativos las mismas que permitieron comprender mejor el objeto de estudio sobre las malas hierbas en el cultivo de maíz, con las cuales se obtuvo una mejor explotación de las 6 especies y a la vez alcanzando los resultados óptimos y satisfactorios a los agricultores, botánicos, Herbario institucional, estudiantes, personal relacionado en el área de la Universidad Técnica de Cotopaxi.

**9.1.1.2. Investigación cuantitativa.**

Este tipo de investigación permitió conocer la realidad en la parroquia Tanicuchi, barrio Chilcapamba Sur donde se ha podido determinar en el lugar de los hechos con la recolección de fotografías de 6 especies vegetales en el cultivo de maíz con diferentes tipos de iluminación, lo cual se logró obtener una información sobre las especies de *Ambrosia Artemisiifolia*, *Urtica Urens*, *Rapahus Rapanistrum*, *Eradium Cicutarium*, *Galinsoga Parviflora*.

**9.1.1.3. Investigación cualitativa.**

En base a este tipo de investigación se estableció un análisis profundo, donde se obtuvo información en base a las guías de observación, fichas, revisión de documentos entre otras, con

esto se estableció la construcción la delimitación del problema, marco teórico, formulación del problema.

#### **9.1.1.4. Investigación bibliográfica.**

La investigación bibliográfica es imprescindible el empleo de los instrumentos o métodos adecuados que permitirá el análisis e interpretación de nueva información. La investigación bibliográfica es el punto de partida de cualquier tipo de investigación, por ende estos instrumentos serán los canales o hilos conductores que guiarán al investigador por el inmenso mundo del internet o por las bibliotecas o centros documentales clásicos en la búsqueda y selección de la información requerida.(Bellolio, 2013).

En la presente investigación de empleó la investigación bibliográfica, la cual permitió tomar como referencia investigaciones de distintos autores sobre el tema a tratar, para lo cual, lo cual será útil para sustentar el marco teórico y los resultados de la investigación e incluso permitió que la información sea precisa y confiable.

#### **9.1.1.5. Investigación de campo.**

La investigación de campo es la que consiste en la recolección de datos directamente de los sujetos investigados, o de la realidad donde ocurren los hechos obteniendo datos primarios, en la cual investigador obtiene la información, pero no altera las condiciones existentes. De allí su carácter de investigación no experimental. Los instrumentos que se utilizan de manera frecuente son la encuesta, entrevista y la observación. (Edison Cabezas, 2017).

Se utilizó la investigación de campo para la recolección de información en el lugar de los hechos en el Barrio Chilcapamba Sur Parroquia de Tanicuchi, en esta investigación se utilizó la técnica de la observación conjuntamente con las fichas de observación y por ende se aplicó el método no experimental.

#### **9.1.1.6. Investigación explicativa.**

La investigación explicativa se encarga de buscar el porqué de los hechos mediante el establecimiento de relaciones causa y efecto. En este sentido, los estudios explicativos pueden ocuparse tanto de la determinación de las causas de un hecho, como de los efectos, mediante la prueba de hipótesis. Obteniendo como resultados y conclusiones donde constituyen el nivel más profundo de conocimientos.(Edison Cabezas, 2017)

En el presente proyecto se aplicó la investigación explicativa la cual comprobó la hipótesis, el uso de las redes neuronales convolucionales en tareas de clasificación que demuestran ser

técnicas prometedoras capaz de clasificar la imagen que se pretende identificar en el cultivo de maíz.

## **9.2. Métodos teóricos.**

### **9.2.1. Hipotético deductivo.**

En este método se hace referencia a dos puntos de partida para nuevas deducciones, donde son puntos importantes dentro de cualquier investigación, de modo que se pueda comprobar a futuro la veracidad o falsedad de la investigación y del desarrollo de la investigación, pues son importante porque dichas variables demuestran la inconsistencia lógica de la hipótesis. (Omar & Ean, 2017).

En la investigación se utilizó este método, que permitió plantear la hipótesis en la que mediante ella se podrá explicar el tema que se investigó, realizando, varias pruebas que nos ayuden a comprobar la veracidad o la falsedad del problema a solucionar, comprobando de este modo si se puede obtener posibles soluciones.

### **9.2.2. Método no experimental.**

En este tipo de método no tiene determinación aleatoria, manipulación de variables o grupos de comparación de forma intencionada, la finalidad de esta investigación es observar lo que ocurre de manera natural, para luego analizarla. En los estudios experimentales las situaciones son reales, se observan situaciones existentes. Existen diferentes criterios para clasificar la investigación no experimental, en este sentido las investigaciones no experimentales pueden ser: longitudinales y transversales. (Sousa, Driessnack, Amélia, & Mendes, 2017).

El método no experimental no permite manipular deliberadamente las variables, este tipo de investigación permite observar los fenómenos tal y como se dan en su forma natural para después analizarlos.

## **9.4. Métodos empíricos.**

### **9.4.1. Técnicas de investigación.**

#### **9.4.1.1. Fichaje**

El fichaje es una técnica auxiliar empleada en la investigación científica, en la que consiste en registrar los datos que se van obteniendo de acuerdo a las fichas las cuales contienen mayor parte de la información que se recopila en una investigación ahorrando tiempo y espacio. (Chagoya, 2013).

En base a esta técnica permitió recolectar y almacenar información sobre las diferentes especies de malas hierbas que se encuentran en el cultivo de maíz, así como también las técnicas usadas para el reconocimiento de especies vegetales.

#### **9.4.2. Observación.**

La observación es una técnica fundamental de todo proceso investigativo por ende consiste en visualizar o captar mediante la vista, en forma sistemática, cualquier hecho, fenómeno o situación que se produzca en la naturaleza o en la sociedad, en función de unos objetivos de investigación preestablecidos, a la vez existe dos tipos de observación de forma directa ya que la indirecta se lo realiza mediante microscopio, telescopio, monitores, entre otros. (Paz, 2017)

Mediante esta técnica se pudo establecer una observación directa ya que se pone en contacto personalmente con lo que se va indagar, en este caso los cultivos de maíz, de donde se extrajo especies de malas hierbas considerando el tamaño y textura de cada especie.

#### **9.5. Instrumentos de investigación.**

##### **9.5.1. Ficha bibliográfica**

La ficha bibliográfica que se utiliza de forma directa o indirecta para cualquier investigación, tenemos que registrar con el fin de contener información suficiente para identificar la obra. (Paz, 2017).

Mediante la ficha bibliografía se obtuvo la información clave de las fuentes primarias y secundarias utilizados en la investigación, dicho instrumento hacer permitió hacer referencia a un artículo, libro o capítulos, especificando datos necesarios como el título, autor y año de publicación.

##### **9.5.2. Guía de observación.**

La guía para la observación es el instrumento que permite al investigador situarse y concentrarse de manera ordenada en aquello que realmente es objeto de estudio para la investigación, también es un medio que conduce a la recolección y obtención de datos de un hecho o fenómeno de una forma clara y objetiva para mediante ello el análisis de una situación o problema determinado. (Paz, 2017).

A través de la guía de observación, se registró y recopiló los datos en este caso una serie de fotografías correspondientes en tamaño y textura, tomadas en tres momentos del día en la mañana, medio día y en la tarde.

## **9.6. Métodos específicos.**

### **9.6.1. Plan de proyecto.**

#### **Objetivo**

Diseñar una aplicación móvil de especies de malas hierbas en imágenes a través del uso de clasificadores empleando técnicas de aprendizaje profundo para la identificación en cultivo de maíz.

#### **Delimitaciones de campo**

La aplicación móvil está diseñada para los agricultores, botánicos, Herbario institucional, estudiantes y docentes relacionados con el tema de la Universidad Técnica de Cotopaxi, se lo realizó en Android Studio, con su respectivo modelo en la plataforma Custom Vision.

A continuación, se detalla los siguientes requerimientos:

- Ingreso a la aplicación móvil
- Realizar la clasificación de las malas hierbas, tomando en cuenta que solo se seleccionó seis especies de malas hierbas en el cultivo de maíz.
- Captura la imagen clasificada entre las seis especies.
- Genera una información detallada de la mala hierba clasificada.

**Recursos Humanos:** Tesistas investigadoras.

#### **Recursos tecnológicos:**

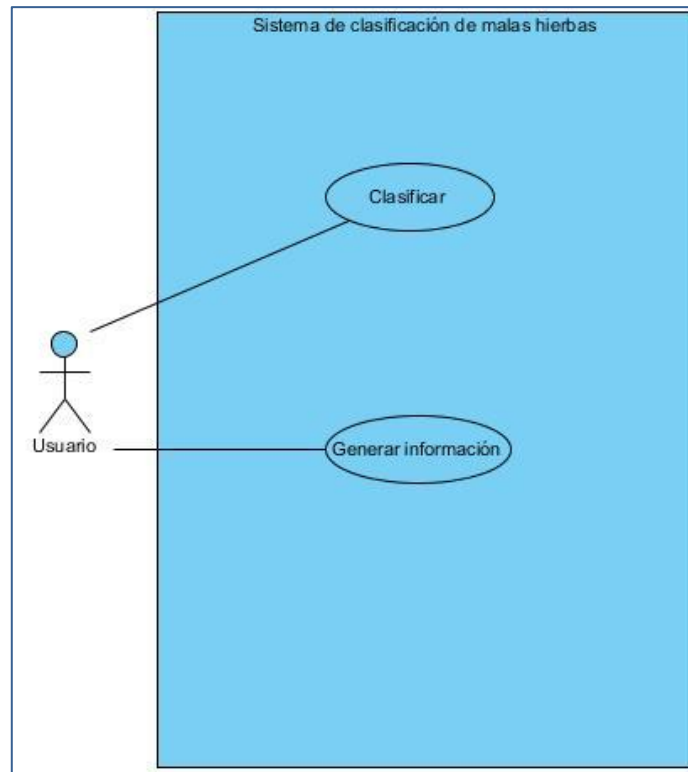
**Software:** Visual Paradigm.

Android Studio.

Custom Vision.

## Modelo de caso de uso general

Figura 18: Tipo de tratamiento



## Caso de uso expandido

### CU001- Clasificar

Tabla 2: Caso de uso clasificador.

