



UNIVERSIDAD LAICA “ELOY ALFARO” DE MANABÍ  
EXTENSIÓN EN EL CARMEN  
CARRERA DE INGENIERÍA EN TECNOLOGÍAS DE LA INFORMACIÓN  
Creada Ley No. 10 – Registro Oficial 313 de noviembre 13 de 1985

**PROYECTO INTEGRADOR  
PREVIO A LA OBTENCIÓN DEL TÍTULO DE INGENIERO EN TECNOLOGÍAS DE  
LA INFORMACIÓN**

**APLICACIÓN MÓVIL CON APRENDIZAJE AUTOMÁTICO PARA LA  
PRODUCCIÓN DEL PLÁTANO BARRAGANETE EN EL CANTÓN EL CARMEN**

**AUTOR/ES**

MOLINA MACIAS MELANY MARIUXI

OLMEDO ZAMBRANO ERIK JOEL

**TUTOR**

CESAR AUGUSTO SINCHIGUANO CHIRIBOGA

EL CARMEN, AGOSTO 2024

Ulearn



	NOMBRE DEL DOCUMENTO: CERTIFICADO DE TUTOR(A).	CÓDIGO: PAT-04-F-010
	PROCEDIMIENTO: TITULACIÓN DE ESTUDIANTES DE GRADO BAJO LA UNIDAD DE INTEGRACIÓN CURRICULAR	REVISIÓN: 1 Página 1 de 1

## CERTIFICACIÓN

En calidad de docente tutor de la Extensión El Carmen de la Universidad Laica "Eloy Alfaro" de Manabí, CERTIFICO:

Haber dirigido y revisado el trabajo de Integración Curricular bajo la autoría de la estudiante **MOLINA MACIAS MELANY MARIUXI** y el estudiante **ERIK JOEL OLMEDO ZAMBRANO** legalmente matriculados en la carrera de Tecnologías de la Información, período académico 2020(1) - 2024(1), cumpliendo el total de 360 horas, cuyo tema del proyecto es: **APLICACIÓN MÓVIL CON APRENDIZAJE AUTOMÁTICO PARA LA PRODUCCIÓN DE PLÁTANO BARRAGANETE EN EL CANTÓN EL CARMEN.**

La presente investigación ha sido desarrollada en apego al cumplimiento de los requisitos académicos exigidos por el Reglamento de Régimen Académico y en concordancia con los lineamientos internos de la opción de titulación en mención, reuniendo y cumpliendo con los méritos académicos, científicos y formales, suficientes para ser sometida a la evaluación del tribunal de titulación que designe la autoridad competente.

Particular que certifico para los fines consiguientes, salvo disposición de Ley en contrario.

Lugar, El Carmen 26 de julio del 2024.

Lo certifico,



Ing. César Sinchiguano Chiriboga  
**Docente Tutor**  
**Área: Tecnologías de la Información**



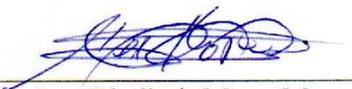
**UNIVERSIDAD LAICA “ELOY ALFARO” DE MANABÍ**

**EXTENSIÓN EL CARMEN**

**APROBACIÓN DEL TRABAJO DE TITULACIÓN**

Los miembros del Tribunal Examinador aprueban el Trabajo de Titulación con modalidad Proyecto Integrador, titulado “APLICACIÓN MOVIL CON APRENDIZAJE AUTOMÁTICO PARA LA PRODUCCIÓN DE PLÁTANO BARRAGANETE EN EL CANTÓN EL CARMEN”, cuyos autores son Molina Macias Melany Mariuxi y Olmedo Zambrano Erik Joel de la Carrera de Ingeniería en Tecnologías de la Información y como Tutor de Trabajo de Titulación el Ing. Sinchiguano Chiriboga César Augusto

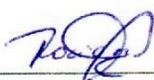
El Carmen, agosto de 2024



---

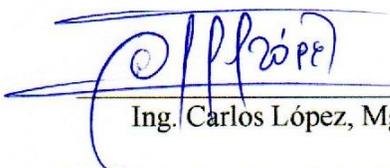
Ing. Bladimir Mora, Mg.

Presidente del tribunal de titulación



---

Ing. Rocío Mendoza, Mg.  
Miembro del tribunal de titulación



---

Ing. Carlos López, Mg.  
Miembro del tribunal de titulación

**UNIVERSIDAD LAICA “ELOY ALFARO” DE MANABÍ**

**EXTENSIÓN EN EL CARMEN**



**DECLARACIÓN DE AUTORÍA**

La responsabilidad del contenido de este Trabajo de titulación, cuyo tema es: Aplicación móvil con Aprendizaje Automático para la Producción del Plátano Barraganete en el Cantón el Carmen, corresponde exclusivamente a: Molina Macias Melany Mariuxi con CI. 131502745-6, y los derechos patrimoniales de la misma corresponden a la Universidad Laica “Eloy Alfaro” de Manabí.



---

Molina Macias Melany Mariuxi

**C.I. 131502745-6**

**UNIVERSIDAD LAICA “ELOY ALFARO” DE MANABÍ**

**EXTENSIÓN EN EL CARMEN**



**DECLARACIÓN DE AUTORÍA**

La responsabilidad del contenido de este Trabajo de titulación, cuyo tema es: Aplicación móvil con Aprendizaje Automático para la Producción del Plátano Barraganete en el Cantón el Carmen, corresponde exclusivamente a: Olmedo Zambrano Erik Joel con CI. 235070986-7, y los derechos patrimoniales de la misma corresponden a la Universidad Laica “Eloy Alfaro” de Manabí.

A handwritten signature in blue ink, appearing to be "Olmedo Zambrano Erik Joel", is written over a solid horizontal line.

Olmedo Zambrano Erik Joel

**C.I. 235070986-7**

## DEDICATORIA

Dedico este logro a Jehová Dios, por permitirme alcanzar mis metas académicas. A mis padres, Ider Olmedo y Martha Zambrano, por su esfuerzo y sacrificio que hicieron posible mis estudios. A mis abuelos, por su sabiduría y apoyo en momentos clave. A mis padrinos, Eduardo Zambrano y María Arteaga, por su respaldo emocional y material, a mi tía Cecilia Zambrano, por su amor incondicional y brindar ese apoyo cuando más lo necesitaba. También quiero dedicar este proyecto y mi carrera universitaria a mi compañera Melany Molina por haber estado académicamente a mi lado, ayudando y apoyándome desde el inicio de la carrera. Este reconocimiento es también de todos quienes han contribuido a mi camino académico. Este gran paso en mi vida es dedicado a todos ellos con mucho respeto y amor.

Erik Olmedo.

Este proyecto se lo dedico principalmente a Dios, en quien encontré refugio y apoyo en todo momento enfrentado a lo largo de mi proceso académico. Con amor a mi madre Jacqueline Macías, quien a pesar de todas las adversidades se ha mantenido fuerte y siempre apoyándome en mis estudios y en las decisiones que he tomado a lo largo de mi vida, por ser el pilar de mi vida y mi gran amiga. A mis hermanos por ser un impulso para poder superarme y seguir avanzando en la vida. A mis abuelos Ángel Macias y Jacinta Farias, por brindarme todo su apoyo y amor para poder seguir adelante con mis estudios. A quien en vida fue mi padre, Jacinto Molina, por haberme amado y cuidado hasta su último aliento, pues es un motivo más para esforzarme. Por último, pero no menos importante, a mi compañero y persona preciada Erik Olmedo, por haber estado en las buenas y en las malas desde el comienzo de esta carrera universitaria, por ser un gran amigo y compañero en todo momento.

Melany Molina

## **AGRADECIMIENTO**

Queremos expresar nuestro total agradecimiento a nuestro tutor de tesis, el Ing. Cesar Sinchiguano, por su inestimable apoyo emocional y su orientación durante todo este proceso que se inició hace más de un año. Su esfuerzo y dedicación han sido fundamentales para el desarrollo de este proyecto de titulación. Agradecemos especialmente por mostrarnos el camino que debíamos seguir y por compartir generosamente todo su conocimiento con nosotros. Además, queremos extender nuestro agradecimiento a la Universidad Laica Eloy Alfaro de Manabí Ext. El Carmen por brindarnos servicios de preparación académica de la más alta calidad y por permitirnos hacer uso de su infraestructura durante estos 4 años de carrera. Estamos profundamente agradecidos por todas las oportunidades de aprendizaje y crecimiento que nos han brindado. Sin duda, estas experiencias serán fundamentales en nuestra futura trayectoria profesional.

## ÍNDICE GENERAL

<b>PORTADA.....</b>	<b>I</b>
<b>CERTIFICACIÓN DEL TUTOR .....</b>	<b>III</b>
<b>APROBACIÓN DEL TRABAJO DE TITULACIÓN.....</b>	<b>IV</b>
<b>DECLARACIÓN DE AUTORÍA .....</b>	<b>V</b>
<b>DEDICATORIA.....</b>	<b>VII</b>
<b>AGRADECIMIENTO .....</b>	<b>VIII</b>
<b>ÍNDICE DE TABLAS.....</b>	<b>XII</b>
<b>ÍNDICE DE ILUSTRACIONES .....</b>	<b>XIII</b>
<b>ÍNDICE DE ANEXOS .....</b>	<b>XV</b>
<b>RESUMEN.....</b>	<b>XVI</b>
<b>ABSTRACT.....</b>	<b>XVII</b>
<b>CAPÍTULO I.....</b>	<b>18</b>
<b>1 INTRODUCCIÓN .....</b>	<b>18</b>
<b>1.1 Presentación del tema.....</b>	<b>19</b>
<b>1.2 Ubicación y contextualización de la problemática.....</b>	<b>19</b>
<b>1.3 Planteamiento del problema.....</b>	<b>20</b>
<b>1.4 Diagrama causa – efecto del problema.....</b>	<b>21</b>
<b>1.5 Objetivos.....</b>	<b>22</b>

1.6	<i>Justificación</i> .....	22
1.7	<i>Impactos esperados</i> .....	23
<b>CAPÍTULO II .....</b>		<b>26</b>
2	MARCO TEÓRICO .....	26
2.1	<i>Antecedentes históricos</i> .....	26
2.2	<i>Antecedentes de investigaciones relacionadas al tema presentado</i> .....	27
2.3	<i>Definiciones conceptuales</i> .....	29
2.4	<i>Metodología de desarrollo</i> .....	45
2.5	<i>Conclusiones del marco teórico</i> .....	48
<b>CAPÍTULO III.....</b>		<b>50</b>
3	MARCO INVESTIGATIVO.....	50
3.1	<i>Introducción</i> .....	50
3.2	<i>Tipos de investigación</i> .....	50
3.3	<i>Métodos de investigación</i> .....	51
3.4	<i>Fuentes de información de datos</i> .....	52
3.5	<i>Estrategia operacional para la recolección de datos</i> .....	53
<b>CAPÍTULO IV .....</b>		<b>71</b>
4	MARCO PROPOSITIVO .....	71
4.1	<i>Introducción</i> .....	71
4.2	<i>Descripción de la propuesta</i> .....	72
4.3	<i>Determinación de recursos</i> .....	72
4.4	<i>Desarrollo</i> .....	74

<b>CAPÍTULO V.....</b>	<b>102</b>
5    EVALUACIÓN DE RESULTADOS.....	102
5.1 <i>Introducción</i> .....	102
5.2 <i>Presentación y monitoreo de resultados</i> .....	102
5.3 <i>Interpretación objetiva</i> .....	107
<b>CAPÍTULO VI.....</b>	<b>109</b>
6    CONCLUSIONES Y RECOMENDACIONES .....	109
6.1 <i>Conclusiones</i> .....	109
6.2 <i>Recomendaciones</i> .....	110
<b>BIBLIOGRAFÍA.....</b>	<b>112</b>
<b>ANEXOS.....</b>	<b>115</b>
<b>GLOSARIO .....</b>	<b>122</b>

## ÍNDICE DE TABLAS

Tabla 1 Parámetros de calidad del plátano .....	44
Tabla 2 Plan de recolección de datos .....	60
Tabla 3 Tabulación de encuestas .....	65
Tabla 4 Tabulación de entrevistas.....	68
Tabla 5 Recursos Humanos .....	73
Tabla 6 Características de Recursos Tecnológicos (Hardware) .....	73
Tabla 7 Características de Recursos Tecnológicos (Software).....	74
Tabla 8 Recursos Económicos .....	74
Tabla 9 Requerimientos de Hardware y Software .....	75
Tabla 10 Tipos y Roles de Usuario.....	76
Tabla 11 Caso de Prueba CT001 .....	99
Tabla 12 Caso de Prueba CT002 .....	101
Tabla 13 Planificación de la evaluación .....	103

## ÍNDICE DE ILUSTRACIONES

Figura 1 Diagrama Causa - Efecto.....	21
Figura 2 Estructura de una red neuronal.....	40
Figura 3 Funcionamiento de una CNN.....	41
Figura 4 Refractómetro portátil.....	45
Figura 5 Fases de la metodología Cascada.....	46
Figura 6 Interfaz de Inicio de "Plátano App".....	76
Figura 7 Interfaz de Detección por Imágenes.....	77
Figura 8 Interfaz de Detección en Tiempo Real.....	78
Figura 9 Recolección de datos para Dataset.....	81
Figura 10 Recolección de datos para Dataset.....	81
Figura 11 Limpieza y etiquetado de imágenes.....	82
Figura 12 Clasificación del set de datos.....	83
Figura 13 Creación de carpetas en Colab.....	84
Figura 14 Verificar integridad de las imágenes.....	85
Figura 15 Estructuración del set de datos en Colab.....	86
Figura 16 Verificación de cantidades de imágenes.....	86
Figura 17 Aumento de datos con Keras.....	87
Figura 18 Descarga y configuración de la arquitectura MobileNet v2.....	87
Figura 19 Entrenamiento del modelo.....	88
Figura 20 Generación de la gráfica de entrenamiento.....	89
Figura 21 Gráfica de precisión de MobileNet v2.....	89
Figura 22 Creación de clases y carga de imágenes en Teachable Machine.....	90

Figura 23 Ajuste de entrenamiento del modelo .....	91
Figura 24 Vista previa al modelo.....	92
Figura 25 Gráfica de precisión por época en Teachable Machine .....	92
Figura 26 Gráfica de pérdida por época en Teachable Machine .....	93
Figura 27 Exportación del modelo a TFLite.....	94
Figura 28 Archivo TFLite.....	94
Figura 29 Código de Página principal .....	95
Figura 30 Integración del Modelo TFLite en la APP .....	96
Figura 31 Código del Interprete del Modelo.....	96
Figura 32 Código de función Detección por Imagen.....	97
Figura 33 Código de función Detección en Tiempo Real.....	98
Figura 34 Prueba Funcional de Detección por Imagen.....	104
Figura 35 Prueba Funcional de Detección en Tiempo Real .....	105

## ÍNDICE DE ANEXOS

Anexo A Asignación de tutor 1 .....	115
Anexo B Asignación de tutor 2.....	116
Anexo C Reporte del sistema antiplagio.....	117
Anexo D Tutoría con Docente tutor.....	118
Anexo E Tutoría con Docente tutor para revisión de documentación .....	118
Anexo F Fotografía con jurado del concurso.....	119
Anexo G Demostración de uso de la aplicación móvil.....	119
Anexo H Encuesta aplicada a productores.....	120
Anexo I Resultados obtenidos de la encuesta .....	120
Anexo J Aplicación de entrevista .....	121

## RESUMEN

El presente proyecto integrador tiene como finalidad el desarrollo de una aplicación móvil con capacidad de aprendizaje automático para la clasificación del plátano barraganete en el cantón El Carmen, Ecuador. La importancia de la agricultura en la economía local es innegable, y el plátano es uno de los principales productos de exportación. No obstante, los pequeños productores enfrentan desafíos significativos en la determinación precisa de la madurez del plátano, lo que puede resultar en pérdidas económicas considerable.

La investigación realizada se fundamenta en un análisis bibliográfico exhaustivo y en la recolección de datos a través de encuestas y entrevistas a productores y expertos agrónomos. Se identificó que la mayoría de los productores utilizan métodos empíricos para evaluar la madurez del plátano, lo que no siempre garantiza resultados precisos. Por consiguiente, se propone el desarrollo de una aplicación que permita a los agricultores clasificar los plátanos en "apto para exportar" o "rechazo" utilizando técnicas de inteligencia artificial.

El proceso de desarrollo se llevó a cabo utilizando la metodología en cascada, lo cual permitió una planificación detallada y la validación de requisitos. Se entrenó un modelo de aprendizaje profundo utilizando imágenes de diferentes estados de madurez del plátano, logrando una precisión adecuada en las clasificaciones.

Los resultados de la evaluación de la aplicación muestran que esta puede mejorar la eficiencia en la clasificación del plátano, reducir el tiempo de trabajo y aumentar la calidad del producto final.

## **ABSTRACT**

The purpose of this integrative project is the development of a mobile application with machine learning capacity for the classification of the barraganete banana in the canton of El Carmen, Ecuador. The importance of agriculture in the local economy is undeniable, and bananas are one of the main export products. However, small producers face significant challenges in accurately determining banana ripeness, which can result in considerable economic losses.

The research carried out is based on an exhaustive bibliographic analysis and the collection of data through surveys and interviews with producers and agronomist experts. It was identified that most producers use empirical methods to evaluate banana maturity, which does not always guarantee accurate results. Therefore, the development of an application is proposed that allows farmers to classify bananas as "suitable for export" or "rejection" using artificial intelligence techniques.

The development process was carried out using the waterfall methodology, which allowed detailed planning and validation of requirements. A deep learning model was trained using images of different stages of banana maturity, achieving adequate accuracy in the classifications.

The results of the evaluation of the application show that it can improve efficiency in banana classification, reduce work time and increase the quality of the final product.

## Capítulo I

### 1 Introducción

La agricultura en el Ecuador es una de las principales fuentes de producción alimenticia y de ingresos económicos para muchas comunidades del país, pues al ser una actividad que viene siendo parte de las familias ecuatorianas desde hace mucho tiempo como sustento, más para las zonas rurales donde su única fuente de trabajo es justamente, el cultivo y venta de productos agrícolas. Uno de los cultivos que se suelen cosechar en las zonas rurales, y más en la región Costa, es el plátano, esto gracias a su versatilidad para ser transformado y sus distintas variedades, convirtiéndolo así en una opción de comercio favorable para las comunidades productoras del Ecuador.

Según Beltrón C, et al. (2018), “la mayor área para cultivos de plátano se encuentra en el cantón El Carmen de la provincia de Manabí, el cual constituye el mayor exportador del producto hacia Estados Unidos y Europa”. Sin embargo, la mayoría de este producto proviene de pequeños productores que, en algunos casos, tienen poco o nulo conocimiento en la verificación de que el plátano cumpla con los requisitos necesarios para su comercialización nacional e internacional. Por lo tanto, deben llamar a un fiscalizador el cual es el encargado de verificar el cumplimiento de las normas de calidad de la producción de plátano, el problema presente en la comunidad de El Carmen es la falta de fiscalizadores para la toma de decisiones a la hora de cosechar el producto.

El presente trabajo se centra en el desarrollo de un sistema de clasificación en tiempo real de plátanos barraganetes mediante el uso de inteligencia artificial, con la finalidad de crear un método eficiente y preciso que permita a los productores determinar que plátano es apto para ser exportado y cual es considerado rechazo.

## **1.1 Presentación del tema**

Desarrollo de aplicación móvil de aprendizaje automático para la detección de la madurez del plátano barraganete utilizando técnicas de aprendizaje profundo y análisis de imágenes para clasificar el plátano en exportación y rechazo.

## **1.2 Ubicación y contextualización de la problemática**

En el cantón El Carmen, la comercialización y exportación del plátano barraganete es la principal fuente de ingreso económico para más del 75% de las familias Carmenses, sin embargo, su producción y comercio se realiza en zonas con poco desarrollo industrial y tecnológico, en el cual tiene que verificar el nivel de madurez de la fruta de forma empírica, donde se necesita la presencia de un fiscalizador, el cual se encarga de determinar si la fruta esta apta para ser exportada o deberá pasar a ser calificada como rechazo.

Los problemas de la ausencia de una herramienta de detección del nivel de madurez, radica en la falta de fiscalizadores en la zona y el no poder distinguir de manera precisa la madurez adecuada para exportar, el resultado de esta problemática se puede observar en el desperdicio del producto, ya que si la fruta no es exportada en un nivel adecuado, esta no estará en su punto óptimo al momento de llegar a su destino en los mercados internacionales, provocando su desecho al estar madura o ser una fruta senescencia, esto último puede provocar la mala reputación de la empresa exportadora, causando una pérdida de ingresos significativamente alta, afectando negativamente el precio de la exportación y a su vez los ingresos de las miles de familia que dependen de este comercio.

### **1.3 Planteamiento del problema**

#### **1.3.1 Problematización**

##### **Inconsistencia en la calidad del plátano en los mercados internacionales.**

El plátano, como cualquier fruta, tiene varias etapas de maduración en las cuales tanto su textura y sabor son distintos, por lo que para exportación el estado del plátano debe ser tierno ya que conserva su sabor suave y almidonado. Sin embargo, el control de calidad al clasificarlos puede ser ineficiente, lo que provoca la venta de plátanos en diferentes estados de madurez, generando una percepción de sabor y calidad negativa del producto tanto exportado como consumido localmente. Este problema puede desencadenar una serie de consecuencias, afectando a los minoristas y distribuidores con problemas en la gestión de los productos almacenados, mala gestión de la cadena de suministros, grandes pérdidas de ventas y desbalances económicos significativos.

#### **1.3.2 Génesis del problema**

Si bien la ciudad de El Carmen es el principal exportador por excelencia del plátano, tiende a encontrarse con problemas a la hora de verificar los estándares de calidad de la fruta, por lo que los productores se ven en la obligación de recurrir a un inspector externo. Sin embargo, estos expertos residen en localidades distantes, esto implica un gasto adicional para los productores locales.

Frente a la necesidad de facilitar el trabajo de muchos agricultores de la zona, se presenta una herramienta accesible con el objetivo de permitir que los mismos productores puedan determinar por sí mismos el estado del plátano y, de la misma forma, poder cosechar y empacar sus productos mejorando así la calidad y disminuyendo las pérdidas producidas por empacar en el estado inadecuado.

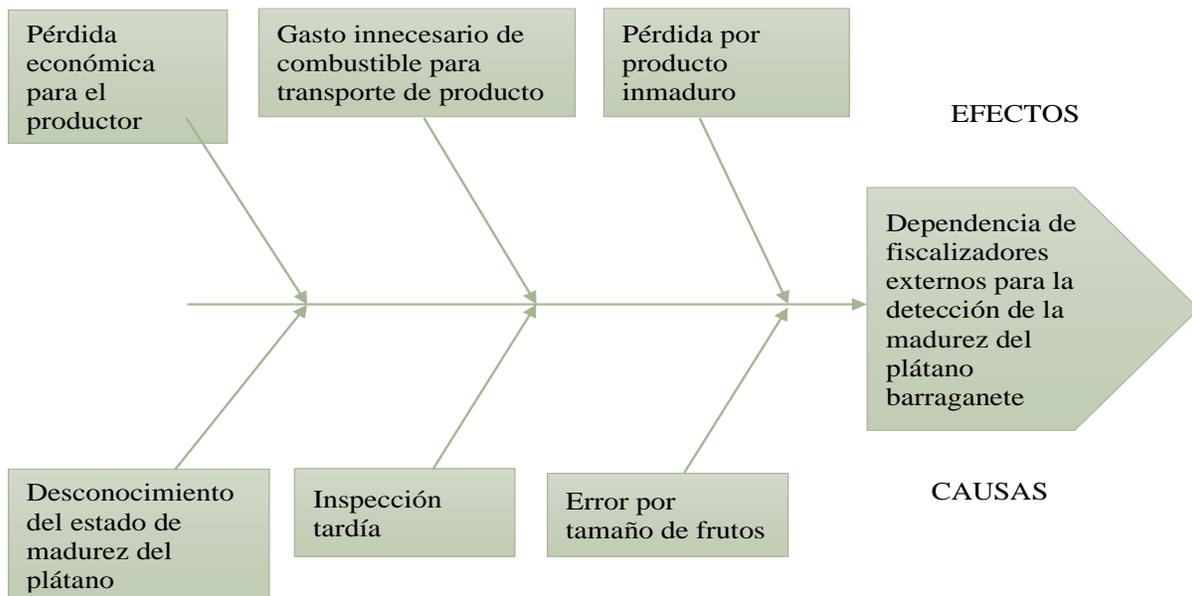
### 1.3.3 Estado actual del problema

A pesar de la importancia que tiene la agricultura y, en este caso, el cultivo del plátano barraganete para la economía, aún no se han implementado otras formas eficientes y eficaces para la determinación de la madurez de la fruta, además de que se presentan los siguientes problemas:

- Dependencia de un fiscalizador externo para determinar la madurez del cultivo.
- Falta de conocimiento y capacitación para tomar decisiones al momento.
- Potencial pérdida económica por clasificación deficiente del producto.
- Demora en la toma de decisiones.

### 1.4 Diagrama causa – efecto del problema

Como se muestra en la figura 1, se presenta un diagrama de Ishikawa o de espina de pescado con la finalidad de visualizar y analizar las diferentes variables que influyen en la dependencia de fiscalizadores para la clasificación de plátanos en el cantón El Carmen.



*Figura 1 Diagrama Causa - Efecto*  
*Fuentes: Elaboración propia*

## **1.5 Objetivos**

### **1.5.1 Objetivo general**

Desarrollar una aplicación móvil con aprendizaje automático para la producción del plátano en el cantón El Carmen.

