



**UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE GUAYAQUIL**

Carrera:

INGENIERÍA ELECTRÓNICA

Proyecto Técnico previo a la obtención del título de:

INGENIERO ELECTRÓNICO

Título:

**DISEÑO E IMPLEMENTACIÓN DE UN PROTOTIPO CLASIFICADOR
DE GRANOS DE CACAO USANDO
VISIÓN ARTIFICIAL Y MACHINE LEARNING**

Autores:

Bajaña Morán Luis Angel
Paladines Gallardo Josué Aarón

Tutor de Proyecto Técnico:

Periodo:

2020-2021

GUYAQUIL -ECUADOR

DECLARACIÓN DE RESPONSABILIDAD Y AUTORÍA

Nosotros, Paladines Gallardo Josué Aarón con cédula de identidad N°.0950882076 y Bajaña Morán Luis Ángel con cédula de identidad N°.1250882592, declaramos que este trabajo de titulación “DISEÑO E IMPLEMENTACIÓN DE UN PROTOTIPO CLASIFICADOR DE GRANOS DE CACAO USANDO VISIÓN ARTIFICIAL Y MACHINE LEARNING” ha sido implementado bajo los conceptos, análisis y conclusiones considerando los métodos de investigación, así como también el respeto a los derechos intelectuales a terceros, son de exclusiva responsabilidad de los autores; y la propiedad intelectual de la UNIVERSIDAD POLITÉCNICA SALESIANA.

Guayaquil, agosto del 2021



Josué Paladines Gallardo

C.I.:0950882076



Luis Bajaña Morán

C.I.: 1250882592

DECLARACIÓN DE CESIÓN DE DERECHOS DE AUTOR

Nosotros, Paladines Gallardo Josué Aarón con documento de identificación N°.0950882076 y Bajaña Morán Luis Ángel con cédula de identidad N°.1250882592, manifestamos nuestra voluntad y cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos autores del trabajo de grado intitulado: “DISEÑO E IMPLEMENTACIÓN DE UN PROTOTIPO CLASIFICADOR DE GRANOS DE CACAO USANDO VISIÓN ARTIFICIAL Y MACHINE LEARNING”, mismo que ha sido desarrollado para optar por el título de: Ingeniero Electrónico en Sistemas Industriales, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En aplicación a lo determinado en la Ley de Propiedad Intelectual, en mi condición de autor me reservo los derechos morales de la obra antes citada. En concordancia, suscribo este documento en el momento que hago entrega del trabajo final en formato impreso y digital a la Biblioteca de la Universidad Politécnica Salesiana.



Josué Paladines Gallardo

C.I.:0950882076



Luis Bajaña Morán

C.I.: 1250882592

DECLARACIÓN DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Por medio de la presente declaro que bajo mi dirección y asesoría fue desarrollado este trabajo de titulación “DISEÑO E IMPLEMENTACIÓN DE UN PROTOTIPO CLASIFICADOR DE GRANOS DE CACAO USANDO VISION ARTIFICIAL Y MACHINE LEARNING” realizado por los estudiantes LUIS ÁNGEL BAJAÑA MORÁN con cédula de identidad N°.1250882592 y JOSUÉ AARÓN PALADINES GALLARDO con cédula de identidad N°.0950882076, el mismo que cumple con los objetivos específicos y generales del diseño de aprobación y todos los requisitos pertinentes.

Guayaquil, agosto del 2021

A handwritten signature in blue ink, reading "David Larco", is written over a horizontal line.

Ing. Víctor Larco Torres, MSc.

Tutor

DEDICATORIA

Este trabajo de titulación está dedicado a Dios principalmente, por darme salud y fuerzas en cada paso que doy; A mis queridos padres, mis hermanas, mis abuelos y novia quienes me han acompañado y apoyado durante todo este tiempo el cual me ha llevado a ser un profesional, brindándome los recursos necesarios para culminar mi proyecto de estudio.

Agradecer a mi madre, quien con su esfuerzo me dio lo necesario para salir adelante, enseñándome que el trabajo digno engrandece el espíritu, y a mi padre por estar ahí dándome el soporte para superarme diariamente y demostrarme lo valioso que es pertenecer a esta familia.

Luis Ángel Bajaña Morán.

DEDICATORIA

La presente dedicatoria está dirigida principalmente a Dios, por bendecirme con este momento que me ha tomado mucho esfuerzo y sacrificio, por darle salud a mis padres y darme la dicha de que ellos presencien este logro.

A mi madre porque Dios se dio la sabiduría para que me direcciona a estudiar esta carrera que me apasiona mucho, por siempre estar presta a escucharme en los días buenos y más aún en los días malos, por ser mi única e irremplazable mejor amiga, por el amor que demuestra con sus actos y por ser mi muro incondicional. A mi padre por siempre orar conmigo y compartir sus vivencias, por el esfuerzo que hace día a día por la nuestra familia.

A mi hermano José Ricardo Vásquez Gallardo, que sirva como ejemplo para que se proponga metas y sean culminadas con resoluciones exitosas.

A mi hermano Andrés Paladines por brindarme el enfoque necesario en los momentos correctos para cumplir mis metas.

Josué Aarón Paladines Gallardo

AGRADECIMIENTO

Agradezco a Dios por haberme dado la fuerza para llegar a esta etapa de mi vida profesional, pudiendo así superar cada uno de los duros obstáculos que se han presentado durante todo este camino.

A mis padres Luis Bajaña y Mayra Morán quienes con su amor, paciencia y esfuerzo me han permitido llegar a cumplir hoy un sueño más, gracias por inculcar en mí el ejemplo de esfuerzo y valentía, de no temer a las adversidades porque Dios está conmigo siempre.

A mis hermanas Camila y Karla por su cariño y apoyo incondicional, durante todo este proceso, por estar conmigo en todo momento gracias. A toda mi familia porque con sus oraciones, consejos y palabras de aliento hicieron de mí una mejor persona y de una u otra forma me acompañan en todos mis sueños y metas.

Agradezco a mi director de tesis Ing. Víctor Larco quien con su experiencia, conocimiento y motivación nos orientó en la investigación.

Agradezco a mis segundos padres Lcdo. Washington Paucar Vecilla y Lcda. Ana María Falconi por el apoyo incondicional desde mis inicios en la educación básica.

Agradezco el apoyo del Ing. Álvaro Vaca Menes, quien fue uno de los primeros en dirigirme al área de la automatización industrial.

Agradezco también a mis compañeros y amigos que siempre estuvieron ahí para responder mis dudas; Joel Banguera, Josué Paladines, Hernán Montalvo, Juan Yanayaco, Xavier García, Diego Tandazo, Lowis Cáceres, Andrés Alarcón.

Agradezco también a unos de los primeros y mejores docentes que pude tener en mi vida universitaria, Ing. Jorge Fariño, gran persona, gran docente y buen amigo.

Agradezco a mi carrera, director Ing. Orlando Barcia y en su momento Lcda. Mariela Quispe, así mismo al Ex Vicerrector de la UPS Sede Guayaquil economista Andrés Bayolo por su colaboración y siempre estar presto a escuchar.

Luis Ángel Bajaña Morán.

AGRADECIMIENTO

El presente proyecto de titulación ha sido una gran bendición en todo sentido. por eso doy gracias a Dios por darme el privilegio de vivir esta experiencia como profesional y por darme las fuerzas para culminar mi etapa universitaria con éxito.

Agradezco eternamente a mis padres Pedro Paladines Muñoz y Blanca Gallardo Parreño, por estar presente y acompañarme en todos los momentos de triunfos y derrotas. Sobre todo, por el apoyo absoluto, dándome las palabras correctas para direccionarme en el camino de bien, enseñándome del amor de Dios.

A mi hermano Andrés Paladines y su esposa Angelina Román por siempre apoyarme a su manera y tenerme presente en cada oración familiar.

A mi abuelo, Walter Gallardo por tomarse el tiempo necesario de sentarse conmigo y contarme sus experiencias con el fin de enseñarme a discernir lo bueno y lo malo.

A mis abuelos Gloria Parreño y Pedro Paladines Valenzuela, que en donde quiera que estén, los recuerdo con mucho amor y me dan las fuerzas para salir adelante.

A mi familia materna, por siempre estar conmigo cuando lo necesité, en los buenos y sobre todo malos momentos.

Agradezco al Ing. Víctor Larco por tener la disposición de enseñarnos y guiarnos en el presente proyecto de titulación.

Agradezco a mis compañeros y amigos que estuvieron prestos a apoyarme en diferentes situaciones: Melanie Mendoza, Luis Bajaña, Joel Banguera, David Camino, Johan León, Raúl Saltos, Daniel Villagómez, Hernán Montalvo.

Josué Aarón Paladines Gallardo

RESUMEN

AÑO	ALUMNOS	TUTOR DEL PROYECTO	TEMA DEL PROYECTO
2021	Paladines Gallardo Josué Aarón, Bajaña Morán Luis Ángel	Ing. Víctor David Larco Torres MSc.	"DISEÑO E IMPLEMENTACIÓN DE UN PROTOTIPO CLASIFICADOR DE GRANOS DE CACAO USANDO VISIÓN ARTIFICIAL Y MACHINE LEARNING".

El presente trabajo de grado tiene como objetivo diseñar e implementar un prototipo clasificador de cacao usando Visión Artificial y Machine Learning.

El paso inicial fue entrenar una neurona mediante Teachable Machine (Plataforma de Google) para lograr identificar acorde a las características del grano del cacao su nivel de fermentación y asimismo ignorar otros elementos inherentes al target a analizar, una vez ya entrenada la neurona se procedía al análisis en tiempo real para después llegar a la clasificación.

La idea base de implementar estos tipos de conceptos en este tipo de actividades es demostrar que tan maleables pueden ser al momento de utilizarlos en áreas que aparentemente no estarían correlacionadas de manera directa con este nivel de tecnología.

En cuanto al sistema será una amalgama de herramientas tanto lógicas como físicas, ya que de manera estructural estará formado por motores servos, una cinta transportadora, una cámara, un sistema de led, un sensor infrarrojo y demás; en cuanto a los recursos lógicos se usará Python como lenguaje base y se emplearán librerías como Tkinter, Numpy, Tensorflow, entre otros.

Palabras claves: Machine Learning, Teachable Machine, Visión Artificial, neurona, Tkinter, Numpy, Tensorflow, Python, Motores Servos y Sensor Infrarrojo.

ABSTRACT

YEAR	STUDENTS	PRJ. DIRECTOR	SUBJECT
2021	Paladines Gallardo Josué Aarón, Bajaña Morán Luis Ángel	Ing. Víctor David Larco Torres MSc.	"DESIGN AND IMPLEMENTATION OF A COCOA GRAIN CLASSIFIER PROTOTYPE USING ARTIFICIAL VISION AND MACHINE LEARNING".

The objective of this degree project is to design and implement a cocoa classifier prototype using Artificial Vision and Machine Learning using open sources resources and technologies.

The initial step was to train a neuron using Teachable Machine to identify its fermentation level according to the characteristics of the cocoa bean and also ignore other elements inherent to the target to be analyzed, once the neuron was trained, the analysis was carried out in real time to then get to the classification The basic idea of implementing these types of concepts in these types of activities is to demonstrate how malleable they can be when used in areas that apparently would not be directly correlated with this level of technology.

As for the system, it will be an amalgam of both logical and physical tools, since in a structural way it will be made up of servo motors, a conveyor belt, a camera, a LED system, an infrared sensor and others; in terms of logic, Python will be used as the base language and libraries such as Tkinter, Numpy, Tensorflow, among others, will be used.

Keywords: Machine Learning, Teachable Machine, Artificial Vision, Neuron, Tkinter, Numpy, Tensorflow, Python, Servo Motors and Infrared Sensor.

ÍNDICE DE CONTENIDO

DECLARACIÓN DE RESPONSABILIDAD Y AUTORÍA.....	II
DECLARACIÓN DE CESIÓN DE DERECHOS DE AUTOR.....	III
DECLARACIÓN DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN... 	IV
DEDICATORIA	V
AGRADECIMIENTO	VII
RESUMEN.....	IX
ABSTRACT	X
ÍNDICE DE CONTENIDO	XI
ÍNDICE DE TABLAS.....	XIV
ÍNDICE DE FIGURAS.....	XV
INTRODUCCIÓN	1
EL PROBLEMA	3
1.1. Antecedentes	3
1.2. Importancia y alcance	4
1.3. Delimitación.....	5
1.3.1. Delimitación espacial	5
1.3.2. Delimitación temporal.....	5
1.3.3. Delimitación académica	5
1.4. Objetivos	5
1.4.1. Objetivo general	5
1.4.2. Objetivos específicos.....	5
FUNDAMENTOS TEÓRICOS	6
2.1. Cacao CCN-51 y Criollo.....	6
2.1.1. CCN-51	6
2.1.2. Criollo	7

2.2. Fermentación del cacao.....	8
2.3. Inteligencia Artificial	8
2.4. Visión artificial	9
2.5. Visión artificial en la fermentación de cacao.....	11
2.6. El modelo de color RGB.....	12
2.7. Procesamiento de imágenes por convolución	13
2.8. Machine Learning	13
2.9. Teachable Machine	15
2.10. Matriz de Confusión	15
2.11. Capa de Entrada y Salida.....	16
2.12. Equipos Tangibles (Hardware).....	18
2.12.1. Raspberry Pi	18
2.12.2. Cámara PI v2.....	19
2.12.3. Tiras led.....	19
2.12.4. Motor Servo.....	20
2.12.5. Banda transportadora.....	21
2.12.6. Sensor de Infrarrojo.....	21
2.12.7. Variador de Frecuencia	22
2.12.8. Selector dos posiciones de inicio/paro de proceso	23
12.13. Componentes Lógicos (Software).....	24
12.14. Lenguajes de Programación	24
2.14.1. Python	24
METODOLOGÍA	27
3.1. Diseño e Implementación del prototipo clasificador de granos de cacao	27
3.1.1. Selección del hardware.....	28
3.1.1.1.Diagrama eléctrico-electrónico de Prototipo	28
3.1.1.2.Cámara	29

3.1.1.3.Sistema de iluminación	30
3.1.1.4. Banda transportadora	31
3.1.2. Selección de Software	32
3.1.3. Implementación del prototipo	33
3.1.4. Procesos lógicos del prototipo.....	34
3.1.4.1. Fase I: Preprocesamiento de Información.....	34
3.1.4.2. Fase II: Proceso de aprendizaje del prototipo	37
3.1.4.3. Fase III: Proceso lógico para clasificación de granos de cacao	58
RESULTADOS.....	65
CONCLUSIÓN.....	69
RECOMENDACIONES.....	70
REFERENCIAS	71

ÍNDICE DE TABLAS

Tabla 1. Superficie, según producción y ventas de cacao (ESPAC, 2019).....	4
Tabla 2. Matriz de Confusión de Selección de Muestras	67

ÍNDICE DE FIGURAS

Figura 1. Cacao CCN-51 (Barrezueta & González, 2017).....	7
Figura 2. Cacao criollo (Barrezueta & González, 2017).....	7
Figura 3. Aplicación de visión por computadora para detección de placas (Medium, 2019)	10
Figura 4. Grano de Cacao Fermentado (SPS Export, 2021)	11
Figura 5. Granos de cacao dentro de prototipo	11
Figura 6. Coordenadas de color (Hernández, Alejos, & Cázares, 2019)	13
Figura 7. Redes Neuronales (Ruiz & Basualdo, 2001)	16
Figura 8. Redes Neuronales para clasificación de granos.....	17
Figura 9. Placa Raspberry Pi (Pastor, 2018)	18
Figura 10. Cámara PI V2 (Brico Geek , n.d.)	19
Figura 11. Clasificación y características de las Tiras led (Grealtec, n.d.)	20
Figura 12. Motor Servo de modelado (La electrónica, n.d.)	21
Figura 13. Banda Transportadora (Vulcabar, n.d.)	21
Figura 14. Sensor Infrarrojo (Electronilab, n.d.).....	22
Figura 15. Variador de frecuencia 1 HP, modelo ATV312 (Schneider Electric, 2021)	23
Figura 16. Selector dos posiciones Siemens	23
Figura 17. Diagrama eléctrico de prototipo	29
Figura 18. Placa de Raspberry Pi (Rodríguez De Luis, 2018).....	29
Figura 19. Cámara Raspberry Pi V2 (EC Robotics , s.f.)	30
Figura 20. Sistema de iluminación interna.....	31
Figura 21. Perspectiva superior de banda transportadora	32
Figura 22. Diseño del prototipo propuesto.....	33
Figura 23. Posicionamiento de granos en las bandas trasportadoras	35
Figura 24. Recopilación de imágenes al Teachable Machine	38