<b>Núm.:</b>	CU001
<b>Nombre:</b>	Clasificar.
<b>Autores:</b>	Tesistas investigadoras.
<b>Fecha:</b>	07/01/2020
<b>Descripción:</b>	El usuario realiza la clasificación.
<b>Actor:</b>	Cliente.
<b>Precondiciones:</b>	El usuario debe tener la aplicación.
<b>Flujo normal:</b>	<ol style="list-style-type: none"> <li>1.-El usuario ingresa a la aplicación.</li> <li>2.-L aplicación muestra la interfaz con una opción.</li> <li>3.-El usuario elige la opción "Clasificar".</li> <li>4.-La aplicación le muestra la cámara para la "clasificación".</li> <li>5.-La aplicación clasifica las malas hierbas.</li> <li>6.-La aplicación emite el nombre de la mala hierba.</li> </ol>

<b>Flujo alternativo 1:</b>	<b>OPCIÓN INCORRECTA.</b> 8.-El usuario no selecciona ninguna opción (no selecciona la opción clasificar). 9.- El usuario se mantiene en el paso 1.
<b>Flujo alternativo 2:</b>	<b>DATOS INCORRECTOS.</b> 10.- No selecciona ninguna opción por favor seleccione la opción. 11.-El usuario está en el paso 2.
<b>Post-condiciones:</b>	El usuario realiza la clasificación de malas hierbas con éxito.

### CU002-Generar información

**Tabla 3:** Caso de uso generar información.

<b>Núm.:</b>	CU002
<b>Nombre:</b>	Generar información.
<b>Autores:</b>	Tesistas investigadoras.
<b>Fecha:</b>	10/01/2020
<b>Descripción:</b>	Si el usuario genera información de la mala hierba clasificada.
<b>Actor:</b>	Cliente.
<b>Precondiciones:</b>	El usuario debe tener la aplicación.
<b>Flujo normal:</b>	1.-El usuario ingresa a la aplicación. 2.-La aplicación muestra la interfaz con una opción. 3.-El usuario elige la opción "Clasificar". 4.-La aplicación le muestra la cámara para la "clasificación". 5.-La aplicación clasifica las malas hierbas. 6.-La aplicación emite el nombre de la mala hierba. 7.- La aplicación muestra la interfaz con la información correspondiente.
<b>Flujo alternativo 1:</b>	<b>SELECCIÓN DE DATO INCORRECTO.</b> 8.-El usuario no selecciona la opción información. 13.- El usuario permanece en el paso 4.
<b>Post-condiciones:</b>	El usuario genera información de la planta clasificada.

Diagrama de Secuencia

Diagrama CU001 (Clasificar)

Figura 19: Diagrama de secuencia clasificar.

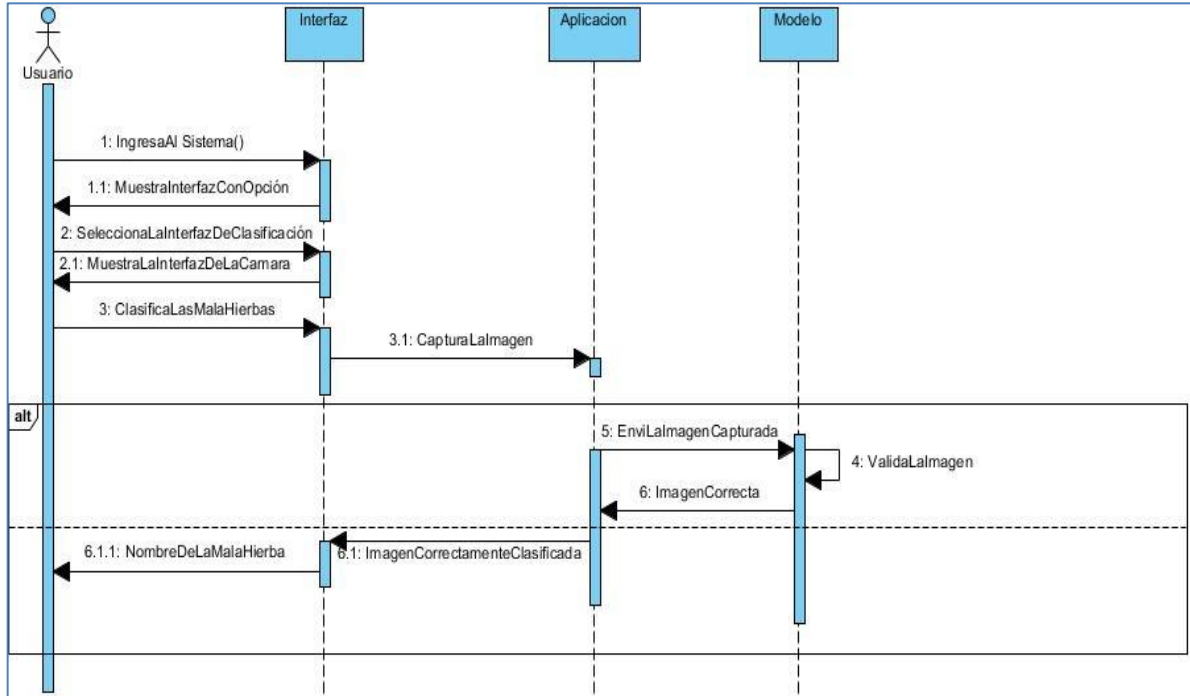
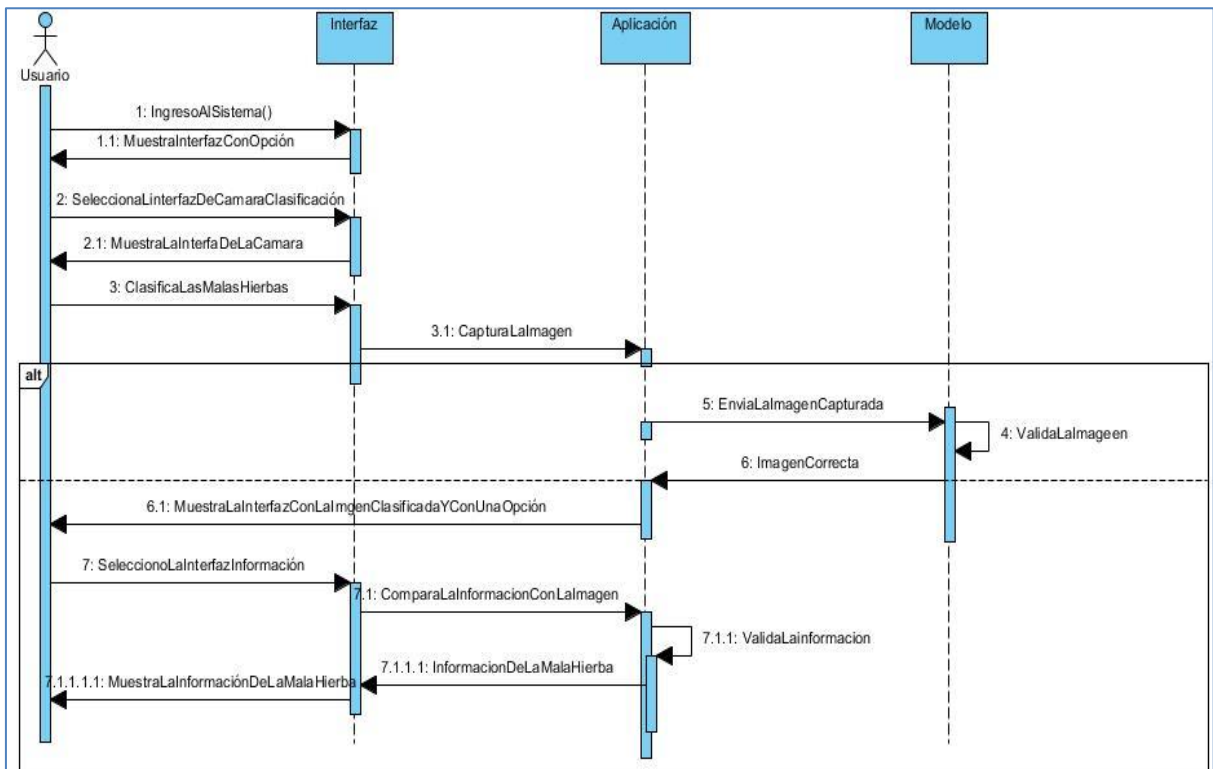


Diagrama CU001 (Generar Información)

Figura 20: Diagrama de secuencia generar información.



## Caso de pruebas

### Alcance

El presente plan de pruebas pretende comprobar y evaluar cada uno de los casos de uso del software a desarrollar, en este caso el de “Clasificar”, así también como sus flujos principales y flujos alternos.

**Tabla 4:** Caso de Prueba 1

<b># Caso de Prueba</b>	<b>CP_001</b>		
<b># Caso de Uso</b>	<b>CU_001</b>	<b>Fecha</b>	<b>10/01/2020</b>
<b>Descripción</b>	Caso de prueba que tiene por objetivo verificar que el Usuario pueda ingresar a la aplicación para clasificar las malas hierbas.		
<b>Condiciones de Ejecución</b>	El usuario debe tener la aplicación móvil en su celular.		
<b>Entradas</b>	<ul style="list-style-type: none"> <li>• Clasificar</li> </ul>		
<b>Resultados Esperados 1</b>	El usuario ingresa a la aplicación		
<b>Resultados Esperados 2</b>	Mensaje “el nombre de la mala hierba ”		
<b>Evaluación de la Prueba</b>	SUPERADA		
<b>Responsable</b>	Tester del Equipo de Trabajo (Mercedes Casa y Jenny Tumbaco)		

### Alcance

El presente plan de pruebas pretende comprobar y evaluar cada uno de los casos de uso del software a desarrollar, en este caso el de “Generar Información”, así también como sus flujos principales y flujos alternos.

**Tabla 5:** Caso de Prueba 2

<b># Caso de Prueba</b>	<b>CP_002</b>		
<b># Caso de Uso</b>	<b>CU_002</b>	<b>Fecha</b>	<b>07/01/2020</b>
<b>Descripción</b>	Caso de prueba que tiene por objetivo verificar que el Usuario pueda ingresar al aplicación para generar información de la mala hierba.		
<b>Condiciones de Ejecución</b>	El usuario debe tener la aplicación móvil en su celular.		
<b>Entradas</b>	<ul style="list-style-type: none"> <li>• Información</li> </ul>		

<b>Resultados Esperados 1</b>	El usuario ingresa a la aplicación información.
<b>Resultados Esperados 2</b>	Mensaje “información de la mala hierba”
<b>Evaluación de la Prueba</b>	SUPERADA
<b>Responsable</b>	Tester del Equipo de Trabajo (Mercedes Casa y Jenny Tumbaco)

### Informe de pruebas

Tabla 6: Informen de pruebas

Nº Caso de prueba	Fecha de prueba	Resultados		Fecha de nueva prueba	Resultados	
		Superada	No superada		Superada	No superada
CP001	20/12/2019		x	03/01/2020	x	
CP002	23/12/2019		x	06/01/2020	x	

### Requisitos Funcionales

#### Visión del negocio

La aplicación móvil, ofrece un servicio de clasificación automática de malas hierbas en imágenes, donde el usuario (agricultor) desconoce el tipo de mala hierba que crece en el cultivo de maíz, que tiene como efecto aplicar el herbicida de forma indebida, sobre dicho cultivo, entonces para ello se dio la necesidad de realizar una aplicación móvil que permita clasificar de manera automática las malas hierbas donde proporciona toda la información de la mala hierba clasificada.