### **1.5.2 Objetivos específicos**

- Identificar los libros y las publicaciones científicas más relevantes y actualizadas sobre el aprendizaje automático y la producción de plátano.
- Organizar y resumir los conocimientos teóricos adquiridos de los libros consultados para tener una base sólida de información que sustente el proyecto.
- Recopilar y analizar los datos necesarios para justificar las causas y efectos planteados en el proyecto.
- Generar la propuesta y soluciones basadas en el análisis del marco investigativo para abordar los problemas identificados.
- Valorar el impacto de las soluciones propuestas en el marco propositivo de manera cuantitativa y cualitativa en relación con los objetivos establecidos.

## **1.6 Justificación**

El plátano barraganete es una variedad del plátano que se produce y consume en Ecuador. Además, es el segundo producto más exportado por el país. Este producto se produce en el Litoral y en zonas de clima cálido, como el cantón El Carmen, donde la producción de esta fruta es una de las principales actividades económicas para gran parte de las familias carmenses.

Sin embargo, varios de los productos que son cosechados para exportación se desechan porque no cumplen con los requisitos de calidad, ya que, para exportar a países de Europa o Estados Unidos, el plátano debe ser de tonalidad verde brillante, sin manchas negras, melladuras

o insectos. Para saber que el producto cumpla con estos requisitos, los productores deben depender de un experto que inspeccione el proceso de clasificación de la fruta para su respectivo traslado.

Este proceso de inspección suele tomar un tiempo significativo, sin tomar en cuenta que primero se debe contactar con un inspector, el cual normalmente reside en otras ciudades o cantones por lo que el simple hecho de encontrar y esperar la llegada de uno, además de depender del tiempo en que se tarde, se implica un gasto económico que podría resultar contradictorio para el productor en caso el fruto no cumpla con los estándares de exportación.

El desarrollo de una aplicación móvil de aprendizaje automático que ayude a la detección de la madurez del plátano en la agricultura no solo resolvería el problema de la dependencia de un experto para la inspección del producto, sino que también impulsaría la implementación de otras tecnologías en el sector agrícola, ayudando así en la mejora de la calidad del producto, reducción de pérdidas, lograr que los agricultores sean autosuficientes en la toma de decisiones al momento de cosechar aumentando la producción y competitividad, lo que a su vez traería un impacto positivo en la economía de la comunidad.

## **1.7 Impactos esperados**

### **1.7.1 Impacto tecnológico**

La inteligencia artificial ha revolucionado la forma en la que las empresas llevan a cabo sus procesos y la agricultura no es la excepción. En este sentido, la industria agrícola ha comenzado a implementar tecnologías de reconocimiento de madurez de frutas de mayor exportación tal como lo es el plátano, para optimizar la producción y reducir costos.

El sistema de reconocimiento de madurez es una herramienta innovadora que permite a los productores mayoristas y minoristas recolectar más frutas en menor tiempo, aumentando

considerablemente su producción y reduciendo los costos asociados con la cosecha manual. Además, esta tecnología permite un ahorro de tiempo y recursos, ya que se evita el error de comercializar frutas que no están óptimas para ser recolectadas, lo que provoca desperdicios y pérdidas para el productor.

### **1.7.2 Impacto social**

El uso de herramientas en el ámbito laboral de los agricultores siempre ha sido fundamental para mejorar la calidad de su trabajo y el producto final. Por lo que el desarrollo de un sistema de detección de madurez en los plátanos tendrá un impacto positivo en la eficiencia y productividad de los agricultores, lo que les permitirá dedicar más tiempo a otras actividades y mejorar su calidad de vida.

Además, esta herramienta también contribuirá a mejorar la seguridad alimentaria de las personas que consumen plátanos, ya que se asegurará que los frutos estén en su punto óptimo de madurez y calidad.

Para concluir, la implementación de herramientas tecnológicas en la agricultura, como la que se presenta en este proyecto, es fundamental para mejorar la productividad y eficiencia del sector, así como garantizar la calidad y seguridad alimentaria de los productos que se consumen.

### **1.7.3 Impacto ecológico**

La agricultura puede tener un gran impacto en el medio ambiente, pero también tiene el potencial de ser una herramienta poderosa para su mejora. En este sentido, la tecnología juega un papel fundamental. Una de las innovaciones más interesantes en este ámbito es la implementación de asistentes inteligentes de clasificación de frutas, como la herramienta presentada en este proyecto.

El sistema permite predecir el punto de madurez exacto para ser comercializado, lo que no solo mejora la calidad del producto, sino que también reduce la huella de carbono al disminuir los viajes innecesarios de los vehículos cargados de plátanos rechazados.

## Capítulo II

### 2 Marco Teórico

#### 2.1 Antecedentes históricos

##### *Génesis de la inteligencia artificial (1943-1955)*

Según lo mencionan Russell y Norving (2022, p.31), “Warren McCulloch y Walter Pitts (1943) han sido reconocidos como los autores del primer trabajo de IA. Partiendo de tres fuentes: conocimientos sobre la fisiología básica y funcionamiento de las neuronas en el cerebro, el análisis formal de la lógica proposicional de Russel y Whitehead y la teoría de la computación de Turing. Propusieron un modelo constituido por neuronas artificiales, en el que cada una de ellas se caracterizaba por estar “activada” o “desactivada”, la “activación” se daba como respuesta a la estimulación producida por una cantidad suficiente de neuronas vecinas.” Aunque el modelo de McCulloch-Pitts era muy simple, tuvo un impacto significativo en el desarrollo de la IA, pues demostró que era posible representar la lógica en un sistema físico, lo que abrió la puerta al desarrollo de sistemas de inteligencia artificial más complejos.

Si bien, existen varios trabajos iniciales que pueden ser considerados como de Inteligencia Artificial, fue Alan Turing quien articuló primero una visión de la IA en su artículo *Computing Machinery and Intelligence*, en 1950, donde se introduce la prueba de Turing, el aprendizaje automático, los algoritmos genéricos y el aprendizaje por refuerzo. La prueba o test de Turing es un método para evaluar la inteligencia de una máquina, en esta prueba, un interrogador humano interactúa con una máquina y con una persona real. Si el interrogador no puede identificar de forma fiable a la máquina, entonces se considera que la máquina ha pasado la prueba y puede considerarse inteligente.

### ***Nacimiento de la inteligencia artificial (1956)***

Uno de los primeros pioneros en el campo de la IA fue John McCarthy, quien en 1956 acuñó el término “Inteligencia Artificial” y organizó la Conferencia de Dartmouth, considerada el inicio oficial del campo de la IA. McCarthy (2007, p.1030-1034) describe la Conferencia de Dartmouth como un “evento trascendental” que marcó el comienzo de la era moderna de la IA, en donde se reunieron los principales investigadores de la IA de la época, quienes estaban convencidos de que era posible crear “máquinas inteligentes”.

### ***Aprendizaje Automático (1960)***

En la década de 1960, se produjo un cambio importante en el enfoque de la IA, con el surgimiento del aprendizaje automático y las redes neuronales. Uno de los primeros ejemplos de aprendizaje automático fue el programa “Adeline”, creado por Bernard Widrow y Ted Hoof en 1960, que fue capaz de aprender a reconocer patrones de sonido. Sánchez (2023, p.5) afirma que el aprendizaje automático comenzó a ganar popularidad en la década de 1990, ya que permitía a las máquinas aprender de los datos sin ser programadas explícitamente. Los algoritmos de aprendizaje automático han seguido evolucionando y mejorando, permitiendo a las máquinas aprender de manera más eficiente y efectiva.

## **2.2 Antecedentes de investigaciones relacionadas al tema presentado**

- ***Uso de Aprendizaje Profundo para Detección de Maduración en Plátanos. Tapia-Méndez et al. (2023).***

En el artículo, los autores desarrollaron un sistema inteligente basado en técnicas de aprendizaje profundo para poder predecir tres estados de maduración en plátanos: sin madurar, maduro y sobre maduro. La metodología utilizada se basó en una serie de pasos que inician desde la recolección de datos, preparación, análisis, entrenamiento, prueba y uso. Como

resultado se encontró que el sistema propuesto es capaz de predecir la madurez del plátano tipo Cavendish con una precisión del 100%.

- ***Diseño de un sistema embebido de monitoreo por visión artificial que permita medir el grado de madurez de las frutas (Bachelor's thesis). Universidad Técnica de Manabí. Erazo Narváez, C. A. (2023).***

El autor desarrolló un sistema de monitoreo de visión artificial para medir el grado de madurez de plátano y fresas. El sistema consta de una aplicación móvil que permite visualizar los resultados de las frutas monitoreadas, esta aplicación también tiene la capacidad de emitir una notificación de alerta cuando una o varias frutas estén en un estado de maduración excesiva. Como resultado de las pruebas realizadas al sistema, se mostró que tiene un nivel de confianza aproximado al 80% considerándolo un porcentaje aceptable ya que detecta gran parte de la fruta.

- ***Prototipo de un sistema que determine el estado de madurez de un plátano utilizando Deep Learning y Visión Artificial. Villalba et al. (2020).***

Los autores desarrollaron un prototipo de sistema que utiliza Deep Learning y Visión Artificial para determinar el estado de madurez del plátano (*Musa balbisiana*). Este sistema fue entrenado con un conjunto de datos de imágenes de plátanos en diferentes estados de madurez. Como resultado de las pruebas realizadas se demostró que el sistema tiene una precisión del 96%, considerándolo como una clasificación casi perfecta de no ser por algunas confusiones al momento de predecir correctamente en un fondo diferente al blanco o con más de un plátano.

## 2.3 Definiciones conceptuales

### 2.3.1 Aplicación Móvil con Aprendizaje Automático

#### 2.3.1.1 Definición de Aplicaciones Móviles

De acuerdo al autor Joyanes (2022), podemos decir que las aplicaciones móviles, también conocidas como “apps”, son programas diseñados específicamente para instalarse y ejecutarse en dispositivos móviles como celulares o tablets. Estas aplicaciones pueden ser ejecutadas en diversos sistemas operativos, dependiendo de cómo haya sido programada, ofreciendo una alta gama de funcionalidades que van desde el entretenimiento hasta la salud y la educación, entre otras.

Según los autores Puetate y Ibarra (2020), las aplicaciones móviles se pueden obtener mediante la descarga e instalación desde tiendas de aplicaciones, como la App Store de Apple o Google Play Store, o desde páginas oficiales de internet, y pueden ser gratuitas o de pago. Es necesario saber que una vez instaladas, estas aplicaciones pueden acceder a diversas funciones del dispositivo, tales como la cámara, micrófono, el GPS, entre otros.

Joyanes (2022) menciona que existen tres tipos de aplicaciones móviles: Aplicaciones móviles nativas, Aplicaciones móviles web y Aplicaciones móviles híbridas.

- **Aplicaciones Móviles Nativas.** – Desarrolladas para un sistema operativo específico (Android, iOS o Windows Phone), utilizando lenguajes como JavaScript, Kotlin, Python, C++, y no pueden ser utilizadas entre plataformas (Puetate & Ibarra, 2020)
- **Aplicaciones Móviles Web.** – Accesibles desde un navegador, no requieren instalación y son multiplataforma, dependen de una conexión a internet.
- **Aplicaciones Móviles Híbridas.** – Desarrolladas con tecnología web (HTML, CSS y JavaScript) y empaquetadas para sistemas operativos específicos (Joyanes, 2022).

### **2.3.1.2 Inteligencia Artificial**

Antes de definir la Inteligencia Artificial, es importante recordar lo que significa el término “Inteligencia”, que es la facultad cognitiva que involucra la capacidad de comprender, razonar, aprender, resolver problemas y adaptarse a nuevas situaciones, esto permite a las personas procesar información, tomar decisiones y enfrentar desafíos por sí mismas.

Rouhiainen (2018) afirma que “la inteligencia Artificial (IA) es la capacidad de las computadoras para realizar actividades mediante algoritmos y tomar decisiones de manera similar a las personas”. Además, “la IA se enfoca en la creación de máquinas pensantes basadas en modelos biomatemáticos dándoles la capacidad de razonar, aprender y resolver problemas” (Valbuena, 2021).

De acuerdo a los autores Russel y Norving (2022), el objetivo de la inteligencia artificial es desarrollar máquinas capaces de imitar la inteligencia humana, permitiéndoles realizar tareas que requieran capacidades cognitivas. Esto se logra mediante el uso de un conjunto de datos previamente seleccionado y otorgado a la máquina, la cual, después de analizar e interpretar los datos, pueda llevar a cabo actividades a partir de la ejecución de una serie de órdenes. Estas pueden ir desde pequeños y sencillos algoritmos hasta complejas redes neuronales artificiales.

Autores como Rouhiainen (2018) consideran que la IA tiene la capacidad de realizar tareas que haría una persona, convirtiéndolas en procesos más eficientes y eficaces si se entrena y utiliza correctamente. Por ejemplo, la IA puede realizar una tarea repetidas veces de una manera más rápida y precisa de lo que lo haría una persona, siempre y cuando esta haya sido entrenada con los datos correctos, permitiendo así optimizar varios procesos y tomar decisiones de forma precisa y eficiente ahorrando muchos recursos para el ser humano.

Sin embargo, según el criterio de autores como Bobadilla (2021), Pérez y Gegúndez (2021), la inteligencia artificial también presenta varias limitaciones. Uno de sus principales problemas es su dependencia a los datos, tomando en cuenta que debe entregarse una gran cantidad de datos y que estos deben ser de alta calidad con sus respectivas etiquetas con el fin de garantizar resultados precisos. En el caso de otorgar una base de datos incompleta o mal etiquetada podría generar resultados poco confiables.

Además, aunque la IA es capaz de analizar patrones y datos, desde el punto de vista de los autores Russell y Norving (2022), no es capaz de comprender un contexto más amplio. Por ejemplo, al intentar utilizar datos o lenguaje figurativo que solo el cerebro humano puede comprender, la IA puede dar respuestas incorrectas. La interacción entre el humano y la IA también puede ser limitada debido a los modismos y términos utilizados en el lenguaje natural, que resultan difíciles de comprender para la inteligencia artificial, complicando así la comunicación y ejecución de órdenes complejas.

### **2.3.1.3 Aprendizaje Automático**

El aprendizaje automático se puede considerar como la ciencia encargada de dotar a las máquinas de inteligencia basándose en un conjunto de datos concreto. Norman (2019) lo define como “la rama de la inteligencia artificial que busca que un programa aprenda de un conjunto de datos y realice predicciones sobre nuevos datos”. Al ser un proceso basado en el aprendizaje, no es necesario que el usuario inserte un código de programación con instrucciones precisas sobre las acciones o respuestas deseadas del sistema. En su lugar, se debe alimentar al programa con bloques de datos que son procesados de forma independiente por los algoritmos de aprendizaje, y, de este modo, la máquina analizará la información obtenida y desarrollará su propia lógica para así realizar una tarea específica.

Pineda, (2022) destaca que el aprendizaje automático conlleva una serie de etapas:

### **1. Conjunto de datos**

Un conjunto de datos o Dataset es una colección estructurada de información utilizada para entrenar y evaluar modelos de aprendizaje automático. Estos conjuntos abarcan varios tipos de datos, incluyendo números, texto, imágenes o audio. La importancia de los conjuntos de datos radica en su papel fundamental para el desarrollo y mejora de algoritmos de inteligencia artificial. Al proporcionar ejemplos concretos y etiquetados, los conjuntos de datos permiten a los modelos de aprendizaje automático aprender patrones y realizar predicciones precisas.

La calidad y representatividad de los datos en un conjunto influyen directamente en la eficacia y generalización del modelo resultante. Por tanto, la selección cuidadosa y el preprocesamiento adecuado de los conjuntos de datos son aspectos críticos en el desarrollo de sistemas de aprendizaje automático.

Según Bobadilla (2021), cuando no hay suficientes datos, los algoritmos de aprendizaje automático tienden a aprender los patrones específicos de las muestras disponibles, en lugar de generalizar los resultados, este fenómeno se lo conoce como sobreajuste (overfitting).

### **2. Procesamiento del conjunto de datos**

En el ámbito del machine learning, la manipulación cuidadosa de los datos juega un papel crucial en la mejora del rendimiento y la precisión de los algoritmos. Al conservar y transformar meticulosamente los datos, se pueden abordar cuestiones fundamentales como el sesgo en los conjuntos de datos, el manejo de valores faltantes y la optimización de la selección de características relevantes.

La mitigación del sesgo en los datos es un paso fundamental en la preparación de datos para machine learning. Al identificar y corregir posibles sesgos en los conjuntos de datos, se

puede mejorar la equidad y la imparcialidad de los modelos resultantes. Esto es especialmente importante en aplicaciones críticas donde la toma de decisiones automatizada puede tener un impacto significativo en las personas.

Según Norman (2019), "Elegir el conjunto de datos correcto y tener suficientes datos para la capacitación es fundamental para el éxito de un proyecto de aprendizaje automático".

Para lo cual se siguen 2 pasos fundamentales en el procesamiento de los datos:

- **Limpieza de datos.**

Para abordar la tarea de manejar valores faltantes en conjuntos de datos, existen diversas técnicas y herramientas disponibles. Una estrategia empleada es la imputación, que implica rellenar valores faltantes usando enfoques estadísticos como la media, la mediana o la imputación basada en la regresión. Herramientas como Pandas, una biblioteca de manipulación de datos en Python, ofrecen funciones especializadas para realizar esta tarea eficazmente.

Norman (2019) afirma: "La limpieza de datos es un proceso fundamental en el análisis de datos, ya que garantiza la calidad y la integridad de estos. El primer paso consiste en eliminar los registros que presentan valores faltantes en variables clave, lo cual puede afectar significativamente el rendimiento del modelo." (p. 40).

- **Etiquetado de datos.**

El etiquetado de datos en el aprendizaje automático consiste en identificar y asignar etiquetas a datos sin procesar, como imágenes, archivos de texto o videos. Estas etiquetas agregan contexto y significado a los datos, permitiendo que los modelos de machine learning puedan aprender de ellos de manera efectiva.

### 3. Selección del algoritmo

La selección del algoritmo son pasos claves a la hora de entrenar un modelo de aprendizaje automático, dependiendo del problema (clasificación, regresión, clustering), se elige el algoritmo adecuado. Por ejemplo, para clasificación se pueden utilizar SVM (Máquinas de Vector Soporte), árboles de decisión o redes neuronales, mientras que para regresión se puede usar regresión lineal, regresión polinómica, entre otros.

#### 4. **Entrenamiento del modelo**

El entrenamiento del modelo es el proceso mediante el cual el algoritmo de aprendizaje automático aprende de los datos de entrenamiento. Durante el entrenamiento, el algoritmo ajusta sus parámetros internos para minimizar una función de pérdida o error, estos parámetros pueden ser los pesos de una red neuronal o los coeficientes en una regresión lineal.

El entrenamiento se realiza de manera iterativa. En cada iteración, el modelo ajusta sus parámetros en función del error cometido en la iteración anterior, utilizando métodos como descenso de gradiente. Es recomendable que a menudo se utilice un conjunto de validación o pruebas para evaluar el modelo durante el entrenamiento y ajustar hiperparámetros en tiempo real para evitar el sobreajuste.

#### 5. **Predicción**

Una vez que el modelo ha sido entrenado, debe utilizarse para hacer predicciones sobre nuevos datos, esto se hace aplicando los datos del conjunto de pruebas. Las predicciones arrojadas por el modelo se comparan con los valores reales para evaluar su precisión.

#### 6. **Evaluación**

La evaluación del modelo implica medir su rendimiento utilizando diversas métricas:

- **Exactitud (Accuracy):** Es la proporción de predicciones correctas sobre el total de predicciones, es útil para problemas balanceados.

- **Precisión y Recall:** En problemas de clasificación, especialmente con clases desbalanceadas, estas métricas son cruciales. La precisión es el número de verdaderos positivos dividido con el número total de elementos predichos como positivo. El recall es el número de verdaderos positivos dividido por el número total de elementos que realmente son positivos.
- **Error cuadrático medio:** Utilizado en problemas de regresión, mide el promedio de los errores cuadrados entre los valores predichos y los reales.
- **Curva ROC y AUC:** En clasificación binaria, la curva ROC (Receiver Operating Characteristic) y el área bajo la curva (AUC) son útiles para evaluar la capacidad del modelo para discriminar entre clases.
- **Matriz de confusión:** En problemas de clasificación, una matriz de confusión ayuda a visualizar el desempeño del modelo al mostrar las predicciones correctas e incorrectas distribuidas entre las clases
- **K-fold Cross Validation:** Se utiliza para evaluar la estabilidad del modelo. El conjunto de datos se divide en K-subconjuntos, y el modelo se entrena y evalúa K veces, cada vez utilizando un subconjunto diferente para la prueba y los otros K-1 para el entrenamiento.

#### 2.3.1.4 Tipos de Aprendizaje Automático

Antes de adentrarse en el entrenamiento de un modelo ML, se debe conocer que existen técnicas de aprendizaje especializados para cada tipo de problemas (Clasificación, Regresión, Agrupamiento, etc.), con el fin de aprovechar los datos disponibles de la manera más eficiente posible.

El aprendizaje supervisado es una técnica en la que el usuario debe entrenar al algoritmo utilizando un conjunto de datos previamente etiquetados con las respuestas o salidas correctas. En este proceso, cada ejemplo del conjunto de datos incluye tanto las características de entrada como las etiquetas de salida correspondientes. Cuando más grande y diverso sea el conjunto de datos mayor será la precisión del modelo entrenado, ya que dispondrá de más información para aprender y generalizar correctamente.

Una vez que el algoritmo ha sido entrenado con suficientes datos etiquetados, se pueden proporcionar nuevos datos sin etiquetar, donde el algoritmo, usando su experiencia pasada, tendrá la capacidad de predecir las etiquetas de los nuevos datos. Sin embargo, Pérez Borrero y Gegúndez Arias (2021) describen que “El principal problema del aprendizaje supervisado es la falta de datos para entrenar correctamente el modelo” (p.92). Este problema surge porque cada dato en el conjunto de entrenamiento debe estar etiquetado manualmente por el usuario, un proceso que puede ser muy lento y costoso, especialmente si se requieren grandes volúmenes de datos para entrenar modelos complejos. La necesidad de etiquetar manualmente cada dato implica que se debe contar con un conjunto de datos elaborado y bien etiquetado para que el modelo pueda aprender correctamente, lo que representa un desafío significativo en muchos dominios.

Por el contrario, el aprendizaje no supervisado se centra en el uso de datos que no están etiquetados previamente. A diferencia del aprendizaje supervisado, donde se requiere una salida conocida para cada dato de entrada, en el aprendizaje no supervisado, el algoritmo debe identificar patrones y estructuras en los datos sin ninguna guía previa.

Una de técnica común para llevar a cabo el entrenamiento de un modelo con aprendizaje no supervisado es el **clustering**. El objetivo de esta técnica es agrupar muestras de un conjunto

en un mismo clúster o grupo, de manera que las muestras del mismo clúster sean más similares entre sí que con las de otros clústers. Esta técnica puede ser utilizada para “obtener los diferentes tipos de clientes en un servicio online, para agrupar productos en un comercio electrónico, para identificar comportamientos en la conducción, etc” (Bobadilla, 2021, p. 17).

### **2.3.1.5 Aprendizaje Profundo**

De acuerdo con Pérez y Gegúndez (2021), el aprendizaje profundo o deep learning es un campo del aprendizaje automático el cuál, a diferencia de este, se encarga de extraer por si mismo las características más relevantes de los datos otorgados para resolver el problema. Estos datos extraídos se representan de forma jerárquica de menor a mayor complejidad con el fin de encontrar características de alto nivel.

El aprendizaje profundo se puede entender como una red neuronal con tres o más capas. Estas redes tienen la intención de imitar las redes neuronales del cerebro humano para tratar de emular su comportamiento, permitiéndoles aprender a partir de una gran cantidad de datos. Esto ayuda a optimizar y perfeccionar las predicciones generadas. “En la práctica, todos los algoritmos de Deep Learning son redes neuronales que comparten algunas propiedades básicas comunes, como que todas consisten en neuronas interconectadas que se organizan en capas” (Torres J. , 2020).

### **2.3.1.6 Transfer Learning**

El transfer learning, o aprendizaje por transferencia, es una técnica que se basa en la reutilización de componentes de modelos de machine learning previamente entrenados en nuevos modelos con propósitos similares. Esta estrategia nos permite optimizar recursos y datos etiquetados necesarios para el entrenamiento, resultando en un proceso más eficiente.

Al reutilizar componentes de un modelo previamente entrenado en un nuevo modelo, se puede compartir el conocimiento si ambos están diseñados para realizar tareas similares. Esto reduce la necesidad de recursos y datos etiquetados para el entrenamiento de los nuevos modelos, lo que se traduce en un ahorro significativo de tiempo y esfuerzo.

Bobadilla (2021) menciona como una ventaja del transfer learning “su capacidad para generar resultados de clasificación de gran calidad, haciendo uso de redes ya entrenadas”. En la práctica, el transfer learning se realiza adaptando una red pre-entrenada en un dominio específico (como el reconocimiento de imágenes) y ajustándolas para que funcione en un dominio relacionado pero diferente, como la clasificación de nuevas categorías de imágenes. Este proceso, conocido como fine-tuning, permite que el modelo conserve el conocimiento adquirido previamente, mejorando la eficiencia y la precisión en el nuevo contexto.

### **2.3.1.7 Redes neuronales**

Una red neuronal se puede definir como un modelo computacional que intenta imitar el funcionamiento del cerebro humano. Según Bobadilla (2021), es necesario “conocer el funcionamiento de una neurona biológica para entender el modelo simplificado de neurona en el que se basan las redes neuronales artificiales”. Se dice que las redes neuronales “están compuestas por numerosos nodos, cada uno con una función específica, como lo es procesar y analizar información. Estos nodos colaboran de manera conjunta para generar una respuesta” (Norman, 2019). Sin embargo, para que la red adquiera conocimientos se debe llevar a cabo un proceso de entrenamiento y aprendizaje.