Figura 25. Establecer parámetros predeterminados	39
Figura 26. Preparación del modelo para entrenamiento.....	39
Figura 27. Acercamiento de un grano de cacao fermentado	40
Figura 28. Prueba y error en identificación de granos de cacao fermentado	40
Figura 29. Acercamiento de un grano de cacao no fermentado	41
Figura 30. Prueba y error en identificación de granos de cacao no fermentado ...	41
Figura 31. Acercamiento de un grano de cacao parcialmente fermentado	42
Figura 32. Prueba y error en identificación de granos de cacao parcialmente fermentado.....	42
Figura 33. Acercamiento de banda transportadora vacía.	43
Figura 34. Prueba y error en identificación de banda vacía.....	43
Figura 35. Acercamiento de varios objetos en el proceso.....	44
Figura 36. Prueba y error en identificación de varios objetos.....	44
Figura 37. Acercamiento de una piedra	45
Figura 38. Prueba y error en identificación de una piedra	45
Figura 39. Acercamiento de una hoja	45
Figura 40. Prueba y error en identificación hojas	46
Figura 41. Gráfica de precisión.....	46
Figura 42. Gráfica de pérdidas	47
Figura 43. Matriz de composiciones	47
Figura 44. Pantalla principal de la Raspberry	48
Figura 45. Ventana general de archivos referenciales	49
Figura 46. Ventana en Python de “CapturaFotos.py” (1)	49
Figura 47. Ventana en Python de “CapturaFotos.py” (2)	50
Figura 48. Ventana en Python de “CapturaFotos.py” (3)	50
Figura 49. Ventana en Python de “CapturaFotos.py” (4)	51
Figura 50. Ventana en Python de “CapturaFotos.py” (5)	51

Figura 51. Muestras de la categoría “Piedra”.....	52
Figura 52. Recopilación de datos en la nube.....	53
Figura 53. Plataforma Teachable Machine	53
Figura 54. Neurona en preparación.....	54
Figura 55. Opciones para exportar modelo Tensorflow.js.....	55
Figura 56. Opciones para exportar modelo Tensorflow.....	55
Figura 57. Opciones para exportar modelo Tensorflow Lite	56
Figura 58. Propiedades del archivo	57
Figura 59. Diagrama de flujo del funcionamiento base del prototipo.....	58
Figura 60. Carga del modelo entrenamiento al script desarrollado	59
Figura 61. Captura de imágenes desde la cámara del Raspberry Pi	59
Figura 62. Pasos requeridos para la conversión de la imagen a un array.....	59
Figura 63. Procesos requeridos para generar la predicción estipulada	59
Figura 64. Procesos requeridos para generar la predicción estipulada de los granos de cacao fermentados	60
Figura 65. Procesos requeridos para generar la predicción estipulada de los granos de cacao no fermentados	60
Figura 66. Procesos requeridos para generar la predicción estipulada de los granos de cacao parcialmente fermentados	61
Figura 67. Procesos requeridos para generar la predicción estipulada del proceso cuando no hay presencia de objetos	61
Figura 68. Procesos requeridos para generar la predicción estipulada “No se puede Clasificar”	61
Figura 69. Procesos requeridos para generar la predicción estipulada “Piedra”... ..	62
Figura 70. Procesos requeridos para generar la predicción estipulada “Hoja”	62
Figura 71. Interfaz desarrollada bajo Tkinter.....	63
Figura 72. Cálculo de porcentaje por clasificación total de muestras.....	63
Figura 73. Comando para mostrar “ESTADO DEL CACAO” en la interfaz.....	63

Figura 74. Comando para mostrar “FERMENTACIÓN ALTA” en la interfaz ...	63
Figura 75. Comando para mostrar “FERMENTACIÓN MEDIA” en la interfaz.	64
Figura 76. Comando para mostrar “FERMENTACIÓN BAJA” en la interfaz....	64
Figura 77. Comando para mostrar “TOTAL MUESTRAS” en la interfaz.....	64
Figura 78. Maquetado para GUI (del inglés graphical user interface).....	64
Figura 79. Detección de un grano de cacao fermentado	65
Figura 80. Detección de un grano de cacao no fermentado	65
Figura 81. Detección de un grano de cacao parcialmente fermentado	66
Figura 82. Detección de objetos que no se pueden clasificar	66
Figura 83. Detección de una piedra.....	67
Figura 84. Detección de una hoja.....	67

INTRODUCCIÓN

Antes de cualquier procesamiento en productos terminados, los granos de cacao deben someterse a un tratamiento post cosecha. La fermentación es una de las operaciones más importantes de este proceso (León, Abderrahim, Nuñez, Arribas, & Condezo, 2016), porque mejora la calidad final del producto y los procesadores siempre exigen que los granos de cacao estén bien fermentados, ya que asegura el desarrollo de los precursores del aroma y el sabor del cacao.

El grado de fermentación está fuertemente correlacionado con atributos de calidad del cacao como azúcares reductores, aminoácidos libres y pH del grano (Yro, N'zi, & Kpalma, 2018). Así mismo, una buena fermentación contribuye a la reducción del amargor y astringencia del cacao.

Generalmente, se utiliza una “prueba de corte” para evaluar el grado de fermentación de un grano de cacao a granel (Parra, Negrete, Llaguno, & Vega, 2018). Consiste en cortar un frijol a lo largo y analizar visualmente su color interno a la luz del día. Al final de este análisis, los granos se dividen según su grado de fermentación en tres clases diferentes: los granos bien fermentados (BF) se caracterizan por el color marrón, mientras que los colores violeta y gris oscuro indican respectivamente granos parcialmente fermentados (PF) y sin fermentar (SF) (Teye, y otros, 2015). En cada clase, se cuentan los granos y luego se estima su porcentaje de acuerdo con 300 granos examinados. Este sistema de clasificación visual es el método estándar que se utiliza actualmente para evaluar la calidad y aceptabilidad del cacao comercializable. Sin embargo, este enfoque es cualitativo, tedioso y bastante subjetivo. Este método es muy limitado en la evaluación de defectos y color de los granos de cacao. Además, puede resultar ineficaz para grandes volúmenes de cacao en grano debido a errores humanos.

Para superar estas limitaciones, se han propuesto otros métodos de control de calidad como la espectrofotometría (Cádiz, y otros, 2020), la cromatografía líquida de alta resolución, la espectroscopia infrarroja por transformada de Fourier (Viera, 2018) y la formación de imágenes (León, Abderrahim, Nuñez, Arribas, & Condezo, 2016). Sin embargo, incluso si todos estos métodos de análisis son fiables y precisos, consumen mucho tiempo, son laboriosos, caros y requieren más

experiencia. Estos sistemas no pueden utilizarse para controles de rutina de la calidad de los granos de cacao comerciales. Por lo tanto, se requiere esencialmente un método rápido y confiable para clasificar los granos de cacao para el control de calidad.

La visión por computadora o visión artificial ha surgido en los últimos años como una tecnología confiable en la evaluación de la calidad de los productos agrícolas y alimentarios (Sandoval, 2017). La visión artificial combina el análisis de imágenes y las técnicas de aprendizaje automático para proporcionar una inspección automatizada. Es más económico, rápido, confiable y no destructivo (Angelia & Linsangan, 2018). Los sistemas de visión por ordenador se han utilizado con éxito para el control de calidad de productos como manzanas, tomates y arroz (Patrício & Rieder, 2018).

En la producción de cacao existe una enorme cantidad de tiempo empleado en el proceso de selección y clasificación de cacao CCN-51 y criollo, sumado a la inexacta medición de los niveles de fermentación, esto representa una necesidad para los pequeños productores de cacao ubicado en cantón de Pueblo Viejo en la provincia de Los Ríos, ya que esto impide el crecimiento competitivo de las micro empresas, sumado a los bajos niveles de satisfacción de sus principales clientes, lo que conlleva a pérdidas económicas y bajos ingresos.

Como se mencionó, el proceso para determinar los niveles de fermentación en los dos tipos de cacao presentan irregularidades y errores de clasificación debido a que es empírico y depende de la observación de los expertos y agricultores mediante el corte del grano de cacao durante la post cosecha, lo que genera que exista un ineficiente control de calidad debido a que, dependiendo del nivel de fermentación se puede obtener el color, aroma y sabor requerido por los clientes, lo que garantiza la venta del producto una vez concluya todo el proceso de producción.

Bajo este contexto, es necesario implementar un sistema que permita determinar y clasificar el grano de cacao de acuerdo con su nivel de fermentación de manera eficaz y eficiente, es por esta razón que se aplicará una de las ramas de la inteligencia artificial (IA), que permite la clasificación de variables mediante el análisis de imágenes y la aplicación de técnicas automatizadas de inspección, la cual se denominan Machine Learning y visión artificial (VA).

EL PROBLEMA

1.1. Antecedentes

La producción de cacao en Ecuador tiene lugar en 23 de las 24 provincias y se produce como "monocultivo" o en combinación con otras variedades. Las provincias costeras (Guayas, El Oro, Manabí, Los Ríos y Esmeraldas), son las que generan mayor aporte respecto al cultivo de cacao, en la región amazónica y en las provincias nororientales del Ecuador (Orellana, Sucumbíos y Napo). La superficie cultivada se ha incrementado en alrededor de 20.000 hectáreas de cacao doméstico en los últimos años, lo que ha estandarizado la superficie en dos o tres años de grandes proveedores de cacao.

Cabe señalar que la producción de cacao en Ecuador está dominada por productoras de cacao pequeñas (20 hectáreas (ha) o menos) y medianas (20-50 ha). Estas categorías cubren el 88% de todas las unidades de producción y el 73,4% del área cultivada, dato que provee el último Censo Nacional de Producción realizado en el año 2000.

En cuanto a la distribución relativa de la producción de cacao por tamaño de unidades producidas, muestra que el porcentaje de producción de "monocultivo" suele ser mayor en las explotaciones medianas y grandes (más de 50 ha). Por el contrario, la proporción de cacao como "monocultivo" es generalmente menor en las pequeñas productoras (hasta 20 hectáreas).

Esto se debe principalmente a los métodos empleados durante la producción o cultivo de cacao. En Ecuador existen dos tipos de cacao, el cacao criollo y el CCN-51, los cuales deben pasar por la evaluación de un experto en cacao durante la post cosecha. En este periodo el experto debe analizar el nivel de fermentación de los granos que se establecieron como muestra, el método en mención, que realizan las pequeñas productoras, no suele ser eficaz y su duración es extremadamente extensa, generando paralizaciones en la producción. Al no ser un método totalmente certero, existe la probabilidad de que el producto final de todo el lote producido, no se encuentre fermentado comprometiendo la disposición final de los granos de cacao, puesto que, un grano de cacao no fermentado produce amargura y astringencia impidiendo que se desarrolle el sabor característico del chocolate.

Bajo esta premisa, es necesario mejorar los métodos de selección de los granos de cacao de acuerdo con los niveles de fermentación que presentan, para aquellos los avances tecnológicos, como la visión por computadora o visión artificial, bajo la aplicación de Machine Learning, han aportado al empleo de técnicas de selección, que, para el presente trabajo, se ajusta a las necesidades de las pequeñas productoras de cacao.

1.2. Importancia y alcance

La importancia de este trabajo recae, sobre la aplicación de nueva tecnología en las pequeñas productoras de cacao en el cantón Pueblo Viejo, en la provincia de Los Ríos, siendo la segunda provincia con mayor producción en toneladas de cacao, en la región costa, debajo de la provincia del Guayas, además las ventas generadas según la tabla 1, indica que se vende casi en su totalidad la producción generada, por ende es necesario, mejorar los análisis de fermentación de los granos de cacao de forma eficiente, aminorando tiempos de producción, desecho de granos, y pérdida de clientela por no conformidades e incluso los costos de producción ya que un sistema clasificador de granos de cacao según su nivel de fermentación generará estandarización y automatización en el proceso en cuestión, provocando un impacto considerable en los ingresos de las pequeñas productoras de cacao.

Región y Provincia		SUPERFICIE (Has.)		PRODUCCIÓN (Tm.)	VENTAS (Tm.)
		Plantada	Cosechada		
TOTAL NACIONAL		601.954	525.435	283.680	275.798
REGIÓN SIERRA		80.058	69.309	40.610	39.067
REGIÓN COSTA		463.553	407.275	224.960	221.034
REGIÓN AMAZÓNICA		58.343	48.851	18.110	15.696
REGIÓN COSTA					
EL ORO	Solo	10.772	8.664	5.726	5.539
	Asociado	544	334	204	192
ESMERALDAS	Solo	66.924	52.995	22.591	21.024
	Asociado	1.793	1.602	491	475
GUAYAS	Solo	120.218	112.441	87.290	87.006
	Asociado	3.739	3.492	1.589	1.589
LOS RÍOS	Solo	112.019	103.397	62.079	60.365
	Asociado	15.900	13.500	4.889	4.859
MANABÍ	Solo	110.319	93.046	34.096	33.990
	Asociado	20.625	17.400	5.788	5.783
SANTA ELENA	Solo	667	402	216	213
	Asociado	34			

Tabla 1. Superficie, según producción y ventas de cacao (ESPAC, 2019)

1.3. Delimitación

1.3.1. Delimitación espacial

El proyecto será desarrollado en el cantón de Pueblo Viejo en la provincia de Los Ríos, Ecuador en el periodo 2020-2021.

1.3.2. Delimitación temporal

El presente trabajo será ejecutado en el cantón Pueblo Viejo, por motivos de seguridad dada la situación mundial por la pandemia (COVID-19), el diseño y la implementación del prototipo se realizará desde los hogares, además, debido a las pruebas de ensayo y error es necesario que el desarrollo del trabajo se efectúe en el cantón en mención, dada su cercanía con las pequeñas productoras de cacao en el sector, siguiendo todas las medidas de bioseguridad, a fin de tener una eficiente recolección de datos y un mejor desempeño del trabajo propuesto, el trabajo tiene un periodo de 4 meses desde su diseño hasta la implementación, iniciando en el mes de Octubre del 2020.

1.3.3. Delimitación académica

Por medio del diseño, implementación y desarrollo de un prototipo clasificador de cacao de acuerdo con su nivel de fermentación para el presente proyecto de titulación, se aplicarán los conocimientos técnicos además de los conocimientos empíricos, que se dictan durante toda la Carrera en disciplinas como las Redes Informáticas III, Teoría de Control III, Sistema Digitales I y II, Automatización Industrial I y II.

1.4. Objetivos

1.4.1. Objetivo general

Diseño e implementación de un prototipo clasificador de granos de cacao de acuerdo con el nivel de fermentación usando Visión Artificial y Machine Learning.

1.4.2. Objetivos específicos

- Diseñar y construir la maqueta del prototipo clasificador de granos de cacao fermentado.
- Configurar la Raspberry para capturar los fotogramas de los granos de cacao y enviarlos a la herramienta Teachable Machine.
- Obtener el modelo de aprendizaje automático y cargarlo a la Raspberry.

- Clasificar los granos de cacao de acuerdo con sus características.

FUNDAMENTOS TEÓRICOS

2.1. Cacao CCN-51 y Criollo

2.1.1. CCN-51

CCN-51 (Colección Castro Naranjal 51) fue desarrollado por el científico vegetal independiente Homero Castro en la década de 1960 en respuesta a la devastadora introducción de la escoba de bruja en Ecuador. Este árbol de cacao híbrido altamente productivo y resistente a enfermedades se usó para reemplazar variedades menos resistentes a enfermedades (Espinoza, 2019). Esta variedad comenzó a dominar la escena en las regiones productoras de cacao fino de Ecuador a fines de la década de 1990.

CCN-51 fue una solución a corto plazo construida para garantizar la supervivencia de la industria del cacao cuando se introdujo. Su ubicuidad es producto de un sistema que exige una alta productividad con énfasis en la consistencia, en lugar de centrarse en el sabor.

Pero con el crecimiento del chocolate artesanal y la industria del cacao fino, las demandas están cambiando. Los productores de chocolate artesanal están usando una métrica diferente para la calidad y quieren ver más diversidad en los sabores y sistemas de producción, así como valorar el bienestar de los agricultores (Barrezueta & González, 2017). Algunos actores de la industria ven al CCN-51 y otras variedades de cacao de alta eficiencia como una amenaza para la industria del cacao fino y la diversidad agrícola.

El cacao básico se comercializa dentro de un sistema que premia la cantidad en lugar de la calidad. Cuanto más producen los agricultores, más pueden vender para obtener ganancias. Los compradores garantizados también suelen ser menos propensos a discriminar en función del sabor o la calidad del cacao fino. Para muchos productores de cacao, invertir recursos en cultivar árboles menos productivos y resistentes a enfermedades sin un comprador garantizado, por el bien de la diversificación del cacao fino, simplemente no tiene sentido económico. En cuanto a su apariencia física se lo podrá visualizar en la Figura 1.



Figura 1. Cacao CCN-51 (Barrezueta & González, 2017)

2.1.2. Criollo

Los investigadores genéticos (Barrezueta & González, 2017) han comparado el Criollo Antiguo de América Central y lo encuentran estrechamente relacionado con el Criollo de América del Sur. Su análisis de RFLP y microsatélites revela una alta homocigosidad / baja diversidad genética, lo que sugiere que probablemente se originó en unos pocos árboles de cacao en América del Sur que luego pueden haber sido diseminados por antiguos viajeros hacia el norte. De hecho, los árboles Criollos Antiguos están más los árboles de la Amazonía Colombo-Ecuatoriana de otro Amazonas de América del Sur, lo que respalda la idea de que dicha diversidad también infiere un punto de origen de la especie.

En comparación con otras cepas, Criollo parece poseer menos polifenoles, un compuesto ácido amargo que la fruta utiliza como defensa para protegerse de los depredadores (Samaniego, 2020). Asimismo, esta especie formada por componentes que incluyen flavonoides unidos a un azúcar para formar glucósido de antocianina, lo que explica parcialmente el color oscuro de la mayoría de las semillas de cacao, tal como se lo muestra en la Figura 2.



Figura 2. Cacao criollo (Barrezueta & González, 2017)

2.2. Fermentación del cacao

Los frutos maduros se elevan directamente del tallo del árbol del cacao, tienen paredes gruesas y contienen de 30 a 40 granos (semillas). Cada grano consta de dos cotiledones y un embrión (radícula) rodeado por una cubierta de semilla (testa) y está envuelto en una pulpa mucilaginosa, blanca y dulce que comprende aproximadamente el 40% del peso fresco de la semilla (Teneda, 2016). (De Vuyst & Weckx, 2016) aseguran que se requiere un proceso de secado y fermentación microbiana para iniciar la formación de los precursores del sabor del cacao.