#### Perfiles de usuario

Usuario: es la persona que podrá clasificar las malas hierbas y a la misma vez generar una información de la mala hierba clasificada anteriormente.

#### 9.6.2. Desarrollo de la Aplicación Móvil.

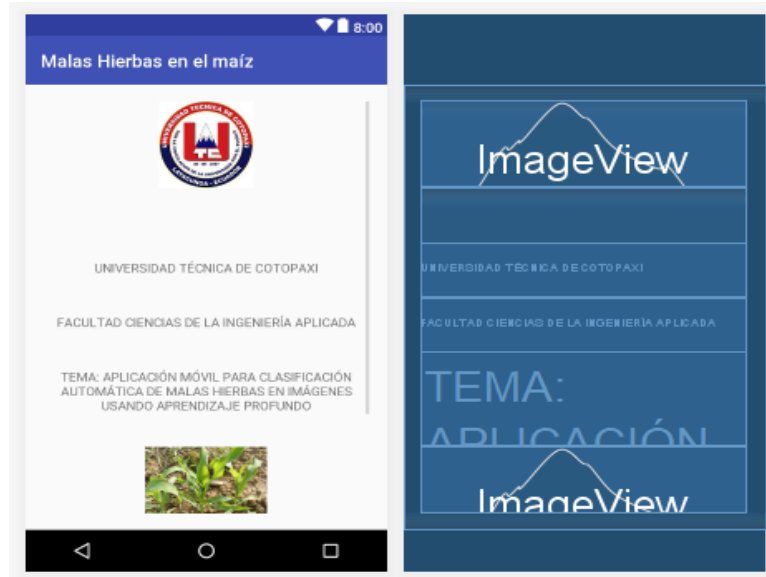
Para la construcción de la aplicación móvil fue desarrollada en el lenguaje de programación Android Studio, permitiendo crear varias vistas como se detalla a continuación:

#### Layout activity\_ principal.

En la Figura 21 se visualiza el primer layout que se hace referencia a la portada de la aplicación móvil detallando el encabezado, conjuntamente con una opción de clasificar, permitiendo ingresar al siguiente layout (diseño) donde se encuentra la cámara para proceder a la

clasificación de las 6 especies de malas hierbas, tomando en cuenta que la clasificación es en tiempo real.

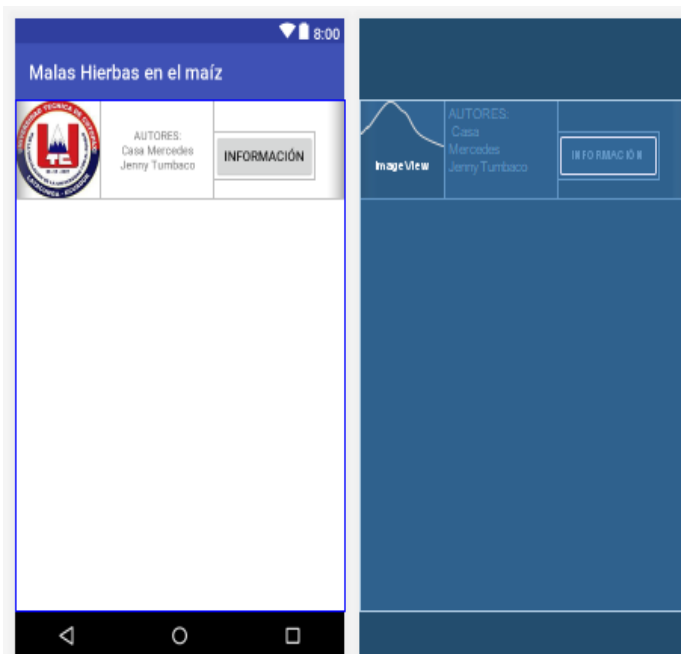
**Figura 21.-** Activity\_principal.



### Layout activity\_camara

El segundo layout (diseño) es la parte de la cámara que se menciona anteriormente en el primer layout como se muestra en la Figura 22, donde consta de una opción información, que permite la visualización de la información de la mala hierba clasificada en tiempo real, proporcionando información útil para el usuario.

**Figura 22:** Activity\_camara.



## Clase OverlayView

Con referente a esta clase es donde contiene líneas de código que clasifica la mala hierba de las 6 especies de forma automática en imágenes como se muestra la Figura 23, tomando en cuenta que en dichas líneas de código genera el nombre de la mala hierba.

**Figura 23:** Activity\_principal.

```

public class RecognitionScoreView extends View
    implements ResultsView {

    public static String inforGet="null";
    private static final float TEXT_SIZE_DIP =
        24;
    private List<Recognition> results;
    private final float textSizePx;
    private final Paint fgPaint;

    public RecognitionScoreView(final Context
        context, final AttributeSet set) {
        super(context, set);

        textSizePx =
            TypedValue.applyDimension(
                TypedValue.COMPLEX_UNIT_DIP, TEXT_SIZE_DIP,
                getResources().getDisplayMetrics());
        fgPaint = new Paint();
        fgPaint.setTextSize(textSizePx);
    }

    @Override
    public void setResults(final
        List<Recognition> results) {
        this.results = results;
        postInvalidate();
    }

    @Override
    public void onDraw(final Canvas canvas) {

        fgPaint.setColor(Color.WHITE);

        if (results != null && results.size()
            > 0) {
            int y = (int)
                (fgPaint.getTextSize() * 1.4f);
            final Recognition recog =
                results.get(0);
            final int x =
                (int) (canvas.getWidth() -
                    fgPaint.measureText(recog.getTitle()) / 2;
                canvas.drawText(recog.getTitle(),
                    x, y, fgPaint);

            if(recog.getTitle() == ""){
                inforGet= "null";
            }else{
                inforGet =
                    recog.getTitle().toString();
            }

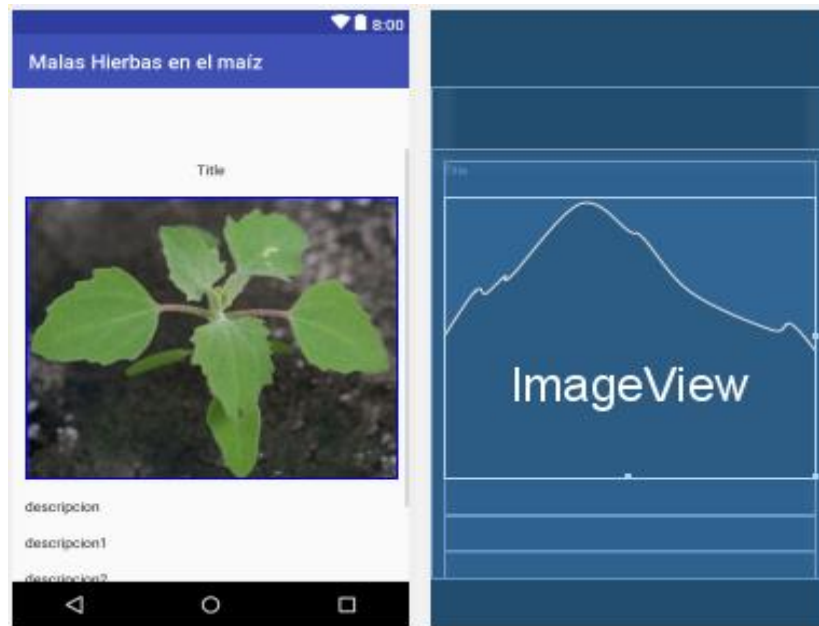
            }else {
                inforGet= "null";
            }
        }
    }
}

```

## Layout activity\_informacion

En el tercer layout (diseño), es la parte donde se visualiza la información, que se obtiene en base a la clasificación de la mala hierba, en la Figura 24 se detalla la información de la especie mostrando el título, nombre, descripción, tipo de herbicida, preparación, tomando en cuenta que re lo genera en el momento que se clasifica la mala hierba.

Figura 25: Activity\_información.



### Clase Información

Con referente a esta clase es donde contiene líneas de código que contiene información de las 6 especies que son Chenopodium Album, Erodium Cicutarium, Galinsoga Parviflora, Raphanus Raphanistrum, Urtica urens que se establece de forma automática en imágenes como se muestra la Figura 25.

Figura 25: Clase información.

```

public void load() {
    String val =
        RecognitionScoreView.inforGet.toString();
    Toast.makeText(this, val, Toast.LENGTH_LONG).show();
    if (val.equals("Eradium Cicutarium")) {
        titulo.setText(val);
        imagen.setBackgroundResource(R.drawable.erodum);
        descripc.setText("NOMBRE COMÚN: Alfider de pastor");
        descripc1.setText("DESCRIPCIÓN: se caracteriza por ser cotiledóneas asimétricos que mide de unos 4-7 mm, sus hojas son verdaderas alternas, ovales, a menudo el tallo y las hojas toman un color rojizo.");
        descripc2.setText("HERBICIDA ATECTRA BV: Es un herbicida postemergente que controla malezas de hoja ancha. Su formulación presenta una nueva sal de Dicamba DGA (dicamba diglycolamine) con una volatilidad diez veces menor que la formulación tradicional de la sal DMA conocida en el mercado.");
        descripc3.setText("VOLUMEN DE APLICACION: Realizar la aplicación, con un pulverizadora con agua hasta
        descripc4.setText("PREPARACIÓN: Después que todas las malezas hayan emergido, ya que Basagran 60 no posee efecto residual en el suelo. Cuando las malezas son pequeñas (hasta 5 cm) y están en activo crecimiento. En no menos de 250 litros de agua por ha. Basagran 60 actúa por contacto, por lo tanto es necesario mojar bien las hojas y tallos de las malezas. Alta luminosidad y temperatura favorecen la acción de Basagran 60, mientras que el tiempo fresco la retarda");
    }
    if (val.equals("Chenopodium Album")) {
        titulo.setText(val);
        imagen.setBackgroundResource(R.drawable.h2);
        descripc.setText("NOMBRE COMÚN: Cenizo blanco"); ("Galinsoga Parviflora")) {
            titulo.setText(val);
            imagen.setBackgroundResource(R.drawable.h3);
            descripc.setText("NOMBRE COMÚN: Hierba Pajarito

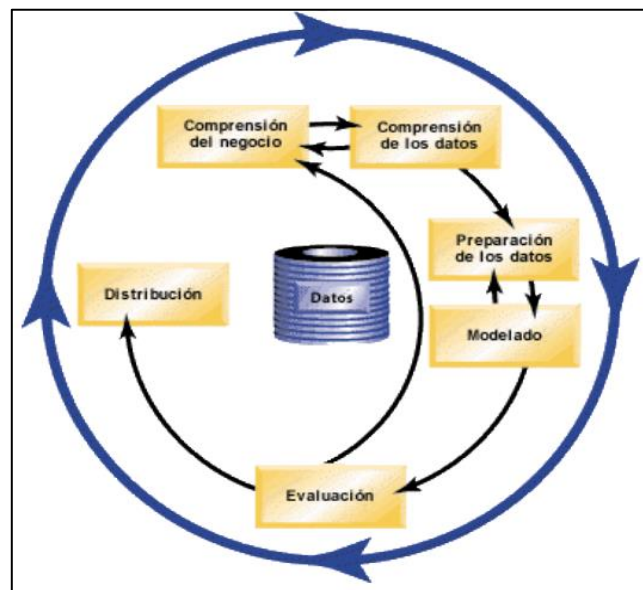
```