Varios autores afirman que una red neuronal “aprende mediante el ajuste de sus parámetros; cada neurona de la red se interconecta con las demás mediante conexiones que tienen parámetros asociados que se inicializan de manera aleatoria” (Soria Olivas et al. , 2023).

Estas conexiones se ajustan durante el entrenamiento utilizando algoritmos de optimización como el descenso de gradiente, que minimizan el error en las predicciones.

Las redes neuronales están compuestas por capas, si bien se puede tener una red con una única capa, cuando el número de capas es superior se suele nombrar cada una según su posición en la red:

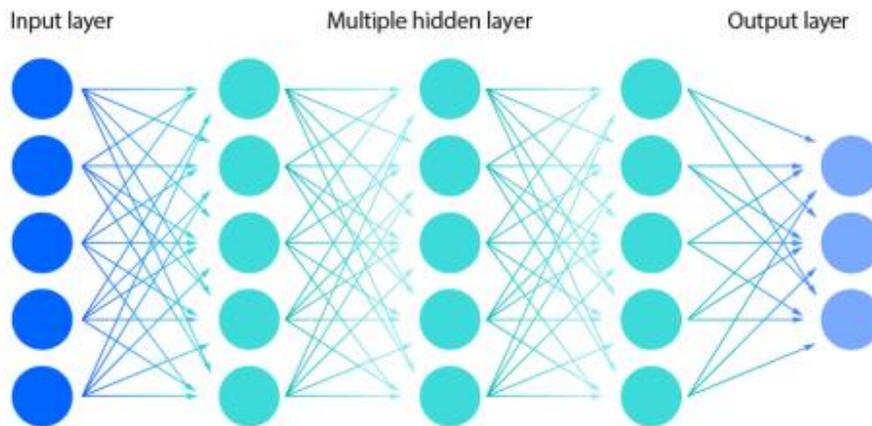
- **Capa de entrada.** – Corresponde a la capa inicial de la red y representa las características de entrada del conjunto de datos. Cada nodo en esta capa recibe una característica distinta de los datos de entrada,
- **Capa oculta.** – Son aquellas que se encuentran entre la capa de entrada y la capa de salida. Se denominan “ocultas” porque los nodos de estas capas no son accesibles desde el exterior.

Cada capa oculta realiza operaciones matemáticas en las entradas recibidas y produce resultados que se utilizan como entradas para la siguiente capa. La profundidad y complejidad de las redes neuronales se incrementa con el número de capas ocultas, permitiendo la extracción de características cada vez más abstractas y complejas.

- **Capa de salida.** – Es la capa encargada de producir los resultados finales de la red. Cada nodo de esta capa representa una salida específica dependiendo del problema que aborda, como una clase en un problema de clasificación o un valor continuo en un problema de regresión.

A continuación, en la figura 2 se muestra la estructura de una red neuronal profunda de manera gráfica:

## Deep neural network



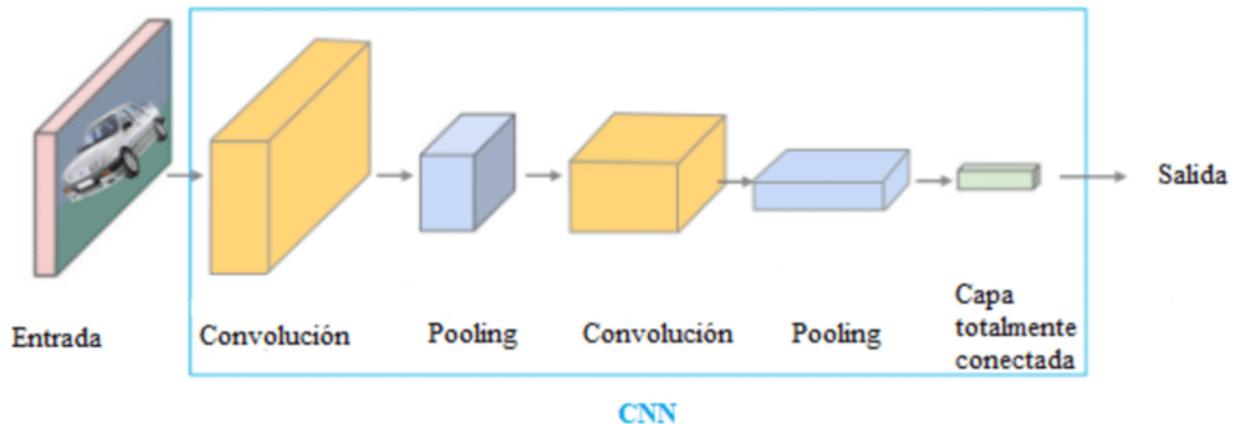
**Figura 2 Estructura de una red neuronal**  
*Fuente: <https://www.ibm.com/es-es/topics/neural-networks>*

### 2.3.1.8 Redes neuronales convolucionales

De acuerdo con Rungta (2019) una red neuronal convolucional (CNN) es una red neuronal multicapa con una arquitectura única diseñada para extraer características cada vez más complejas de los datos en cada capa para determinar la salida. Las redes neuronales convolucionales han revolucionado el reconocimiento de imágenes al permitir la clasificación y detección de objetos a partir de modelos entrenados. Según Bobadilla (2021), “a diferencia de las redes neuronales convencionales, las CNN realizan la convolución haciendo uso de un *filtro* o *kernel*, que se va desplazando por los valores de las muestras” (p.195).

Mirjalili y Raschka (2020) afirman que una CNN funcionará muy bien en tareas relacionadas con imágenes debido a dos razones: La conectividad dispersa y el uso compartido de parámetros. La red se entrena con imágenes y etiquetas, y aprende a través de la aplicación de filtros que buscan coincidencias en la imagen. La CNN toma como entrada tensores que incluyen el alto, ancho y canales de color de la imagen, y como salida se obtiene la clase o probabilidad de pertenencia a una categoría. Las redes neuronales convolucionales son una herramienta valiosa

en el análisis de imágenes y su aplicación en diversos campos, desde la medicina hasta la seguridad. En la figura 3 se muestra de manera breve el funcionamiento de una red neuronal convolucional:



*Figura 3 Funcionamiento de una CNN*

*Fuente: [https://www.researchgate.net/figure/Figura-1-Descripcion-del-funcionamiento-de-una-red-neuronal-convolucional-CNN-10\\_fig1\\_348825166](https://www.researchgate.net/figure/Figura-1-Descripcion-del-funcionamiento-de-una-red-neuronal-convolucional-CNN-10_fig1_348825166)*

### 2.3.1.9 Visión artificial

La visión artificial, también conocida como visión por computadora o visión computacional, es una rama de la IA que se enfoca en permitir que las computadoras interpreten y comprendan el mundo visual tal como lo hacen los humanos., utilizando algoritmos y técnicas avanzadas para procesar, analizar y entender imágenes digitales. También se describe la visión artificial como “una disciplina que se ocupa de la captación, el análisis y la comprensión de imágenes y vídeos” (Duque Domingo et al. , 2024).

Domínguez Mínguez (2021) afirma que el objetivo de la visión artificial es interpretar las imágenes con el fin de extraer información de utilidad, por ejemplo, saber si delante de una cámara hay alguien conocido o un lugar de interés. También se menciona su aplicación en campos como la clasificación y búsqueda de imágenes, conducción autónoma, medicina, agricultura, turismo, videojuegos, etc.

### **2.3.1.10 TensorFlow**

TensorFlow es una biblioteca de software de código abierto que facilita la creación y entrenamiento de redes neuronales. Desarrollada por un grupo de ingenieros del grupo de Google Brain y lanzada en 2015, “es una interfaz de programación multiplataforma y escalable para implementar y ejecutar algoritmos de aprendizaje automático, incluyendo *wrappers* preparados para aprendizaje profundo” (Mirjalili y Raschka, 2020).

Rungta (2019) menciona que TensorFlow se construyó para ejecutarse en múltiples CPUs o GPUs e incluso en sistemas operativos móviles, lo que la hace extremadamente versátil y potente. Además, es compatible con varios lenguajes de programación, incluyendo Python, C++ y Java, lo que facilita su integración en diversos entornos y aplicaciones. Esta flexibilidad permite a los desarrolladores implementar modelos de aprendizaje automático y aprendizaje profundo en una amplia gama de plataformas, desde servidores de alto rendimiento hasta dispositivos móviles con recursos limitados.

### **2.3.1.11 TensorFlow Lite**

De acuerdo con la página oficial de TensorFlow, TFLite es una plataforma diseñada para implementar modelos de aprendizaje automático en dispositivos integrados, móviles o de IoT. Esta tecnología es crucial para ejecutar modelos de manera eficiente en dispositivos con recursos limitados, lo que es especialmente útil para aplicaciones que requieren inferencias en tiempo real o en entornos con conectividad limitada.

Baranwal et al. (2019) destacan varias características clave de TensorFlow Lite. Entre ellas se incluyen un intérprete optimizado y afinado específicamente para el dispositivo objetivo, APIs que soportan múltiples lenguajes de programación, y la disponibilidad de modelos pre-

entrenados y tutoriales que facilitan a los desarrolladores novatos desplegar modelos de aprendizaje automático en dispositivos de baja potencia.

## **2.3.2 Determinación de la Madurez del Plátano**

### **2.3.2.1 Plátano**

- **Nombre científico:** Musa x paradisiaca L.
- **Nombre común:** Platanera, plátano, bananero o banana
- **Familia:** Musaceae

El plátano o banano es un cultivo de origen indomalayo, su propagación va desde Indonesia hacia el sur y el este. Hoy en día, la cosecha de esta fruta es fundamental para países como Colombia y Ecuador, donde los subproductos vegetales se usan en la alimentación animal, además de constituir a los principales exportadores de este producto en América,

### **2.3.2.2 El plátano en Ecuador**

El plátano es un producto tropical de gran relevancia económica y social en América Central y Latinoamérica. Su consumo es fundamental para muchas personas en estas regiones, y su producción representa una importante fuente de empleo. Aunque se comercializa en menor escala como producto procesado, el plátano fresco es el principal producto exportado a Estados Unidos y Europa.

Los países con tradición exportadora de banano son los principales actores en el comercio mundial del plátano, aprovechando la infraestructura y conocimiento desarrollados para el cultivo y comercialización del banano. Ecuador es uno de los principales productores de plátano del mundo, representando el 32% del comercio mundial de este producto.

La producción de plátano en Ecuador es un importante motor económico, representando el 3.84% del PIB total y el 50% del PIB agrícola nacional. Además, alrededor de 400 000

personas trabajan directamente en la producción de plátano, lo que significa que alrededor del 12% de la población económicamente activa del país está empleada en este sector.

### 2.3.2.3 Parámetros de calidad para exportación

Según la empresa Montoya Vélez (2022), el plátano debe cumplir con las siguientes características o parámetros de calidad para poder ser exportado (Tabla 1) :

*Tabla 1 Parámetros de calidad del plátano*  
*Fuente: Ficha técnica plátano de exportación, <https://montoyavelez.com/wp-content/uploads/2022/11/Exportacion-1.pdf>.*

<b>Longitud</b>	<b>Mínimo 28 centímetros, máximo 36 centímetros medido por el borde externo de la fruta</b>
<b>Perímetro</b>	Desde 15 hasta 17 centímetros en el centro de la fruta
<b>Peso</b>	Desde 350 gramos en adelante
<b>Diámetro</b>	Desde 4 centímetros en adelante
<b>Textura</b>	Consistente (Dura, firme)
<b>Color</b>	Verde manzana
<b>Olor y sabor</b>	Característicos
<b>Características</b>	<ul style="list-style-type: none"> <li>- Libre de plagas y/o enfermedades</li> <li>- Libre de deformidades</li> <li>- Libre de maltrato en la cosecha</li> <li>- Apariencia fresca, saludable, limpia, sin grietas, heridas o cicatrices que afecten la pulpa.</li> </ul>

### 2.3.2.4 Métodos tradicionales para determinar la madurez

La madurez del plátano es un factor importante a la hora de cosechar y almacenar el producto. Los plátanos verdes son firmes y tienen un sabor amargo, mientras que los plátanos maduros son blandos y tienen un sabor dulce.

La madurez de esta fruta se puede determinar empíricamente con la aplicación de métodos tradicionales, sencillos y fáciles de aplicar, pero subjetivos. Estos métodos se basan en la observación de los cambios físicos que sufre la fruta a medida que madura, entre estos se incluyen el color, la textura y el sabor del plátano.

### 2.3.2.5 Métodos destructivos

Los métodos destructivos para determinar si la madurez del plátano cumple con los parámetros adecuados para su cosecha se basan en la medición de los parámetros físicos o químicos del fruto. Estos métodos son más precisos que los métodos tradicionales, pero requieren equipos especializados y concluyen con la destrucción y desperdicio de la fruta.

- **Medición de la concentración de azúcares.** – La concentración de azúcares se puede medir con un refractómetro, este es un instrumento que mide la refracción de la luz en una solución. En la figura 4 se muestra la herramienta de medición mencionada.



*Figura 4 Refractómetro portátil*

*Fuente: <https://maruplast.com/producto/refractometro-portatil/>*

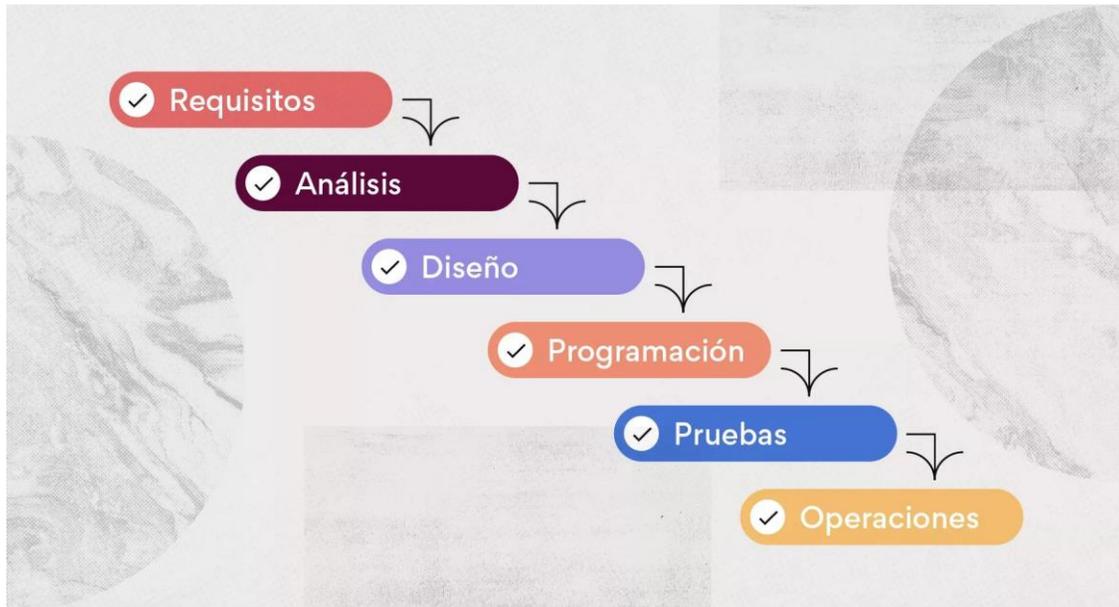
- **Medición del contenido del almidón.** – El contenido del almidón se puede medir con un analizador de almidón, si el contenido de almidón es alto quiere decir que el plátano es verde.

## 2.4 Metodología de desarrollo

### 2.4.1 Método de cascada

El Modelo en Cascada, propuesto por Winston Royce en 1970, es un enfoque sistemático y secuencial que se caracteriza por su disciplina y su base en análisis, diseño, pruebas y mantenimiento. Este modelo establece que al final de cada etapa se deben revisar los documentos

para asegurar el cumplimiento de los requerimientos antes de avanzar a la siguiente fase (Garcés y Egas, 2015). En la figura 5 se muestran las fases que conforman la metodología de cascada, las cuales se implementaron a lo largo del proyecto.



*Figura 5 Fases de la metodología Cascada*

*Fuente: <https://kylsant.com.ar/metodologias-de-gestion-de-proyectos-entendiendo-la-necesidad/>*

Es pionero en la guía del proceso de desarrollo de software dirigido por un plan, al introducir una planificación detallada de cada fase antes de comenzar a trabajar en ella. Esta metodología promueve una gestión estructurada y controlada del desarrollo de software, lo que resulta fundamental para asegurar la calidad y el éxito del proyecto.

#### **2.4.2 Funcionalidades del método de cascada**

La metodología en cascada es un enfoque de desarrollo de proyectos que se caracteriza por su secuencialidad y rigurosidad en la ejecución de las fases. Cada etapa debe ser completada antes de pasar a la siguiente, lo que brinda una estructura ordenada y controlada para el desarrollo de proyectos. (Hadida y Troilo, 2020)

Este método se divide en fases claramente definidas, cada una con sus propios objetivos y tareas específicas, lo que permite una planificación detallada y una clara comprensión de los hitos a alcanzar.

### 2.4.3 Etapas de la metodología en cascada

El modelo secuencial presentado por Royce en su artículo "Managing the development of large software systems: concepts and techniques" establece las fases o etapas a seguir para una correcta elaboración del proyecto:

- **Especificación de requisitos:** Se definen los requisitos del software.
- **Diseño:** Se crea el diseño del software.
- **Implementación:** Se escribe el código del software.
- **Integración:** Se integran las diferentes partes del software.
- **Pruebas:** Se verifica que el software cumpla con los requisitos.
- **Instalación:** Se instala el software en el entorno de producción.
- **Mantenimiento:** Se realizan cambios y correcciones al software.

### 2.4.4 Ventajas de la metodología en cascada

Según el autor Schwalbe (2022), la metodología en cascada es un enfoque estructurado que ofrece un marco sólido para el desarrollo de software. Es apropiada para proyectos con requisitos bien definidos y cambios infrecuentes.

- **Planificación y supervisión:** La metodología en cascada ofrece un proceso estructurado y organizado para la ejecución de proyectos, lo que simplifica la planificación y el control del proyecto.

- **Estimación de costos y plazos:** La metodología en cascada posibilita la realización de estimaciones precisas de los costos y plazos del proyecto, dado que los requisitos se definen y documentan en las etapas iniciales del proyecto.
- **Documentación:** La metodología en cascada genera una amplia documentación, lo que facilita la comunicación entre los miembros del equipo y la comprensión del proyecto por parte de los clientes.

#### 2.4.5 Desventajas de la metodología en cascada

De acuerdo con Schwalbe (2022), la metodología en cascada puede resultar poco ágil y costosa debido a la necesidad de una extensa documentación y pruebas.

- **Falta de adaptabilidad:** La metodología en cascada carece de flexibilidad y puede resultar difícil de ajustar a cambios en los requisitos.
- **Velocidad de desarrollo:** La metodología en cascada puede ser poco ágil, ya que es necesario completar cada fase antes de poder comenzar la siguiente.
- **Gastos:** La metodología en cascada puede resultar costosa debido a la necesidad de una extensa documentación y pruebas.

### 2.5 Conclusiones del marco teórico

Gracias a la búsqueda e investigación de libros y artículos científicos, se pudo proporcionar una visión general de los conceptos y fundamentos relacionados con el desarrollo de aplicaciones móviles, inteligencia artificial y la determinación de la madurez del plátano. Con ayuda de los antecedentes de investigaciones presentadas se encontró que el uso de técnicas de aprendizaje automático para determinar la madurez es un área de investigación activa, pues se demuestra que es posible desarrollar un sistema con probabilidades de precisión altas para clasificar los estados de madurez.

Se señala el uso de la metodología cascada para el desarrollo de la aplicación móvil, debido a que esta metodología tiene un enfoque estructurado y secuencial, lo cual la convierte en una metodología apropiada para proyectos con requisitos definidos, sin embargo, es importante tomar en cuenta las limitaciones que conlleva debido a que resulta poco ágil y costosa de aplicar.

## Capítulo III

### 3 Marco Investigativo

#### 3.1 Introducción

Para la obtención de datos que refuercen la problemática actual se utilizó diferentes tipos de investigación que permitieron analizar de manera efectiva las fuentes de información pertinentes. Los métodos de investigación desempeñaron un papel crucial en el análisis estadístico y en el plan de recolección de datos. A través de encuestas y entrevistas, se obtuvieron los resultados necesarios para comprender a fondo la problemática actual que enfrentan los productores de plátano barraganete. Estos enfoques de investigación nos permiten recopilar información detallada, identificar patrones y tendencias, y comprender las necesidades específicas de los productores.

#### 3.2 Tipos de investigación

##### 3.2.1 Bibliográfica

La investigación histórica es el estudio de los acontecimientos pasados, que utiliza fuentes primarias y secundarias para obtener información. El investigador debe examinar cuidadosamente las fuentes para determinar su confiabilidad, mediante la crítica interna y externa (Hernández, Fernández-Collado, y Baptista, 2014).

La investigación bibliográfica es un paso fundamental en cualquier estudio, ya que implica la revisión exhaustiva del material bibliográfico disponible sobre el tema de interés. En este trabajo se dedicó a la investigación y recolección de información bibliográfica para la adquisición de conocimientos sobre los temas tratados en el desarrollo de la aplicación.

### **3.2.2 Investigación de campo**

Como señalan los autores Hernández, Fernández-Collado y Baptista (2014), a través de la investigación de campo, se pueden identificar patrones de comportamiento, entender las motivaciones detrás de las acciones individuales y colectivas, y captar la complejidad de las relaciones humanas en su contexto natural. Este enfoque proporciona una perspectiva única y profunda sobre las interacciones humanas, las estructuras sociales y los fenómenos culturales.

Durante el proceso de investigación llevada a cabo en este proyecto, se visitaron fincas productoras de plátano con la finalidad de conocer la realidad del proceso de clasificación del producto en la producción de plátano barraganete.

### **3.3 Métodos de investigación**

#### **3.3.1 Método Analítico**

El método analítico es una herramienta fundamental en el estudio científico, ya que se centra en la lógica empírica y la experimentación directa. Este enfoque se utiliza ampliamente en las ciencias sociales y naturales, permitiendo descomponer el fenómeno estudiado en sus elementos constituyentes. Su efectividad se evidencia en campos de estudio inexplorados, así como en investigaciones descriptivas, al revelar vínculos fundamentales y características esenciales del objeto de estudio. (Carrión, 2018)

El método analítico permitió abordar el problema de manera estructurada y lógica, facilitando la identificación de soluciones y la evaluación de su impacto. Al descomponer el problema en partes más pequeñas, se pudo comprender mejor cada aspecto y desarrollar una solución efectiva y adaptada a las necesidades de los productores de plátano.

### 3.3.2 Método inductivo y deductivo

Según Castellanos (2018), en el procesamiento de adquisición de evidencias digitales, es posible aumentar la eficiencia mediante el uso de métodos deductivos e inductivos. Estos métodos permiten un enfoque sistemático para la recolección y análisis de evidencia, lo que resulta fundamental en la investigación forense digital.

El método inductivo se basó en las encuestas y entrevistas a los productores, lo que permitió inferir necesidades y tendencias específicas a partir de sus experiencias y desafíos concretos. El método deductivo, por otro lado, se utilizó para aplicar teorías generales sobre el comportamiento del consumidor y la adopción de tecnología en la agricultura, deduciendo así características deseables en la aplicación. La combinación de estos métodos permitió un enfoque integral que abarcó tanto la teoría como la práctica, asegurando que la aplicación desarrollada fuera relevante y efectiva para abordar el problema de la clasificación de plátanos en el contexto específico de los productores de El Carmen.

## 3.4 Fuentes de información de datos

### 3.4.1 Encuestas

El cuestionario o encuesta es una técnica de recolección de datos con la cual se recoge una gran cantidad de datos mediante preguntas sencillas y cortas que abarquen los puntos importantes de la investigación (Bernal, 2018).

Torres, et, al. (2019) destacan cuatro características fundamentales de una encuesta:

1. **Observación indirecta:** La encuesta se basa en las manifestaciones de los interesados y no de la observación directa de los hechos.
2. **Método estructurado:** La encuesta es un método diseñado específicamente para la investigación.

3. **Aplicación masiva:** Permite una aplicación a un gran número de interesados, utilizando sistemas de muestreo que puedan abarcar una población extensa.
4. **Acceso a aspectos subjetivos:** Facilita la investigación de aspectos subjetivos de los miembros de la sociedad.

Si bien existen varias formas de aplicar una encuesta, en esta ocasión se llevó a cabo una encuesta en línea, con ayuda de la aplicación Microsoft Forms, la cual fue aplicada a la población productora del cantón El Carmen, la información obtenida fue en base a las causas y efectos presentados en el primer capítulo.

### **3.4.2 Entrevista**

La entrevista es el instrumento más importante de la investigación, ya que, además de obtener respuestas subjetivas del encuestado sobre las preguntas del cuestionario, permite observar el contexto circundante y registrar las respuestas exactamente como las expresa el entrevistado. A diferencia de la encuesta, las preguntas deben ser presentadas de forma contundente, sin ambigüedades, de forma personal y no anónima. (Torres et al, 2019).

La entrevista para esta investigación se realizó de forma presencial a ingenieros agrónomos conocedores del proceso de producción del plátano, los cuales colaboraron abiertamente respondiendo todas las preguntas realizadas e interesándose en el proyecto actual.