Las semillas cosechadas se dejan inmediatamente someterse a una fermentación natural durante la cual la acción microbiana sobre la pulpa mucilaginosa produce etanol y ácidos, además de liberar calor. La difusión de estos metabolitos desencadena reacciones bioquímicas complejas en los cotiledones (Arias, 2019). La testa proporciona una barrera para la penetración del ácido en el grano y la difusión de teobromina, cafeína y polifenoles indeseables. El embrión de la semilla muere y los tejidos de la fruta se degradan, lo que facilita el secado de los granos. En el trabajo realizado por Melo y otros (2020) el proceso de secado se hizo al sol (usando techos móviles para protegerse de las lluvias tropicales) con un giro regular hasta que el contenido de agua sea inferior al 8%, lo que lleva de una a cuatro semanas.

Alternativamente, se utilizan secadores artificiales, pero es importante mantener la temperatura no superior a 60 ° C y secar lentamente (al menos 48 horas), tiempo durante el cual algunos ácidos en exceso pueden volatilizarse y ocurrir algo de oxidación, ambos beneficiosos (Erazo, 2019). Luego, los granos se pueden almacenar hasta por un año, pero eventualmente se envejecerá. En esta etapa, los granos cortados muestran un color púrpura debido a la presencia de antocianinas el cual es uno de los principales aspectos que se presentan durante el proceso de fermentación.

2.3. Inteligencia Artificial

El campo de la inteligencia artificial (IA) incorpora varios métodos, que se centran principalmente en resolver problemas que son difíciles para las computadoras, pero aparentemente fáciles para los humanos (Collins & Moons, 2019). Quizás la clase más importante de estas tareas pertenece a los problemas de aprendizaje. Para Ullah y otros (Ullah, Al-Turjman, Mostarda, & Gagliardi, 2020) consideran que existen varios aspectos algorítmicos de los problemas de aprendizaje se abordan en el

campo del Machine Learning (ML), que evolucionó a partir del estudio del reconocimiento de patrones en el contexto de la IA. El ML moderno aborda una variedad de escenarios de aprendizaje, que se ocupan del aprendizaje de los datos, por ejemplo, el aprendizaje supervisado (clasificación de datos) y no supervisado (agrupación de datos), o de interacción, como el aprendizaje reforzado (de la Hoz & Fontalvo, 2019). La IA moderna establece, como su objetivo final, el diseño de un agente inteligente que aprende y prospera en entornos desconocidos. Los agentes artificiales que son inteligentes en un sentido general, humano, deben tener la capacidad de abordar todos los problemas individuales abordados por el aprendizaje automático y otras ramas más especializadas de la IA (Greene, Hoffmann, & Stark, 2019). En consecuencia, requerirán una combinación compleja de técnicas.

En su ámbito más amplio, el campo moderno de la inteligencia artificial (IA) abarca una amplia variedad de subcampos. La mayoría de estos subcampos se ocupan de la comprensión y la abstracción de aspectos de diversas capacidades humanas que se describirían como inteligentes, e intentan realizar las mismas capacidades en las máquinas.

La inteligencia humana, en gran medida, se basa en el conocimiento. Se puede acumular conocimientos, razonar sobre ellos y utilizarlos para tomar las mejores decisiones, por ejemplo, en el contexto de la resolución de problemas y la planificación. Un aspecto de la IA intenta formalizar ese razonamiento lógico, la acumulación de conocimientos y la representación del conocimiento, a menudo basándose en la lógica formal, la mayoría de las veces en la lógica de primer orden.

Una clase particularmente importante de problemas centrales para la IA y relacionados con la adquisición de conocimiento, involucra la capacidad de la máquina para aprender a través de la experiencia. Esta característica se enfatizó en los primeros días de la IA, y el campo derivado del aprendizaje automático (ML) ahora se presenta como posiblemente el aspecto más exitoso (o derivado) de la IA

2.4. Visión artificial

En la actualidad se dispone de técnicas fiables para calcular con precisión un modelo 3D parcial de un entorno a partir de miles de fotografías que se superponen parcialmente. Dado un conjunto suficientemente grande de vistas de un objeto o fachada en particular, se pueden crear modelos de superficie 3D densos y precisos

utilizando la visión por estéreo computarizado. Es posible rastrear a una persona que se mueve en un contexto complejo, donde se espera un éxito moderado, intentar encontrar y nombrar a todas las personas en una fotografía usando una combinación de detección y reconocimiento de rostro, ropa y cabello. Sin embargo, a pesar de todos estos avances, el sueño de que una computadora interprete una imagen al mismo nivel que una de dos años sigue siendo esquivo. La complejidad acerca de esta tecnología se debe a que la visión es un problema inverso, en el que se pretende recuperar algunas incógnitas ante una información insuficiente para concretar completamente la solución. Por tanto, es necesario recurrir a modelos probabilísticos y basados en la física para eliminar la ambigüedad entre posibles soluciones.

La VA se utiliza hoy en día en una amplia variedad de aplicaciones del mundo real, que incluyen:

- Imágenes médicas: registrar imágenes preoperatorias e intraoperatorias o realizar estudios a largo plazo de la morfología del cerebro de las personas a medida que envejecen.
- Reconocimiento de huellas dactilares y biometría: para autenticación de acceso automático y aplicaciones forenses.
- Reconocimiento óptico de caracteres (ROC): lectura de códigos postales escritos a mano en letras y reconocimiento automático de matrículas, tal como se lo muestra en la Figura 3.

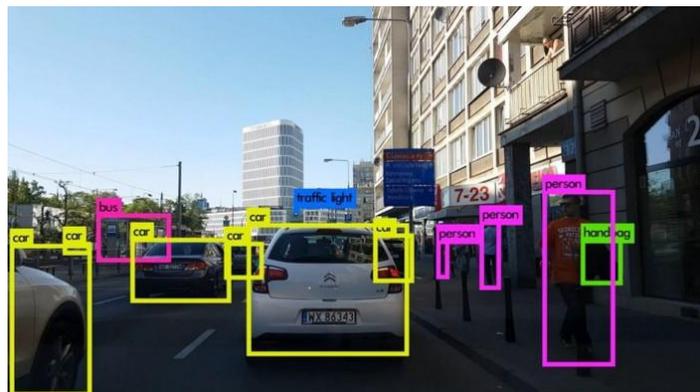


Figura 3. Aplicación de visión por computadora para detección de placas (Medium, 2019)

2.5. Visión artificial en la fermentación de cacao

El control de calidad y la seguridad alimentaria son preocupaciones fundamentales de los fabricantes de alimentos, los gobiernos y los consumidores porque ha habido muchos brotes de enfermedades en los últimos años. Debido al procesamiento en la fabricación de granos de cacao, incluido el tratamiento térmico y la eliminación del exceso de humedad, es comparativamente menos probable una enfermedad transmitida por los alimentos de los productos de chocolate. Sin embargo, la industria del cacao, los dulces y el chocolate se enfrenta al desafío de garantizar que las materias primas, incluidos los granos de cacao, sean de alta calidad y seguras, tal como se lo refleja en la Figura 4, también se ve reflejada la aplicación de visión artificial en la detección de granos de cacao mostrado en la figura 5.



Figura 4. Grano de Cacao Fermentado (SPS Export, 2021)

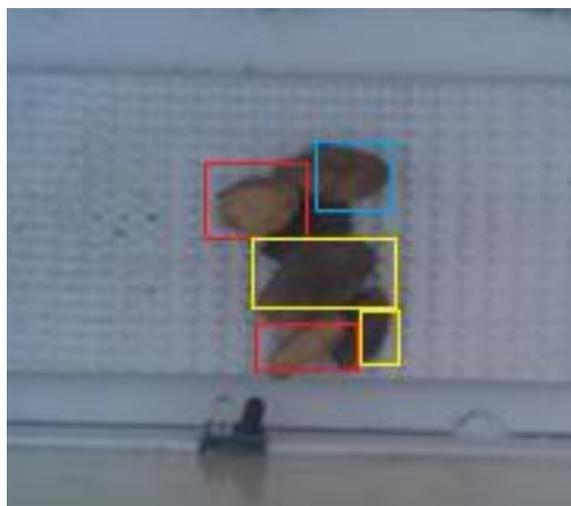


Figura 5. Granos de cacao dentro de prototipo

Los granos de cacao son semillas fermentadas espontáneamente y, como tales, están sujetas a un alto nivel de variabilidad según las condiciones de cultivo, la genética, la fermentación post cosecha y el secado de los granos de cacao antes de su envío o manipulación. Esta variabilidad puede tener un gran impacto en el producto de chocolate terminado, por lo tanto, es importante poder determinar si los granos de cacao están fermentados adecuadamente, son de alta calidad y carecen de defectos (Humston, Knowles, McShea, & Synovec, 2010).

Las técnicas de visión artificial se han utilizado para la automatización de procesos en el sector agrícola debido a los beneficios obtenidos como la eficacia y la calidad (Arefi, Motlagh, & Khoshroo, 2011). Recientemente, varios autores se han centrado en algoritmos de visión artificial para determinar la calidad del cacao fermentado (Giraldo, Salazar, & Daza, 2016). Por tanto, es importante identificar qué algoritmos de visión artificial ya se han estudiado para el procesamiento de imágenes en la fermentación del cacao y cuáles son las características físicas y químicas de los granos de cacao identificados.

2.6. El modelo de color RGB

El color de un píxel se compone de tres componentes; rojo, verde y azul (RGB), descritos por sus intensidades correspondientes (Plaza & Cardozo, 2018). Los componentes de color también se conocen como canales de color o planos de color. Cada color primario puede tomar un valor de intensidad que va desde 0 (más bajo) a 1 (más alto). La mezcla de estos tres colores primarios a diferentes niveles de intensidad produce una variedad de colores. La colección de todos los colores obtenidos mediante una combinación lineal de rojo, verde y azul forma el espacio de color RGB en forma de cubo (Hernández, Alejos, & Cázares, 2019).

La esquina del cubo de color RGB que está en el origen del sistema de coordenadas corresponde al negro, mientras que la esquina del cubo que está diagonalmente opuesta al origen representa el blanco. La línea diagonal que conecta el blanco y el negro corresponde a todos los colores grises entre el blanco y el negro, que también se conoce como eje gris.

En el modelo de color RGB, se puede especificar un color arbitrario dentro del espacio de color cúbico mediante sus coordenadas de color: (r, g, b), como se muestra en la Figura 6.

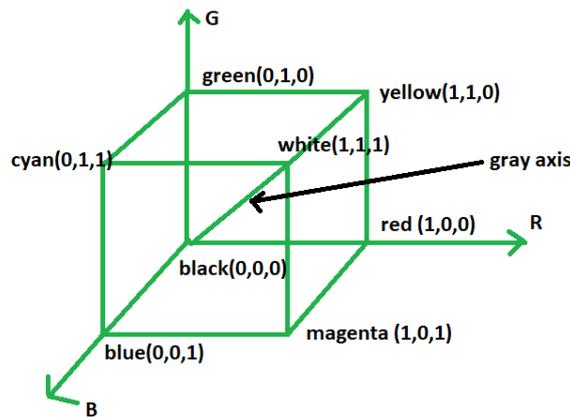


Figura 6. Coordenadas de color (Hernández, Alejos, & Cázares, 2019)

2.7. Procesamiento de imágenes por convolución

La convolución es una operación matemática simple que es fundamental para muchos operadores de procesamiento de imágenes comunes. La convolución proporciona una manera de "multiplicar" dos matrices de números, generalmente de diferentes tamaños, pero de la misma dimensionalidad, para producir una tercera matriz de números de la misma dimensionalidad (Cheng & Guo, 2017). Esto se puede utilizar en el procesamiento de imágenes para implementar operadores cuyos valores de píxeles de salida son combinaciones lineales simples de ciertos valores de píxeles de entrada.

En un contexto de procesamiento de imágenes, una de las matrices de entrada normalmente es solo una imagen de nivel de grilla. La segunda matriz suele ser mucho más pequeña y también bidimensional (aunque puede tener un solo píxel de grosor) y se conoce como kernel.

2.8. Machine Learning

Machine Learning (ML) es una aplicación de inteligencia artificial (IA) que proporciona a los sistemas la capacidad de aprender y mejorar automáticamente a partir de la experiencia sin estar programados explícitamente (Alpaydin, 2020). El aprendizaje automático se centra en el desarrollo de programas informáticos que pueden acceder a los datos y utilizarlos para aprender por sí mismos.

El proceso de aprendizaje comienza con observaciones o datos, como ejemplos, experiencia directa o instrucción, con el fin de buscar patrones en los datos y tomar mejores decisiones en el futuro basados en los ejemplos que proporcionan. El objetivo principal es permitir que las computadoras aprendan automáticamente sin intervención o asistencia humana y ajustar las acciones en consecuencia.

Una perspectiva más amplia (Alpaydin, 2010) sobre el Machine Learning es que ciertos procesos también incluyen el aprendizaje por refuerzo (Sutton y Barto, 1998), el cual está estrechamente relacionado con el aprendizaje realizado por entidades biológicas inteligentes. Partiendo de estos dogmas se puede decir que los algoritmos de aprendizaje se dividen en:

Algoritmos de aprendizaje automático supervisados: pueden aplicar lo aprendido en el pasado a nuevos datos utilizando ejemplos etiquetados para predecir eventos futuros. A partir del análisis de un conjunto de datos de entrenamiento conocido, el algoritmo de aprendizaje produce una función inferida para hacer predicciones sobre los valores de salida. El sistema puede proporcionar objetivos para cualquier entrada nueva después de una capacitación suficiente (Rodríguez & Camacho, 2018). El algoritmo de aprendizaje también puede comparar su salida con la salida prevista correcta y encontrar errores para modificar el modelo en consecuencia.

Algoritmos de aprendizaje automático no supervisados: se utilizan cuando la información utilizada para entrenar no está clasificada ni etiquetada. El aprendizaje no supervisado estudia cómo los sistemas pueden inferir una función para describir una estructura oculta a partir de datos no etiquetados (Guerreo, 2018). El sistema no encuentra el resultado correcto, pero explora los datos y puede extraer inferencias de conjuntos de datos para describir estructuras ocultas a partir de datos sin etiquetar.

Algoritmos de aprendizaje automático semi-supervisados: se encuentran en algún lugar entre el aprendizaje supervisado y no supervisado, ya que utilizan datos etiquetados y no etiquetados para el entrenamiento, generalmente una pequeña cantidad de datos etiquetados y una gran cantidad de datos no etiquetados. Los sistemas que utilizan este método pueden mejorar considerablemente la precisión del aprendizaje (Alpaydin, 2020). Por lo general, se elige el aprendizaje semi-supervisado cuando los datos etiquetados adquiridos requieren recursos calificados y relevantes para capacitarlos / aprender de ellos. De lo contrario, la adquisición de datos sin etiquetar generalmente no requiere recursos adicionales.

Algoritmos de aprendizaje automático de refuerzo: son un método de aprendizaje que interactúa con su entorno produciendo acciones y descubre errores

o recompensas. La búsqueda de prueba y error y la recompensa retrasada son las características más relevantes del aprendizaje por refuerzo (Rudkowskyj, 2019).

Este método permite que las máquinas y los agentes de software determinen automáticamente el comportamiento ideal dentro de un contexto específico para maximizar su rendimiento. Se requiere retroalimentación de recompensa simple para que el agente sepa qué acción es mejor; esto se conoce como señal de refuerzo.

2.9. Teachable Machine

Se define como Teachable Machine a una herramienta diseñada por Google que busca crear modelos de aprendizaje autómatas de manera sencilla, veloz e intuitiva. Para trabajar con esta plataforma es necesario incurrir a variados procesos como:

- Recopilación: en esta primera parte se va a recopilar y agrupar lo que se desee que el ordenador aprenda.
- Preparación: una vez ya recopilada la data se prepara el modelo y comprobar y se lo probará para determinar si la clasificación y la recolección se haya elaborado de la manera correcta.
- Exportar: finalmente se podrá exportar el modelado de tu proyecto de forma gratuita y online (Teachable Machine, s.f.).

2.10. Matriz de Confusión

Se conoce como un matriz de confusión a una de las métricas más intuitivas empleadas para encontrar el grado de exactitud de modelo, para su realización se debe realizar una matriz dónde se indicarán valores como verdaderos positivos, falsos positivos, falsos negativos y verdaderos negativos, vale destacar que estos valores nos permitirán conocer diversos parámetros que reflejarán el desempeño del equipo clasificador propuesto.

Entre los factores presentados están (Academática, 2017):

- Exactitud: este valor nos permitirá conocer el porcentaje de la data clasificada correctamente, para esto se tendrá que sumar los valores de verdaderos positivos y verdaderos negativos para posteriormente ese resultado dividirlo para el total de muestras.
- Tasa de error: indicará el porcentaje de data clasificada incorrectamente a partir de una muestra, para esto se tendrá que sumar los valores de

falso positivo y falso negativo y ese resultado dividirlo para el total de las muestras.

- Sensibilidad o exhaustividad: sirve para calcular el porcentaje de las muestras que pudo clasificar, se lo obtiene dividiendo los verdaderos positivos para el total de positivos.