### 9.6.3. Metodología CRISP-DM.

La metodología CRISP-DM (Cross Industry Standard Process for Data Mining), se caracteriza por ser un modelo orientado para el desarrollo de proyectos de minería de datos, tomando en cuenta que como metodología incluye la descripción y explicación de las tareas necesarias de cada fase, por otra parte, como modelo de proceso ofrece un resumen del ciclo vital de una minería de datos, dicho modelo se puede personalizar fácilmente. (IBM, 2012).

CRISP-DM es una de la metodología que se la usa para poner orden en los proyectos, donde realizan tareas en cada fase, asignando tareas concretas lo que se desea obtener tras de cada fase, tomando en cuenta que una de las ventajas es que ayuda al proceso de planeación y gerencia del proyecto de minería de datos, su independencia de la industria aplicación o industria. Crisp-DM ayuda a organizar rutas de proyectos, resultados con estas seis fases fundamentales como se muestra en la Figura 26, en la cual se mencionara el funcionamiento de cada fase de dicho modelo. (García, 2018).

**Figura 26.-** Modelo CRISP-DM



Fuente: (IBM, 2012).

#### **Fase de comprensión de negocio**

En esta fase tiene como finalidad entender los objetivos y requerimientos, en base a una perspectiva de negocio para posteriormente plasmarlo en la definición del problema de minería de datos y en un plan preliminar diseñado para alcanzar los objetivos. (Cantuña, 2016). Tomando en cuenta que en este primer nivel es fundamental el entendimiento del problema que se desea resolver, lo cual permitirá la recolección de los datos necesarios y la interpretación coherente sobre los resultados de los análisis. (García, 2018).

La comprensión de negocio comprende de un conjunto de cuatro pasos o subfases, tales como:

- Determinación de los objetivos comerciales.
- Valoración de la situación
- Determinación d los objetivos de minería de datos.
- Producción de un plan de proyecto. (IBM, 2012).

### **Fase de comprensión de los datos**

La fase de comprensión de datos implica en estudiar más de cerca los datos disponibles de minería de datos, con el fin de evitar problemas inesperados durante la siguiente fase, esto implica determinar la calidad de los datos y describir los resultados en la documentación del proyecto (IBM, 2012). Posteriormente comprensión de datos es necesario con el fin de realizar una recolección inicial de datos con el propósito de relacionarse con ello, verificando atributos como su calidad, donde dicha fase implica el mayor tiempo y esfuerzo en un proyecto (García, 2018). Para ello se utiliza los siguientes pasos:

- Recopilación de los datos iniciales.
- Descripción de los datos.
- Exploración de los datos.
- Verificación de calidad de datos. (García, 2018)

### **Fase de preparación de datos.**

El principal objetivo de esta fase en la preparación de datos es obtener una vista de los datos preparados para el proceso de la minería. (IBM, 2012). Por otro lado, la fase de preparación de datos es donde se agrupa los procesos de selección, limpieza, generación de atributos, integración de diversos orígenes de datos y cambios de formato. Tomando en cuenta que implica que esta fase se encuentra estrechamente relacionado con la siguiente fase. (García, 2018) Los subprocesos de esta fase son:

- Selección de datos.
- Limpieza de datos.
- Construcción de nuevos datos.
- Integración de datos.
- Formato de datos. (IBM, 2012).

### **Fase de modelo**

Esta fase consiste en que los datos que han preparado se incorporen a las herramientas analíticas y los resultados comenzaran a arrojar soluciones al problema, tomando en cuenta las subfases.

(IBM, 2012). Cabe recalcar que esta fase se selecciona la técnica de modelado más apropiado para el proyecto tomando en cuenta los criterios debe ser apropiada para el problema, disponer de los datos adecuados, cumplir los requisitos del problema esto es dar solución a los requerimientos planteados, y sobre todo debe tener tiempo adecuado para obtener un modelo(García, 2018). La fase de modelado implica las siguientes etapas genéricas:

- Selección de técnicas de modelado.
- Generación de un diseño de comprobación.
- Generación de los modelos.
- Evaluación del modelo. (García, 2018)

### **Fase de evaluación**

En este punto, habrá completado casi con la mayoría de la parte del proyecto de minería de datos, en la cual habrá determinado, en la fase de molados, permitiendo responder algunos requerimientos de la negociación. Se divide en sub fases como se menciona a continuación. (IBM, 2012). Sin embargo la fase de evolución se evalúa el modelo escogido en la fase anterior considerando los siguientes aspectos: criterios de éxito del problema, la fiabilidad de los resultados y las herramientas que se puede emplear (García, 2018). Las subfase de esta fase son las siguientes:

- Evaluación de los resultados.
- Proceso de revisión.
- Determinación de los pasos siguientes. (IBM, 2012).

### **Fase de distribución**

En esta fase consiste en utilizar nuevos conocimientos para implicar las mejores en la organización. Además, la distribución se puede utilizar los conocimientos adquiridos en la minería de datos para que pueda ser aplicado en modificaciones en su organización. (IBM, 2012). Se le puede mencionar que esta fase consiste en la transformación del conocimiento obteniendo en acciones dentro del proceso de negocio, en base a los dos mecanismos que es el de reconocimiento de un interpretador de los resultados para tomar acciones en base a los resultados del modelo y aplicación del modelo en otros conjuntos de datos y su incorporación al modelo de negocio. (García, 2018). Constan de subfases como se menciona a continuación.

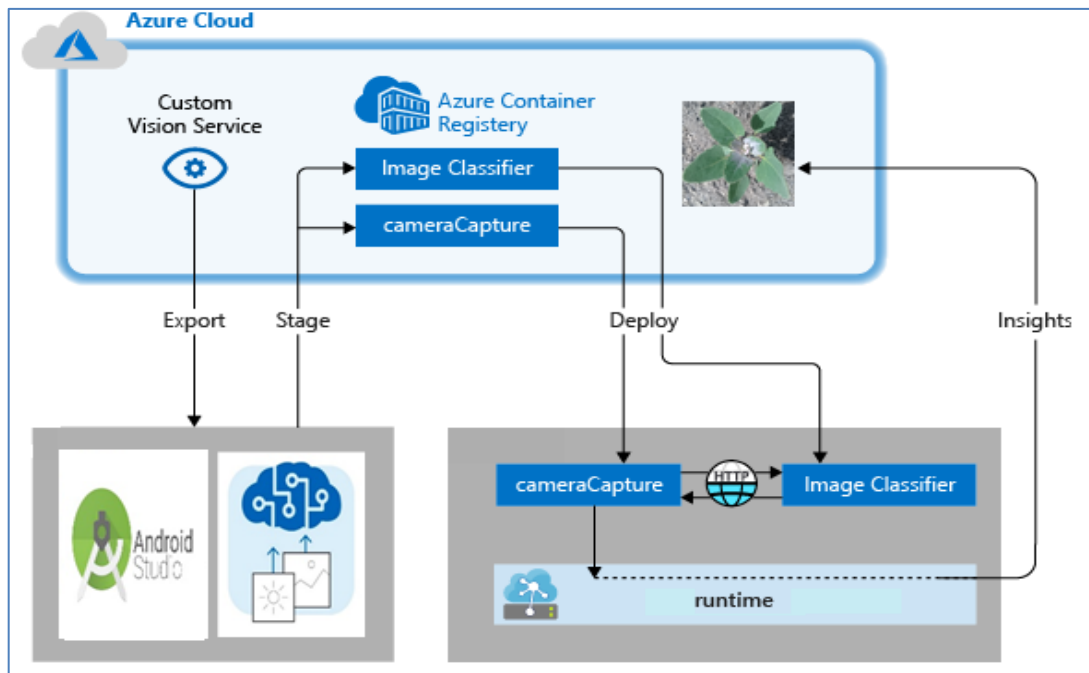
- Panificación de distribución.
- Planificación de control y mantenimiento.
- Creación de un informe final.

- Revisión final del proyecto. (García, 2018).

Una vez descrita la metodología CRISP-DM es así como sus etapas principales es necesario definir el negocio y con ello los datos a procesar, donde las herramientas de trabajo y las técnicas de modelado para satisfacer todos los requerimientos de la metodología lo cual se trató anteriormente. (García, 2018).

### 9.6.2. Gráfica del proceso.

**Figura 27:** Proceso de clasificación.



En la Figura 27, muestra el diseño del modelo clasificador que realiza la plataforma Custom Vision para clasificar las malas hierbas personalizadas para 6 especies en el cultivo de maíz. El modelo clasificador de imágenes se lo realizó en el lenguaje de programación Android Studio que tiene incorporar el modelo clasificador, lo cual permite clasificar de forma automática las malas hierbas en el cultivo. Al entrenar el clasificador de imágenes personalizados e implementarlos en dispositivos como contenedores, cabe recalcar que estos dos servicios permiten buscar información a partir de imágenes. El proyecto de usa hardware físico y configura una cámara en cámara en directo para entrenar y probar el clasificador de imágenes, que es útil para cualquier que desee probar un escenario real.

## **10. ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS.**

### **10.1. Metodología CRISP-DM.**

La metodología que se aplicó durante el desarrollo del proyecto es la metodología CRISP-DM (Cross Industry Standard Process for Data Mining), que nos permitió describir de manera ordenada las tareas para la recolección de datos e imágenes útiles para el desarrollo del proyecto. Esta metodología consta de 6 fases que comprende: fase de comprensión del negocio, fase comprensión de los datos, fase descripción de datos, fase de modelado, fase de evaluación y finalmente fase de distribución.