## **3.5 Estrategia operacional para la recolección de datos**

### **3.5.1 Población**

La población objetivo de esta investigación son los productores de plátano barraganete en el cantón El Carmen. Según el Ministerio de Agricultura y Ganadería (MAG), existen aproximadamente 5.000 productores de esta fruta, los cuales se caracterizan por tener fincas de diferentes tamaños, desde pequeñas fincas familiares hasta grandes empresas agrícolas.

### 3.5.2 Muestra

La muestra se conforma seleccionando 100 productores de plátano barraganete del cantón El Carmen. La muestra se seleccionó mediante un muestreo aleatorio simple.

Los criterios de selección para la muestra son:

- Ser productor de plátano barraganete en el cantón El Carmen
- Tener una finca de al menos 1 hectárea.
- Estar dispuesto a participar en el estudio.

### 3.5.3 Análisis de las herramientas de recolección de datos a utilizar

La investigación se realizó con el fin de saber cuál es la situación actual de los productores de plátano barraganete frente a la producción y comercialización de este, del mismo modo dando a conocer la posibilidad de implementar una herramienta que sea de gran ayuda en el proceso de determinar si el producto cuenta con los estándares ideales para su cosecha, venta y exportación.

En este apartado, se analizan las herramientas utilizadas para la recolección de datos en la investigación. Para obtener la información de la población objetivo se utilizaron dos herramientas de recolección de datos:

- **Encuestas:** Se aplicó la encuesta a una muestra de 100 productores de plátano barraganete del cantón El Carmen. La encuesta se diseñó para obtener información sobre las prácticas de los productores y su percepción sobre la madurez del plátano barraganete.
- **Entrevista:** Se realizaron entrevistas a 2 ingenieros agrónomos conocedores del campo de producción. Las entrevistas se realizaron para obtener información más detallada sobre las prácticas de producción y sus opiniones sobre la determinación del estado de madurez del plátano barraganete.

### **3.5.3.1 Encuesta**

De acuerdo con Torres, et al (2019), podemos definir que las encuestas son una herramienta de recolección de datos que permite la obtención de información de una gran cantidad de personas de forma rápida y eficiente. Estas encuestas pueden ser estructuradas, semiestructuradas o no estructuradas. En esta investigación se hizo uso de encuestas estructuradas, son aquellas encuestas que cuentan con preguntas predefinidas y las respuestas se codifican en categorías.

- **Ventajas**

- Son fáciles de administrar y analizar
- Permiten obtener información de un numeroso grupo de personas
- Son económicas

- **Desventajas**

- La información que se puede obtener es limitada.
- No se puede obtener información sobre las emociones o motivaciones de los participantes

### **3.5.3.2 Entrevista**

Las entrevistas son una herramienta de recolección de datos que permite la obtención de información detallada de un reducido número de personas.

- **Ventajas**

- Permite obtener información detallada de los participantes
- Permiten obtener información sobre las emociones o motivaciones de los participantes

- **Desventajas**

- Son más costosas y lentas de realizar que las encuestas

### **3.5.4 Estructura de los instrumentos de recolección de datos aplicados**

#### **3.5.4.1 Formato de Encuesta**

**Título:** Prácticas y Desafíos en la Producción del Plátano

La siguiente encuesta tiene como finalidad recopilar información sobre la opinión y experiencias de trabajadores del sector agrícola con relación a la producción del plátano.

Las respuestas son anónimas y serán fundamentales para comprender y buscar mejorar las necesidades en este aspecto.

1. En una escala del 1 al 5, ¿Cuán familiarizado te sientes con los indicadores de madurez de los plátanos?
  - 1
  - 2
  - 3
  - 4
  - 5
2. ¿Con qué frecuencia utilizas tecnologías o herramientas para evaluar el estado de madurez del plátano?
  - Siempre
  - Frecuentemente
  - A veces
  - Raramente
  - Nunca

3. ¿Qué recursos consideras más necesarios para mejorar tu conocimiento sobre el estado de madurez de los plátanos?
  - Acceso a información
  - Capacitación específica
  - Asistencia técnica
4. ¿En qué medida crees que la logística afecta la oportunidad de realizar inspecciones de calidad en los plátanos?
  - No afecta
  - Afecta ligeramente
  - Afecta moderadamente
  - Afecta significativamente
  - Afecta considerablemente
5. ¿Cuál es la mayor barrera que se presenta al momento de realizar inspecciones oportunas en las plantaciones de plátano?
  - Recursos limitados
  - Coordinación logística
  - Falta de personal
6. ¿Qué sugerirías para mejorar la eficiencia en el proceso de inspección y evitar retrasos?
  - Mejorar la comunicación
  - Implementar tecnologías
  - Ajustar horarios de cosecha
7. En una escala del 1 al 5, ¿Cuán relevante crees que es el tema del tamaño de los plátanos con relación a su cosecha?

- 1
  - 2
  - 3
  - 4
  - 5
8. ¿Consideras que el tamaño de los frutos afecta la competitividad en el mercado?
- Si
  - No
9. ¿Qué tipo de apoyo consideras más valioso para mejorar la consistencia en el tamaño del plátano?
- Capacitación técnica
  - Acceso a herramientas de medición
  - Asesoría personalizada
  - Implementación de tecnología
10. ¿Estarías dispuesto a adoptar tecnologías avanzadas con inteligencia artificial para mejorar la inspección del plátano?
- Si
  - No
11. ¿Consideras que una aplicación móvil para la determinación de la madurez del plátano sería de utilidad en la producción y comercialización de plátanos?
- Si
  - No

### 3.5.4.2 Formato de Entrevista

Para realizar las entrevistas al personal experto en la producción del plátano barraganete se llevaron a cabo las siguientes preguntas:

1. ¿Cuál cree que es la importancia de determinar la madurez del plátano en el momento adecuado?
2. ¿Qué métodos conoce o utiliza para determinar la madurez de los plátanos?
3. ¿Qué tan confiables considera que son estos métodos?
4. ¿Con qué frecuencia se debe inspeccionar el plátano para determinar su madurez?
5. ¿Qué factores dificultan la inspección oportuna del plátano?
6. ¿Alguna vez ha tenido problemas con la inspección tardía del plátano?
7. ¿Considera el tamaño de los frutos al determinar la madurez del plátano?
8. ¿Ha tenido problemas con el tamaño de los frutos al momento de ser cosechados?
9. ¿Cuál cree que sería el impacto potencial de una aplicación con aprendizaje automático que pueda detectar el momento oportuno de la comercialización?

### 3.5.5 Plan de recolección de datos

A continuación, en la tabla 2 se presenta el plan de recolección de datos utilizado para recolectar la información necesaria de la investigación.

<b>Preguntas</b>	<b>Explicación</b>
<b>¿Qué tipo de información se necesita recopilar?</b>	Se necesita saber la percepción que tienen los productores frente a las prácticas y métodos utilizados para determinar la madurez del plátano.
<b>¿Quiénes pueden proporcionar la información?</b>	Productores de plátano de El Carmen y expertos en agronomía
<b>¿De qué modo se recolectó la información?</b>	La recolección se divide en encuestas y entrevistas, las encuestas se distribuyen a través de un formulario en línea, mientras que la entrevista se realizó en persona o por teléfono.

<b>¿Cuáles son las limitaciones de tiempo?</b>	La recolección de la información debe realizarse antes de la culminación del periodo 2023(2)
--	--

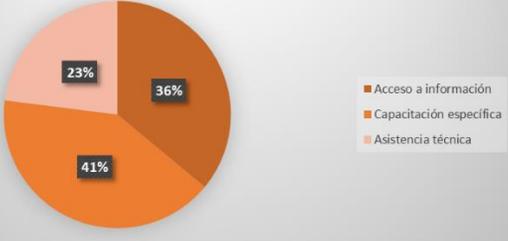
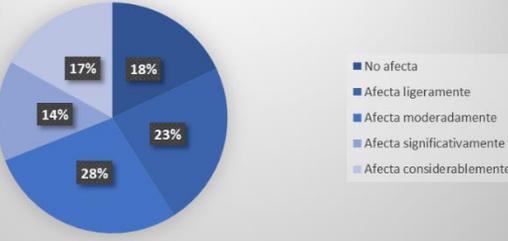
**Tabla 2 Plan de recolección de datos**  
*Fuente: Elaboración propia*

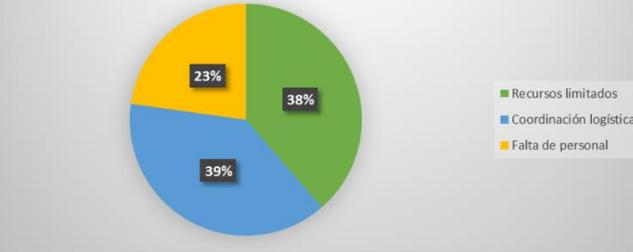
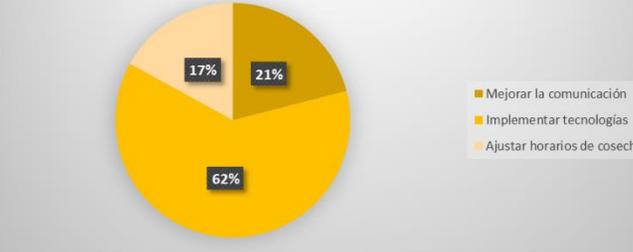
### 3.5.6 Análisis y presentación de resultados

#### 3.5.6.1 Encuestas

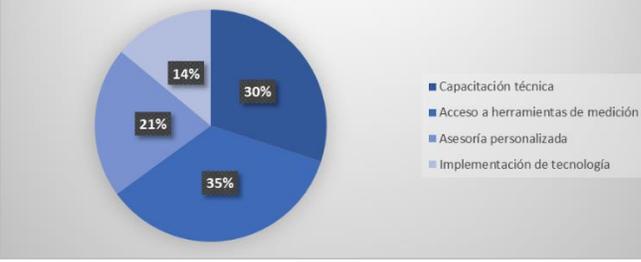
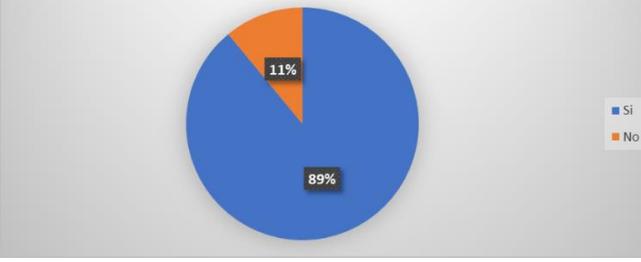
De acuerdo con las encuestas elaboradas a los productores de plátano barraganete del cantón El Carmen, se presentan los resultados tabulados y su interpretación en la tabla 3.

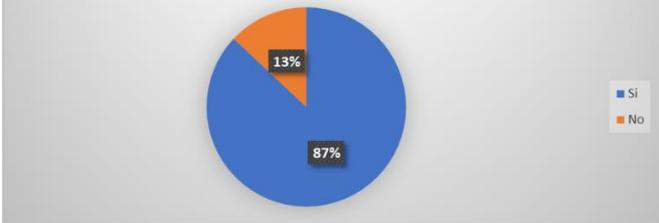
N°	Pregunta	Gráfico	Interpretación												
1	En una escala del 1 al 5, ¿Cuán familiarizado te sientes con los indicadores de madurez de los plátanos?	<p align="center">En una escala del 1 al 5, ¿Cuán familiarizado te sientes con los indicadores de madurez de los plátanos?</p> <table border="1"> <caption>Data for Familiarity with Maturity Indicators</caption> <thead> <tr> <th>Escala</th> <th>Conteo</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>8</td> </tr> <tr> <td>2</td> <td>14</td> </tr> <tr> <td>3</td> <td>33</td> </tr> <tr> <td>4</td> <td>13</td> </tr> <tr> <td>5</td> <td>32</td> </tr> </tbody> </table>	Escala	Conteo	1	8	2	14	3	33	4	13	5	32	Se pudo determinar que gran parte de los productores tienen cierto grado de conocimiento relacionado a los indicadores de madurez del plátano.
Escala	Conteo														
1	8														
2	14														
3	33														
4	13														
5	32														
2	¿Con qué frecuencia utilizas tecnologías o herramientas para evaluar el estado de madurez del plátano?	<p align="center">2. ¿Con qué frecuencia utilizas tecnologías o herramientas para evaluar el estado de madurez del plátano?</p> <table border="1"> <caption>Data for Frequency of Using Tools</caption> <thead> <tr> <th>Frecuencia</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>Siempre</td> <td>4%</td> </tr> <tr> <td>Frecuentemente</td> <td>23%</td> </tr> <tr> <td>A veces</td> <td>14%</td> </tr> <tr> <td>Raramente</td> <td>31%</td> </tr> <tr> <td>Nunca</td> <td>28%</td> </tr> </tbody> </table>	Frecuencia	Porcentaje	Siempre	4%	Frecuentemente	23%	A veces	14%	Raramente	31%	Nunca	28%	Las respuestas muestran que la mayoría de los encuestados raramente han utilizado herramientas que les permita precisar el nivel de madurez óptimo para la cosecha del plátano.
Frecuencia	Porcentaje														
Siempre	4%														
Frecuentemente	23%														
A veces	14%														
Raramente	31%														
Nunca	28%														

3	<p>¿Qué recursos consideras más necesarios para mejorar tu conocimiento sobre el estado de madurez de los plátanos?</p>	<p><b>3. ¿Qué recursos consideras más necesarios para mejorar tu conocimiento sobre el estado de madurez de los plátanos?</b></p>  <table border="1"> <thead> <tr> <th>Recurso</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>Acceso a información</td> <td>36%</td> </tr> <tr> <td>Capacitación específica</td> <td>41%</td> </tr> <tr> <td>Asistencia técnica</td> <td>23%</td> </tr> </tbody> </table>	Recurso	Porcentaje	Acceso a información	36%	Capacitación específica	41%	Asistencia técnica	23%	<p>Estos resultados resaltan la relevancia de enfocar los esfuerzos en brindar capacitación especializada y acceso a información relevante para los productores de plátanos, lo que a su vez podría tener un impacto significativo en la mejora de la calidad y la productividad en la industria.</p>				
Recurso	Porcentaje														
Acceso a información	36%														
Capacitación específica	41%														
Asistencia técnica	23%														
4	<p>¿En qué medida crees que la logística afecta la oportunidad de realizar inspecciones de calidad en los plátanos?</p>	<p><b>4. ¿En qué medida crees que la logística afecta la oportunidad de realizar inspecciones de calidad en los plátanos?</b></p>  <table border="1"> <thead> <tr> <th>Medida</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>No afecta</td> <td>18%</td> </tr> <tr> <td>Afecta ligeramente</td> <td>23%</td> </tr> <tr> <td>Afecta moderadamente</td> <td>28%</td> </tr> <tr> <td>Afecta significativamente</td> <td>14%</td> </tr> <tr> <td>Afecta considerablemente</td> <td>17%</td> </tr> </tbody> </table>	Medida	Porcentaje	No afecta	18%	Afecta ligeramente	23%	Afecta moderadamente	28%	Afecta significativamente	14%	Afecta considerablemente	17%	<p>Estos hallazgos sugieren que existe una variedad de opiniones en cuanto al impacto de la logística en las inspecciones de calidad de los plátanos, lo que indica la importancia de evaluar y mejorar continuamente los procesos logísticos para garantizar la eficiencia en la cadena de suministro de este producto.</p>
Medida	Porcentaje														
No afecta	18%														
Afecta ligeramente	23%														
Afecta moderadamente	28%														
Afecta significativamente	14%														
Afecta considerablemente	17%														

5	<p>¿Cuál es la mayor barrera que se presenta al momento de realizar inspecciones oportunas en las plantaciones de plátano?</p>	<p><b>5.¿Cuál es la mayor barrera que se presenta al momento de realizar inspecciones oportunas en las plantaciones de plátano?</b></p>  <table border="1"> <thead> <tr> <th>Barrera</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>Recursos limitados</td> <td>38%</td> </tr> <tr> <td>Coordinación logística</td> <td>39%</td> </tr> <tr> <td>Falta de personal</td> <td>23%</td> </tr> </tbody> </table>	Barrera	Porcentaje	Recursos limitados	38%	Coordinación logística	39%	Falta de personal	23%	<p>Estos resultados revelan que tanto la disponibilidad limitada de recursos como la coordinación logística son identificados como los principales obstáculos para llevar a cabo inspecciones oportunas en las plantaciones de plátano, seguidos por la escasez de personal. Estos factores han sido identificados como desafíos significativos que afectan la capacidad de realizar inspecciones efectivas en el sector.</p>
Barrera	Porcentaje										
Recursos limitados	38%										
Coordinación logística	39%										
Falta de personal	23%										
6	<p>¿Qué sugerirías para mejorar la eficiencia en el proceso de inspección y evitar retrasos?</p>	<p><b>6.¿Qué sugerirías para mejorar la eficiencia en el proceso de inspección y evitar retrasos?</b></p>  <table border="1"> <thead> <tr> <th>Sugerencia</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>Implementar tecnologías</td> <td>62%</td> </tr> <tr> <td>Mejorar la comunicación</td> <td>21%</td> </tr> <tr> <td>Ajustar horarios de cosecha</td> <td>17%</td> </tr> </tbody> </table>	Sugerencia	Porcentaje	Implementar tecnologías	62%	Mejorar la comunicación	21%	Ajustar horarios de cosecha	17%	<p>Los resultados muestran que la implementación de tecnologías es la alternativa más respaldada para mejorar la eficiencia en el proceso de inspección y prevenir retrasos. Esta estrategia es seguida de cerca por la mejora en la comunicación entre los distintos actores involucrados en el</p>
Sugerencia	Porcentaje										
Implementar tecnologías	62%										
Mejorar la comunicación	21%										
Ajustar horarios de cosecha	17%										

			proceso y el ajuste de la clasificación.												
7	En una escala del 1 al 5, ¿Cuán relevante crees que es el tema del tamaño de los plátanos en relación a su cosecha?	<p>7. En una escala del 1 al 5, ¿Cuán relevante crees que es el tema del tamaño de los plátanos en relación a su cosecha?</p> <table border="1"> <thead> <tr> <th>Relevancia (Escala)</th> <th>Número de Respuestas</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>1</td> </tr> <tr> <td>2</td> <td>12</td> </tr> <tr> <td>3</td> <td>17</td> </tr> <tr> <td>4</td> <td>31</td> </tr> <tr> <td>5</td> <td>39</td> </tr> </tbody> </table>	Relevancia (Escala)	Número de Respuestas	1	1	2	12	3	17	4	31	5	39	<p>Actualmente existe un grado considerable de conocimiento sobre los indicadores de madurez, lo cual es positivo en términos de la capacidad para evaluar la calidad de los plátanos. Sin embargo, siempre es importante seguir aprendiendo y actualizando los conocimientos en este campo, ya que la industria de los plátanos está en constante evolución.</p>
Relevancia (Escala)	Número de Respuestas														
1	1														
2	12														
3	17														
4	31														
5	39														
8	¿Consideras que el tamaño de los frutos afecta la competitividad en el mercado?	<p>8. ¿Consideras que el tamaño de los frutos afecta la competitividad en el mercado?</p> <table border="1"> <thead> <tr> <th>Respuesta</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>Si</td> <td>92%</td> </tr> <tr> <td>No</td> <td>8%</td> </tr> </tbody> </table>	Respuesta	Porcentaje	Si	92%	No	8%	<p>Aquí se muestra la relevancia que se le otorga al tamaño de los frutos en la percepción del consumidor y en la estrategia de comercialización. Es evidente que existe un consenso abrumador sobre la influencia que el tamaño de los frutos tiene en la competitividad del mercado.</p>						
Respuesta	Porcentaje														
Si	92%														
No	8%														

9	<p>¿Qué tipo de apoyo consideras más valioso para mejorar la consistencia en el tamaño del plátano?</p>	<p>9. ¿Que tipo de apoyo consideras más valioso para mejorar la consistencia en el tamaño del plátano?</p>  <table border="1"> <thead> <tr> <th>Tipo de apoyo</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>Capacitación técnica</td> <td>30%</td> </tr> <tr> <td>Acceso a herramientas de medición</td> <td>35%</td> </tr> <tr> <td>Asesoría personalizada</td> <td>21%</td> </tr> <tr> <td>Implementación de tecnología</td> <td>14%</td> </tr> </tbody> </table>	Tipo de apoyo	Porcentaje	Capacitación técnica	30%	Acceso a herramientas de medición	35%	Asesoría personalizada	21%	Implementación de tecnología	14%	<p>Los resultados de esta pregunta muestran lo clave que es proporcionar a los productores de plátano las herramientas y conocimientos necesarios para garantizar la uniformidad en el tamaño de sus productos, lo que a su vez puede tener un impacto significativo en la eficiencia y competitividad del mercado.</p>
Tipo de apoyo	Porcentaje												
Capacitación técnica	30%												
Acceso a herramientas de medición	35%												
Asesoría personalizada	21%												
Implementación de tecnología	14%												
10	<p>¿Estarías dispuesto a adoptar tecnologías avanzadas con inteligencia artificial para mejorar la inspección del plátano?</p>	<p>10. ¿Estarías dispuesto a adoptar tecnologías avanzadas con inteligencia artificial para mejorar la inspección del plátano?</p>  <table border="1"> <thead> <tr> <th>Respuesta</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>Si</td> <td>89%</td> </tr> <tr> <td>No</td> <td>11%</td> </tr> </tbody> </table>	Respuesta	Porcentaje	Si	89%	No	11%	<p>A través de las respuestas queda claro que se debe continuar promoviendo la educación y concienciación sobre las ventajas y oportunidades que ofrece la inteligencia artificial en el ámbito de la inspección de productos agrícolas, como el plátano, para así impulsar su adopción y contribuir a la mejora de la calidad y seguridad alimentaria.</p>				
Respuesta	Porcentaje												
Si	89%												
No	11%												

11	¿Consideras que una aplicación móvil para la determinación de la madurez del plátano sería de utilidad en la producción y comercialización de plátanos?	<p>11. ¿Consideras que una aplicación móvil para la determinación de la madurez del plátano sería de utilidad en la producción y comercialización de plátanos?</p>  <p>A pie chart with a blue segment representing 'Si' at 87% and an orange segment representing 'No' at 13%. A legend to the right shows a blue square for 'Si' and an orange square for 'No'.</p>	Los resultados reflejan un amplio respaldo hacia la implementación de tecnologías móviles en este campo, lo que sugiere un interés significativo en la búsqueda de soluciones innovadoras para mejorar la eficiencia y calidad en la producción y comercialización de plátanos.
----	---	---	---

*Tabla 3 Tabulación de encuestas  
Fuente: Elaboración propia*

### 3.5.6.2 Entrevista

Una vez realizadas las entrevistas necesarias, se realizó el análisis de las respuestas otorgadas por los expertos en el área, como se muestra en la Tabla 4.

N°	Pregunta	Respuesta	Interpretación
1	¿Cuál cree que es la importancia de determinar la madurez del plátano en el momento adecuado?	<p>Es muy importante porque la calidad del producto es óptima cuando ha alcanzado su etapa final de maduración, tanto para el consumo como para la satisfacción del consumidor.</p> <p>La importancia de determinar la madurez en el momento adecuado es para llevar un mejor producto al mercado, para ofrecer al cliente o consumidor final un producto de calidad.</p>	En esta pregunta ambos ingenieros están de acuerdo en la importancia de evaluar la madurez del plátano en el momento oportuno para asegurar la excelencia del producto final y cumplir con las expectativas del consumidor.

2	¿Qué métodos conoce o utiliza para determinar la madurez de los plátanos?	<p>Generalmente para saber que el plátano está en su etapa final, empíricamente siempre se ha determinado por la parte final del toro, cuando ya se empieza a desgajar y a caer, ya sabemos que el verde está en su máximo esplendor o cuando se empieza a partir.</p>	<p>Se evidencia que los ingenieros suelen emplear el método empírico de observación visual para determinar la madurez de los plátanos por lo cual este enfoque se centra en el desgajamiento y la apariencia de la parte final del fruto, lo que proporciona indicadores clave sobre su estado de maduración.</p>
		<p>Principalmente, el método visual que es el más común, aunque existen otros métodos en donde se utilizan herramientas para medir la madurez.</p>	
3	¿Qué tan confiables considera que son estos métodos?	<p>Estos métodos son confiables hasta cierto punto, pero no siempre son precisos, todo depende de la experiencia del productor.</p>	<p>Los ingenieros mencionan que la fiabilidad de los métodos está condicionada hasta cierto punto por la experiencia del productor, en este sentido, se observa que el método visual es ampliamente utilizado por productores con recursos limitados, mientras que las herramientas son preferidas por empresas y empacadoras.</p>
		<p>Los métodos utilizados, en especial el visual, es un método empírico utilizado por los productores de escasos recursos, mientras que las herramientas son utilizadas por las empresas o empacadoras, incluso haciendas.</p>	
4	¿Con qué frecuencia se debe inspeccionar el plátano para determinar su madurez?	<p>Depende de la variedad del plátano, pero es recomendable revisarlos al menos una vez al día durante la temporada de cosecha.</p>	<p>Los resultados de la entrevista demuestran la frecuencia de inspección para evaluar la madurez de esta fruta varía dependiendo de la variedad y la temporada de cosecha.</p>
		<p>La frecuencia de inspección ya lo determinaría el productor, aunque también depende de la variedad del plátano, pues hay unas que maduran más rápido y también depende del tipo de</p>	

		mercado, ya sea nacional o internacional.	
5	¿Qué factores dificultan la inspección oportuna del plátano?	<p>Un gran problema se presentaría cuando hay una gran extensión de cultivo, pues puede llevar mucho tiempo realizar la inspección y más cuando no hay suficiente mano de obra.</p> <p>No creo que hay algún factor en sí que haya un factor que dificulte la inspección del plátano, de pronto en el método visual si hay un día lluvioso.</p>	Los ingenieros agrónomos destacan que la expansión de las áreas de cultivo de plátano y la disponibilidad limitada de mano de obra pueden representar un desafío para llevar a cabo inspecciones oportunas en las plantaciones, especialmente en aquellas de gran extensión, también señalan que las condiciones climáticas adversas, como los días lluviosos, pueden dificultar la realización de inspecciones visuales efectivas
6	¿Alguna vez ha tenido problemas con la inspección tardía del plátano?	<p>Sí, ya que se puede encontrar con cosecha de plátanos demasiado maduros o verdes.</p> <p>Claro, a veces por exceso de confianza, ya que por ejemplo si se dice que para la siguiente semana tengo tantos racimos maduros, y resulta que cuando se va a ver ya están pasados del grado en el que se deberían cortar. Ese sería uno de los problemas que ya para un mercado internacional debe ser un producto de calidad, ya que si me demoro un poco en la inspección ya no será para mercado internacional y voy a perder dinero.</p>	Los ingenieros agrícolas coinciden en que la inspección tardía del plátano barraganete puede causar problemas, y que los plátanos demasiado maduros son más propensos a sufrir daños durante el transporte y la manipulación.