2.11. Capa de Entrada y Salida

Se define como una capa de Entrada y Salida al conjunto interactivo de varias redes neuronales interconectadas entre sí, para llevar a cabo la realización de un proceso. En la Figura 7 se detallará los elementos básicos que compone una red neuronal (Ruiz & Basualdo, 2001).

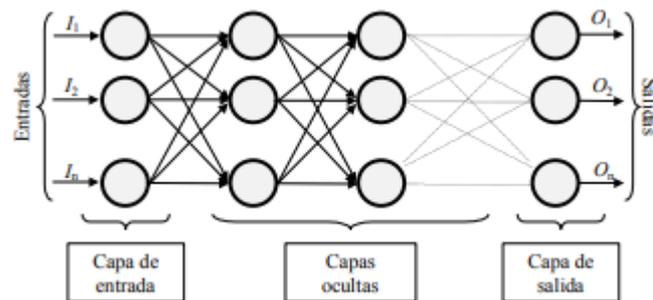


Figura 7. Redes Neuronales (Ruiz & Basualdo, 2001)

Este modelo de capas tiene como principio la interconectividad de capas de entrada, capas ocultas y las capas de salida. Por un lado, la capa de entrada son las encargadas de obtener la información y mediante un proceso interno y una serie de algoritmos enviarán toda esa información a las neuronas de procesamiento para que finalmente la capa de salida termine procesando esa información y finalmente dé el resultado requerido.

Para que este proceso pueda ser llevado a cabo se requiere la realización del siguiente algoritmo:

- La neurona debe tener un valor X que es la data recibida y W que es el peso que tiene la neurona y asimismo incluirá un factor que le dé prioridad a una neurona específica para que se active.
- Como primer paso cada neurona debe realizar la sumatoria de los valores capturados con el peso dado de la neurona para finalmente sumarle el factor de prioridad.

- Finalmente se activa una bandera dentro de la neurona y siguiendo como principio básico que si el resultado de la operación estipulada es mayor a un valor determinado esa neurona tendrá prioridad ante las otras, es decir, que será la primera en activarse.

Como trabajo futuro se podría proponer la implementación de una red neuronal, en dónde cada neurona tendrá cargada información de cada una de los targets a analizar, en este caso granos de cacao, piedras, hojas, varios y nada, una vez cargada toda esta procedería a realizar análisis comparativos mediante el uso de dos capas intermedias, en este punto se sugiere el uso de dos neuronas, la primera será para analizar los granos de cacao y de piedras y la otra para analizar, los otros elementos, tal cual se lo indica en la Figura 8. Se sugiere este método, ya que al analizar por separado las pepas de cacao y las rocas en análisis será más dedicado y exhaustivo lo que permitiría que el margen de error de la clasificación sea mucho menor.

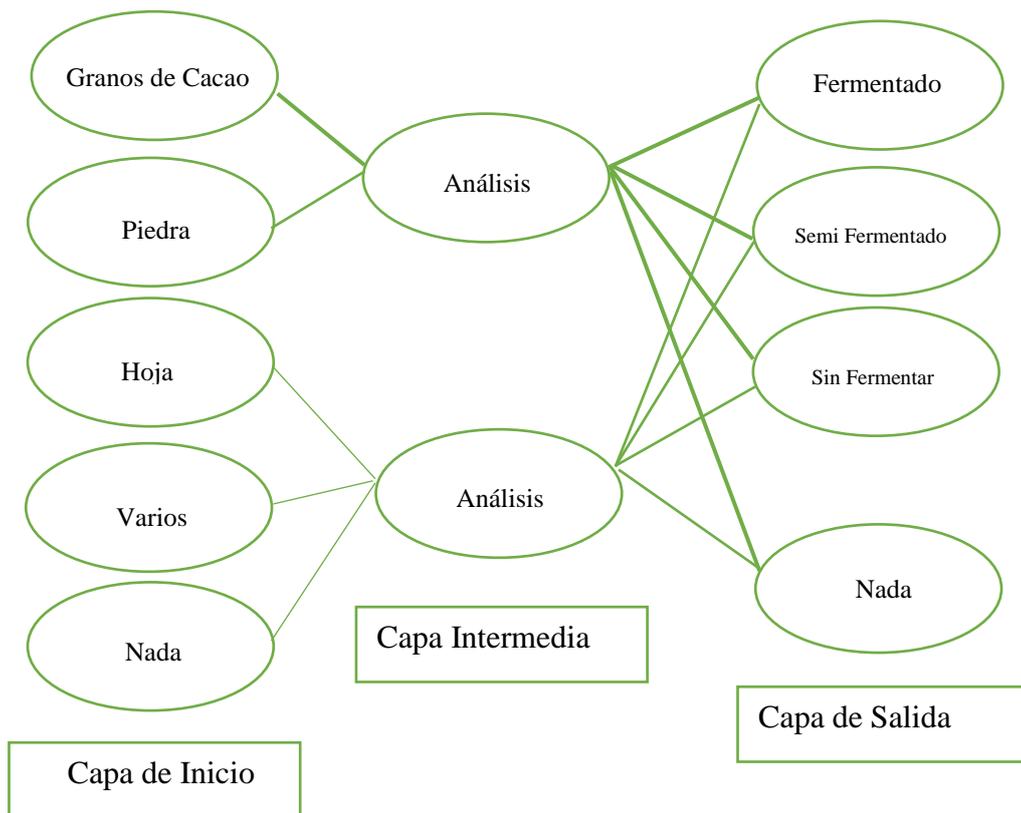


Figura 8. Redes Neuronales para clasificación de granos

2.12. Equipos Tangibles (Hardware)

Se define como hardware al conjunto de elementos físicos (tangibles) que está compuesto un equipo (Díaz Herrera, 2012). En este caso se emplearán: Raspberry pi, cámara Piv2, matrices de led, motor servo, bandas transportadoras y un sensor infrarrojo como gadgets base para la elaboración del prototipo.

2.12.1. Raspberry Pi

La página de este componente (Raspberry Pi Foundation, 2020), indica que, Raspberry Pi (Figura 9) es una computadora cuyo tamaño se asemeja a una tarjeta de crédito barata que se conecta a un monitor de computadora o TV y usa un teclado y mouse estándar. Es un pequeño y poderoso dispositivo que personas de todas las edades pueden usar para explorar la informática y aprender a programar en lenguajes como Scratch y Python. Puede hacer todo lo que se espera de una computadora de escritorio, desde navegar por la web y reproducir videos de alta definición, hasta crear hojas de cálculo, procesadores de texto y juegos. En cuanto a sus características principales se destacan:

- Sistema en chip: BCM2837
- CPU: ARM Cortex A53 de cuatro núcleos a 1,2 GHz
- GPU: Broadcom Video-core IV a 400 MHz
- Memoria: 1 GB LPDDR2-900 SDRAM
- Red: Ethernet de 10/100 Mbps,
- LAN inalámbrica 802.11n y Bluetooth 4.0



Figura 9. Placa Raspberry Pi (Pastor, 2018)

2.12.2. Cámara PI v2

La cámara PI v2 no es más que un módulo de alta calidad con una resolución aproximada de 8 megapíxeles, este equipo cuenta con un sensor de imagen marca Sony y modelo IMX219, el cual fue diseñado a medida para el empleo en estas placa electrónica, una de las ventajas que presenta este dispositivo es la capacidad de tomar imágenes de 3280 x 2464 píxeles y asimismo es capaz de capturar videos de una calidad media de 1080p30 (Electronicalab, s.f.), en cuanto a su diseño se lo reflejará en la Figura 10.

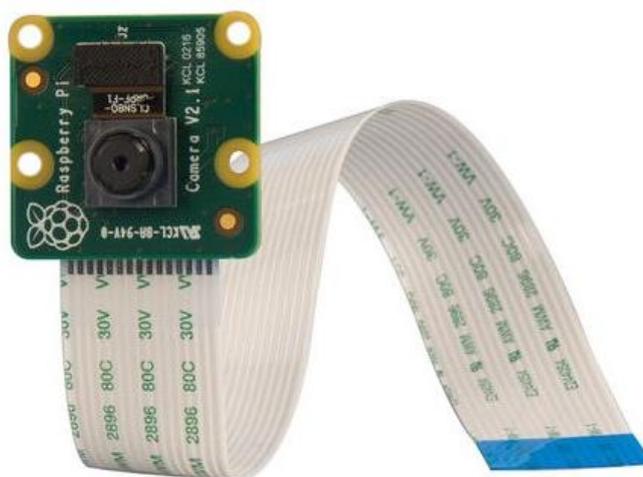


Figura 10. Cámara PI V2 (Brico Geek , n.d.)

2.12.3. Tiras led

Como término general se puede definir que las tiras leds son un sistema de iluminación que está montada sobre un circuito impreso sumamente flexible (Grealtec, s.f.), pero para poder entender de mejor manera el concepto de este gadget es justo y necesario ahondar desde qué es un led, pues para la Universidad de (Universidad de Coimbra, 2017), los led son diodos semiconductores que condescienden que la corriente sea unidireccional, es decir, que fluya en una única dirección, entre las ventajas de este módulo puede inferir están:

- Presenta un 60% de eficacia sobre los sistemas de iluminación de bajo consumo.
- Emite un fluctuante de 60 y 90% de calor emitido frente a sistemas tradicionales.

- Representa un alto grado de ahorro tanto en consumo como en mantenimiento.

Otro punto para resaltar de las tiras leds es que es que en el meta actual existen tres tipos de tiras, las cuales varían de acuerdo con el chip que este emplee ya sea: SMD3528, SMD5050 o SMD2835, cuyas características y funcionalidades se las detallará en la Figura 11.

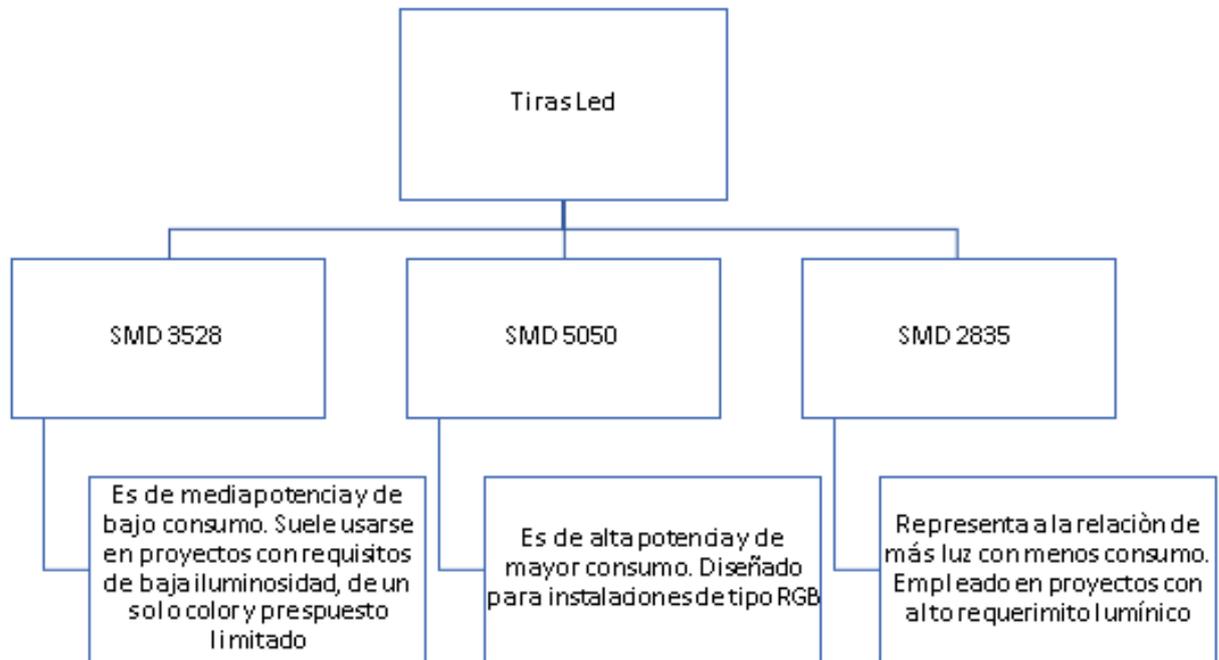


Figura 11. Clasificación y características de las Tiras led (Grealtec, n.d.)

2.12.4. Motor Servo

Un servomotor o motor servo (Figura 12) es un tipo específico motor que tiene como base controlar la posición del eje en un momento determinado, la ventaja de este tipo de equipos es que tiene la capacidad de moverse bajo determinado grado y en caso de ser requeridos se puede mantener fijo en dicha posición. Otras características base de estos servomotores de modelismo es que se los puede operar en voltajes realmente bajos, ya que solamente requiere entre 4 a 6 voltios para su correcto funcionamiento. (García González, 2016).



Figura 12. Motor Servo de modelado (La electrónica, n.d.)

2.12.5. Banda transportadora

Las bandas transportadoras (Figura 13) es un mecanismo diseñado a movilizar cargas a ciertas distancias de manera automatizada, se lo suele emplear en diversos procesos como: industriales, agroindustriales, agrícola y minero y entre los materiales que más comúnmente suelen transportar a través de este medio se destacan: arena, piedrín, arcilla, caliza, asfalto, coke, fosfatos, urea, azúcar, frutas, entre otros. Entre las ventajas claves del empleo de este mecanismo se destaca el cuidado ambiental, puesto que gracias a su funcionamiento la dispersión del polvo al momento de transportar cargas es sumamente tratable hasta el punto de minimizar este efecto en su totalidad (López Arenales).



Figura 13. Banda Transportadora (Vulcabar, n.d.)

2.12.6. Sensor de Infrarrojo

Según Direct (2018), los sensores infrarrojos (Figura 14) son dispositivos opto electrónicos que tiene la capacidad de medir la radiación electromagnética infrarroja de todos los cuerpos que estén disponible en su campo de visión. Suelen ser empleados para la detección, clasificación y posicionamiento de objetos;

asimismo para detección de características extrínsecas de superficies. Entre los sectores que más suelen emplear este módulo se destacan:

- Seguridad: usado generalmente para la detección de intrusos en sectores perimetrales.
- Ciencias médicas y biológicas: empleado para la medición de temperatura corporal y para la realización de diagnósticos no invasores en mama y en músculos.
- Domótica en hogares y negocios: utilizado esencialmente para el control climático y detección de oscilaciones exageradas de temperatura.



Figura 14. Sensor Infrarrojo (Electronilab, n.d.)

2.12.7. Variador de Frecuencia

Se define como un variador de frecuencia a un regulador industrial donde se muestra en la Figura 15, diseñado para ajustar la velocidad de los motores eléctricos acorde a la demanda que del proyecto que se esté llevando a cabo, lo que permitirá que una reducción del consumo energético de un 20% hasta un 70%.

Vale destacar que los variadores de frecuencia están compuestos por diversas etapas. Las cuales son:

- Etapa Rectificadora: se encarga de convertir la tensión alterna en continua mediante rectificadores de diodos, entre otros.
- Etapa Intermedia: permite suavizar la tensión rectificada y de igual manera reduce la emisión de armónicos.
- Inversor: es la encargada de convertir la tensión continua en tensión y frecuencia variable, para este proceso se emplea como dispositivo semiconductor al transistor bipolar de puerta aislada

(IGBT), ya que estos permitirán generar los pulsos controlados de tensión.

- Etapa de Control: aquí se controlarán los IGBT`s con el fin de generar los pulsos variables de tensión y frecuencia requeridos (Pesántez Erazo, 2012).
- Alimentación: Tiene una entrada bifásica de 110[v] cada una, haciendo que funcione a 220 [v] con una salida trifásica de 220 [v].



Figura 15. Variador de frecuencia 1 HP, modelo ATV312 (Schneider Electric, 2021)

2.12.8. Selector dos posiciones de inicio/paro de proceso

Es un interruptor de control a prueba de fallos (Figura 16), que busca proporcionar un sistema de control de seguro tanto para la maquinaria como para el operador, ya que su funcionalidad básicamente se centra en detener la maquinaria cuando exista un riesgo de lesiones o cuando es determinante detener el flujo de trabajo sin importar las condiciones se tengan.



Figura 16. Selector dos posiciones Siemens

12.13. Componentes Lógicos (Software)

Se cataloga como software a todo equipamiento o soporte lógico necesario para la realización de tareas específicas. En cuanto a su clasificación se los puede dividir en tres secciones, las cuales son (Sánchez López):

- Software de sistemas: su objetivo a priori es desvincular de modo adecuado al usuario y a los desarrolladores de detalles intrínsecos del sistema operativo que emplee; aislándolo particularmente en los procesamientos adherentes como memoria, discos, puertos y dispositivos de comunicación.
- Software de programación: este nicho corresponde al conjunto de IDEs y herramientas que faciliten al desarrollo de aplicaciones informáticas, en ellas se incluyen los editores de textos, intérpretes, depuradores y enlazadores.
- Software de aplicación: este permite a los usuarios llevar a cabo ciertas tareas específicas sea cual sea su campo de actividad, en este punto se destacan las aplicaciones de control, softwares tanto de ofimática, educativo como empresarial, base de datos, videojuegos y demás.

12.14. Lenguajes de Programación

Se puede definir como lenguaje de programación a un conjunto de léxicos, sintaxis y semánticas que permitirán diseñar algoritmos sobre un ordenador, es decir, permite escribir una serie de órdenes de manera secuencial y lógica con la finalidad de realizar alguna actividad en específico (Informática IV).