La presente metodología se considera como gran ayuda para organizar rutas de proyectos, resultados y notaciones, de acuerdo con las fases, que se detalla a continuación.

#### **10.1.1. Fase de comprensión de negocio**

##### **Objetivos comerciales.**

Esta subfase permite crear un modelo para clasificar las malas hierbas en imágenes sobre dispositivos móviles empleando técnicas de aprendizaje profundo para la identificación en cultivo de maíz.

##### **Situación actual y objetivos.**

Para el desarrollo del modelo se dispone de un total de 461 imágenes fotográficas del cultivo de maíz, tomando en cuenta las diferentes condiciones de iluminación y los diversos estados de crecimiento en diferentes días, para dar paso al desarrollo del modelo que permita clasificar de manera automática las malas hierbas.

El modelo construido se integró en una aplicación móvil que permite mostrar en tiempo real las malas hierbas, donde se clasificara que tipo de mala hierba pertenece, una descripción de la misma.

##### **Objetivo de minería de datos.**

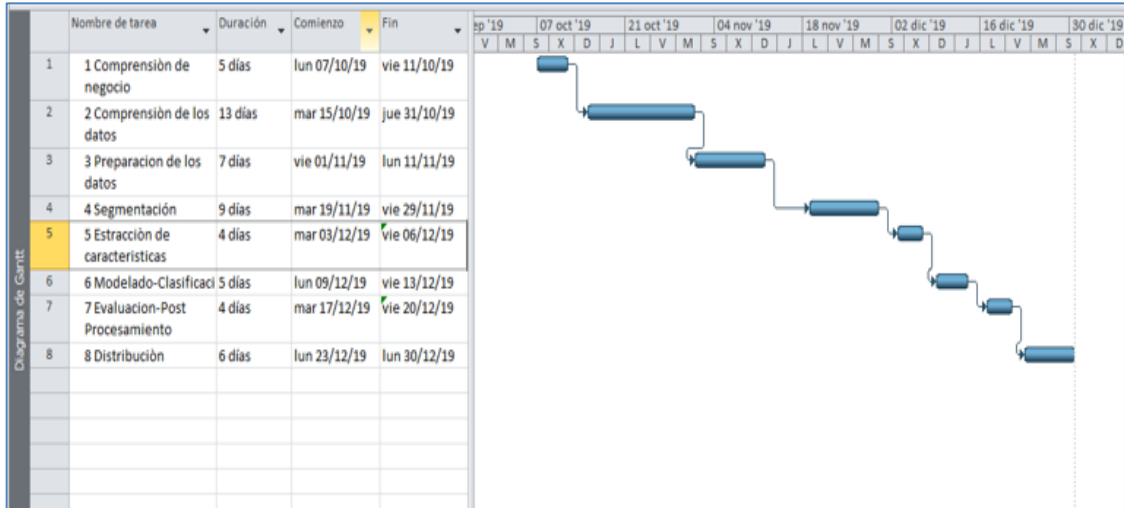
Los objetivos se traducen a continuación en términos de minería de datos:

- Utilizar las imágenes digitales de un cultivo para la extracción de zonas de interés.
- Realizar un modelo de clasificación automática de imágenes que clasifique entre las especies de malas hierbas.
- Acoplar el modelo clasificador en una aplicación que permite obtener el nombre de cada especie por imagen en tiempo real.

## Plan del proyecto.

En la Figura 28 se muestra el plan del proyecto.

**Figura 28.-** Plan de proyecto



## Valoración de herramientas y técnicas.

Para crear el modelo de clasificación de imágenes digitales de malas hierbas se ha empleado la plataforma Custom Vision como una herramienta para generar el clasificador de imágenes.

**Custom Vision** es una herramienta que permite crear, implementar y mejorar sus propios clasificadores de imágenes. Un clasificador de imágenes es un servicio de IA que aplica etiquetas (que representan clases) a las imágenes, en función de sus características visuales.

### 10.1.2. Fase de compresión de datos.

#### Adquisición de datos.

Para la adquisición de los datos se estimó una cantidad de 461 imágenes con un formato jpg con una resolución de 3264 \* 2448 tomadas con un dispositivo móvil. Las imágenes fueron capturadas en tres condiciones naturales: en la mañana, medio día y en la tarde en diversos estados de crecimiento del cultivo y con el fondo libre de basura u otro tipo de hierba o cultivo de maíz.

#### Recopilación de datos.

Las imágenes recolectadas provienen de la parroquia de Tanicuchi barrio Chilcapamba Sur, los días sábado, miércoles, jueves, viernes las fotografías de las malas hierbas fueron capturadas en 5 posiciones diferentes con diversos estados de iluminación por cada especie de mala hierba.

### **Descripción de datos.**

En base a los datos de partida, se dispone de un conjunto de datos subdivididos por clases que consiste en imágenes categorizadas en carpetas separadas de acuerdo a las seis especies de malas hierbas.

### **Exploración de datos.**

En esta etapa las imágenes en las por cada especie, fueron revisadas y recortadas por la mitad para incrementar la base de datos y encontrar un mejor clasificador.

#### **10.1.3. Fase de descripción de datos.**

##### **Selección de datos.**

Esta fase tiene la finalidad de integrar, recopilar y seleccionar las imágenes necesarias para utilizarlas en el modelo. Dichas imágenes debieron considerar malas hierbas estén solas sin basura, sin tierra o gotas de agua sobre la planta.

##### **Formato de datos.**

Los datos corresponden a imágenes con una resolución de 3264\*2448.

#### **10.1.4. Fase de modelo.**

Esta fase tiene como objetivo extraer el conocimiento a partir de las imágenes recogidas durante varios días. En esta se procede a la creación del modelo mediante la plataforma Custom Vision. El clasificador de imágenes se lo realizó considerando. Las clases contienen una cierta cantidad de imágenes por cada especie de mala hierba, como se muestra en la tabla 2. Seguido se probará el modelo y se realizaran pruebas necesarias para el correcto funcionamiento.

**Tabla 7:** Cantidad de imágenes.

<b>Especies</b>	<b>N° imágenes</b>
Ambrosia Artemisifolia	77
Chenopodium Album	85
Galinsoga Parviflora	72
Eradium Cirrcutarium	69
Raphanus Raphanistrum	80
Urtica Urens	78

**Fuente:** Grupo de trabajo.

### Técnica de modelado.

La solución está ligada a resolver una tarea de clasificación, que tiene como objetivo encontrar un clasificador que permita clasificar las malas hierbas en el cultivo de maíz. Existen varias técnicas para clasificar las malas hierbas sin embargo este estudio consideró emplear la aplicación de la técnica de validación cruzada para la clasificación automática de malas hierbas.

#### 10.1.5. Fase de evaluación.


##### Validación cruzada.

Se utilizó la validación cruzada multicapa, para lo cual los datos se dividieron en 6 clases que permitió calcular el rendimiento del modelo realizado en Custom Vision, donde se usó varias imágenes que fueron enviados para el entrenamiento para calcular la precisión, recall y el A. P que mediante dicha técnica evalúa los resultados de un análisis estadístico que generan a un conjunto de datos independientes que implica dividir una muestra de datos en subconjuntos al realizar el análisis en otro subconjunto llamado conjunto de validación o conjunto de pruebas, donde cada entrenamiento efectuado es considerado una iteración, es decir cada vez que se entrene o re-entrena el clasificador, se está creando una nueva iteración del modelo.

##### Descripción del modelo.


Una vez que se termine de entrenar el modelo, aparecen los gráficos que contiene información acerca de los resultados obtenidos. En este punto, se procede a evaluar el modelo obteniendo los valores de precisión, recall y AP. Donde la precisión es la probabilidad de acierto de que el modelo asocie las imágenes con el objetivo al cual deberían representar, recall es el porcentaje de imágenes subidas que son reconocidas correctamente por la plataforma y A.P es el porcentaje de rendimiento medio general del detector. Los resultados del modelo general desde la plataforma de Custom Vision generó una precisión del 97.9%, un recall de 97.9% y un AP de 97.7%. En la Figura 29 se muestra el detalle de los resultados.

**Figura 29:** Resultados del modelo




En la Figura 30, se aprecia el resultado del modelo de *Urtica Urens* con una precisión del 100%, un recall del 100% y un A.P. del 100% con aproximadamente 78 imágenes.

**Figura 30:** Resultados de *Urtica Urens*

Tag	Precision	↑	Recall	A.P.	Image count
<i>Urtica Urens</i>	100.0%		100.0%	100.0%	78 


En la Figura 31, se aprecia el resultado del modelo de *Raphanus Raphanistrum* con una precisión de 100%, un recall del 93.8% y un A.P. de 94.8% con aproximadamente 80 imágenes.

**Figura 31:** Resultados de *Raphanus Raphanistrum*.

Tag	Precision	↑	Recall	A.P.	Image count
<i>Raphanus Raphanistrum</i>	100.0%		93.8%	94.8%	80 


En la Figura 32, se aprecia el resultado del modelo de *Galinsoga Parviflora* con una precisión de 100%, un recall de 100% y un A.P. de 100% con aproximadamente 72 imágenes.

**Figura 32:** Resultados de *Galinsoga Parviflora*

Tag	Precision	↑	Recall	A.P.	Image count
<i>Galinsoga Parviflora</i>	100.0%		100.0%	100.0%	72 


En la Figura 33, se aprecia el resultado del modelo de *Ambrosia Artemisiifolia* con una precisión de 100%, un recall de 93.8% y un A.P. de 100% con aproximadamente 77 imágenes.

**Figura 33:** Resultados de *Ambrosia Artemisiifolia*.

Tag	Precision	↑	Recall	A.P.	Image count
<i>Ambrosia Artemisiifolia</i>	100.0%		93.8%	100.0%	77 


En la Figura 34, se aprecia el resultado de Chenopodium Album con una precisión de 94.4%, un recall de 100% y un A.P. de 93.5% con aproximadamente 85 imágenes.

**Figura 34:** Resultados del modelo

Tag	Precision	↑	Recall	A.P.	Image count
Chenopodium Album	94.4%		100.0%	93.5%	85 

En la Figura 35, se aprecia el resultado del modelo de Eradium Citutarium con una precisión de 93.3%, un recall de 100% y un A.P. de 100% con aproximadamente 69 imágenes.