7	¿Considera el tamaño de los frutos al determinar la madurez del plátano?	Sí, se debe considerar el tamaño, pues los plátanos más grandes generalmente tardan más en madurar.	Los ingenieros agrícolas coinciden en que el tamaño es un factor importante para considerar puesto que es la principal característica que se visualiza al momento de cosechar el fruto.
		Claro, ese es uno de los puntos principales, ya que es el valor más determinante, por eso algunas empresas o haciendas utilizan herramientas para saber esto.	
8	¿Ha tenido problemas con el tamaño de los frutos al momento de ser cosechados?	Normalmente cosechar plátanos de diferentes tamaños al mismo tiempo puede dificultar la determinación del punto óptimo de madurez de todos los frutos.	Los ingenieros agrícolas coinciden en que el tamaño de los frutos puede ser un problema para determinar la madurez óptima, puesto que los frutos de diferentes tamaños maduran a diferentes ritmos, lo que puede dificultar la cosecha de todos los frutos en el momento adecuado.
		Normalmente no, pero por ejemplo con el plátano hartón que es un poco grande y un poco pesado, para el mercado internacional no serviría puesto a que no es tan apetecible ya que se prefiere un tamaño más estándar.	
9	¿Cuál cree que sería el impacto potencial de una aplicación con aprendizaje automático que pueda detectar el momento oportuno de comercialización?	Sería maravilloso puesto que no hay una aplicación actualmente que determine cuando ya esté el plátano listo para comercializar y sería un gran aporte para el sector agrícola.	Los ingenieros agrícolas consideran que la aplicación será de gran utilidad para los agricultores que exportan sus productos puesto que los compradores internacionales suelen exigir una calidad muy alta en los plátanos, y una aplicación que pueda garantizar dicha calidad sería una ventaja para los agricultores.
		Como ya sería un método más profesional y automático, ya no habría esas pérdidas como en el método visual en las que hay situaciones en las que el ojo humano falla, en cambio con un mecanismo automatizado se va a ser más exactos y tendremos un producto de mayor calidad.	

**Tabla 4 Tabulación de entrevistas**  
**Fuente: Elaboración propia**

### **3.5.7 Presentación y descripción de los resultados obtenidos**

En las primeras tres preguntas tanto de la encuesta como de la entrevista realizadas se enfatizó la importancia de determinar la madurez del plátano para asegurar la calidad de el mismo, así como los métodos y herramientas que se utilizan para realizar el proceso de clasificación, gracias a esto se puede interpretar que si bien existe un conocimiento generalizado en relación a los indicadores de madurez del plátano, existe una baja adopción de herramientas para evaluar la madurez del plátano, dependiendo así solo del método visual que en ocasiones puede fallar, más aún si no se cuenta con la capacitación, experiencia y conocimiento empírico necesario para esta tarea.

En las preguntas 4, 5 y 6 relacionadas a las inspecciones que se deben realizar a los frutos, tanto los productores como los ingenieros expertos coinciden en que la logística puede ser un factor importante que afecta la eficiencia de las inspecciones, especialmente en grandes plantaciones de plátano, pues como ha sido mencionado en las respuestas recibidas, se pueden presentar problemas relacionados a la falta de coordinación, recursos e incluso personal para llevar a cabo una revisión de calidad, además de las condiciones climáticas que retrasarían el proceso realizado empíricamente.

Como otro punto importante se menciona el tamaño de los frutos cosechados en las preguntas 7, 8 y 9 de la encuesta y las preguntas 7 y 8 entrevista, pues como supieron mencionar los involucrados, el tamaño del plátano es un factor crucial para la calidad del producto y la competitividad en el mercado, por ello los productores consideran la posibilidad de aplicar herramientas que puedan ayudar a determinar bien este factor, como lo menciona uno de los entrevistados que es un método utilizado por empresas o haciendas donde el volumen de las plantaciones es mayor.

Para finalizar, en las preguntas 10 y 11 de la encuesta y la pregunta 9 de la entrevista se les planteó el uso de tecnología para facilitar estos procesos anteriormente mencionados, y se pudo observar un interés considerable tanto de parte de los productores como de los ingenieros, pues consideran que podría ser de gran utilidad para los agricultores al momento de realizar las inspecciones y así entregar productos de calidad.

### **3.5.8 Informe final del análisis de los datos**

En conclusión, los resultados de la encuesta y la entrevista realizada a productores y expertos en plátanos de Ecuador destacan la importancia crucial de la madurez del plátano para garantizar la calidad del producto. A pesar de esto, la mayoría de los productores aún confían en el método visual para determinar la madurez, el cual puede resultar impreciso y demandante en términos de tiempo y esfuerzo.

Además, se identificó que la logística juega un papel fundamental en la eficiencia de las inspecciones de madurez, sobre todo en plantaciones de gran escala. La falta de coordinación, recursos e incluso de personal puede impactar negativamente en el proceso de inspección.

## Capítulo IV

### 4 Marco Propositivo

#### 4.1 Introducción

En este apartado, se realizó un seguimiento detallado del sistema propuesto, tomando en cuenta los recursos humanos, tecnológicos y económicos necesarios para su desarrollo.

Se empleó la metodología en cascada, la cual permitió profundizar los requerimientos funcionales y no funcionales de la aplicación móvil con aprendizaje automático. Esto permite identificar las etapas de acción necesarias, así como los roles involucrados, los diagramas de casos de uso. Todo este proceso fue fundamental para el desarrollo de la interfaz de usuario de la aplicación.

Durante la etapa de desarrollo, se procedió a validar los datos a través de la codificación de los procesos requeridos, haciendo uso de las herramientas y tecnologías seleccionadas, como TensorFlow, Android Studio con Kotlin, datasets de imágenes y las 3 arquitecturas de redes neuronales convolucionales evaluadas. El objetivo es verificar el correcto funcionamiento de la aplicación mediante pruebas de simulación.

Finalmente, se hace una comprobación para asegurar que la implementación cumple con los requerimientos funcionales y no funcionales, logrando así un equilibrio en los resultados y mejorar la interacción del usuario final con la aplicación móvil. De esta manera, se busca generar un impacto positivo en la mejora de la producción de plátano barraganete en el cantón El Carmen.

## 4.2 Descripción de la propuesta

Con la metodología en cascada se busca tener una visión general del proyecto para tener una mejor planificación y uso eficiente de los recursos, hay que recalcar que este proyecto es de tipo aplicativo, puesto que se implementó en las zonas de trabajo de productores de plátano que comercializan el producto a la empacadora “Divino niño”.

Las actividades para la elaboración del proyecto son las siguientes:

- Recolectar una muestra representativa de imágenes de plátanos en distintas etapas de madurez.
- Preprocesar y etiquetar adecuadamente las imágenes para facilitar el entrenamiento del modelo de aprendizaje.
- Seleccionar una arquitectura adecuada de aprendizaje profundo, en base a redes neuronales convolucionales (CNN), para la clasificación de la madurez del plátano barraganete.
- Entrenar el modelo de aprendizaje utilizando el conjunto de datos previamente preparado y ajustar los hiperparámetros para obtener una alta precisión.
- Desarrollar una interfaz de usuario amigable y accesible para la aplicación móvil de detección de madurez del plátano barraganete.
- Integrar el modelo entrenado a la aplicación móvil para realizar las predicciones en tiempo real.

## 4.3 Determinación de recursos

Para desarrollar el proyecto de manera eficiente se designaron los recursos a utilizar dividiéndolos en tres categorías: Recursos humanos, tecnológicos y económicos, así planificaremos de mejor manera el alcance de la aplicación.

### 4.3.1 Humanos

Los recursos humanos se refieren a las personas que están directamente involucradas en el desarrollo del sistema, ya sea con la mano de obra o con la transferencia de conocimientos. En la Tabla 5 se presentan los recursos humanos que fueron necesarios para el progreso del proyecto.

<b>Personal</b>	<b>Función</b>
<b>Programador</b>	Para la elaboración de la aplicación móvil.
<b>Científico de datos</b>	Para la creación del dataset y entrenamiento del modelo de machine learning.
<b>Productor de Plátano</b>	Para brindar información del proceso de clasificación del plátano.

*Tabla 5 Recursos Humanos  
Fuente: Elaboración propia*

### 4.3.2 Tecnológicos

Los recursos tecnológicos son cruciales en este proyecto, y es importante saber cuáles son las capacidades de las herramientas que se utilizarán. Por lo tanto, en la Tabla 6 y Tabla 7, se muestran los recursos tecnológicos utilizados.

<b>Hardware</b>	<b>Especificaciones</b>
<b>Laptop (Programador)</b>	<ul style="list-style-type: none"><li>• Windows 10 Pro 22H2</li><li>• RAM 4GB.</li><li>• AMD A4-9125 RADEON R3</li><li>• 220GB de SDD de estado Sólido.</li></ul>
<b>Laptop (Científico de datos)</b>	<ul style="list-style-type: none"><li>• Windows 11 Pro 23H2</li><li>• RAM 16GB.</li><li>• Intel I3 11145G 11va Generación.</li><li>• 250GB de SDD de estado Sólido.</li></ul>
<b>Celular (Dataset)</b>	<ul style="list-style-type: none"><li>• Snapdragon 665</li><li>• 4GB RAM</li><li>• 48 MP.</li></ul>

*Tabla 6 Características de Recursos Tecnológicos (Hardware)  
Fuente: Elaboración propia*

Software	Especificaciones
IDE	<ul style="list-style-type: none"> <li>• Android Studio versión 2021.2.0.0</li> </ul>
Modelo ML	<ul style="list-style-type: none"> <li>• TensorFlow 2.16</li> <li>• Mobilenet v2</li> </ul>

*Tabla 7 Características de Recursos Tecnológicos (Software)*

*Fuente: Elaboración propia*

### 4.3.3 Económicos

En la tabla 8 se toman en cuenta los recursos económicos que fueron necesarios para el proyecto.

Cantidad	Concepto	Características	C\U	Subtotal
2	Laptops	Para el desarrollo del sistema	\$400 \$350	\$750
768	Horas de trabajo	Tiempo empleado para la elaboración del sistema	\$5	\$3.840
1	Celular	Para la elaboración del Set de datos.	\$150	\$150

*Tabla 8 Recursos Económicos*

*Fuente: Elaboración propia*

## 4.4 Desarrollo

### 4.4.1 Fase I: Análisis de requerimientos.

#### 4.4.1.1 Requerimientos funcionales.

- La aplicación debe permitir a los usuarios cargar imágenes de plátanos desde la galería del dispositivo móvil.
- La aplicación debe permitir a los usuarios capturar imágenes de plátanos en tiempo real utilizando la cámara del dispositivo.
- La aplicación debe clasificar cada plátano como "apto para exportar" o "rechazado" y mostrar el resultado al usuario.

#### 4.4.1.2 Requerimientos no funcionales.

- La aplicación debe tener un tiempo de respuesta de clasificación de 5 segundos o menos.
- La aplicación debe funcionar de manera fluida y sin interrupciones en dispositivos móviles con al menos 2 GB de RAM.
- La aplicación debe ser compatible con los últimos sistemas operativos Android.
- La aplicación debe consumir un máximo de 40 MB de espacio en el dispositivo.
- La aplicación debe tener una interfaz de usuario intuitiva y de fácil navegación.
- La aplicación debe tener un diseño responsive y adaptarse a diferentes tamaños de pantalla.
- La aplicación debe tener un bajo consumo de batería durante su uso.

#### 4.4.1.3 Requerimientos de Hardware y Software

En la tabla 9 se indican qué requerimientos mínimos necesita la aplicación para poder ejecutarse.

Sistema	Requerimientos mínimos de hardware	Requerimientos mínimos de software
Aplicación móvil	<ul style="list-style-type: none"><li>• Dispositivo móvil inteligente(celular)</li></ul>	<ul style="list-style-type: none"><li>• Android 7.0 o superior</li><li>• 50 Mb de almacenamiento disponible.</li></ul>

*Tabla 9 Requerimientos de Hardware y Software*

*Fuente: Elaboración propia*

#### 4.4.1.4 Tipos y roles de usuario

Para el uso de la aplicación móvil se describe el rol del usuario y a que funciones del programa tiene acceso, estos detalles se muestran en la tabla 10.

Usuario	Descripción
Productor	Tiene todo el acceso posible de la aplicación a sus dos únicas opciones. <ul style="list-style-type: none"> <li>• Acceder a la detección en tiempo real.</li> <li>• Acceder a la clasificación desde las imágenes del dispositivo móvil.</li> </ul>

*Tabla 10 Tipos y Roles de Usuario*

*Fuente: Elaboración propia*

**4.4.2 Fase II Diseño**

**4.4.2.1 Interfaz de la aplicación móvil**



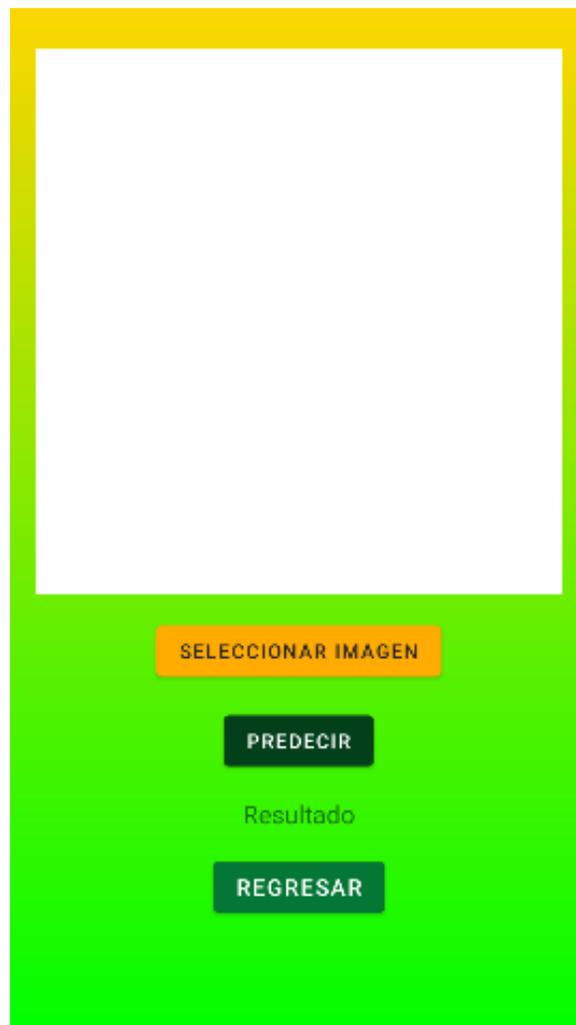
*Figura 6 Interfaz de Inicio de "Plátano App"*

*Fuente: Elaboración propia*

Como se muestra en la figura 6, la pantalla de inicio de “Plátano App” está diseñada para proporcionar una experiencia accesible y sencilla para el usuario. Cuenta con 2 botones con los

cuales el usuario puede interactuar para ingresar a los 2 modos de clasificación del estado del plátano: Detección por imágenes y Detección en tiempo real. Estos botones utilizan colores vivos que contrastan con el fondo, asegurando que los usuarios puedan identificar fácilmente las opciones disponibles. Además, contiene iconos debajo de cada botón con el fin de proporcionar una referencia visual sobre la funcionalidad de cada botón.

#### 4.4.2.2 Interfaz de Detección por Imágenes

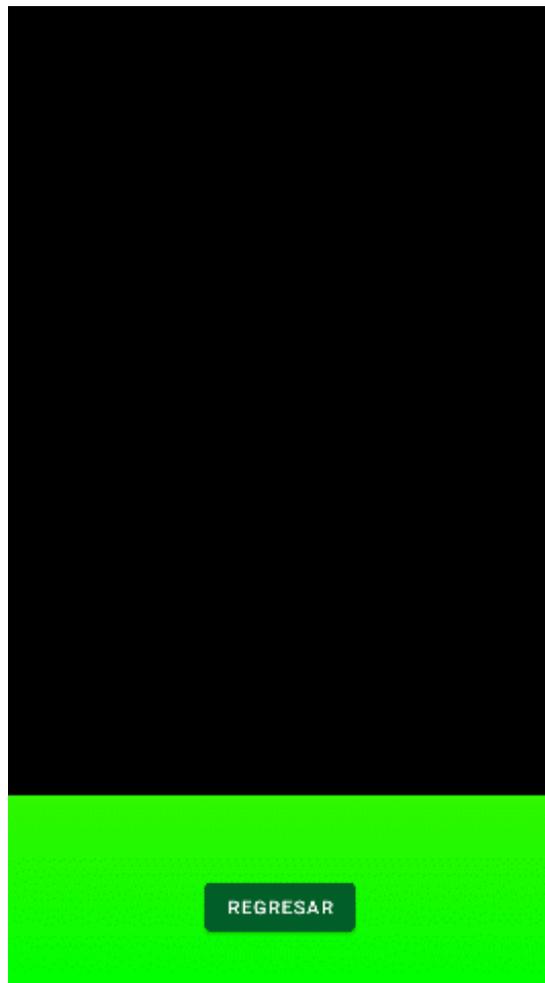


*Figura 7 Interfaz de Detección por Imágenes  
Fuente: Elaboración propia*

En la interfaz mostrada en la figura 7, el usuario puede seleccionar una imagen de su dispositivo para realizar la detección. Cuenta con un contenedor con fondo blanco el cual es el

área destinada a mostrar la imagen seleccionada por el usuario. También se incluyen 3 botones con distintas funciones: El botón “Seleccionar Imagen” el cual permite abrir la galería y seleccionar una imagen. El botón “Predecir” sirve para que, una vez seleccionada la imagen, la aplicación procese y analice la imagen, mostrando el resultado en el texto situado bajo el botón. Y el botón “Regresar” que permite volver a la pantalla principal.

#### **4.4.2.3 Interfaz Detección en Tiempo Real**



*Figura 8 Interfaz de Detección en Tiempo Real*

*Fuente: Elaboración propia*

En la interfaz mostrada en la figura 8, el usuario puede interactuar con la cámara del dispositivo y obtener resultados en tiempo real. El área principal de la pantalla muestra una vista

previa en tiempo real de la cámara del dispositivo. Esta vista ocupa la mayor parte del espacio de la pantalla permitiendo al usuario ver lo que se está capturando. Cada imagen capturada por la cámara será procesada y analizada por la aplicación y arrojando los resultados debajo de la vista de la cámara, este texto va cambiando, dependiendo de los resultados del procesamiento de lo que se esté capturando en pantalla. Además, se incluye el botón “Regresar” para volver a la pantalla principal.

#### **4.4.3 Fase III: Desarrollo del sistema.**

##### **4.4.3.1 Herramientas de desarrollo**

Para la elaboración del sistema móvil con aprendizaje automático se emplearon diversas herramientas con diferentes finalidades, las cuales son:

- **Google Colab.**

Se utilizó este servicio para configurar y entrenar una arquitectura de machine learning aplicando transfer learning del modelo Mobilenet V2. Este modelo se eligió debido a su alta precisión y bajo consumo de recursos móviles una vez implementado en el celular. El uso de transfer learning nos permitió aprovechar el conocimiento previamente adquirido por Mobilenet V2 en tareas similares, lo que aceleró significativamente el proceso de entrenamiento y mejoró la precisión de nuestro modelo. Esta estrategia permitió obtener resultados satisfactorios en un tiempo reducido, lo que resulta fundamental en entornos donde se requiere eficiencia y escalabilidad.

- **Teachable Machine**

Esta plataforma es altamente intuitiva y fácil de usar, lo que proporciona una precisión extraordinaria al clasificar imágenes. Esto permite obtener una referencia sólida para comparar las gráficas de precisión con la arquitectura de Mobilenet v2. Es importante destacar que

Teachable Machine hace un uso extensivo del aprendizaje por transferencia, con EfficientNet como su proveedor principal.

- **TensorFlow Lite**

TFLite es una herramienta que ofrece una gran facilidad para la implementación de modelos de machine learning en aplicaciones móviles. Su eficiencia ha demostrado resultados sobresalientes, permitiendo que los modelos se ejecuten de manera rápida y precisa en dispositivos con recursos limitados.

- **Android Studio**

Android Studio es la principal herramienta de programación que se utilizó, ya que permite codificar la aplicación móvil en el lenguaje Kotlin. Esta elección se debe a que Kotlin ofrece una mayor legibilidad, lo que facilita la escritura del código sin complicarlo con errores comunes como el NullPointerExceptions. Además, nos brinda una mayor seguridad al momento de compilar, lo que es fundamental para garantizar un funcionamiento óptimo de la aplicación.

#### **4.4.3.2 Desarrollo**

- **Toma de fotografías para el Dataset**

Para dar inicio al proyecto, se realizó una visita al área de trabajo de los productores de plátano barraganete en el cantón El Carmen. Una vez en el sitio de producción del plátano barraganete, se mantuvo una conversación con el productor encargado de la clasificación del plátano para exportación y rechazo. Esta persona brindó una capacitación detallada sobre las características y recomendaciones que deben considerarse al momento de llevar a cabo dicha clasificación. Posteriormente, se procedió a la toma de alrededor de 900 fotografías que muestran los diferentes estados de madurez de la fruta. Este paso es fundamental para obtener información

visual que sirvió como base para el desarrollo de nuestro proyecto. En la figura 9 y figura 10 se muestra parte del proceso que se llevó al momento de recolectar las fotografías necesarias.



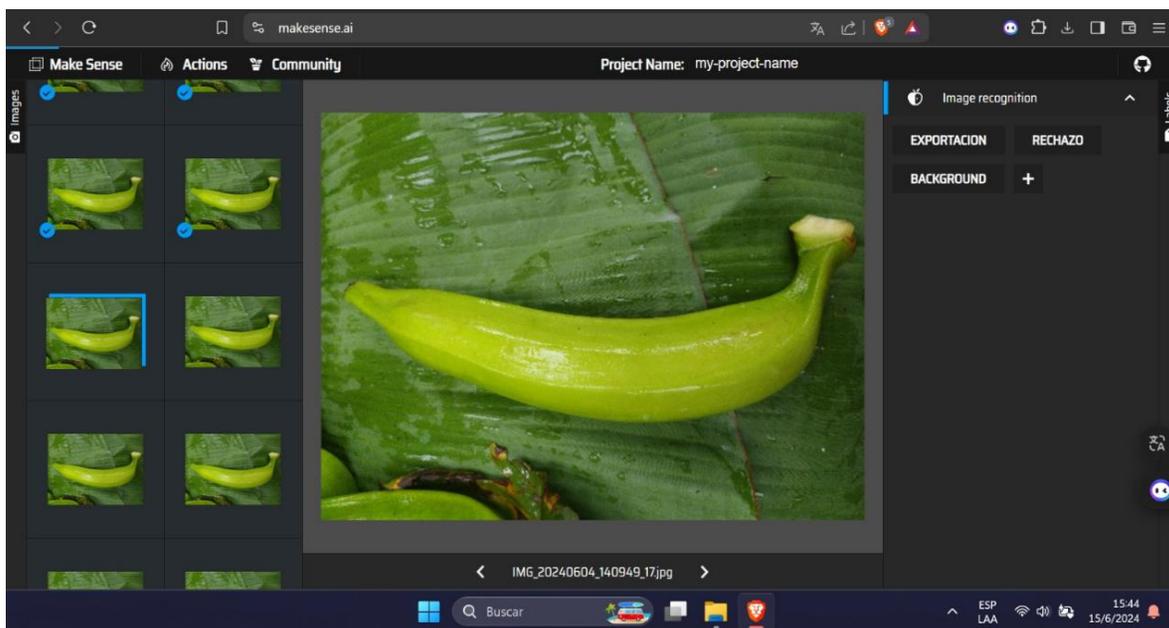
*Figura 9 Recolección de datos para Dataset  
Fuente: Elaboración propia*



*Figura 10 Recolección de datos para Dataset  
Fuente: Elaboración propia*

### ➤ Limpieza del set de datos.

En el proceso de limpieza de las 900 imágenes obtenidas previamente, se descartaron aquellas que presentaban desenfoque, mala calidad de toma u otros aspectos no aptos para el modelo. Como resultado, se cuenta con un total de 636 imágenes seleccionadas. Adicionalmente, se incorporaron 222 imágenes adicionales que actúan como fondo, con el fin de crear una tercera clase para cuando la cámara no detecte ningún plátano. Este paso permitió enriquecer el dataset y mejorar la capacidad del modelo para reconocer situaciones en las que no esté presente el objeto de interés. La figura 11 presenta parte del proceso de limpieza realizado:



*Figura 11 Limpieza y etiquetado de imágenes*

*Fuente: Elaboración propia*

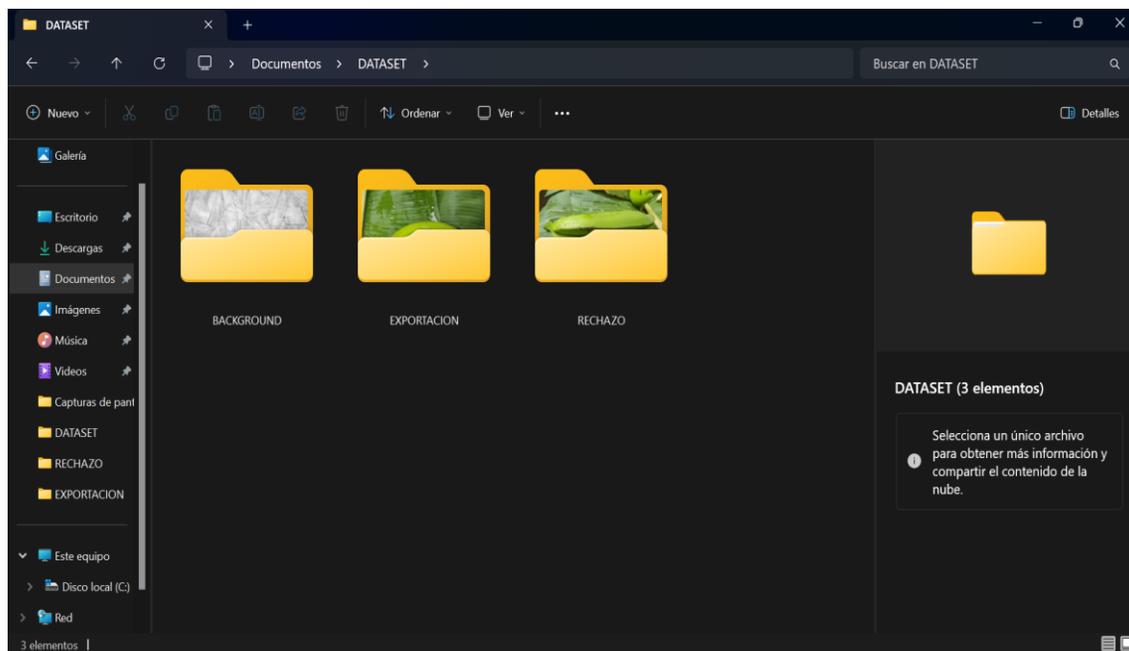
### ➤ Clasificación de imágenes del set de datos.