2.14.1. Python

Python es un lenguaje de programación de alto nivel que viene incluida de manera implícita ciertas funciones como listas, diccionarios, tuplas y conjuntos, lo que permite realizar muchas tareas de gran envergadura de manera legible y con pocas líneas de código.

Como reseña histórica este lenguaje fue diseñado por Guido Van Rossum entre los finales de los 80 y los inicios de los 90 mientras se encontraba diseñando el sistema operativo Amoeba. Tanto es la aceptación de este lenguaje que la comunidad diseñó una serie de doctrinas, consideradas *buenas prácticas*, que se deben respetar al

momento de programar bajo este lenguaje. Entre los dogmas estipulados, se destacan:

- Hermoso es mejor que feo.
- Mientras más explícito sea el código mejor será su entendimiento.
- Un código simple será mucho más aceptado y entendible que un conjunto de algoritmos complejos.
- Lo práctico tiene mayor presencia que la formalidad.
- En caso de que exista una ambigüedad trate de evitar la tentación de adivinar,
- Si la implementación es sencilla de explicar seguramente es una buena idea.
- Si la implementación es compleja de explica se la debe descartar de modo ipso facto (Challenger-Pérez, Díaz-Ricardo, & Becerra-García, 2014).

Uno de los puntos fuertes de este lenguaje aparte de contar una librería estándar es la amplia cantidad de scripts que se puede acoplar a este lenguaje de manera sencilla solo bastaría descargarla desde el terminal con el comando `pip install nombredelalibrería`, y si en caso de usar la versión 3 de Python bastará utilizar `pip3 install nombredelalibrería`. En este caso particular se emplearon las siguientes librerías.

- Tkinter: desde hace tiempo Tk/Tcl ha sido una parte integral de Python y permite el desarrollo de interfaces gráficas de usuario, entre las ventajas de los módulos aglomerados en este módulo está la velocidad y fluidez que este representa en producción y qué se lo puede suministrar de forma nativa (Python, 2021)
- Pil: python Imaging Library (PILLOW) es una de las bibliotecas más populares que se utilizan para el procesamiento de imágenes. PIL se puede utilizar para mostrar imágenes, crear miniaturas, cambiar el tamaño, rotar, convertir entre formatos de archivo, mejorar el contraste, filtrar y aplicar otras técnicas de procesamiento de imágenes digitales, etc. PIL admite formatos de imagen como PNG, JPEG, GIF, TIFF, BMP, etc. También posee potentes capacidades de procesamiento de imágenes y gráficos (Recursos Python, s.f.).

METODOLOGÍA

La metodología aplicada para el diseño e implementación del prototipo clasificador de cacao, constará principalmente por la investigación de campo, método que permitió la recolección de datos provenientes de fuentes primarias, de esta manera se asistió a los puntos de cosecha y venta de cacao donde se pudo constatar el método de selección y clasificación de granos de cacao de acuerdo al nivel de fermentación, a fin de que dichos granos de acuerdo al nivel de fermentación que se encuentran sean registrados y analizados por el sistema clasificador, posterior a esto se procedió con la fase de entrenamiento del prototipo con el objetivo de que este realice la clasificación de los granos de acuerdo a los niveles de fermentación, mismos que ya posee como registro en su base de datos permitiendo de esta manera una clasificación eficiente.

Bajo este contexto el trabajo se clasificó en 3 fases. La fase 1 corresponde al preprocesamiento de información, el cual consiste en procesos que abarcan desde la adquisición de granos, toma de imágenes hasta el análisis del nivel de fermentación aplicando la visión por computadora concluyendo con la segmentación de imágenes. La fase 2 comprende el proceso de aprendizaje del prototipo específicamente al entrenamiento que este recibirá, dentro de esta fase se detalla el ingreso de información, como el procesamiento de las imágenes para un aprendizaje de carácter automático, la codificación de dicha información recopilada y posteriormente la validación de resultados y la fase final corresponde al análisis comparativo de los resultados obtenidos.

3.1. Diseño e Implementación del prototipo clasificador de granos de cacao

Para que la clasificación sea efectiva, algunas características, como la distancia de captura de la imagen y el nivel y calidad de iluminación, deben permanecer constantes. Para cumplir con estos requisitos, se creó un prototipo simple que cumple con las condiciones anteriores y permita validar de manera eficiente cada procesamiento de imagen. La elección del material utilizado, el diseño y la construcción del prototipo se detallan a continuación.

3.1.1. Selección del hardware

Al elegir el equipo, se tuvieron en cuenta las características técnicas, la facilidad de uso y el costo de su elección. Primero, se describen en detalle los requisitos de la cámara cuya principal función es la captura de imágenes. A continuación, se selecciona la fuente de iluminación de acuerdo con sus parámetros como propiedades e intensidad. En la última instancia, se detalla el controlador a usar, esto en función del tipo de entradas y salidas utilizadas, así como de la facilidad de programación y aplicación.

3.1.1.1. Diagrama eléctrico-electrónico de Prototipo

Debido a la naturaleza, complejidad y demanda de este proyecto se optó indiscutiblemente por el uso de la placa de Raspberry Pi, ya que para que cumplir con los objetivos trazados a lo largo de este Trabajo de Titulación se requirió un módulo capaz de trabajar con ciertas librerías dedicadas al mundo del *Machine Learning*, lo que desembocó en el uso de Python como lenguaje de desarrollo del prototipo y gracias las características intrínsecas del Raspberry Pi la gestión de este proyecto es más que viable; asimismo gracias a sus propiedades extrínsecas fue posible interactuar con sensores y módulos imprescindibles para la clasificación de granos de cacao como es el uso de una cámara para hacer posible el uso del paradigma de la visión artificial; el empleo de los motores servos que permite hacer la clasificación post análisis de fermentación; la conexión led para la iluminación y la gestión del sensor infrarrojo empleado para la detección del grano de cacao en la cinta transportadora del prototipo. En resumen, esta placa en particular nos va a permitir gestionar toda la parte lógica embebida en *Machine Learning* como en visión artificial; y nos permitirá controlar todos los dispositivos electrónicos necesarios para el prototipo. En cuanto a diagrama y aspecto del Raspberry Pi se los reflejará en la Figura 17 y Figura 18 respectivamente

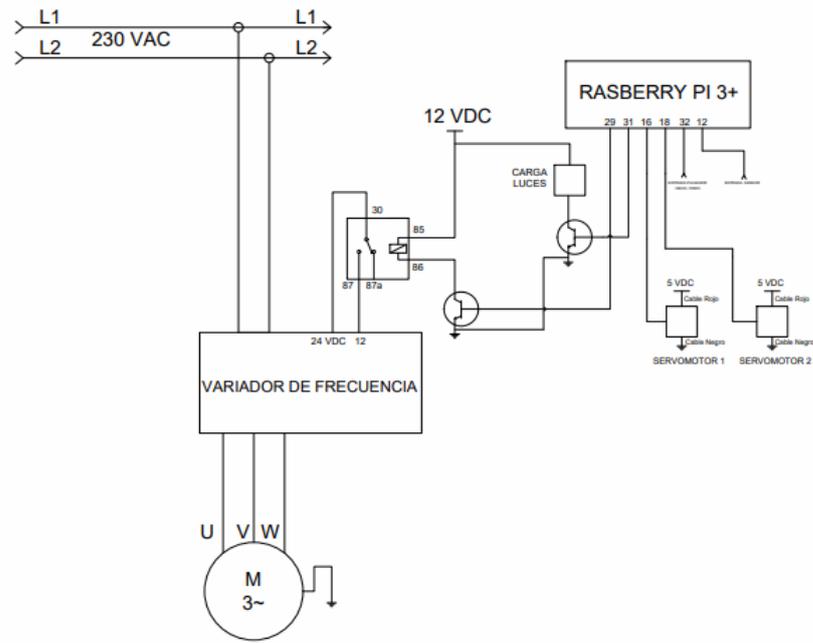


Figura 17. Diagrama eléctrico de prototipo



Figura 18. Placa de Raspberry Pi (Rodríguez De Luis, 2018)

3.1.1.2. Cámara

La cámara utilizada para este prototipo debe tener una buena resolución y velocidad de grabación para obtener imágenes claras, además entre sus principales características deberá disponer de un enfoque automático de corto alcance ya que la captura de imagen será en movimiento.

Se seleccionó la cámara Raspberry Pi v2 para la toma de imágenes tal como se la ve en la figura 19, el módulo de cámara v2 tiene un sensor Sony IMX219 de 8 mega píxeles el cual permite tomar fotos y videos de alta resolución. Las ventajas actuales de este dispositivo son alta definición, corrección de luz, vista de 360°, alta velocidad y varios tipos de conexión al ordenador. La adquisición de datos, en este caso las imágenes se realizan en una distancia corta que no requiere alta resolución y el tiempo de procesamiento de la imagen es mayor. La corrección de la iluminación se resuelve con la presencia de un módulo de adquisición de datos, que asegura una iluminación uniforme.

El modelo v2 fue seleccionado debido a que cuenta con resoluciones HD compatibles en 1080p, 720p60 y VGA90. Ofrece imágenes claras y buen contraste incluso cuando está en movimiento, y puede cambiar la resolución según sea necesario. Tiene una función de enfoque automático de 7 cm que garantiza imágenes nítidas al momento de captar imágenes en movimiento a distancias cortas. Además, cuenta con un corrector de luz HD que se adapta a las condiciones de iluminación para obtener imágenes más brillantes y mejores.



Figura 19. Cámara Raspberry Pi V2 (EC Robotics , s.f.)

3.1.1.3. Sistema de iluminación

Para el diseño del prototipo se requiere de una buena iluminación, ya que mejora el contraste de la imagen entre el fondo y el objeto analizado (granos de cacao), de esta manera se facilita la segmentación y libera la imagen capturada de factores externos que pueden cambiar sus propiedades deterioradas. Las pruebas se

realizaron con diferentes fuentes de luz en el módulo de detección y los mejores resultados se obtuvieron con tiras de LED de 20lm/led, 1200 lm/metro, con un consumo de 15 watts.

Las cintas LED tienen una intensidad aceptable para este tipo de proyecto, su fácil instalación, iluminación uniforme del objeto, gran reducción de sombras y aumento de contraste son factores. La foto adjunta muestra la prueba de captura de imágenes realizada en el módulo con el sistema de iluminación a base de cintas LED para la iluminación en una configuración universal, no crea sombras y la iluminación es uniforme en todos los granos que se encuentran dentro del módulo cumpliendo con los requisitos requeridos. Se muestra tiras led en la figura 20.

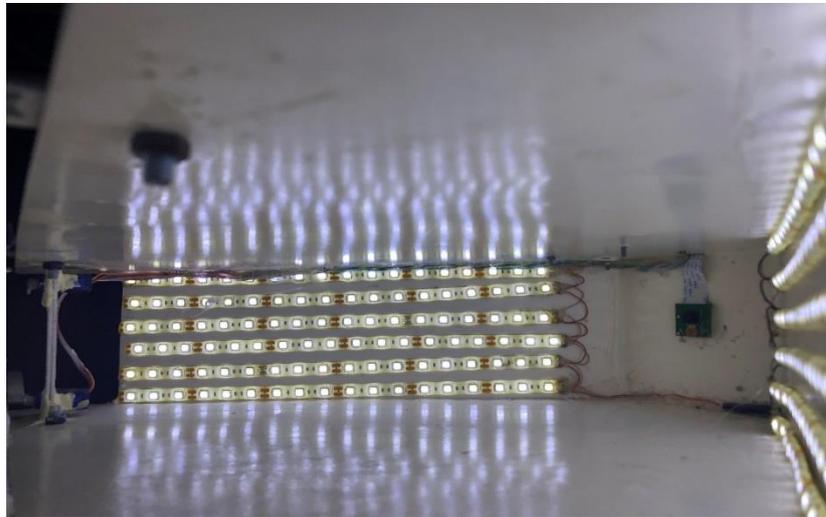


Figura 20. Sistema de iluminación interna

3.1.1.4. Banda transportadora

La estructura de la cinta transportadora está elaborada de acero, los rodamientos sobre los que gira las poleas se encuentran ubicados a los extremos y se encuentran fijados a la estructura, misma que posee un soporte estilo trípode para poder maniobrar la visualización con una altura promedio de 1.50 metros, la cual tendrá como objetivo de movilizar los granos de cacao a velocidad constante por todo el prototipo.

La estructura de la banda transportadora está elaborada de acero, los rodamientos que se usaron son de numeración 608 2RSH marca SKF, tienen un diámetro externo de 22 [mm], diámetro interno de 8 [mm] y un ancho de 7 [mm], estos se usaron para que el eje de los rodillos ruede de manera continua y con una cantidad casi nula de

fricción en alguna parte del proceso, mismos están fijados en la estructura de la esquina de cada rodillo del eje motriz, se fabricaron unas chumaceras, mismas que sirven para brindar soporte los ejes de rotación. La banda que se utilizó es de uso industrial para tener mejor adherencia y ajuste al proceso, esta tiene una medida de 75 x 11 [cm].

Para la existencia de sinergia e ingeniería se usó un servomotor el cual hace el funcionamiento del movimiento en la banda. En la figura 21 se muestra la perspectiva superior de la banda transportadora.

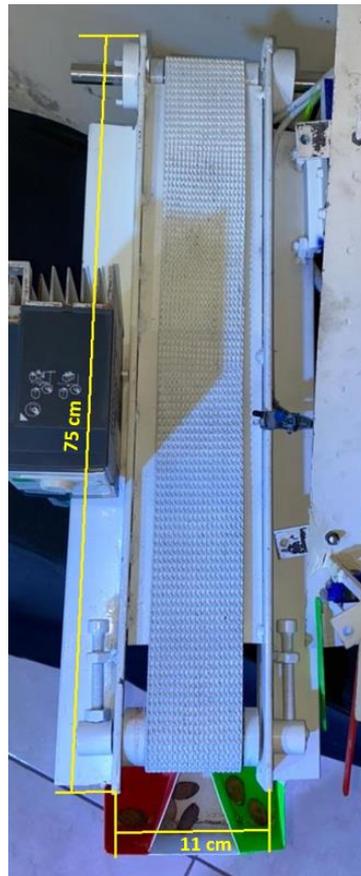


Figura 21. Perspectiva superior de banda transportadora

3.1.2. Selección de Software

El proyecto se basa en dos pilares angulares: el primero es el Machine Learning, el cual nos va a permitir dentro de una red neuronal entrenar al sistema para la detección de los granos de cacao tanto fermentados, semifermentados o sin fermentar, para este punto se empleará el software Teachable Machine, que su base es el aprendizaje de la máquina, esta función nos permitirá enseñar y direccionar al prototipo a las necesidades requeridas por el usuario; y el segundo factor será la

visión artificial, para lo cual se utilizarán las librerías tensorflow, numpy y pil como cimiento, por lo que Python vendría ser el lenguaje del script a desarrollar.

3.1.3. Implementación del prototipo

Una vez definido tanto la parte de software como hardware requeridos y empleados se procederá a indicar tanto las características técnicas del prototipo como los pasos lógicos llevados a cabo para la clasificación del grano de cacao.

Para llevar a cabo todo este proceso el primer paso requerido fue diseñar un mecanismo que cuente con un área dedicada a la captura de imágenes; un sistema de transmisión de luz y módulos diseñados para retirar los granos de cacao después de completar la clasificación.

En lo que consiste la “capucha” del prototipo tiene como dimensiones lo siguiente: Longitud de 50 cm, ancho de 11 cm, el cuadrante donde va la cámara internamente tiene 10x11 cm y la longitud del lado inclinado es de 32 cm.

La estructura de la banda transportadora tiene una dimensión de 75x11cm, donde los 25 cm sobrantes en comparación con la “capucha” son para tener facilidad al momento de colocar los granos de cacao u objetos que van a ingresar y salir del prototipo clasificador, la visión general del sistema se la puede observar en la Figura 22.

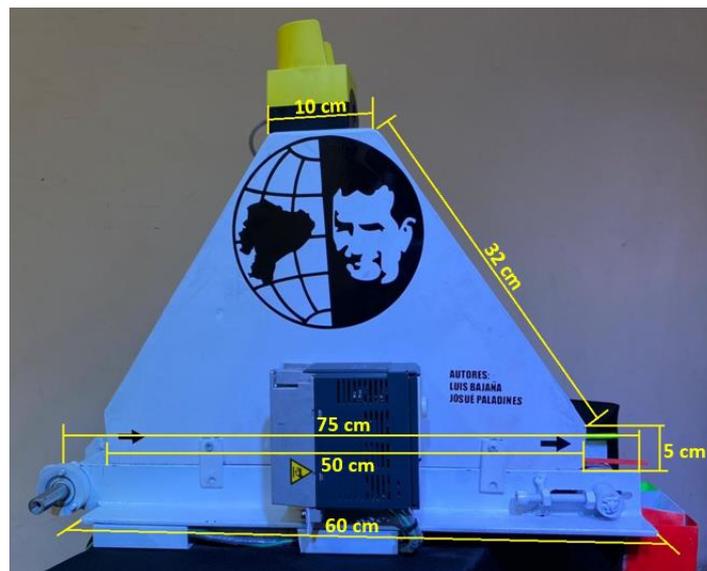


Figura 22. Diseño del prototipo propuesto

3.1.4. Procesos lógicos del prototipo

Una vez que se ha dado un panorama general del prototipo y sus módulos se procederán a explicar cada una de las fases lógicas justas y necesarias para el funcionamiento del sistema, para esto se va a dividir este apartado en 3 etapas claves, las cuales se detallarán en los siguientes ítems.