**Figura 35:** Resultados de Eradium Citutarium

Tag	Precision	↑	Recall	A.P.	Image count
Eradium Cicutarium	93.3%		100.0%	100.0%	69 

### 10.1.6. Fase de distribución.

Una vez evaluado el modelo clasificador el siguiente objetivo es integrar el modelo en una aplicación móvil diseñada en Android Studio. La aplicación desarrollada se denomina aplicación móvil para la clasificación automática de malas hierbas en imágenes.

### Requerimientos técnicos de la aplicación

#### Software

Android Studio

Custom Vision

#### Funcionalidad

La aplicación móvil para la clasificación automática de malas hierbas en imágenes ofrece funcionalidades básicas que permite la clasificación de la mala hierba en tiempo real.

Funciones:

- Muestra ventana principal.
- Clasifica la mala hierba mostrada en tiempo real.
- Muestra información de la mala hierba clasificada.

### 10.1.6.1. Manual de usuario.

La Figura 36, contiene la primera interfaz de la aplicación móvil, estructurado de un encabezado y un botón clasificar que conlleva a la siguiente interfaz.

**Figura 36.-**Venta principal.



### **Clasificación de malas hierbas.**

La aplicación móvil clasifica la mala hierba que se muestra en tiempo real, entre las 6 especies que se tomaron en cuenta durante el desarrollo del proyecto como se muestra en la Figura 37.

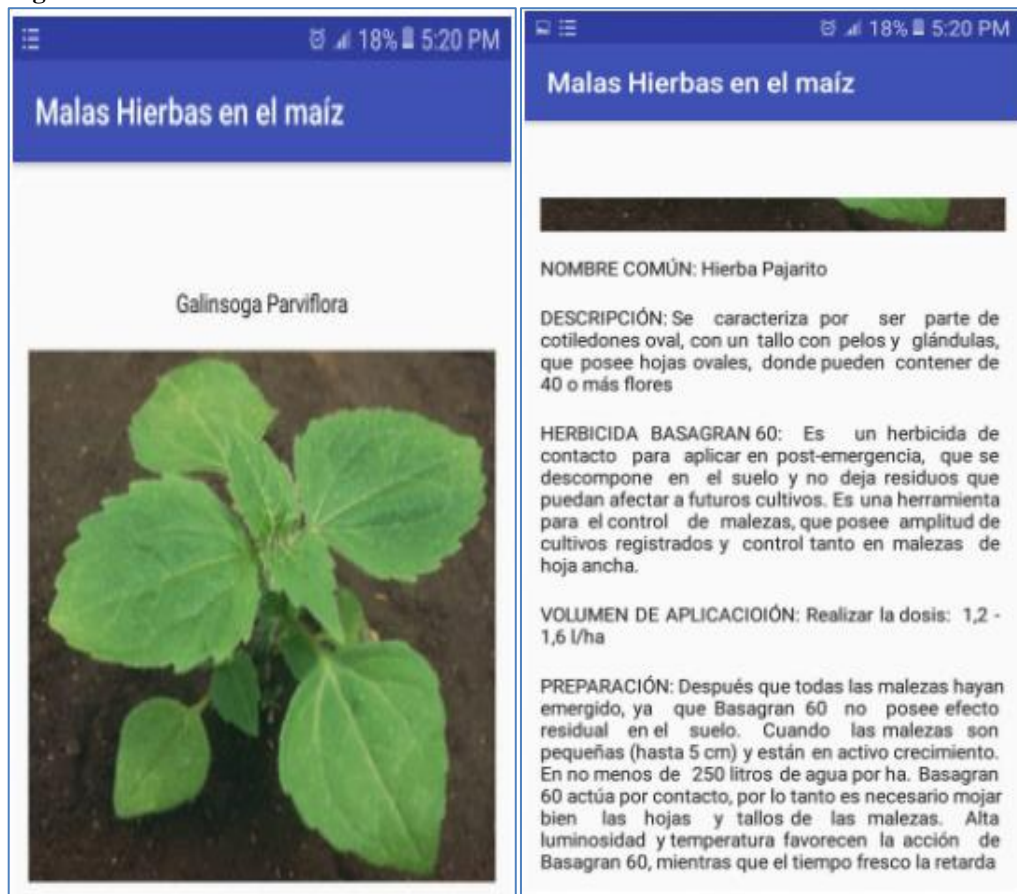
**Figura 37:** Clasificación.



**Información de la mala hierba.**

Da clic en información y pasa a la siguiente ventana mostrando una pequeña información de la especie detectada en tiempo real, la información que se revela en el nombre d la especie, descripción, herbicida y preparación esto se genera de forma automática como se muestra en la Figura 38.

**Figura 38:** Mala hierba.



## 10.2. Discusión de resultados.

Heba Elnemr, empleó una arquitectura de redes neuronales convolucionales para clasificar plántulas en sus primeras etapas de crecimiento, obteniendo como resultado la discriminación de 12 especies en tres cultivos diferentes y 9 malezas. El sistema logró una precisión de clasificación de un 94.38% dando un resultado eficaz y fiable.

Otro estudio de Mads Dyrmann, Henrik Karstoft, Henrik Skov Midtiby en su obra Plant species classification using Deep convolutional neural network, realizó un método que es capaz de reconocer especies de plantas en imágenes en base a las redes convolucionales, la red fue construida desde cero y probada en un total de 10.413 imágenes, en donde contiene 22 especies de malezas en cultivos en primeras etapas de crecimiento, tomando en cuenta que las imágenes varían con respecto a la iluminación, la resolución y el tipo de suelo, obteniendo un resultado de 22 especies logrando una precisión de clasificación del 86,2% usando para dicha clasificación una red neuronal convolucional.

Este estudio uso alrededor de 461 imágenes de seis especies diferentes con variación de iluminación, en tres estados: en la mañana, al medio día y en la tarde, donde se obtuvo como resultado una precisión del 97.9%, recall de 97.9% y un AP de un 97.7%, este modelo fue integrado en una aplicación móvil desarrollada en el lenguaje de programación Android Studio.

## **11. IMPACTOS (TÉCNICOS, SOCIALES, AMBIENTALES O ECONÓMICOS).**

### **11.1. IMPACTO SOCIAL.**

El presente proyecto de investigación tendrá un impacto social, ya que mediante la investigación se logró desarrollar una aplicación móvil para clasificación automática de malas hierbas en imágenes usando aprendizaje profundo, que es de gran ayuda para los agricultores, los botánicos y Herbario institucional.

### **11.2. IMPACTO TÉCNICO.**

Al proporcionar una aplicación móvil para la clasificación automática de las malas hierbas de las siguientes especies: *Chenopodium Album*, *Erodium Cicutarium*, *Ambrosia Artemisiifolia*, *Urtica urens*, *Raphanus raphanistrum* y *Galinsoga Parviflora*, que se representa en el transcurso del crecimiento en el cultivo de maíz, permitiendo a la experiencia de manipular de nuevas tecnologías e innovadoras para llevar a cabo el proceso de apropiación de la ciencia y la tecnología el desarrollo del proyecto ha permitido centrarnos más en la búsqueda de tener un espacio donde pueden explorar y admirar la ciencia y tecnología de una manera práctica y segura.

### **11.3. IMPACTO AMBIENTAL**

Emplear herramientas tecnológicas para beneficiar a los agricultores en el campo para identificar las malas hierbas en el cultivo de maíz empleando temáticas novedosas como lo son el aprendizaje profundo específicamente las redes neuronales convolucionales.

## **12. PRESUPUESTO PARA LA PROPUESTA DEL PROYECTO**

### **12.1. GASTOS DIRECTOS.**

**Tabla 8:** Gastos directos.

<b>DETALLE</b>	<b>CANTIDAD</b>	<b>V. UNITARIO</b>	<b>V. TOTAL</b>
Impresiones.	450	\$0,05	\$22,50
Anillados.	3	\$2,50	\$7,50

Flash Memory	2	\$7,00	\$14.00
Empastados.	2	\$25	\$50.00
Copias	20	0,03	\$0,60
<b>TOTAL</b>		<b>\$94.60</b>	

## 12.2. GASTOS INDIRECTOS.

**Tabla 9:** Gastos indirectos.

<b>DETALLE</b>	<b>CANTIDAD</b>	<b>PERSONAS</b>	<b>V. UNITARIO</b>	<b>V. TOTAL</b>
Transporte	48 días	2	\$2	\$192,00
Alimentación	48 días	2	\$1,25	\$120,00
<b>TOTAL</b>				<b>\$312,00</b>

## 12.3. GASTOS APROXIMADOS.

**Tabla 10:** Gastos indirectos

<b>Descripción</b>	<b>Total</b>
Gastos directos.	\$94,60
Gastos indirectos.	\$312,00
<b>Total, gastos directos + gastos indirectos.</b>	<b>\$406,60</b>

### **13. CONCLUSIONES Y RECOMENDACIONES.**

#### **13.1. CONCLUSIONES.**

- La revisión de la literatura permitió la sustentación de varios documentos, entre artículos científicos en fuentes de la investigación científica, dando como resultado la construcción del marco teórico, así como a la vez informo de la metodología que se emplea, de igual manera las diferentes herramientas tecnológicas que permitió realizar una aplicación para la clasificación de malas hierbas.
- La investigación ha permitido crear un clasificador de especies de malas hierbas, que permitirá a los agricultores, botánicos, Herbario institucional, estudiantes y profesores de áreas relacionadas en la Universidad Técnica de Cotopaxi, contar con una herramienta de clasificación de malas hierbas.
- La precisión y el recall óptimas y máximas que se obtuvieron del modelo generado utilizando aprendizaje profundo fue de un 97.9% de precisión, un recall de 97.9% y un A.P de 97.7% estos valores se obtuvieron empleando la plataforma de Custom Vision.

#### **13.2.RECOMENDACIONES.**

- Mejorar la precisión del modelo incrementando de mayor cantidad de imágenes tomadas con diferentes variaciones respecto a la iluminación, resolución, tipo de suelo estados de crecimiento, fondos diferentes, y junto al maíz con el fin de clasificar entre mala hierba y cultivo (maíz).
- También se puede plantear el mejoramiento del modelo, con el objetivo de emplear en tiempo real, para lo cual se puede recomendar usar un web service.
- Se recomienda que el clasificador de imágenes sea ampliado para varias especies de malas hierbas, atreves de otras arquitecturas de aprendizaje profundo, con el objetivo de tener un clasificador más preciso y eficaz.
- En el desarrollo de una aplicación móvil debe comenzarse con el análisis de tendencias del mercado ya que día tras día las apps van mejorando su interfaz por lo cual hay que tratar de ir a la par con estos avances.
- El paso más importante se recomienda hacer pruebas con Flowers classify la cual detecta las flores en grupos como las monocotiledóneas y dicotiledóneas esta reconoce las flores, tallos y las venas de las plántulas al realizar el análisis de nuevas variables detectara la clasificación de plantas.