Entonces, se han recopilado un total de 858 imágenes para clasificar en tres categorías distintas. La primera categoría, denominada "Exportación", incluye imágenes de plátanos en perfecto estado, listos para su exportación.

La segunda categoría, denominada "Rechazo", está compuesta por imágenes de plátanos que presenten características no aptas para la exportación, como madurez inadecuada, manchas o tamaño incorrecto.

Por último, la categoría "Background" contiene imágenes destinadas a servir como fondo cuando la cámara no detecte un plátano para su clasificación. Este proceso de clasificación nos permite gestionar de manera eficiente las imágenes recopiladas, facilitando así la identificación y selección de imágenes al momento de entrenar el modelo de inteligencia artificial.

En la figura 12 se muestra el resultado de la clasificación del dataset, en esta se muestran las 3 carpetas que almacenan las imágenes etiquetadas y clasificadas correctamente:



*Figura 12 Clasificación del set de datos*

*Fuente: Elaboración propia*

## **Entrenamiento de los modelos de Machine Learning.**

### ➤ **MobileNet v2**

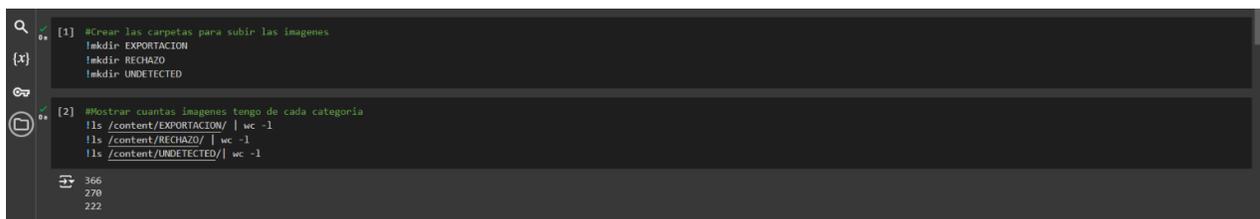
MobileNet v2 es una arquitectura ampliamente utilizada en el campo del machine learning para dispositivos móviles debido a sus significativas ventajas. Esta arquitectura destaca

por su eficiencia computacional, lo que significa que requiere menos recursos de hardware, una característica fundamental dadas las limitaciones de los dispositivos móviles.

Se utilizó Google Colab para llevar a cabo el entrenamiento del modelo, aprovechando el entorno de ejecución en la nube con GPU T4. Esta elección se basó en la necesidad de obtener un rendimiento óptimo para el entrenamiento del modelo, ya que la GPU T4 ofrece capacidades de procesamiento paralelo que aceleran significativamente el tiempo de entrenamiento.

El entrenamiento se realizó de la siguiente manera:

- Para comenzar, como se muestra en la figura 13, se crean tres carpetas separadas para cada una de las clases con las que se va a trabajar. Luego, se procede a cargar las imágenes en las carpetas correspondientes. A continuación, se utiliza el comando "ls" para verificar la cantidad de imágenes que contiene cada carpeta.



```
[1] #Crear las carpetas para subir las imagenes
mkdir EXPORTACION
mkdir RECHAZO
mkdir UNDETECTED

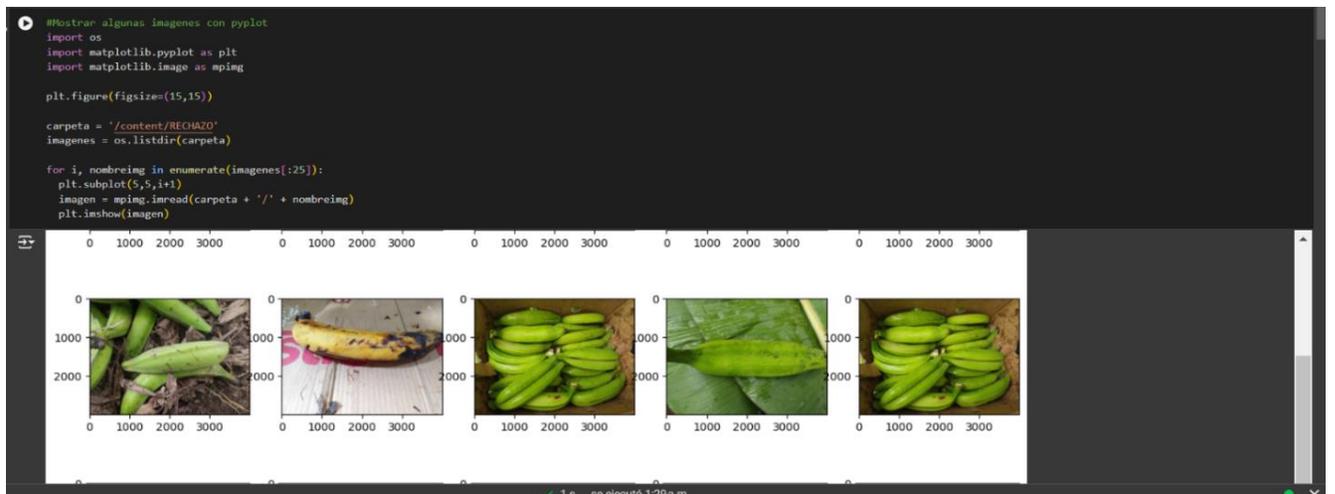
[2] #Mostrar cuantas imagenes tengo de cada categoria
ls /content/EXPORTACION/ | wc -l
ls /content/RECHAZO/ | wc -l
ls /content/UNDETECTED/ | wc -l

366
270
222
```

*Figura 13 Creación de carpetas en Colab*

*Fuente: Elaboración propia*

- Posteriormente, se procede a verificar el estado de las imágenes para asegurar su calidad. Para ello, se muestra un conjunto de imágenes pertenecientes a la clase "rechazo" utilizando la librería matplotlib, este proceso se presenta en la figura 14.



**Figura 14** Verificar integridad de las imágenes

*Fuente: Elaboración propia*

- Luego, tal como se indica en la figura 15, se procede a estructurar el dataset en el entorno de ejecución en la nube con el fin de establecer un orden adecuado. A continuación, se lleva a cabo la creación de un limitador de imágenes, tomando como referencia la clase que posea la menor cantidad de elementos, en este caso "Undetected" con un total de 222 imágenes. Esta acción se realiza con el propósito de igualar la cantidad de imágenes en todas las clases, lo que contribuirá a un mejor rendimiento durante el entrenamiento del modelo. Para lograr este objetivo, se crea un directorio denominado "dataset" y se generan tres subcarpetas correspondientes a cada una de las clases, trasladando las imágenes a estas nuevas ubicaciones.

```
[ ] #Crear carpetas para hacer el set de datos
mkdir dataset
mkdir dataset/EXPORTACION
mkdir dataset/RECHAZO
mkdir dataset/UNDETECTED

#Copiar imagenes que subimos a carpetas del dataset
#Limitar para que todos tengan la misma cantidad de imagenes
#maximo 222 (el num. menor de imagenes que subi)

import shutil
carpeta_fuente = '/content/EXPORTACION'
carpeta_destino = '/content/dataset/EXPORTACION'

imagenes = os.listdir(carpeta_fuente)

for i, nombreimg in enumerate(imagenes):
    if i < 222:
        #Copia de la carpeta fuente a la destino
        shutil.copy(carpeta_fuente + '/' + nombreimg, carpeta_destino + '/' + nombreimg)

[ ] carpeta_fuente = '/content/RECHAZO'
carpeta_destino = '/content/dataset/RECHAZO'

imagenes = os.listdir(carpeta_fuente)

for i, nombreimg in enumerate(imagenes):
    if i < 222:
        #Copia de la carpeta fuente a la destino
        shutil.copy(carpeta_fuente + '/' + nombreimg, carpeta_destino + '/' + nombreimg)
```

**Figura 15 Estructuración del set de datos en Colab**

*Fuente: Elaboración propia*

- Como siguiente paso, en la Figura 16, se confirma que se hayan copiado el mismo número de imágenes en las 3 carpetas para poner en práctica el proceso del entrenamiento.

```
[ ] #Mostrar cantidad imagenes tipo de cada categoria en el dataset
ls /content/dataset/EXPORTACION | wc -l
ls /content/dataset/RECHAZO | wc -l
ls /content/dataset/UNDETECTED | wc -l

222
222
222
```

**Figura 16 Verificación de cantidades de imágenes**

*Fuente: Elaboración propia*

- Para finalizar la preparación del conjunto de datos, como se indica en la figura 17, se utiliza el ImageDataGenerator de Keras para aplicar aumentos a las imágenes. Esto incluye distorsiones y redimensionamientos, con el fin de evitar el sobreajuste del modelo a las imágenes de entrenamiento. Además, se reserva un 20% del conjunto de datos para propósitos de validación, dejando el resto disponible para el entrenamiento. Finalmente, se generan 10 ejemplos de imágenes para ilustrar el proceso de aumento de datos. Este enfoque garantiza que el modelo esté bien preparado para manejar una variedad de imágenes y reducir el riesgo de sobreajuste.

```

[] Aumento de datos con ImageDataGenerator
from tensorflow.keras.preprocessing.image import ImageDataGenerator
import numpy as np

#Crear el dataset generador
datagen = ImageDataGenerator(
    rescale=1./255,
    rotation_range = 30,
    width_shift_range = 0.2,
    height_shift_range = 0.2,
    shear_range = 15,
    zoom_range = (0.5, 1.5),
    validation_split=0.2 #ok para pruebas
)

#generadores para sets de entrenamiento y pruebas
data_gen_entrenamiento = datagen.flow_from_directory('/content/dataset', target_size=(224,224),
                                                    batch_size=32, shuffle=True, subset='training')
data_gen_pruebas = datagen.flow_from_directory('/content/dataset', target_size=(224,224),
                                              batch_size=32, shuffle=True, subset='validation')

#Imprimir 10 imagenes del generador de entrenamiento
for images, classes in data_gen_entrenamiento:
    for i in range(10):
        plt.subplot(2,5,i+1)
        plt.axis('off')
        plt.imshow(images[i])
        plt.show()

Found 534 images belonging to 3 classes.
Found 132 images belonging to 3 classes.

```



**Figura 17 Aumento de datos con Keras**

*Fuente: Elaboración propia*

- A continuación, como se indica en la figura 18, se procede a descargar el modelo de MobileNet v2 desde su sitio oficial. Cabe destacar que esta versión cuenta con 1280 capas de redes neuronales convolucionales, las cuales no se modificaron y se mantuvieron los sesgos y pesos originales. Posteriormente, se congeló el modelo hasta el momento del entrenamiento. Luego, se modificó la última capa de salida para adaptarla a las 3 clases que se utilizaron: "Exportación", "Rechazo" y "Undetected". Finalmente, se compiló con el optimizador "adam" y se definieron las métricas de precisión correspondientes.

```

[] import tensorflow as tf
import tensorflow_hub as hub

url = "https://tfhub.dev/google/tf2-preview/mobilenet_v2-feature_vector/4"
mobilenetv2 = hub.keras_layer(url, input_shape=(224,224,3))

[] #congelar el modelo descargado
mobilenetv2.trainable = False

[] #modelo = tf.keras.Sequential([
    mobilenetv2,
    tf.keras.layers.Dense(3, activation='softmax')
])

[] #definir como modelo
modelo.compile(
    optimizer='adam',
    loss=tf.keras.losses.CategoricalCrossentropy,
    metrics=['accuracy'])

```

**Figura 18 Descarga y configuración de la arquitectura MobileNet v2**

*Fuente: Elaboración propia*

- Como se indica en la figura 19, se utilizó la función `fit ()` para entrenar el modelo con los datos generados de entrenamiento, especificando el número de épocas, que en este caso es de 25, y un tamaño de lote de 32. Además, se utilizó el conjunto de datos de pruebas como datos de validación para evaluar el rendimiento del modelo durante el entrenamiento. Todo esto se llevó a cabo con el objetivo de ajustar y mejorar el rendimiento del modelo a lo largo del tiempo.

```

Entrenar el modelo
EPOCHS = 25

historial = modelo.fit(
    data_gen_entrenamiento, epochs=EPOCHS, batch_size=32,
    validation_data=data_gen_pruebas
)

Epoch 1/25 [=====] - 965 55/step - loss: 0.6270 - accuracy: 0.7210 - val_loss: 0.3590 - val_accuracy: 0.9409
Epoch 2/25 [=====] - 894 55/step - loss: 0.1363 - accuracy: 0.9457 - val_loss: 0.2411 - val_accuracy: 0.9815
Epoch 3/25 [=====] - 884 55/step - loss: 0.1200 - accuracy: 0.9813 - val_loss: 0.1714 - val_accuracy: 0.9773
Epoch 4/25 [=====] - 854 55/step - loss: 0.1815 - accuracy: 0.9700 - val_loss: 0.1793 - val_accuracy: 0.9394
Epoch 5/25 [=====] - 884 55/step - loss: 0.0837 - accuracy: 0.9831 - val_loss: 0.1594 - val_accuracy: 0.9394
Epoch 6/25 [=====] - 874 55/step - loss: 0.0734 - accuracy: 0.9831 - val_loss: 0.1618 - val_accuracy: 0.9470
Epoch 7/25 [=====] - 874 55/step - loss: 0.0793 - accuracy: 0.9813 - val_loss: 0.1150 - val_accuracy: 0.9773
Epoch 8/25 [=====] - 924 66/step - loss: 0.0609 - accuracy: 0.9850 - val_loss: 0.1583 - val_accuracy: 0.9394
Epoch 9/25 [=====] - 884 55/step - loss: 0.0672 - accuracy: 0.9831 - val_loss: 0.1291 - val_accuracy: 0.9697
Epoch 10/25 [=====] - 914 55/step - loss: 0.0634 - accuracy: 0.9850 - val_loss: 0.1080 - val_accuracy: 0.9621
Epoch 11/25 [=====] - 894 55/step - loss: 0.0563 - accuracy: 0.9813 - val_loss: 0.1472 - val_accuracy: 0.9394
Epoch 12/25 [=====] - 824 55/step - loss: 0.0645 - accuracy: 0.9794 - val_loss: 0.1544 - val_accuracy: 0.9394
Epoch 13/25 [=====] - 864 55/step - loss: 0.0576 - accuracy: 0.9850 - val_loss: 0.1187 - val_accuracy: 0.9773
Epoch 14/25 [=====] - 904 55/step - loss: 0.0601 - accuracy: 0.9775 - val_loss: 0.1166 - val_accuracy: 0.9545
Epoch 15/25 [=====] - 924 55/step - loss: 0.0551 - accuracy: 0.9831 - val_loss: 0.1049 - val_accuracy: 0.9394
Epoch 16/25 [=====] - 884 55/step - loss: 0.0512 - accuracy: 0.9880 - val_loss: 0.1545 - val_accuracy: 0.9621
Epoch 17/25 [=====] - 854 55/step - loss: 0.0531 - accuracy: 0.9775 - val_loss: 0.1154 - val_accuracy: 0.9545
Epoch 18/25 [=====] - 884 55/step - loss: 0.0556 - accuracy: 0.9775 - val_loss: 0.1490 - val_accuracy: 0.9470
Epoch 19/25 [=====] - 844 55/step - loss: 0.0460 - accuracy: 0.9809 - val_loss: 0.1118 - val_accuracy: 0.9697
Epoch 20/25 [=====] - 864 55/step - loss: 0.0459 - accuracy: 0.9794 - val_loss: 0.0947 - val_accuracy: 0.9697
Epoch 21/25 [=====] - 854 55/step - loss: 0.0561 - accuracy: 0.9831 - val_loss: 0.1423 - val_accuracy: 0.9470
Epoch 22/25 [=====] - 884 55/step - loss: 0.0555 - accuracy: 0.9794 - val_loss: 0.1488 - val_accuracy: 0.9242
Epoch 23/25 [=====] - 854 55/step - loss: 0.0529 - accuracy: 0.9813 - val_loss: 0.0991 - val_accuracy: 0.9697
Epoch 24/25 [=====] - 864 55/step - loss: 0.0389 - accuracy: 0.9906 - val_loss: 0.1240 - val_accuracy: 0.9773
Epoch 25/25 [=====] - 834 55/step - loss: 0.0409 - accuracy: 0.9850 - val_loss: 0.1202 - val_accuracy: 0.9697

```

*Figura 19 Entrenamiento del modelo*

*Fuente: Elaboración propia*

- Posteriormente, se procede a realizar la respectiva gráfica de precisión, tal cual se muestra en la figura 20. Para esto, se obtienen los valores de precisión y pérdida del historial del modelo, es decir, `acc = historial.history['accuracy']`, `val_acc = historial.history['val_accuracy']`, `loss = historial.history['loss']` y `val_loss = historial.history['val_loss']`. Estos valores se grafican en función del número de épocas, que en este caso es de 25.

En la gráfica resultante que se presenta en la figura 21, se puede observar la evolución de la precisión tanto en el conjunto de entrenamiento como en el de pruebas, así como la evolución de la pérdida en ambos conjuntos.

Como resultado, el diagrama obtenido en la figura 21 muestra que el modelo está aprendiendo y mejorando en precisión, pero las fluctuaciones en la precisión y la pérdida en las pruebas sugieren que el modelo puede no estar generalizando perfectamente a datos no vistos.

```

# Generación de precisión
acc = Historical.History('accuracy')
val_acc = Historical.History('val_accuracy')

loss = Historical.History('loss')
val_loss = Historical.History('val_loss')

range_epochs = range(25)

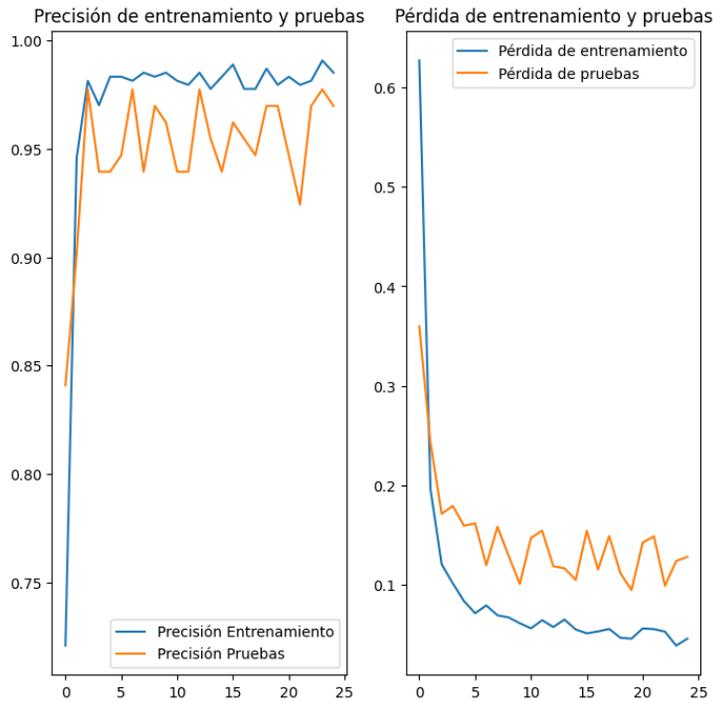
plt.figure(figsize=(8,8))
plt.subplot(1,2,1)
plt.plot(range_epochs, acc, label='Precisión Entrenamiento')
plt.plot(range_epochs, val_acc, label='Precisión Pruebas')
plt.legend(loc='lower right')
plt.title('Precisión de entrenamiento y pruebas')

plt.subplot(1,2,2)
plt.plot(range_epochs, loss, label='Pérdida de entrenamiento')
plt.plot(range_epochs, val_loss, label='Pérdida de pruebas')
plt.legend(loc='lower right')
plt.title('Pérdida de entrenamiento y pruebas')
plt.show()

```

**Figura 20** Generación de la gráfica de entrenamiento

*Fuente: Elaboración propia*



**Figura 21** Gráfica de precisión de MobileNet v2

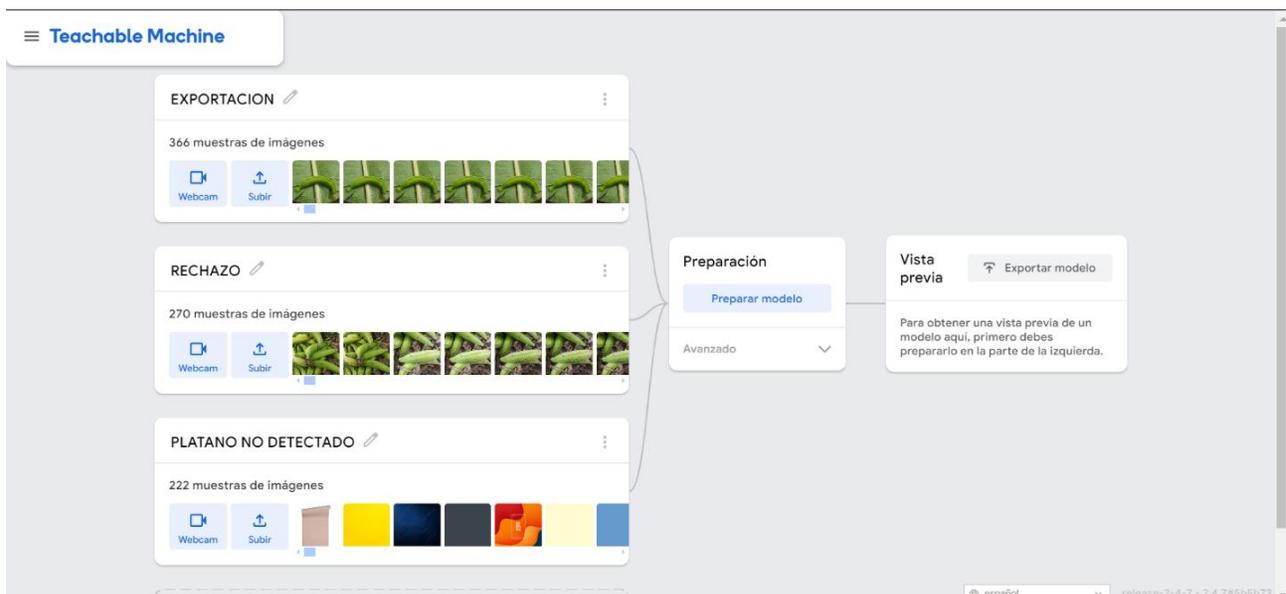
*Fuente: Elaboración propia*

## ➤ Teachable Machine

Para comparar las gráficas de precisión, se utilizó otra arquitectura para entrenar el modelo. Siendo Teachable Machine la opción ideal. Esto se debe a que pone en práctica el Transfer Learning de diferentes arquitecturas, lo que permite obtener resultados más precisos y eficientes.

El proceso en esta plataforma fue la siguiente:

- Como se presenta en la figura 22, se han establecido las 3 clases correspondientes a la arquitectura previamente definida, las cuales son: "Exportación", "Rechazo" y "Plátano no detectado", para luego cargar las imágenes del set de datos correspondientes a cada clase.