3.1.4.1. Fase I: Preprocesamiento de Información

3.1.4.1.1. Diseño del Sistema de Visión Artificial

El objetivo del sistema de visión artificial consiste en extraer las principales características y su interpretación a partir de la captura de imagen de los granos de cacao, para lo cual es necesario que la imagen pase por múltiples etapas de procesamiento de imagen (filtros, moralización, operaciones morfológicas, etc.) para lograr una correcta extracción de características e interpretación.

Para asegurar el óptimo funcionamiento del paradigma de Visión Artificial se deberán seguir las siguientes etapas:

3.1.4.1.2. Adquisición y captura de imagen

La tarea inicial para este proceso consistió en la toma de imágenes asociados a los diversos niveles de fermentación que presentan los granos de cacao, para este caso se los divide de la siguiente manera:

- Fermentado
- Semi fermentado
- No fermentado

Se instalará el gestor de imágenes de Python Imaging Library (PILLOW), por medio de Tensorflow donde se almacenarán las imágenes captadas y permitirá ejecutar el modelo el cual se va a introducir, a fin de que queden registradas en la memoria de la máquina y sirvan de referencia para el proceso de entrenamiento.

La obtención de la imagen se realizó utilizando la cámara Raspberry Pi v2. Para el procesamiento de imágenes se empleó la herramienta web Teachable Machine la cual permite crear modelos de Machine Learning de forma rápida y sencilla, convirtiéndola en una plataforma accesible para todos y encajando con el propósito del prototipo

La captura de la imagen se realiza con unas dimensiones de 700 x 500 en el módulo de captura elaborado. En este la cámara realiza la captura en el momento en el cual los granos de cacao se encuentren en el rango de visión de la cámara mostrado en la figura 23, para determinar cuándo se le mandara el disparo por software se colocó un sensor infrarrojo detector de obstáculos previo al ingreso de los granos al módulo, el cual actuara como un sensor de presencia. La captura se realizará después de que el sensor indique la presencia de los granos de cacao en la entrada del módulo.



Figura 23. Posicionamiento de granos en las bandas trasportadoras

Para obtener el tiempo de retardo de captura fue necesario realizar varias pruebas en el prototipo, siendo 0.5 segundos el resultado más adecuado de captura de la imagen.

La captura debe realizarse con la imagen de los granos de cacao en su totalidad dentro del rango de captura, para diferentes tamaños de los granos, la imagen de estos se ubicará en distintas posiciones en la captura, mas no afectará significativamente el procesamiento de la imagen.

3.1.4.1.3. Preprocesamiento de imágenes

1. Adquisición de imágenes desde la cámara

Para comenzar, se conecta la cámara a la placa Raspberry Pi y se inicia el script *sorter.py* para comenzar su visualización en vivo. Deberá pasar el Flag apropiado para la cámara que está utilizando. El comando por usar es este:

- `python3 sorter.py -flir`

2. Detecta cuando un objetivo de clasificación pasa frente a la cámara

Al iniciar la fase de detección, se determina cuándo se va a ejecutar la clasificación una vez que haya un objeto en el centro del cuadro. Posterior a esto se inicia el proceso ejecutando el script del clasificador en modo de entrenamiento pasando la marca *--train*. Esto significa que las imágenes no serán enviadas para su procesamiento, ya que aún no ha comenzado el entrenamiento del modelo. En cambio, las imágenes analizadas para tener un objeto en el centro se enviarán a Teachable Machine y se mostrarán localmente. Este modo es para probar qué tan bien están funcionando las configuraciones de adquisición y para enviar imágenes a Teachable Machine para su análisis más adelante. Los comandos para iniciar esto son:

- `CD teachable-sorter`
- `python3 sorter.py --flir --train --zone-activation`

La segunda Flag, *--zone-activación*, se refiere al algoritmo que se usa para determinar si hay un objeto en el centro del marco. El Flag de activación de zona busca cambios en un grupo de píxeles justo en el centro del marco. Si encuentra que está obteniendo muchos falsos positivos (imágenes de la cámara del módulo vacía) o falsos negativos (imágenes de los objetos que caen), cambiar este Flag a menudo puede ayudar.

A la imagen capturada se le aplicará un filtro digital con el objetivo de suavizar la imagen y eliminar el ruido modificando los valores de intensidad entre píxeles aledaños los cuales son muy diferentes entre sí. El filtro gaussiano emborrona la imagen y elimina el ruido, es similar al filtro de media, pero es menos sensible a cambios locales y puede producir un suavizado más uniforme.

3.1.4.1.4. Extracción de características

Respecto a la arquitectura para el proceso de red neuronal convolucional (RNC) aplicado para la extracción de características, fue necesario el uso de varias capas de RNC. Primero está la capa convolucional, que genera un mapa de características para predecir las probabilidades de clase para una característica en particular mediante la aplicación de un filtro que examina la imagen completa varios píxeles a la vez.

La segunda capa es la capa de agrupación (muestreo descendente); el muestreo descendente del proceso de la capa de agrupación consiste en disminuir el tamaño de la imagen conservando sus características esenciales. Esta capa reduce la cantidad de parámetros y cálculos en la red, mientras que el proceso en esta capa mejora el rendimiento de la red y evita el sobre aprendizaje.

La siguiente capa es la capa de aplanamiento, en la que el aplanamiento de las salidas generadas por las capas anteriores se transforma en un solo vector como entrada para la siguiente capa. Por último, la capa final es la capa completamente conectada. En esta capa, el proceso reduce la cantidad de información y mantiene la información esencial.

Hasta ahora las características extraídas previamente se encuentran como número de píxeles, siendo necesario realizar su conversión a centímetros empleando una escala.

Para obtener dicha escala se realizó una captura de una regla patrón en el módulo en las mismas condiciones que los granos de cacao los cuales se utilizaron como estándar, donde se revisó el número de píxeles en un centímetro de la regla patrón, se observó que para obtener correctamente dicha escala es necesario que la regla patrón se encuentre a la mitad de la altura de los granos de cacao, la cual es la zona del mayor diámetro y área. Para lograr esto se añadió una altura inicial base desde la cinta transportadora hasta la regla patrón.

3.1.4.2. Fase II: Proceso de aprendizaje del prototipo

3.1.4.2.1. Procesamiento de imágenes para aprendizaje automático

El aprendizaje es el proceso por el cual la red neuronal artificial modifica el valor de las propiedades que determinan el grado de fermentación en respuesta a la información en la entrada. El aprendizaje gracias a la herramienta web Teachable Machine, durante la fase de entrenamiento, las imágenes recopiladas en la fase 1 fueron exportadas donde los valores de entrada del banco de datos se aplican a la capa de entrada.

3.1.4.2.2. Proceso de enseñanza o entrenamiento del modelo

El ajuste de los parámetros de entrenamiento para disponer de un mayor control sobre el entrenamiento del modelo, Teachable Machine proporciona dos paneles expandibles: una sección de entrenamiento "avanzada" para el ajuste de parámetros y un panel de datos para visualizaciones de evaluación de modelos. El panel "avanzado" se encuentra en el módulo de capacitación y puede expandirse para revelar opciones para ajustar los parámetros de épocas, tamaño de lote y tasa de aprendizaje.

El patrón de activación en la capa de salida es comparado con el valor correcto del banco de datos, mismo que está conformado por 50 épocas, se debe aclarar que una época representa la revisión total de todos los datos recopilados. Para la presente fase se han recopilado un total de 160 muestras a procesar, entre granos de cacao fermentado, parcialmente fermentados, no fermentado y asimismo se analizaron otro tipo de muestras variados como vacío, varios, piedras y hojas. La Figura 24 presenta la recopilación de datos, en este caso de imágenes al Teachable Machine.

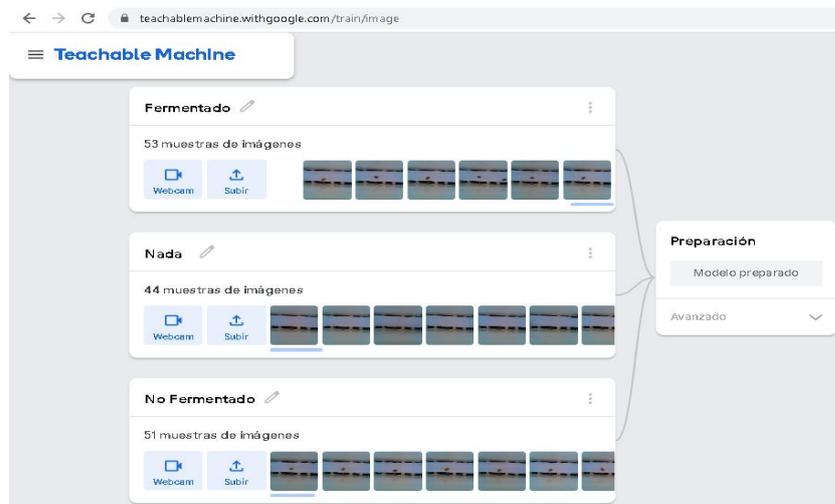


Figura 24. Recopilación de imágenes al Teachable Machine

Además, se ha establecido que el número de lotes fue de un total de 16 muestras, lo que indica que existen 10 lotes, por ende, para entender el término época, el sistema o modelo deberá procesar los 10 lotes, representando de esta manera una época. Los parámetros predeterminados que se muestran en la Figura 25 son para entrenar modelos de clasificación de imágenes.

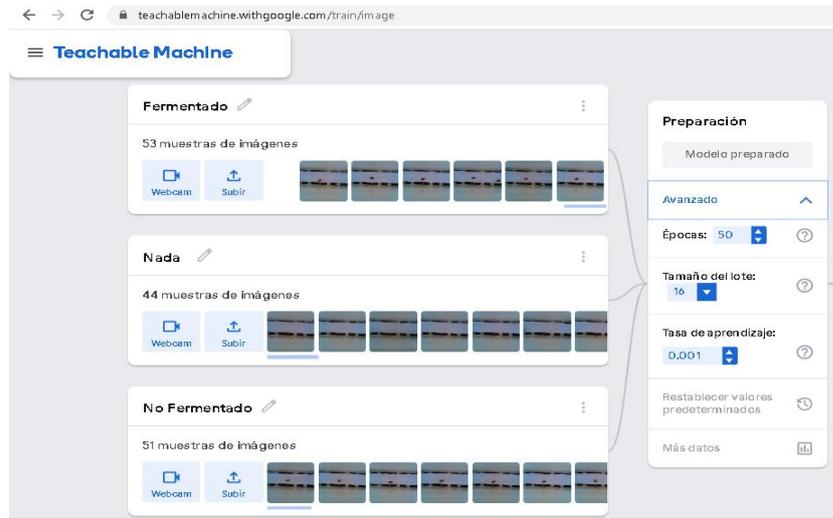


Figura 25. Establecer parámetros predeterminados

Debido a que el proyecto está conformado por la clasificación de imágenes, la herramienta web tiene estos parámetros de forma predeterminada, los cuales pueden ser modificados dependiendo del tipo de prototipo o sistema a implementar. Luego de definir los parámetros se inicia la preparación para el debido aprendizaje, donde se cargan las imágenes y parámetros al modelo, tal como se presenta en la Figura 26.

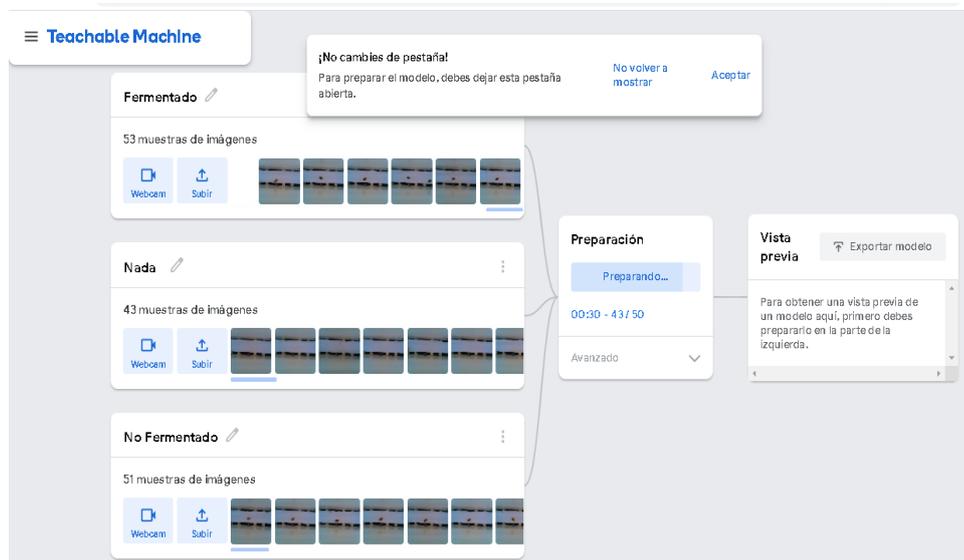


Figura 26. Preparación del modelo para entrenamiento

3.1.4.2.3. Evaluación del aprendizaje del prototipo

La evaluación permite evaluar el prototipo luego de su entrenamiento, Teachable Machine pone a disposición un panel secundario que permite monitorear el funcionamiento y posteriormente evaluar el aprendizaje del modelo. La exactitud,

para la clasificación del nivel de fermentación, las medidas correctivas y la velocidad de aprendizaje se pueden determinar durante este proceso de entrenamiento y aprendizaje del prototipo. Se muestra en la figura 27 el acercamiento de un grano de cacao fermentado, la Figura 28 presenta el proceso de prueba y error al momento que el prototipo procesa solo granos de cacao fermentado, y este arroja el nivel en que se encuentra, siendo esta afirmativa, puesto que, arroja un total del 98% de granos totalmente fermentados, cabe mencionar que el restante se debe a factores externos como el ingreso de granos de cacao no fermentados, además de pequeñas variaciones en la captura de imagen dejando como objetivo la banda transportadora asumiendo que no hay nada.



Figura 27. Acercamiento de un grano de cacao fermentado

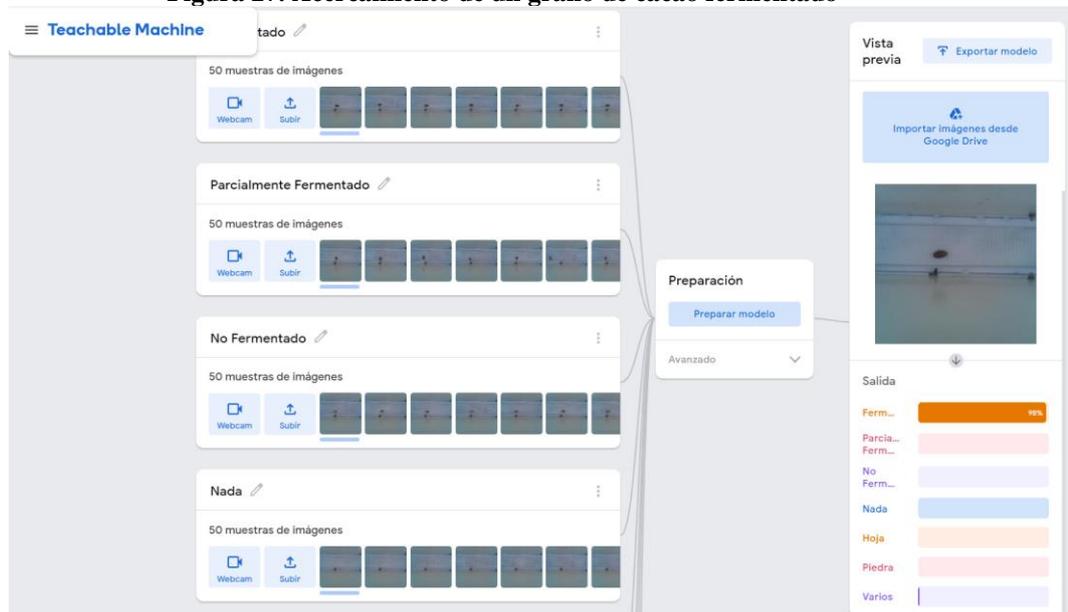


Figura 28. Prueba y error en identificación de granos de cacao fermentado

Por otro lado, Se muestra en la figura 29 el acercamiento de un grano de cacao no fermentado. La Figura 30 presenta el proceso de prueba y error durante la

identificación y clasificación de granos de cacao no fermentados, para esta ocasión el resultado arrojó un 100% de granos clasificados como no fermentados.