#### 14. BIBLIOGRAFÍA

- Alonso, A. B. (2011). Dispositivos móviles. *Revista Negotium*, 12.
- Arias, A. (2015). *Base de datos con Mysql*. ISBN.
- Badra, R. D. (2018). *Clasificador de Vestimenta basado en Redes Neuronales*.
- Bah, M. D., Dericquebourg, E., Hafiane, A., & Canals, R. (2019). Deep learning based classification system for identifying weeds using high-resolution UAV imagery. *Advances in Intelligent Systems and Computing*, 857, 176–187.  
[https://doi.org/10.1007/978-3-030-01177-2\\_13](https://doi.org/10.1007/978-3-030-01177-2_13)
- Barreiro, P. (2014). *Drones en la agricultura*. Madrid.
- Basf, M. (2017). *Portafolio de herbicidas*.
- Baz, A., Ferreira, I., Álvarez, M., & García, R. (2011). *Dispositivos móviles*. 1–12.
- Belloio, P. M. V. (2013). *Evaluación de métodos y estrategias de investigación bibliográfica para optimizar el aprendizaje de los estudiantes del preuniversitario del tecnológico argos y diseño de un módulo alternativo*.
- Betancourt, D. (2014). Sistema de visión por computadoras para detectar hierba no deseada en prototipo en el cultivo usando ambiente controlado. *Pontificia Universidad Catolica Del Peru*, 8(33), 44.
- Brazzera, A. S. M. (2019). *Desarrollo de una aplicación web para reconocimiento de objetos mediante análisis de video*. 5–10.
- Callejo, I. R. (2016). *Segmentación automática de texturas en imágenes agrícolas*.
- Cantuña, K. S. (2016). *Generación automática de un clasificador de especies de malas hierbas en imágenes de campo*.
- Chagoya, E. R. (2013). Métodos y técnicas de investigación. *Universidad Complutense de Madrid*, 1–161. <https://doi.org/10.1017/CBO9781107415324.004>
- Clavijo, T. (2017). *Sistema Operativo de Android*.
- Castro, I. (2017). Optimización de la cartografía de malas hierbas mediante técnicas geoestadísticas y teledetección con UAV. *Congreso Nacional Española de Malherbología*, 6.
- Coloma, L. (27 de Marzo de 2017). *El telègrafo*. Obtenido de 200 mil personas mueren anualmente por pesticidas: <https://www.letelegrafo.com.ec/noticias/sociedad/4/200-mil-personas-mueren-anualmente-por-pesticidas>

- Deere, J. (21 de Agosto de 2014). *Soluciones en agricultura de Precisión*. Obtenido de Agricultureros Red de Especialistas en Agricultura: <http://agricultureros.com/hasta-38-millones-de-hectareas-en-el-mundo-con-malas-hierbas-resistentes-a-herbicidas/>
- Díaz, J. (2017). Rábano. *Ficha Técnica*, 92, 1–2. Retrieved from [http://www.inia.cl/wp-content/uploads/FichasTecnicasSanidadVegetal/Ficha\\_92\\_Rabano.pdf](http://www.inia.cl/wp-content/uploads/FichasTecnicasSanidadVegetal/Ficha_92_Rabano.pdf)
- Durán, J. (2017). *Redes Neuronales Convolucionales en R. Reconocimiento de caracteres escritos a mano*. 78. Retrieved from <http://bibing.us.es/proyectos/abreproy/91338/fichero/TFG+Jaime+Durán+Suárez.pdf>
- Dyrmann, M., Karstoft, H., & Midtiby, H. S. (2016). Plant species classification using deep convolutional neural network. *Biosystems Engineering*, 151, 72–80. <https://doi.org/10.1016/j.biosystemseng.2016.08.024>
- Edison Cabezas, D. A. y J. T. (2017). *Introducción a la metodología de la investigación científica*. Retrieved from [www.repositorio.espe.edu.ec](http://www.repositorio.espe.edu.ec).
- Enriquez, J. G., & Casas, S. I. (2014). Usabilidad en aplicaciones móviles. *Informes Científicos Técnicos - UNPA*, 5(2), 25–47. <https://doi.org/10.22305/ict-unpa.v5i2.71>
- Escorial, M. C. (2017). Control de malas hierbas en maíz. Opciones de manejo con herbicidas convencionales y glifosato. *Congreso de la Sociedad Española de Malherbología*, 5.
- Espino, C. (2017). “Análisis predictivo: técnicas y modelos utilizados y aplicaciones del mismo- herramientas Open Source que permiten su uso.”
- Estradas, C. I. (2017). *Propuesta de un método basado en Deep Learning para Learning Analytics en MOOCs*.
- G.M, S. (2015). *Corrección espacial entre malas hierbas en una pradera y sus relación con la conectividad eléctrica aparente del suelo*. Brasil: MG.
- García, G. (2018). *Aplicación de la metodología Crisp-Dm a la recolección y análisis de datos georreferenciados desde Twitter*. undefined-undefined.
- Garnica, I. (2009). *Herbicidas en maíz*. 13–18.
- Gusmán, A. P. (2019). *Análisis y clasificación de firmas espectrales utilizando técnicas de aprendizaje automático*. Mexico.
- Gutiérrez, J. (2016). Líneas de investigación en minería de datos en aplicaciones en ciencia e ingeniería: Estado del arte y perspectivas. *Arxiv, Artificial Intelligence (Cs.AI)*, 1(1609.05401), 1–17. <https://doi.org/10.1007/s003350010211>
- Heredia, I. (n.d.). *Large-Scale Plant Classification with Deep Neural Networks*. 259–262.

- IBM, I. B. M. (2012). Manual CRISP-DM de IBM SPSS Modeler. *IBM Corporation*, 56.  
Retrieved from  
<http://www.ibm.com/spss.%0Aftp://public.dhe.ibm.com/software/analytics/spss/documentation/modeler/15.0/es/CRISP-DM.pdf>
- Martínez, M. M. (2015). *Técnicas de visión artificial para la segmentación y detección de líneas de cultivo en imágenes agrícolas*. Retrieved from  
<http://eprints.sim.ucm.es/30175/1/T36063.pdf>
- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones. Cátedra: Informática Aplicada a La Ingeniería de Procesos-Orientación I*, 6.
- Mendiola, Á. (2011). *Vision General de malas hierbas. Ingeniería Agrícola*, 10.
- Müllerová, J., Pergl, J., & Py, P. (2013). *International Journal of Applied Earth Observation and Geoinformation Remote sensing as a tool for monitoring plant invasions : Testing the effects of data resolution and image classification approach on the detection of a model plant species Heracleum ma.* 25, 55–65. <https://doi.org/10.1016/j.jag.2013.03.004>
- Ochoa, L. (2019). *Evaluation of Classification Algorithms using Evaluación de Algoritmos de Clasificación utilizando Validación Cruzada.* (July 2019), 24–26.
- Omar, A., & Ean, R. (2017). *Métodos científicos de indagación y de construcción del conocimiento.* (82), 179–200.
- Ortega, S. H. (2014). *Soporte digital de malas hierbas en estado de plántulas.* (Parte 2).
- Parra, F. (2019). *Estadística y Machine Learning con R.* Retrieved January 23, 2020, from <https://bookdown.org/content/2274/portada.html>
- Paulus, S., Dupuis, J., Mahlein, A., & Kuhlmann, H. (2013). *Surface feature based classification of plant organs from 3D laserscanned point clouds for plant phenotyping Highlights :* 1–12.
- Paz, G. B. (2017). *Metodología de la investigación Grupo Editorial Patria Sistema de aprendizaje en línea Metodología de la investigación* (3a. ed.; Patria, Ed.). Retrieved from [www.editorialpatria.com.mxwww.sali.org.mx](http://www.editorialpatria.com.mxwww.sali.org.mx)
- Peñaherrera, D. (INIAP). (2011). *Manejo integrado del cultivo de maíz de altura. INIAP (Estación Experimental Santa Catalina)*, 55. Retrieved from  
<https://repositorio.iniap.gob.ec/bitstream/41000/3302/1/iniapscpm190.pdf>
- F.Quintanilla. (2017). *Las malas Hierbas.* Catarata: CSIC.
- Quiroz García, J. L., Laplace, L. V., Rodríguez, A. M., & Laplace, S. A. (2011). *Plantas tóxicas para el ganado de la cuenca del salado. Instituto Nacional de Tecnología*

- Agropecuaria, Argentina*, pp. 9–73.
- Rigoberto, V. C. (2018). *Deep Learning para la detección de peatones y vehículos*. Retrieved from <http://ri.uaemex.mx/handle/20.500.11799/70995>
- Rivero, J. L. (2014). Técnicas de aprendizaje automático para la detección de intrusos en redes de computadoras. *Seguridad Informàtica*, 23.
- Sanz, D. (2016). *Introducción a Android*.
- Sousa, V. D., Driessnack, M., Amélia, I., & Mendes, C. (2017). *Revisión de diseños de investigación resaltantes para enfermería. Parte 1: diseños de investigación cuantitativa*. Retrieved from [www.eerp.usp.br/rlae](http://www.eerp.usp.br/rlae)
- Taberner, A. (2013). *La resistencia de las malas hierbas a los herbicidas en España*. España: PHYTOMA.
- Timón, C. E. (2017). ii Esta obra está sujeta a una licencia de Reconocimiento-NoComercial-SinObraDerivada 3.0 España de Creative Commons. 26/27, I(Principio activo y prestación ortoprotésica), 67. Retrieved from <http://openaccess.uoc.edu/webapps/o2/bitstream/10609/59565/6/caresptimTFG0117memoria.pdf>
- Valderrama, M. J. A. (2017). *CLASIFICACIÓN DE OBJETOS USANDO APRENDIZAJE PROFUNDO IMPLEMENTANDO EN UN SISTEMA EMBEBIDO*.
- Vanegas, M. (2015). *CARACTERIZACIÓN E IDENTIFICACIÓN DE RAZAS DE MAÍZ EN LA PROVINCIA DEL AZUAY*. Cuenca.
- Vera, A. (2018). Diversidad y análisis fitosociológico de malezas en un cultivo de musáceas del trópico ecuatoriano. *AGRISCIENTIA*, 10.
- Yanez, C. (2013). *Guia de produccion de maiz para pequeños agricultores y agricultoras*. Ecuador: INIAP.
- Yu, J., Sharpe, S. M., Schumann, A. W., & Boyd, N. S. (2019). Deep learning for image-based weed detection in turfgrass. *European Journal of Agronomy*, 104, 78–84. <https://doi.org/10.1016/j.eja.2019.01.004>
- Zubizarreta, L. D. y L. (2014). Guía de reconocimiento de malezas. In *Journal of Chemical Information and Modeling* (Vol. 53). <https://doi.org/10.1017/CBO9781107415324.004>