**Figura 22 Creación de clases y carga de imágenes en Teachable Machine**

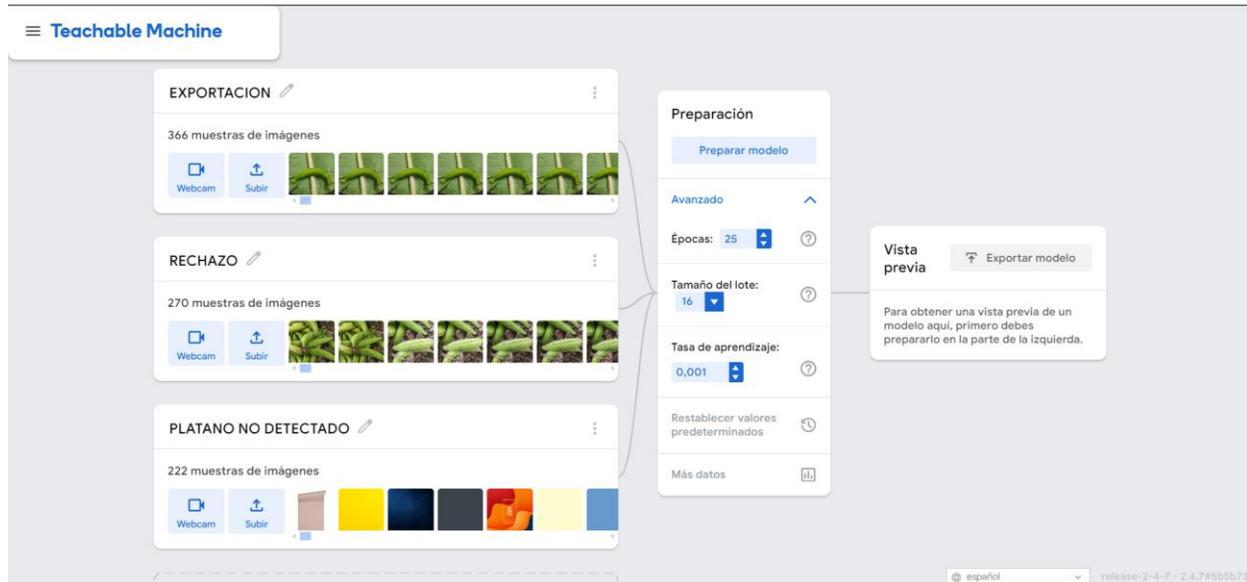
**Fuente: Elaboración propia**

- Para configurar el entrenamiento, se ha designado un número de épocas igual a la arquitectura de MobileNet v2, estableciendo 25 épocas. También se ha definido el número de lotes en 16 para optimizar el proceso de entrenamiento, y por último se

ha seleccionado una tasa de aprendizaje muy baja del 0,001 con el fin de garantizar que el modelo adquiera el mejor aprendizaje posible.

Esta configuración permitió que el modelo se entrene de manera exhaustiva y precisa, lo que resultó en un rendimiento óptimo en la clasificación de imágenes.

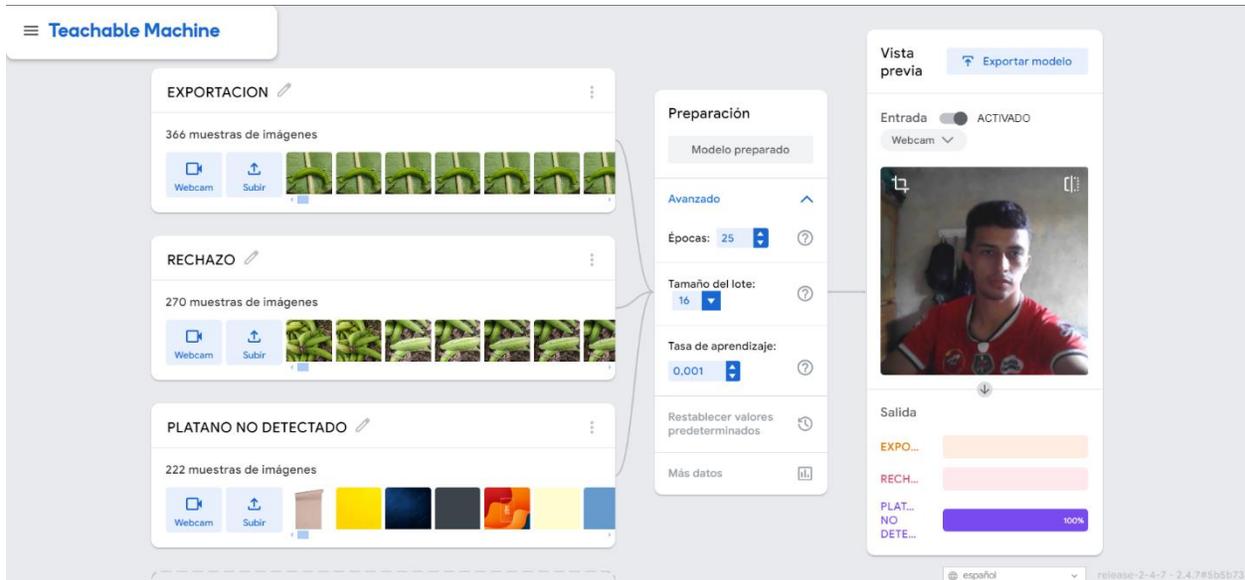
Este proceso se puede ver representado en la figura 23 presentada a continuación:



**Figura 23 Ajuste de entrenamiento del modelo**

**Fuente: Elaboración propia**

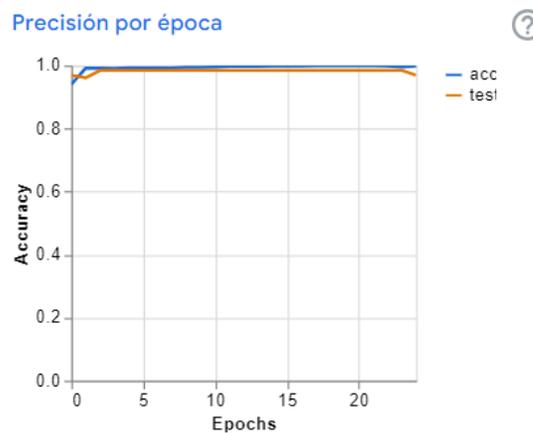
- Cuando el modelo se ha entrenado, como se muestra en la figura 24, este nos permitirá hacer la prueba en vivo como se muestra a continuación, mostrándonos una salida de “Undetected”, siendo correcta esta respuesta.



**Figura 24 Vista previa al modelo**

**Fuente: Elaboración propia**

- A continuación, se presentan los gráficos de precisión donde:
  - El gráfico mostrado en la figura 25 muestra la precisión por época, con líneas representando la precisión de entrenamiento y la precisión de prueba. Ambas líneas están casi superpuestas, indicando altos niveles de precisión cercanos al 100% en todas las épocas.



**Figura 25 Gráfica de precisión por época en Teachable Machine**

**Fuente: Elaboración propia**

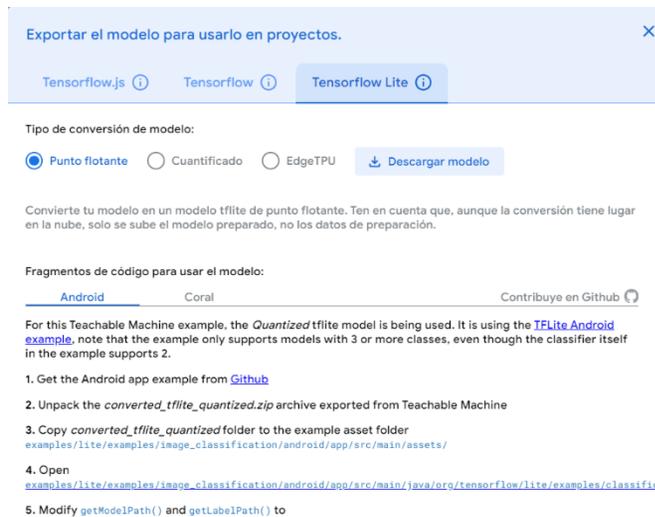
- En la figura 26 titulada "Pérdida por época", se observa una disminución rápida en la pérdida de entrenamiento, comenzando en 0.18 y disminuyendo a un valor ligeramente superior a 0. La pérdida de prueba, por otro lado, muestra cierta variabilidad, comenzando justo por debajo de 0.05, aumentando ligeramente y luego fluctuando alrededor de 0.06.



**Figura 26 Gráfica de pérdida por época en Teachable Machine**

**Fuente: Elaboración propia**

- Estos resultados indican un modelo con un rendimiento sólido, caracterizado por alta precisión y baja pérdida.
- Para concluir, es necesario exportar el modelo a un archivo TensorFlow Lite para su posterior implementación en la aplicación móvil, este proceso se indica en la figura 27 y figura 28.



**Figura 27 Exportación del modelo a TFLite**

**Fuente: Elaboración propia**

labels	Documento de texto	1 KB	No	1 K
model_unquant.tflite	Archivo TFLITE	2.042 KB	No	2.042 K

**Figura 28 Archivo TFLite**

**Fuente: Elaboración propia**

Tras comparar los resultados de ambas arquitecturas, se puede afirmar que las prestaciones ofrecidas por la plataforma Teachable Machine, con sus aplicaciones de Transfer Learning de diferentes arquitecturas de machine learning, superan considerablemente a las de MobileNet v2. Debido a aquello, el modelo entrenado por Teachable Machine es escogido para ser implementado en la aplicación móvil debido a su superior rendimiento.

## Codificación

### ➤ Página Principal

En la figura 29 se muestra el código de la actividad “MainActivity”, la cual actúa como página principal de la aplicación, ofreciendo al usuario la opción de dirigirse a dos funcionalidades distintas del sistema según lo requiera, la finalidad del código es que cada que el usuario presione uno de los botones, este de la orden de iniciar una actividad específica.

```

8
9 class MainActivity : AppCompatActivity() {
10
11     override fun onCreate(savedInstanceState: Bundle?) {
12         super.onCreate(savedInstanceState)
13         setContentView(R.layout.activity_main)
14
15         val imageBtn : Button = findViewById(R.id.imageBtn)
16         val camaraBtn : Button = findViewById(R.id.camaraBtn)
17
18         camaraBtn.setOnClickListener { it: View!
19             val intent = Intent( packageContext: this, Camara::class.java)
20             startActivity(intent)
21         }
22
23         imageBtn.setOnClickListener { it: View!
24             val intent = Intent( packageContext: this, Imagen::class.java)
25             startActivity(intent)
26         }
27

```

*Figura 29 Código de Página principal*

*Fuente: Elaboración propia*

#### **4.4.3.2.1.1 Integración de Modelo TensorFlow Lite**

El modelo de TensorFlow Lite se integró en la aplicación utilizando la clase “ClassifyTF”, presentada en la figura 30, que maneja la carga del modelo, el procesamiento de imágenes y la interpretación de los resultados. En la clase “ClassifyTF” se almacena la lógica que usó la aplicación para procesar imágenes y clasificarlas utilizando el modelo de TensorFlow Lite entrenado previamente. Se utiliza un ‘ByteBuffer’ para convertir los datos de pixeles de una imagen en un formato compatible con el modelo, se realiza la inferencia y devuelve el resultado de la clasificación a través de un objeto llamado “ReturnInterpreter”.

```

class ClassifyTF (val context: Context){

    val model = ModelUnquant.newInstance(context)

    lateinit var returnInterpreter: ReturnInterpreter

    fun listenerInterpreter(returnInterpreter: ReturnInterpreter){
        this.returnInterpreter = returnInterpreter
    }

    fun classify(bitmap: Bitmap) {
        val inputFeature =
            TensorBuffer.createFixedSize(intArrayOf(1, INPUT_SIZE, INPUT_SIZE, 3), DataType.FLOAT32)
        val byteBuffer = ByteBuffer.allocateDirect(4 * INPUT_SIZE * INPUT_SIZE * 3)
        byteBuffer.order(ByteOrder.nativeOrder())

        val intValue = IntArray(INPUT_SIZE * INPUT_SIZE)

        bitmap.getPixels(intValue, 0, bitmap.width, 0, 0, bitmap.width, bitmap.height)

        for (pixelValue in intValue) {
            byteBuffer.putFloat((pixelValue shr 16 and 0xFF) * (1f / 255)) //rojo
            byteBuffer.putFloat((pixelValue shr 8 and 0xFF) * (1f / 255)) //verde
        }
    }
}

```

*Figura 30 Integración del Modelo TFLite en la APP*

*Fuente: Elaboración propia*

#### 4.4.3.2.1.2 Interprete

En la figura 31 se presenta el código que retornará un intérprete necesario para el funcionamiento del modelo. Esta interfaz permite que otras partes de la aplicación reciban y utilicen los resultados de la clasificación según sea necesario.

```

package com.example.platanoapp

interface ReturnInterpreter {

    fun classify(confidence:FloatArray, maxConfidence:Int)
}

```

*Figura 31 Código del Interprete del Modelo*

*Fuente: Elaboración propia*

#### 4.4.3.2.1.3 Detección por Imagen

Como se muestra en la figura 32, se codifica la actividad “Imagen” la cual permite al usuario seleccionar una imagen desde su dispositivo, clasificarla utilizando el modelo TFLite a través de la clase encargada de la clasificación y mostrar el resultado del proceso en la interfaz. Se hace uso de un arreglo de cadenas para representar los resultados, con el fin de que los resultados sean legibles para el usuario.

```
class Imagen : AppCompatActivity() {  
  
    lateinit var binding: ActivityImagenBinding  
    lateinit var classifyTF: ClassifyTF  
  
    companion object {  
        const val INPUT_SIZE = 224  
        const val PICK_IMAGE_REQUEST = 1  
    }  
  
    private val classes = arrayOf("Exportación", "Rechazo", "No Detectado")  
  
    override fun onCreate(savedInstanceState: Bundle?) {  
        super.onCreate(savedInstanceState)  
        binding = ActivityImagenBinding.inflate(layoutInflater)  
        setContentView(binding.root)  
  
        classifyTF = ClassifyTF(context = this)  
  
        binding.selectImageBtn.setOnClickListener { it: View! -> {  
            openImagePicker()  
        }}  
  
        binding.classifyBtn.setOnClickListener { it: View! -> {  
            binding.imageView.drawable?.let { it: Drawable -> {  
                val bitmap = (it as BitmapDrawable).bitmap  
                classifyImage(bitmap)  
            }}  
        }}  
    }  
}
```

*Figura 32 Código de función Detección por Imagen*

*Fuente: Elaboración propia*

#### 4.4.3.2.1.4 Detección en Tiempo Real

La actividad “Cámara” permite capturar imágenes en tiempo real utilizando la cámara del dispositivo, clasificarlas utilizando el modelo TFLite y mostrar el resultado de la clasificación en la interfaz. A diferencia de la Detección por Imágenes, el texto de los resultados se va

actualizando de manera automática sin necesidad de presionar un botón que inicie el proceso de clasificación. En la figura 33 se muestra parte de la codificación realizada para el funcionamiento de esta función:

```
class Camara : AppCompatActivity() {
    lateinit var binding : ActivityCamaraBinding
    lateinit var cameraJhr: CameraJhr
    lateinit var classifyTF: ClassifyTF
    companion object{
        const val INPUT_SIZE = 224
    }

    val classes = arrayOf("Exportación", "Rechazo", "No Detectado")

    override fun onCreate(savedInstanceState: Bundle?) {
        super.onCreate(savedInstanceState)
        binding = ActivityCamaraBinding.inflate(layoutInflater)
        setContentView(binding.root)

        classifyTF = ClassifyTF(this)

        //init camera
        cameraJhr = CameraJhr(this)

        //Regresar
        binding.regresarBtn.setOnClickListener {
            finish()
        }
    }

    override fun onWindowFocusChanged(hasFocus: Boolean) {
```

*Figura 33 Código de función Detección en Tiempo Real*

*Fuente: Elaboración propia*

#### **4.4.4 Fase IV: Verificación**

##### **4.4.4.1 Casos de Prueba**

##### **Detección por Imágenes**

En la tabla 11 se presenta el caso de prueba para la selección y clasificación de imágenes seleccionadas desde la galería por el usuario, incluyendo los requisitos que requieren para el funcionamiento de la aplicación, los pasos a seguir y los resultados obtenidos en las pruebas realizadas:

<b>Información General</b>	
<b>Id del Caso de Prueba</b>	CT001
<b>Nombre del Caso de Prueba</b>	Selección y clasificación de imagen desde la galería
<b>Descripción</b>	Verificar que la aplicación puede seleccionar una imagen desde la galería del dispositivo, procesarla y clasificarla correctamente.
<b>Requisitos y Precondiciones</b>	
<b>Requisitos</b>	<ul style="list-style-type: none"> <li>- El sistema debe permitir la selección de imágenes desde la galería</li> <li>- El sistema debe clasificar imágenes</li> </ul>
<b>Precondiciones</b>	<ul style="list-style-type: none"> <li>- El dispositivo tiene acceso a la galería de imágenes.</li> <li>- Los permisos de acceso a la galería han sido concedidos.</li> <li>- La aplicación está instalada y se ejecuta correctamente.</li> <li>- El modelo TFLite está integrado y funcionando.</li> </ul>
<b>Detalles del Caso de Prueba</b>	
<b>Pasos a Seguir</b>	<ol style="list-style-type: none"> <li>1. Abrir la aplicación</li> <li>2. Hacer clic en el botón “Detección por Imágenes”</li> <li>3. Hacer clic en el botón “Seleccionar Imagen” para abrir el selector de imágenes.</li> <li>4. Seleccionar una imagen de la galería.</li> <li>5. Verificar que la imagen seleccionada se muestra en el recuadro blanco.</li> <li>6. Hacer clic en el botón “Predecir” para iniciar la clasificación de la imagen.</li> <li>7. Verificar que el resultado de la clasificación se muestra correctamente en “Resultado”.</li> </ol>
<b>Resultados</b>	
<b>Resultados Esperados</b>	<ul style="list-style-type: none"> <li>- La imagen seleccionada se muestra donde corresponde.</li> <li>- El resultado de la clasificación se muestra correctamente con el texto “Exportación”, “Rechazo” o “No Detectado” según corresponda.</li> </ul>
<b>Resultado Real</b>	<ul style="list-style-type: none"> <li>- La imagen seleccionada se muestra en el recuadro asignado.</li> <li>- El resultado de la clasificación se muestra correctamente con el texto “Exportación”.</li> </ul>
<b>Observaciones y Comentarios</b>	
<b>Observaciones</b>	<ul style="list-style-type: none"> <li>- La clasificación se completó en menos de 1 segundo.</li> <li>- El selector de imágenes funcionó correctamente y permitió la selección sin problemas.</li> </ul>
<b>Comentarios</b>	<ul style="list-style-type: none"> <li>- La aplicación funciona bajo condiciones normales.</li> </ul>

*Tabla 11 Caso de Prueba CT001*

*Fuente: Elaboración propia*

## DetECCIÓN EN TIEMPO REAL

En la tabla 12 se presenta el caso de prueba para la captura y clasificación de imágenes capturadas por la cámara en tiempo real, incluyendo los requisitos que requieren para el funcionamiento de la aplicación, los pasos a seguir y los resultados obtenidos en las pruebas realizadas:

<b>Información General</b>	
<b>Id del Caso de Prueba</b>	CT002
<b>Nombre del Caso de Prueba</b>	Captura y clasificación de imagen en tiempo real
<b>Descripción</b>	Verificar que la aplicación puede capturar una imagen desde la cámara del dispositivo, procesarla y clasificarla correctamente.
<b>Requisitos y Precondiciones</b>	
<b>Requisitos</b>	<ul style="list-style-type: none"><li>- El sistema debe poder visualizar imágenes en tiempo real desde la cámara</li><li>- El sistema debe clasificar imágenes</li></ul>
<b>Precondiciones</b>	<ul style="list-style-type: none"><li>- El dispositivo tiene la cámara funcional.</li><li>- Los permisos de la cámara han sido concedidos.</li><li>- La aplicación está instalada y se ejecuta correctamente.</li><li>- El modelo TFLite está integrado y funcionando.</li></ul>
<b>Detalles del Caso de Prueba</b>	
<b>Pasos a Seguir</b>	<ol style="list-style-type: none"><li>1. Abrir la aplicación</li><li>2. Hacer clic en el botón “Detección en Tiempo Real”</li><li>3. Capturar una imagen u objeto utilizando la cámara.</li><li>4. Esperar a que la clasificación de la imagen se complete.</li><li>5. Verificar que el resultado de la clasificación se muestra correctamente en “Resultado”.</li></ol>
<b>Resultados</b>	
<b>Resultados Esperados</b>	<ul style="list-style-type: none"><li>- La imagen capturada por la cámara se muestra en el lugar asignado de la interfaz de usuario.</li><li>- El resultado de la clasificación se muestra correctamente con el texto “Exportación”, “Rechazo” o “No Detectado” según corresponda.</li></ul>
<b>Resultado Real</b>	<ul style="list-style-type: none"><li>- La imagen capturada por la cámara se muestra correctamente</li><li>- El resultado de la clasificación se muestra correctamente.</li></ul>

<b>Observaciones y Comentarios</b>	
<b>Observaciones</b>	<ul style="list-style-type: none"> <li>- La clasificación se completó en menos de 1 segundo.</li> <li>- La cámara funcionó sin problemas.</li> </ul>
<b>Comentarios</b>	<ul style="list-style-type: none"> <li>- La aplicación funciona bajo condiciones normales.</li> </ul>

*Tabla 12 Caso de Prueba CT002*

*Fuente: Elaboración propia*

## Capítulo V

### 5 Evaluación De Resultados

#### 5.1 Introducción

La evaluación de los resultados se llevó a cabo mediante una simulación del proceso que realizan los productores de plátano al clasificar las frutas en dos categorías: plátano apto para exportación y plátano considerado rechazo. El objetivo de esta evaluación es verificar el rendimiento de la aplicación en el área de trabajo de los productores, con el fin de comprobar el impacto positivo de la misma.

Se espera que la aplicación reduzca el tiempo de trabajo, aumente la productividad en el campo agrícola y permita comercializar productos de mayor calidad. Esto a su vez evitará pérdidas económicas derivadas de la clasificación errónea de los plátanos.

#### 5.2 Presentación y monitoreo de resultados

##### 5.2.1 Planificación de la evaluación

En la tabla 13 se presenta la planificación utilizada para las pruebas aplicadas a la aplicación móvil, incluyendo los objetivos esperados, los criterios de éxito y el tipo de pruebas empleadas:

<b>Objetivos de Evaluación</b>	<ul style="list-style-type: none"><li>▪ Verificar la precisión del modelo de clasificación.</li><li>▪ Comprobar la estabilidad y rendimiento de la aplicación.</li><li>▪ Verificar que todas las funcionalidades principales funcionen correctamente.</li></ul>
<b>Criterios de Éxito</b>	<ul style="list-style-type: none"><li>▪ La aplicación debe clasificar correctamente al menos el 75% de las imágenes de prueba.</li><li>▪ La aplicación no debe presentar fallos críticos durante las pruebas de estrés y uso prolongado.</li></ul>

	<ul style="list-style-type: none"> <li>▪ Todas las funciones deben ejecutarse sin errores en al menos el 90% de los casos.</li> </ul>
<b>Tipos de Pruebas</b>	<ul style="list-style-type: none"> <li>▪ Pruebas Funcionales</li> <li>▪ Pruebas de Rendimiento</li> <li>▪ Pruebas de Compatibilidad</li> </ul>

*Tabla 13 Planificación de la evaluación*

*Fuente: Elaboración propia*

## 5.2.2 Ejecución del monitoreo

### 5.2.2.1 Pruebas Funcionales

- **Detección por Imágenes**

En la figura 34 se muestra la aplicación funcionando durante el proceso de prueba, en esta se muestra la imagen seleccionada, los elementos diseñados en la codificación y el resultado de la clasificación, a continuación, se describen los resultados obtenidos a través de las pruebas empleadas:

- La aplicación permitió seleccionar una imagen desde la galería del dispositivo sin problemas.
- Todas las imágenes seleccionadas se mostraron correctamente en la interfaz.
- El modelo clasificó correctamente el 80% de las imágenes de prueba y se mostraron los resultados en la interfaz.



*Figura 34 Prueba Funcional de Detección por Imagen*

*Fuente: Elaboración propia*

- **Detección en Tiempo Real**

En la figura 35 se muestra la aplicación funcionando mientras se ejecuta la función de Detección en Tiempo Real durante el proceso de pruebas, en la interfaz se puede observar los elementos codificados para la interfaz, la imagen capturada por la cámara y el resultado arrojado por la aplicación al detectar y clasificar el objeto. A continuación, se enlistan los resultados obtenidos en la aplicación de la prueba tomando en cuenta los criterios de éxito:

- La cámara funcionó correctamente en los dispositivos probados.
- La clasificación se realizó sin problemas de manera inmediata.
- Los resultados se mostraron en la interfaz.



***Figura 35 Prueba Funcional de Detección en Tiempo Real***

***Fuente: Elaboración propia***

### **5.2.2.2 Pruebas de Rendimiento**

#### **Detección por Imágenes**

Para evaluar el rendimiento de la aplicación al momento de clasificar imágenes previamente capturadas o seleccionadas se tomó en cuenta el tiempo que toma cargar y mostrar la imagen y el tiempo necesario para procesar la imagen y generar resultados.

Una vez evaluada esta función, se determinó lo siguiente:

- El tiempo de carga de imágenes es menor a 1 segundo.
- El tiempo de procesamiento de la imagen cargada es de 1 segundo.
- No se presentan retrasos significativos al procesar imágenes de diferentes tamaños y resoluciones.

#### **Detección en Tiempo Real**

Para evaluar el rendimiento de la aplicación al momento de procesar las imágenes u objetos capturados en tiempo real por la cámara se tomaron en cuenta la velocidad con la que la cámara captura un fotograma y lo procesa, la capacidad de la aplicación para mantenerse en constante procesamiento y el tiempo que le toma arrojar resultados.