Figura 29. Acercamiento de un grano de cacao no fermentado

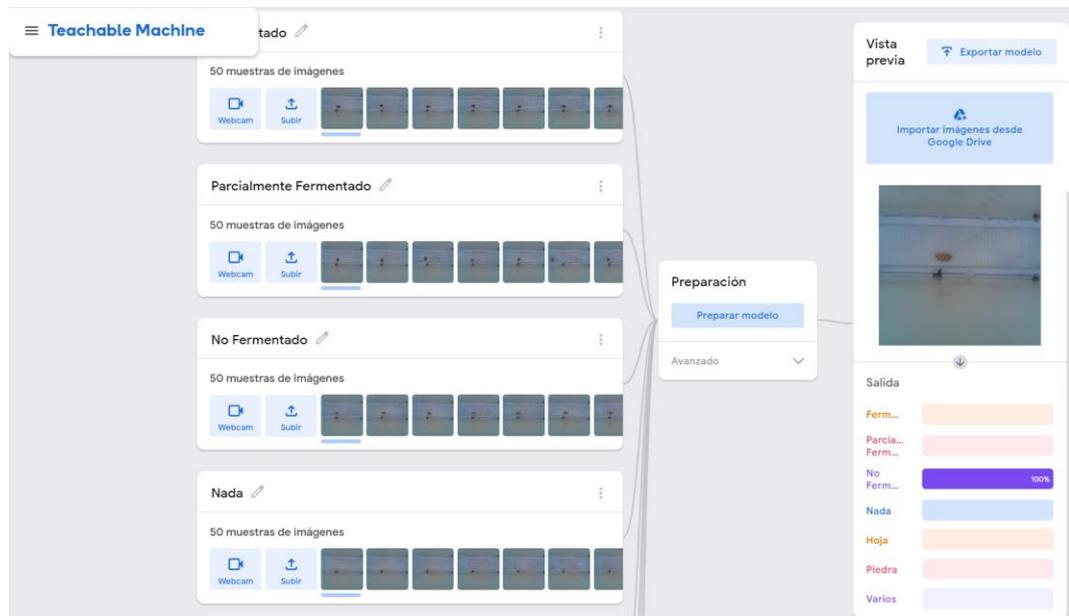


Figura 30. Prueba y error en identificación de granos de cacao no fermentado

Se muestra en la figura 31 el acercamiento de un grano parcialmente fermentado. La Figura 32 presenta el proceso de prueba y error durante la identificación y clasificación de granos de cacao parcialmente fermentados, para esta ocasión el resultado arrojó un 100% de granos clasificados como parcialmente fermentados,



Figura 31. Acercamiento de un grano de cacao parcialmente fermentado

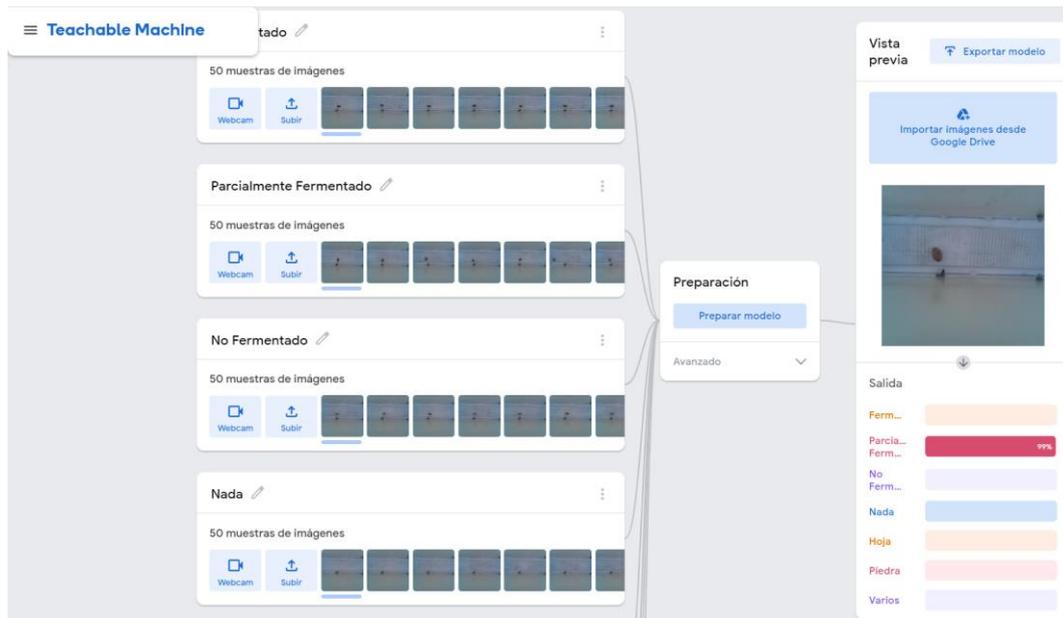


Figura 32. Prueba y error en identificación de granos de cacao parcialmente fermentado

Asimismo, la figura 33 se hace un acercamiento a la banda transportadora sin objeto. En la figura 34 presenta el proceso de prueba y error durante la identificación de la banda totalmente vacía, a fin de evitar interpretaciones indebidas y comprometa la clasificación de granos cacao, dicha evaluación arrojó un 97% de eficacia, esto se debe por causa de filos sin pintar de la cinta debido a la fricción que hace con los rodillos y el movimiento continuo, movimientos de la cámara entre otros, al identificar que la banda se encuentra sin ningún grano de cacao y ningún objeto.



Figura 33. Acercamiento de banda transportadora vacía.

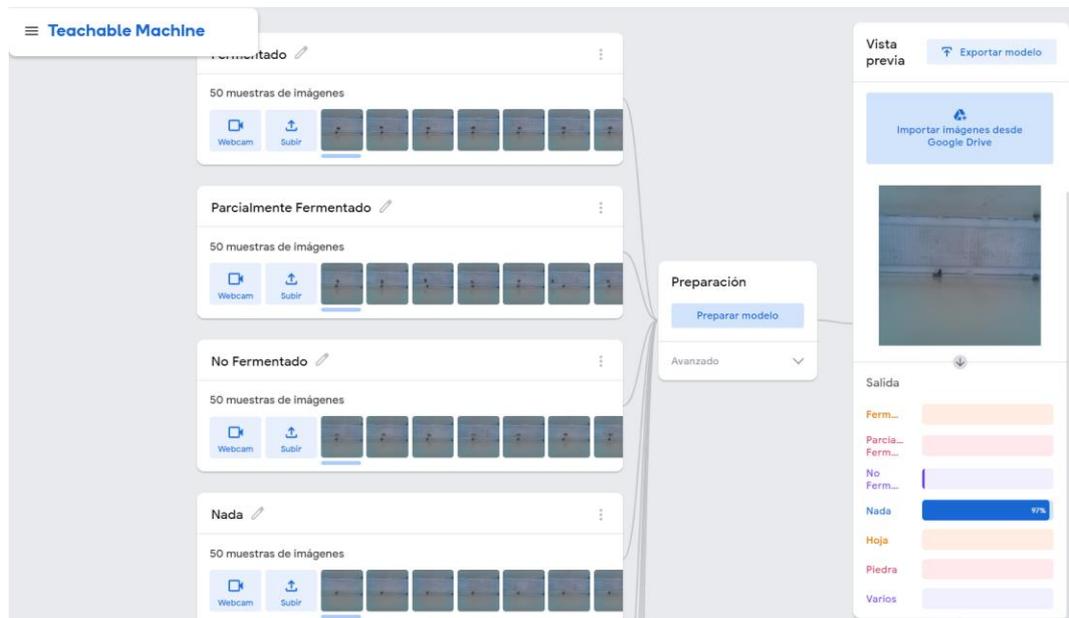


Figura 34. Prueba y error en identificación de banda vacía

Debido al contexto del proyecto se debe considerar otro tipo de muestras como es el caso de objetos varios, de piedra y de hojas, por un lado, la Figura 35 refleja el acercamiento de varios objetos en el proceso, en la figura 36 se muestra el proceso de identificación de objetos varios dicha evaluación arrojó un 100% de eficacia, lo que permitirá evitar que algún objeto que comparta algún patrón con los granos de cacao se vaya a clasificar de manera incorrecta.



Figura 35. Acercamiento de varios objetos en el proceso.

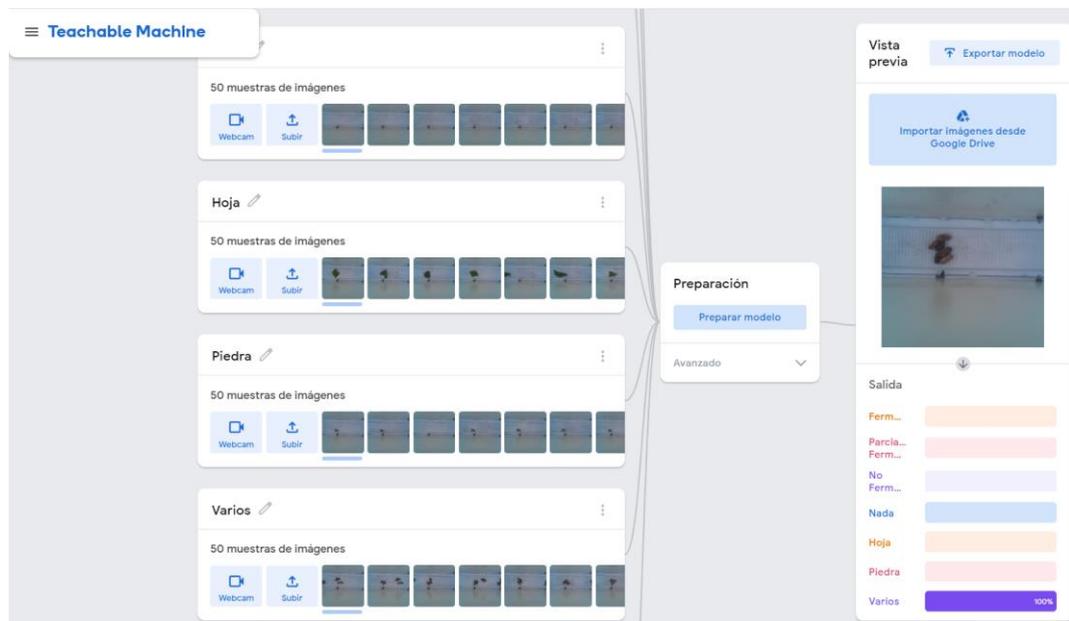


Figura 36. Prueba y error en identificación de varios objetos

Del mismo modo se realizó el análisis pertinente de las muestras de piedra en donde se muestra en la figura 37 un acercamiento. La figura 38 se visualiza la prueba y error, por un lado, el análisis de las Piedras fue mucho más complejo al realizar, ya que comparte muchas características extrínsecas que provocaría que el sistema lo pueda detectar como un grano de cacao, por lo que se tuvo que realizar modelos de decisión y clasificación sumamente precisos para evitar cualquier tipo de inconveniente de clasificación.



Figura 37. Acercamiento de una piedra

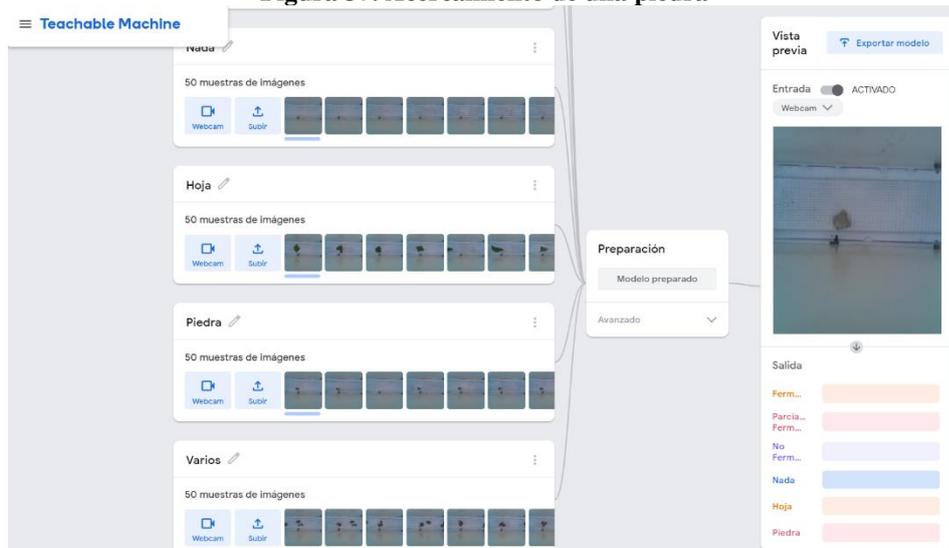


Figura 38. Prueba y error en identificación de una piedra

Para finalizar con la recolección de dato se realizó una extracción de características a las hojas, mostrada en la figura 39 un acercamiento, en este caso en particular la eficacia de resultado fue de un 100% aproximadamente, se muestra prueba y error en identificación de hojas en la figura 40.

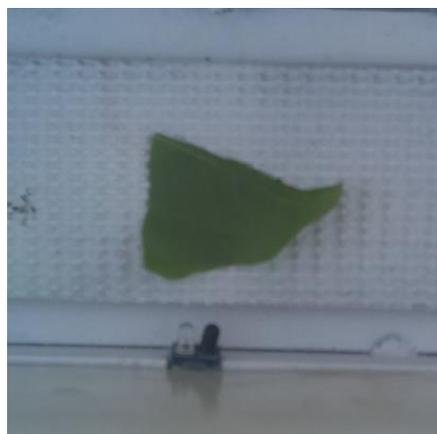


Figura 39. Acercamiento de una hoja

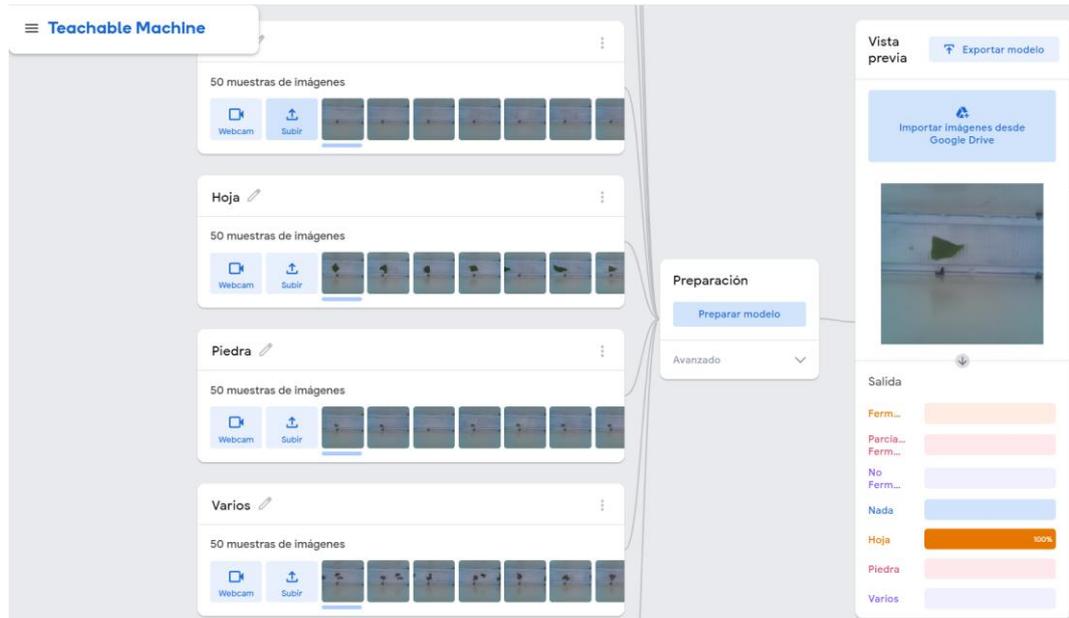


Figura 40. Prueba y error en identificación hojas

La herramienta web retiene el 15% de las muestras (tomadas proporcionalmente de cada clase) para usarlas como un conjunto de datos de validación, por lo que las visualizaciones de precisión y pérdida trazan los resultados del conjunto de datos de entrenamiento y validación.

Bajo este contexto, la Figura 41 presenta la precisión del modelo por época, la precisión es el porcentaje de clasificación que el modelo presentado ha acertado durante la fase de entrenamiento, dado que la precisión de este modelo es igual a 1, se considera que el entrenamiento fue exitoso.



Figura 41. Gráfica de precisión

Además de la precisión como validador para el entrenamiento del modelo, se tiene las pérdidas por época, este indicador mide el nivel de aprendizaje del modelo propuesto a la hora de predecir la clasificación correcta de los granos de cacao según su nivel de fermentación, por ende, la Figura 42 presenta el nivel de pérdida del modelo el cual arroja un valor 0.01189 siendo un valor no representativo y cercano a cero, lo que indica que las predicciones son y serán correctas de parte del modelo.

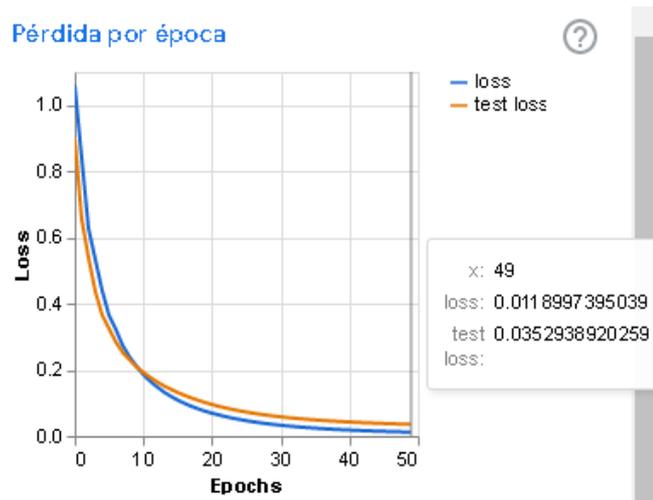


Figura 42. Gráfica de pérdidas

Para corroborar lo obtenido de los indicadores de predicción y pérdida se verifica la matriz de confusiones se aplicó esta herramienta que permite la visualización del desempeño del entrenamiento que se emplea en el aprendizaje supervisado del modelo, la Figura 43 presenta dicha matriz, donde se evidencia que el modelo no confunde ninguna de las clases plateadas (fermentado, no fermentado y nada), esto significa que el modelo es un buen clasificador de granos de cacao de acuerdo a su nivel de fermentación.