**15. ANEXOS.****15.1. Anexo 1: Hoja de vida autor 1.****DATOS PERSONALES****Nombres:** Mercedes Azucena**Apellidos:** Casa Lema.**Fecha de Nacimiento:** 2 de Junio de 1993.**Edad:** 26 años**Nacionalidad:** Ecuatoriana.**Cedula de Identidad:** 172317065-8**Dirección Domiciliaria:** Tanicuchi- Barrio San Pedro**Teléfono Domicilio:** 032-701-881**Teléfono Celular:** 09069732**Estado Civil:** Casada.**Correo Electrónico:** [mercedes.casa9@utc.edu.ec](mailto:mercedes.casa9@utc.edu.ec)**ESTUDIOS PRIMARIOS****Institución:** “Unidad Educativa Batalla de Panupali y Marco Aurelio Subía Martínez”**Dirección:** Parroquia Tanicuchi.**ESTUDIOS SECUNDARIOS****Institución:** “Unidad Educativa Batalla de Panupali y Marco Aurelio Subía Martínez”**Dirección:** Parroquia Tanicuchi**Título de bachiller:** Aplicaciones Informáticas.**Especialización:** Aplicaciones informáticas.**ESTUDIO DE TERCER NIVEL****Institución:** Universidad Técnica de Cotopaxi**Carrera:** Ingeniería en Informática y Sistemas Computacionales.**Dirección:** Av. Simón Rodríguez s/n Barrio El Ejido Sector San Felipe.

-----  
**FIRMA**

## 15.2. Hoja de vida autor 2.

### **DATOS PERSONALES**

**Nombres:** Jenny Celia

**Apellidos:** Tumbaco Sango.

**Fecha de Nacimiento:** 15 de Julio de 1994.

**Edad:** 25 años.

**Nacionalidad:** Ecuatoriana.

**Cedula de Identidad:** 050413908-0

**Dirección Domiciliaria:** Tanicuchi- Barrio San Pedro

**Teléfono Celular:** 0983570484.

**Estado Civil:** Casada

**Correo Electrónico:** [jenny.tumbaco0@utc.edu.ec](mailto:jenny.tumbaco0@utc.edu.ec)



### **ESTUDIOS PRIMARIOS**

**Institución:** “Unidad Educativa Batalla de Panupali y Marco Aurelio Subía Martínez”

**Dirección:** Parroquia Tanicuchi.

### **ESTUDIOS SECUNDARIOS**

**Institución:** “Unidad Educativa Batalla de Panupali y Marco Aurelio Subía Martínez”

**Dirección:** Parroquia Tanicuchi

**Título de bachiller:** Aplicaciones Informáticas.

**Especialización:** Aplicaciones informáticas.

### **ESTUDIO DE TERCER NIVEL**

**Institución:** Universidad Técnica de Cotopaxi

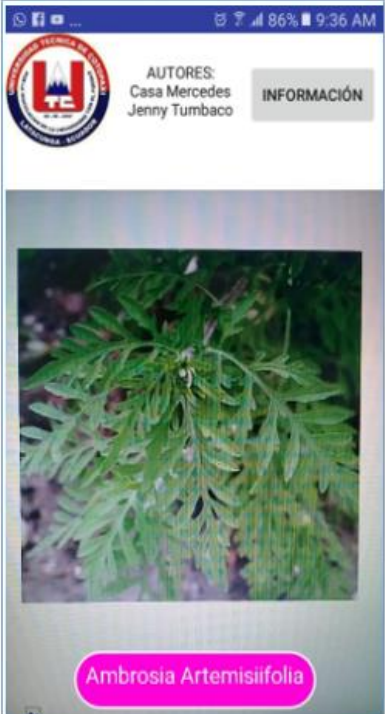


**Carrera:** Ingeniería en Informática y Sistemas Computacionales.

**Dirección:** Av. Simón Rodríguez s/n Barrio El Ejido Sector San Felipe.




-----  
**FIRMA**

## 15.2. Anexo 3: Clasificación de las 6 especies de malas hierbas.


### Ambrosia Artemisiifolia

 <p>AUTORES: Casa Mercedes Jenny Tumbaco</p> <p>INFORMACIÓN</p> <p>Ambrosia Artemisiifolia</p>	<p>Malas Hierbas en el maíz</p> <p>Ambrosia Artemisiifolia</p> 	<p>Malas Hierbas en el maíz</p>  <p>NOMBRE COMÚN: Ambrosia</p> <p>DESCRIPCIÓN: Una especie anual que por lo general germina a finales de la primavera y se desarrolla durante la época de verano, que se puede encontrar en cultivos arados. (Quiroz García, Laplace, Rodríguez, &amp; Laplace, 2011).</p> <p>HERBICIDA ATECTRA: Es un herbicida selectivo y post-emergente soluble en agua que se recomienda para usarse en maíz y sorgo. El ingrediente activo de Aectra, actúa al contacto con la maleza y es absorbido por hojas, tallo y raíces translocándose dentro de la planta y provocando su muerte dentro de los siete días siguientes a la aplicación. (BASF, 2017).</p> <p>VOLUMEN DE APLICACIÓN: Realizar la aplicación, con un volumen de agua de 450-550 L/ha.</p> <p>PREPARACIÓN: Agregue agua al tanque de mezclado hasta las <math>\frac{3}{4}</math> partes de su capacidad, luego agregue la cantidad necesaria de Aectra y llene el tanque a su capacidad mantenimiento una agitación constante. (BASF, 2017).</p>
--	--	--


### Chenopodium Album

 <p>AUTORES: Casa Mercedes Jenny Tumbaco</p> <p>INFORMACIÓN</p> <p>Chenopodium Album</p>	<p>Malas Hierbas en el maíz</p> <p>Chenopodium Album</p> 	<p>Malas Hierbas en el maíz</p>  <p>NOMBRE COMÚN: Hierba Pajarito</p> <p>DESCRIPCIÓN: Se caracteriza por ser parte de cotiledones oval, con un tallo con pelos y glándulas, que posee hojas ovales, donde pueden contener de 40 o más flores</p> <p>HERBICIDA BASAGRAN 60: Es un herbicida de contacto para aplicar en post-emergencia, que se descompone en el suelo y no deja residuos que puedan afectar a futuros cultivos. Es una herramienta para el control de malezas, que posee amplitud de cultivos registrados y control tanto en malezas de hoja ancha.</p> <p>VOLUMEN DE APLICACIÓN: Realizar la dosis: 1,2 - 1,6 l/ha</p> <p>PREPARACIÓN: Después que todas las malezas hayan emergido, ya que Basagran 60 no posee efecto residual en el suelo. Cuando las malezas son pequeñas (hasta 5 cm) y están en activo crecimiento. En no menos de 250 litros de agua por ha. Basagran 60 actúa por contacto, por lo tanto es necesario mojar bien las hojas y tallos de las malezas. Alta luminosidad y temperatura favorecen la acción de Basagran 60, mientras que el tiempo fresco la retarda</p>
---	--	---



## Erodium Cicutarium.





## Galinsoga Parviflora



## Raphanus raphanistrum

	<p><b>Malas Hierbas en el maíz</b></p> <p><b>Raphanus Raphanistrum</b></p> 	<p><b>Malas Hierbas en el maíz</b></p> <p><b>NOMBRE COMÚN:</b> Rábano silvestre</p> <p><b>DESCRIPCIÓN:</b> Esta planta por lo general crece en invierno, esta mala hierba es principal y muy frecuente en todo tipo de cultivos, que se caracteriza por los cotiledones que tienen la forma entre acorazonada que puede alcanzar una altura de 1,5 m, con un tallo erectos, ramificados gruesos, estas son cubiertos de cerdas, cuando son maduros los tallos son semi-leñosos.</p> <p><b>HERBICIDA ATECTRA BV:</b> Es un herbicida postemergente que controla malezas de hoja ancha. Su formulación presenta una nueva sal de Dicamba DGA (dicamba diglycolamine) con una volatilidad diez veces menor que la formulación tradicional de la sal DMA conocida en el mercado.</p> <p><b>VOLUMEN DE APLICACIÓN:</b> Realizar la aplicación, con un volumen de agua de 0,15 a 0,5 l/ha.</p> <p><b>PREPARACIÓN:</b> Atracta BV debe ser aplicado con agua. Para preparar la mezcla, llenar el depósito de la pulverizadora con agua hasta la mitad o ¾ partes de su capacidad, luego agregar el producto Atracta BV con el agitador en marcha, que deberá estar en constante movimiento durante toda la aplicación. Completar el depósito con agua.</p>
---	---	---

## Urtica urens

	<p><b>Malas Hierbas en el maíz</b></p> <p><b>Urtica Urens</b></p> 	<p><b>Malas Hierbas en el maíz</b></p> <p><b>DESCRIPCIÓN:</b> Germina en las épocas de otoño e invierno, por ende se le considera como una mala hierba que no tiene muchos beneficios, posee características como una plántula erecta, con tallos prismáticos y hojas opuestas, con una longitud de 4-mm de longitud, con pelos erizados.</p> <p><b>HERBICIDA PIVOT:</b> Es un herbicida selectivo con acción residual, en aplicaciones postemergentes en los cultivos de soja, maní, alfalfa, arveja, maíz resistente a imidazolinonas (identificado en la bolsa de semilla con el logo CLEARFIELD), y en aplicaciones preemergentes en el cultivo de poroto. Luego de la aplicación de PIVOT, las malezas susceptibles detienen su crecimiento, dejando de competir con el cultivo; la muerte de las mismas puede demorar 3 a 4 semanas.</p> <p><b>VOLUMEN DE APLICACIÓN:</b> Realizar la aplicación de 0.8 LITROS/HA DE PIVOT POR HA.</p> <p><b>PREPARACIÓN:</b> Llène el tanque de la pulverizadora hasta la mitad o las tres cuartas partes con agua limpia. Con el agitador en funcionamiento, vierta la cantidad recomendada de herbicida PIVOT al tanque del pulverizador. Luego complete el tanque con agua. Si las malezas han emergido añada un tensioactivo no iónico a la concentración de 0,25% de principio activo en el volumen total (250 gramos de principio activo cada 100 litros de agua).</p>
---	--	---