Una vez evaluada esta función, se determinó que:

- La velocidad con la que se toma y procesa un fotograma es de 500ms en condiciones normales.
- La aplicación puede mantenerse funcionando con la función de Detección en Tiempo Real sin problemas.
- El tiempo en que se muestran los resultados es de 1 segundo.

### 5.2.2.3 Pruebas de Compatibilidad

En esta prueba se busca asegurar que la aplicación funcione correctamente en una amplia variedad de dispositivos, comprobando si es compatible con diferentes modelos de dispositivos, versiones de sistemas operativos Android, resoluciones de pantalla, hardware y software.

Para llevar a cabo esta prueba, se extrajo el ejecutable de la aplicación desde Android Studio y se compartió vía WhatsApp y Bluetooth, una vez el ejecutable fue descargado e instalado en 10 dispositivos se comprobó que:

- La aplicación se instaló con éxito y sin problemas en todos los dispositivos.
- A pesar de la diferencia de resoluciones, todos los elementos de la interfaz se muestran correctamente y se pueden utilizar sin inconvenientes.
- No se encontraron fallas en el rendimiento de la aplicación en los distintos dispositivos.
- La ejecución de la aplicación no afecta el rendimiento del dispositivo.

### 5.3 Interpretación objetiva

La evaluación de los resultados muestra que la aplicación cumple en gran medida con los objetivos y criterios de éxito establecidos, se demuestra que la aplicación es generalmente robusta y eficiente, sin embargo, presenta áreas por mejorar.

- **Detección por Imágenes**

La aplicación demostró ser efectiva y eficiente a la hora de seleccionar y visualizar las imágenes desde la galería del dispositivo. Además, la precisión de clasificación es del 80%, lo cual supera las expectativas y resultados esperados, pero pudiendo mejorarse aún más para obtener mejor precisión en los resultados obtenidos.

- **Detección en Tiempo Real**

La función de detección en tiempo real mostró un buen rendimiento, clasificando de manera inmediata y mostrando resultados precisos en gran medida. También se indica que la velocidad de procesamiento es la adecuada para la función en tiempo real, cumpliendo así los criterios de rendimiento.

- **Rendimiento**

Tanto para la detección por imágenes como en tiempo real, la aplicación muestra tiempos de respuesta inmediatos, lo que es esencial para su usabilidad en el entorno agrícola. No se observaron retrasos significativos, lo que es bueno para la experiencia del agricultor.

- **Compatibilidad**

Las pruebas de compatibilidad demostraron que la aplicación puede ser instalada y ejecutada desde una gran variedad de dispositivos sin presentar problemas. La interfaz se adapta bien en diferentes resoluciones y configuraciones, considerando que, en un entorno agrícola, los dispositivos utilizados por los usuarios pueden variar, esto permite que la aplicación se adapte bien a cualquier dispositivo y pueda convertirse en una herramienta útil para la clasificación del plátano para los productores.

## Capítulo VI

### 6 Conclusiones Y Recomendaciones

#### 6.1 Conclusiones

El desarrollo de esta aplicación móvil requirió un exhaustivo análisis bibliográfico para fundamentar los antecedentes históricos de la gestión documental en aplicaciones móviles y las integraciones con modelos de machine learning. Gracias a este análisis, se pudieron seleccionar las herramientas y arquitecturas más beneficiosas para el proyecto integrador, garantizando calidad, eficiencia productiva y reducción de pérdidas económicas para los productores de plátano barraganete.

La implementación de la aplicación tiene un impacto significativo en la productividad agrícola, ya que reduce el tiempo de clasificación de plátanos y aumenta la eficiencia en la selección de frutas aptas para exportación. Esto se traduce en una disminución de pérdidas económicas por clasificación errónea, mejorando la calidad del producto final. Además, la interfaz de la aplicación fue diseñada considerando la accesibilidad y facilidad de uso para los trabajadores agrícolas, lo que les permite utilizarla de manera efectiva sin necesidad de una capacitación técnica exhaustiva. La adaptación de la aplicación a diferentes resoluciones de pantalla y condiciones de uso refuerza su utilidad en el campo, lo que la convierte en una herramienta valiosa para mejorar los procesos de clasificación de plátanos en el sector agrícola.

La aplicación desarrollada para la clasificación de plátanos ha demostrado un rendimiento sobresaliente al lograr clasificar correctamente el 80% de las imágenes de prueba, superando así el criterio de éxito inicial del 75%. Su tiempo de respuesta inferior a 1 segundo para la carga y clasificación de imágenes, tanto en tiempo real como en imágenes previamente capturadas, la posiciona como una excelente herramienta para su implementación en el entorno

agrícola. Por otro lado, la alta compatibilidad y rendimiento estable de la aplicación en diferentes dispositivos y sistemas operativos, sin afectar el funcionamiento del hardware, asegura su uso en una amplia gama de equipos en el entorno de trabajo.

Finalmente, la emulación del entorno de trabajo de los productores de plátano permitió constatar los beneficios que esta aplicación obtuvo en el campo laboral agrícola. La aplicación facilita la clasificación precisa del plátano, determinando si es apto para exportación o si debe ser considerado como rechazo.

## **6.2 Recomendaciones**

Se requiere tener en cuenta las siguientes recomendaciones para seguir promoviendo el correcto funcionamiento de la aplicación móvil:

Se recomienda a la Universidad Laica Eloy Alfaro de Manabí Extensión El Carmen continúe promoviendo la implementación de tecnologías en el campo agrícola y brindando apoyo a las carreras de informática a través de capacitaciones para estudiantes y docentes. Dado el avance acelerado de la tecnología, mantener los conocimientos actualizados resulta de suma importancia para estar a la vanguardia en este ámbito.

Se recomienda proporcionar capacitaciones personalizadas a los productores de plátano sobre el uso de la aplicación móvil. Es crucial tener en cuenta que esta aplicación representa solo el inicio de los cambios que se avecinan con el paso del tiempo, por lo que es esencial comenzar a familiarizarse con las tecnologías emergentes y estar abiertos a su integración en el ámbito agrícola.

Finalmente, es recomendable promover de manera general el desarrollo de modelos de inteligencia artificial en diversos ámbitos, incluyendo la agricultura, industrias y empresas. La implementación de inteligencia artificial ofrece numerosos beneficios a corto y largo plazo, por

lo que fomentar su desarrollo resulta clave para potenciar el crecimiento y la eficiencia en distintos sectores.

## BIBLIOGRAFÍA

- Baranwal, A., Khatri, A., & Baranwal, T. (2019). *What's New in TensorFlow 2.0: Use the new and improved features of TensorFlow to enhance machine learning and deep learning*. Packt Publishing Ltd.
- Beltrón Cedeño, C., Sánchez Briones, A., & Ortiz Torres, M. (2018). *El fortalecimiento de la comercialización del plátano mediante formas asociativas. Caso de estudio el cantón el Carmen de la provincia de Manabí*. Caribeña de Ciencias Sociales.
- Bernal, P. P. (2018). *La investigación en Ciencias Sociales: Técnicas de recolección de la información*. Universidad Piloto de Colombia.
- Bobadilla, J. (2021). *Machine Learning y Deep Learning: Usando Python, Scikit y Keras*. Ediciones de la U.
- Camboa, J. Z. (2018). Evolución de las Metodologías y Modelos utilizados en el Desarrollo de Software. *INNOVA Research Journal*. 3(10), 20-33.
- Cuevas Jiménez, E. (2021). *Introducción al Machine Learning con MATLAB*. Marcombo.
- Domínguez Mínguez, T. (2021). *Visión artificial: Aplicaciones prácticas con OpenCV - Python*. Marcombo.
- Duque Domingo, J., Gómez García-Bermejo, J., & Zalama Casanova, E. (2024). *Visión Artificial. Componentes de los sistemas de visión y nuevas tendencias en Deep Learning*. Ra-Ma.
- Erazo Narváez, C. (2023). *Diseño de un sistema embebido de monitoreo por visión artificial que permita medir el grado de madurez de las frutas*. Universidad Técnica de Manabí.

- Garcés, L., & Egas, L. (2015). Evolución de las Metodologías de Desarrollo de la Ingeniería de Software en el Proceso de la Ingeniería de Sistemas. *Revista Científica y Tecnológica UPSE. Vol. 1, No.3.*
- Hadida, S., & Troilo, F. (2020). La agilidad en las organizaciones: trabajo comparativo entre metodologías ágiles y de cascada en un contexto de ambigüedad y transformación digital. *CEMA Working Papers: Serie Documentos de Trabajo, 756, Universidad del CEMA.*
- Joyanes Aguilar, L. (2022). *Computación en la nube 2ed.* España: Marcombo.
- McCarthy, J. (2007). *The History of Artificial Intelligence.* Stanford University.
- Mirjalili, V., & Raschka, S. (2020). *Python Machine Learning.* Marcombo.
- Montoya Vélez. (2022). *Ficha técnica plátano de exportación.* Obtenido de [https://montoyavelez.com/wp-content/uploads/2023/06/FICHATECNICA\\_PLATANO.pdf](https://montoyavelez.com/wp-content/uploads/2023/06/FICHATECNICA_PLATANO.pdf)
- Norman, A. T. (2019). *Aprendizaje automático en acción: Un libro para el lego, guía paso a paso para los novatos.* Tektime.
- Pérez Borrero, I., & Gegúndez Arias, M. (2021). *Deep learning: fundamentos, teorías y aplicación.* España: Universidad de Huelva.
- Pineda Pertuz , C. M. (2022). *Aprendizaje automático y profundo en python.* Ra-Ma Editorial.
- Puetate, G., & Ibarra, J. L. (2020). *Aplicaciones Móviles Híbridas.* Centro de publicaciones PUCE.
- Rouhiainen, L. (2018). *Inteligencia artificial.* Madrid: Alienta Editorial.
- Royce, W. W. (1987). Managing the development of large software systems: concepts and techniques. In Proceedings of the 9th international conference on Software Engineering. *California: IEEE Computer Society Press, 328-338.*

- Rungta, K. (2019). *TensorFlow in 1 Day: Make your own Neural Network*. Publishdrive.
- Russel, S., & Norving, P. (2022). *Artificial Intelligence: A Modern Approach (4th ed)*. Pearson Education.
- Sánchez Reina, R. (2023). *El futuro de la IA según ella misma*.
- Schwalbe, K. (2022). *Information technology project management (10th ed)*. Cengage Learning.
- Soria Olivas, E., Sánchez-Montañes Isla, M. A., Gamero Cruz, R., & Castillo Caballer, B. (2023). *Sistemas de Aprendizaje Automático*. Ra-Ma Editorial.
- Tapia Méndez, E., Morales Hernández, L., Cruz Albarrán, I., & Tovar Arriaga, S. (2023). Uso de aprendizaje profundo para detección de maduración en plátanos. *Revista Mexicana de Ingeniería Agrícola*, 12(2), 405-412.
- Torres, J. (2020). *Python Deep Learning: Introducción práctica con Keras y TensorFlow 2*. Alpha Editorial.
- Torres, M., Salazar, F. G., & Paz, K. (2019). *Métodos de recolección de datos para una investigación*. Obtenido de [http://fgsalazar.net/LANDIVAR/ING-PRIMERO/boletin03/URL\\_03\\_BAS01.pdf](http://fgsalazar.net/LANDIVAR/ING-PRIMERO/boletin03/URL_03_BAS01.pdf)
- Turing, A. M. (1950). Computing Machinery and Intelligence. *Mind*, 59(236), 433-460.
- Valbuena, R. (2021). *Inteligencia Artificial: Investigación Científica Avanzada Centrada en Datos*.
- Villalba, A., Requena, T., Solanilla, F., & Rangel, J. (2020). Prototipo de un sistema que determine el estado de madurez de un plátano utilizando Deep Learning y Visión Artificial. *Revista de Iniciación Científica*, 6, 49-53.

## ANEXOS

### Anexo A: Asignación de tutor



**Universidad Laica Eloy Alfaro de Manabí**

---

#### **Periodo 2023-2024(2) - Notificación de tutor asignado - TECNOLOGÍAS DE LA INFORMACIÓN 2022 (EL CARMEN)**

---

Estimad@  
Docente y Estudiante  
Uleam

En cumplimiento de lo establecido en la Ley, el Reglamento de Régimen Académico y las disposiciones estatutarias de la Uleam, por medio de la presente se oficializa la dirección y tutoría en el desarrollo del Trabajo de Integración Curricular del siguiente estudiante:

**Tema:** APLICACIÓN MÓVIL CON APRENDIZAJE AUTOMÁTICO PARA LA DETECCIÓN DE MADUREZ DEL PLÁTANO BARRAGANETE EN EL CANTÓN EL CARMEN

**Estado de aprobación:** Aprobado

**Tipo de titulación:** Trabajo de Integración Curricular

**Tipo de proyecto:** Trabajo de Integración Curricular se articula con proyectos y programas de Investigación.

**Apellidos y nombres del tutor asignado:** SINCHIGUANO CHIRIBOGA CESAR AUGUSTO

**Apellidos y nombres del estudiante:** MOLINA MACIAS MELANY MARIUXI

**Carrera:** TECNOLOGÍAS DE LA INFORMACIÓN 2022 (EL CARMEN)

**Periodo de inducción:** Periodo 2023-2024(2)

Sírvase cumplir con lo dispuesto en el Manual de Procedimientos de TITULACIÓN DE ESTUDIANTES DE GRADO BAJO LA UNIDAD DE INTEGRACIÓN CURRICULAR: <https://departamentos.uleam.edu.ec/gestion->

*Anexo A Asignación de tutor 1*



## Universidad Laica Eloy Alfaro de Manabí

---

### Periodo 2023-2024(2) - Notificación de tutor asignado - TECNOLOGÍAS DE LA INFORMACIÓN 2022 (EL CARMEN)

---

Estimad@  
Docente y Estudiante  
Uleam

En cumplimiento de lo establecido en la Ley, el Reglamento de Régimen Académico y las disposiciones estatutarias de la Uleam, por medio de la presente se oficializa la dirección y tutoría en el desarrollo del Trabajo de Integración Curricular del siguiente estudiante:

**Tema:** APLICACIÓN MÓVIL CON APRENDIZAJE AUTOMÁTICO PARA LA DETECCIÓN DE MADUREZ DEL PLÁTANO BARRAGANETE EN EL CANTÓN EL CARMEN

**Estado de aprobación:** Aprobado

**Tipo de titulación:** Trabajo de Integración Curricular

**Tipo de proyecto:** Trabajo de Integración Curricular se articula con proyectos y programas de Investigación.

**Apellidos y nombres del tutor asignado:** SINCHIGUANO CHIRIBOGA CESAR AUGUSTO

**Apellidos y nombres del estudiante:** OLMEDO ZAMBRANO ERIK JOEL

**Carrera:** TECNOLOGÍAS DE LA INFORMACIÓN 2022 (EL CARMEN)

**Periodo de inducción:** Periodo 2023-2024(2)

Sírvase cumplir con lo dispuesto en el Manual de Procedimientos de TITULACIÓN DE ESTUDIANTES DE GRADO BAJO LA UNIDAD DE INTEGRACIÓN CURRICULAR: <https://departamentos.uleam.edu.ec/gestion-aseguramiento-calidad/files/2023/04/Titulacion-de-Est.-Grado-Bajo-la-Unidad-Integr.-Curri.-V.2-1-1.pdf>.

*Anexo B Asignación de tutor 2*

## Anexo B: Reporte del sistema antiplagio



**CERTIFICADO DE ANÁLISIS**  
magister

# MOLINA OLMEDO

**2%**  
Textos sospechosos

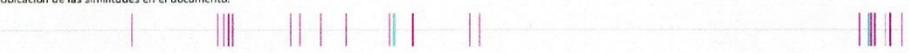
**2% Similitudes**  
< 1% similitudes entre comillas  
0% entre las fuentes mencionadas  
> < 1% Idiomas no reconocidos

Nombre del documento: MOLINA OLMEDO.pdf  
 ID del documento: 1c887e544db3f95571c72349e83d8cd9c96ee9  
 Tamaño del documento original: 3,84 MB

Depositante: CESAR SINCHIGUANO CHIRIBOGA  
 Fecha de depósito: 26/7/2024  
 Tipo de carga: Interface  
 fecha de fin de análisis: 26/7/2024

Número de palabras: 20.934  
 Número de caracteres: 147.637

Ubicación de las similitudes en el documento:



**Fuentes principales detectadas**

N°	Descripciones	Similitudes	Ubicaciones	Datos adicionales
1	<a href="https://montoyavelez.com/wp-content/uploads/2022/11/Aspiracion-1.pdf">montoyavelez.com</a> <small>https://montoyavelez.com/wp-content/uploads/2022/11/Aspiracion-1.pdf</small> 1 Fuente similar	< 1%		Palabras idénticas: < 1% (62 palabras)
2	Documento de otro usuario <small>x20x38</small> <small>El documento proviene de otro grupo</small>	< 1%		Palabras idénticas: < 1% (57 palabras)

**Fuentes con similitudes fortuitas**

N°	Descripciones	Similitudes	Ubicaciones	Datos adicionales
1	Tesis-Yadira-Genith.docx   Aplicación Web para la Gestion Documental <small>~2011e9</small> <small>El documento proviene de mi grupo</small>	< 1%		Palabras idénticas: < 1% (38 palabras)
2	repositorio.utn.edu.ec <small>http://repositorio.utn.edu.ec/bitstream/123456789/15095/2/04_TEL_010_TRABAJO_GRADO.pdf</small>	< 1%		Palabras idénticas: < 1% (40 palabras)
3	www.eumed.net   Bases metodológicas para potenciar la comercialización del plá... <small>https://www.eumed.net/revista/revista/2011/12/comercializacion-platano-morote.html</small>	< 1%		Palabras idénticas: < 1% (29 palabras)
4	docplayer.es   Machine Learning y Deep Learning - PDF Free Download <small>https://docplayer.es/217742100-Machine-learning-y-deep-learning.html</small>	< 1%		Palabras idénticas: < 1% (20 palabras)
5	revistas.utp.ac.pa <small>https://revistas.utp.ac.pa/index.php/nc/article/download/3155/3791</small>	< 1%		Palabras idénticas: < 1% (24 palabras)

**Fuentes mencionadas (sin similitudes detectadas)** Estas fuentes han sido citadas en el documento sin encontrar similitudes.

- 1 <https://www.ibm.com/es-es/topics/neural-networks>
- 2 <https://www.researchgate.net/figure/Figura-1-Descripcion-del-funcionamiento-de-una-red-neuronal>
- 3 <https://montoyavelez.com/wp>
- 4 <https://maruplast.com/producto/refractometro-portatil/>
- 5 <https://kylsant.com.ar/metodologias-de-gestion-de-proyectos-entendiendo-la-necesidad/>



## Anexo C Reporte del sistema antiplagio

## Anexo B: Fotografías

- Tutorías



*Anexo D Tutoría con Docente tutor*



*Anexo E Tutoría con Docente tutor para revisión de documentación*

- **Presentación de Proyecto en Concurso de Robótica e Inteligencia Artificial**

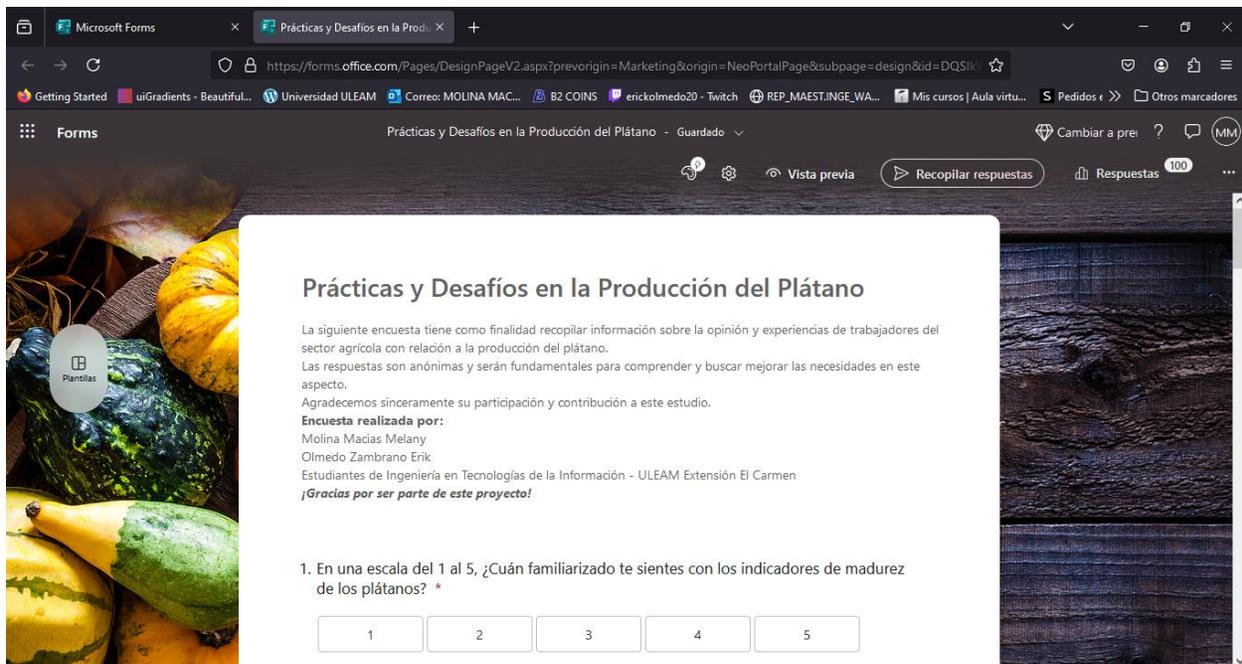


*Anexo F Fotografía con jurado del concurso*

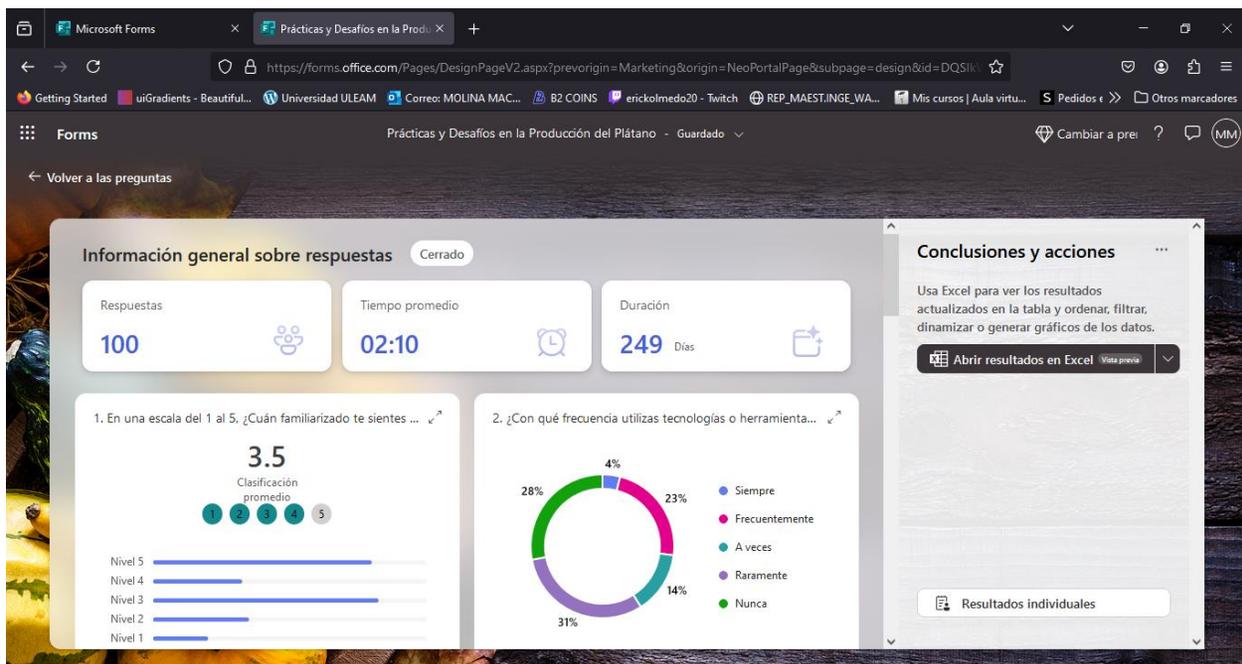


*Anexo G Demostración de uso de la aplicación móvil*

**Anexo C:** Evidencia de aplicación de encuestas y entrevistas



*Anexo H Encuesta aplicada a productores*



*Anexo I Resultados obtenidos de la encuesta*



*Anexo J Aplicación de entrevista*

## GLOSARIO

**Barraganete.** – Variedad de plátano producida y consumida en Ecuador.

**Dataset.** – Conjunto de datos utilizados para entrenar y evaluar modelos de aprendizaje automático.

**Empírico.** – Basado en la experiencia y observación directa, en lugar de la teoría.

**Hiperparámetro.** – Parámetro ajustable que permite controlar el proceso de entrenamiento de un modelo de aprendizaje automático.

**Kotlin.** – Lenguaje de programación moderno utilizado para el desarrollo de aplicaciones móviles Android.

**Overfitting (sobreajuste).** – Fenómeno en el que un modelo de aprendizaje automático se ajusta demasiado a los datos de entrenamiento y no generaliza bien a nuevos datos.

**Senescencia.** - Proceso de envejecimiento de la fruta.

**Sesgo.** – Error que produce una distorsión en los resultados de un estudio.

**Tensor.** – Estructura de datos multidimensional para representar datos en TensorFlow.

**TensorFlow.** – Plataforma de código abierto para aprendizaje automático desarrollada por Google.

**TFLite.** – Versión de TensorFlow optimizada para dispositivos móviles.