Figura 43. Matriz de composiciones

3.1.4.2.4. Generación de la neurona

Dentro del archivo H5 se almacena los datos en HDF (formato de datos jerárquicos), los cuales fueron generados en la sección anterior durante la fase de entrenamiento, lo cual permitirá almacenar datos de tipo texto, numérico o gráficos, dicho almacenamiento se denomina biblioteca de datos, como datos principales se tiene la identificación de imágenes, reconocimiento del nivel de fermentación, los pasos a seguir para la generación de la neurona son los siguientes:

En la figura 44, se puede visualizar la pantalla principal de la Raspberry que es muy similar a la de un ordenador común.



Figura 44. Pantalla principal de la Raspberry

En la figura 45 se muestran algunos archivos y documentos que se usaron para pruebas, se ingresa al documento “CapturaFotos.py”.

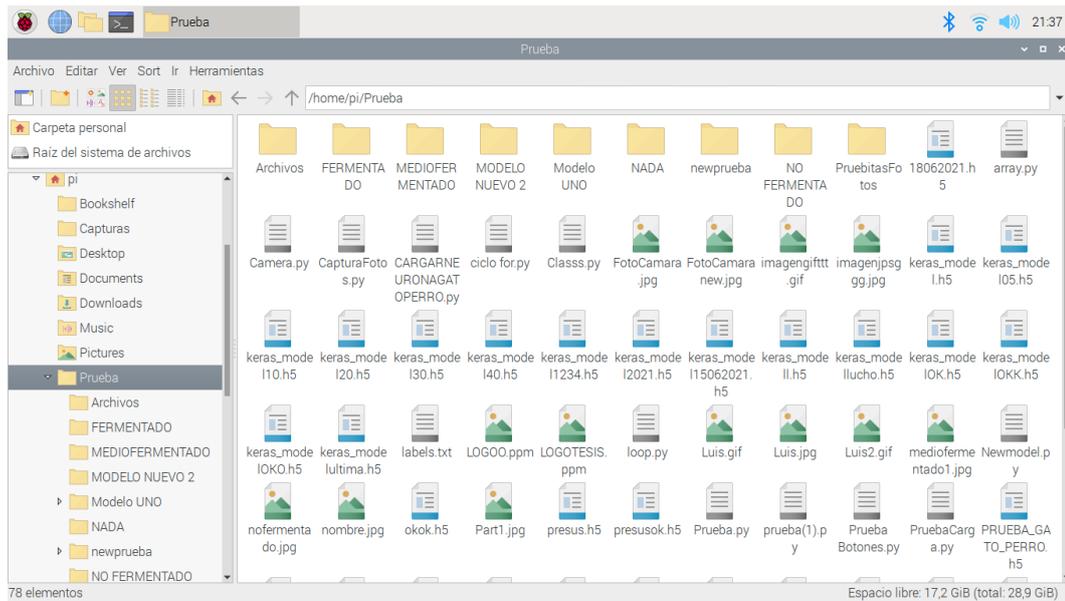


Figura 45. Ventana general de archivos referenciales

En la figura 46, se direcciona según las muestras requeridas por el usuario para su respectiva clasificación a través de la codificación y comandos.

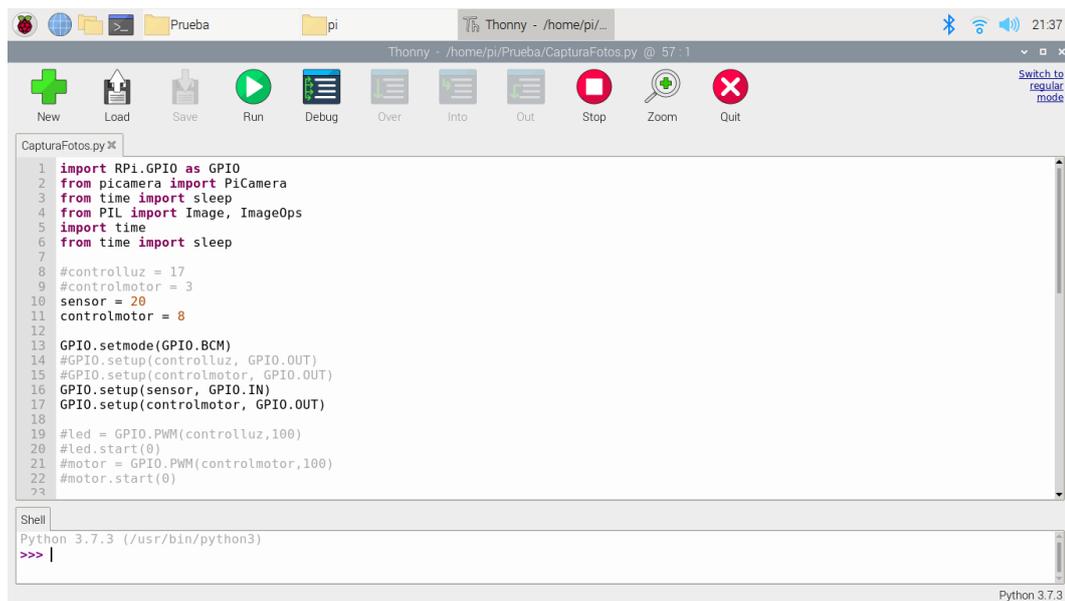


Figura 46. Ventana en Python de “CapturaFotos.py” (1)

En la figura 47, muestra el documento abierto en Python con el fin de tomar las muestras que se necesitan para cada una de las categorías a clasificar, se usará el ejemplo de Piedras, lo cual se debe hacer los mismos pasos por cada categoría. El número sombreado define el ciclo para la toma de muestras, en este caso son “10”.

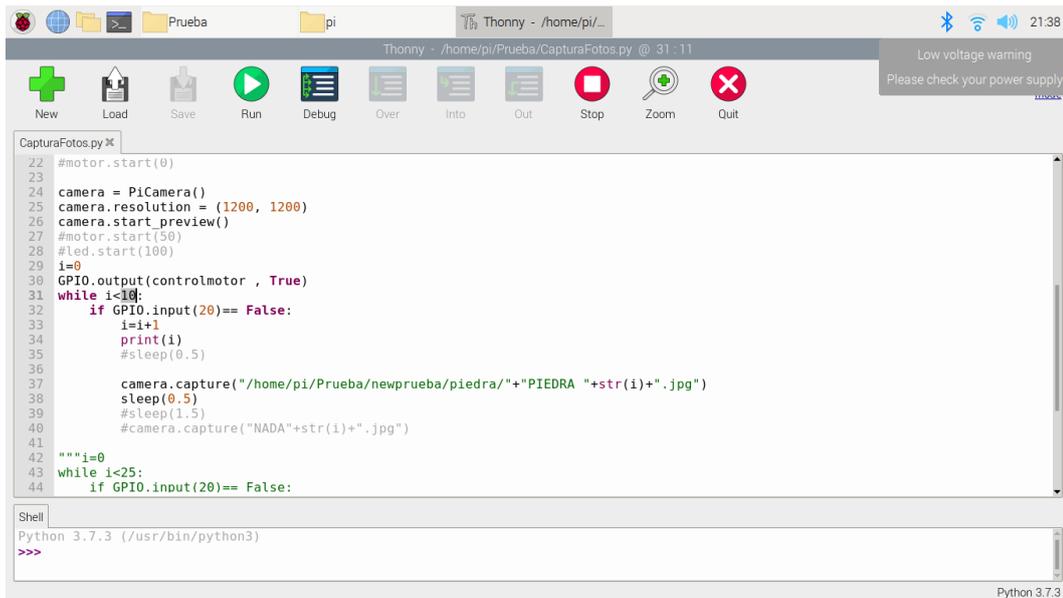


Figura 47. Ventana en Python de “CapturaFotos.py” (2)

En la figura 48 se muestra la ventana donde se visualiza en la línea 32 la codificación de entrada del sensor para la respectiva captura de imagen.

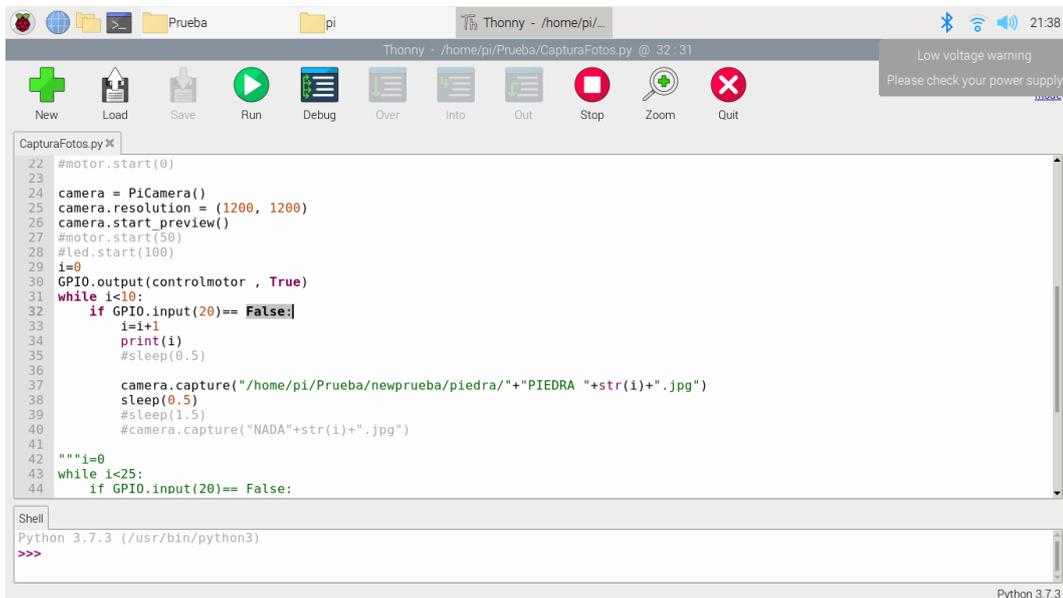


Figura 48. Ventana en Python de “CapturaFotos.py” (3)

En la figura 49, se usa el comando “camera.capture” es el encargado de capturar la pantalla según la detección del sensor, la cantidad de veces que el usuario lo programe, permite direccionar el lugar en donde se va a guardar en el ordenador con su respectivo nombre.

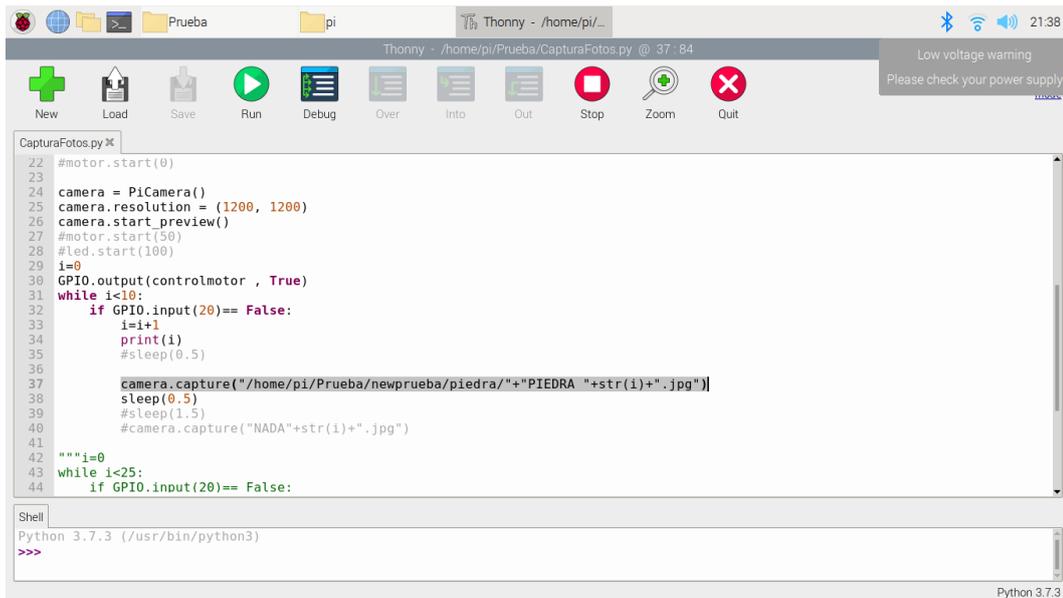


Figura 49. Ventana en Python de “CapturaFotos.py” (4)

En la figura 50, se da clic a la opción “Run” para proceder a ejecutar el programa.

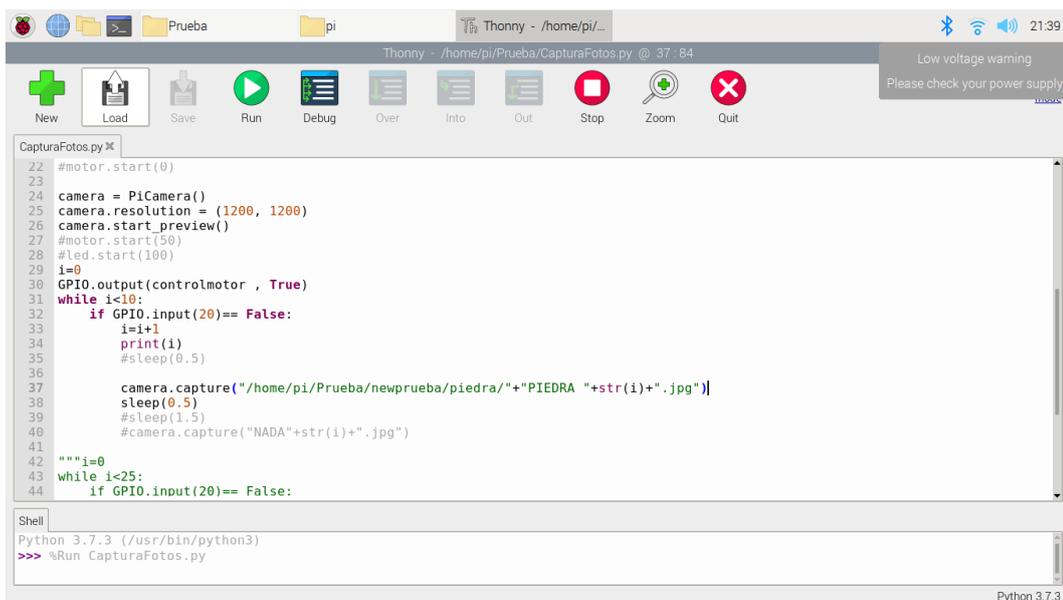


Figura 50. Ventana en Python de “CapturaFotos.py” (5)

En la figura 51 se muestran las fotos obtenidas de la categoría Piedra desde la Raspberry en el proceso.

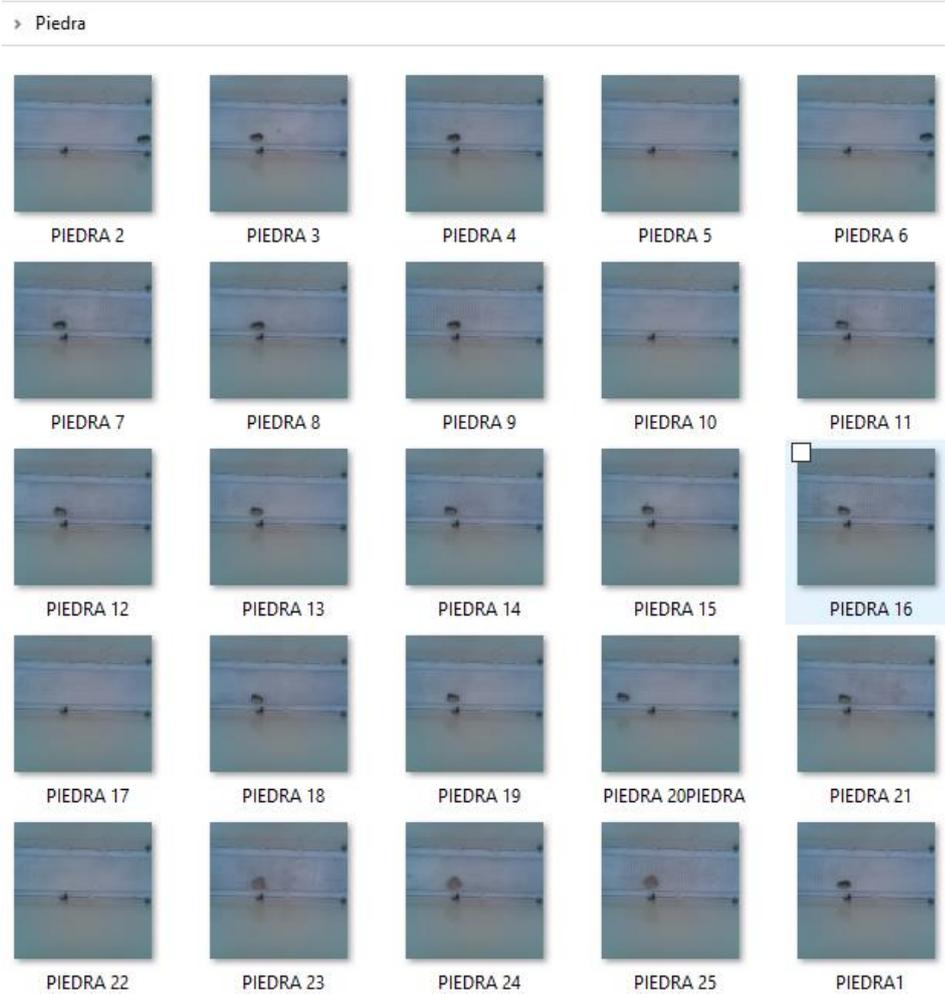


Figura 51. Muestras de la categoría “Piedra”

En la figura 52, se muestra una ventana donde están todas las categorías que van a estar en el proceso, se inclinó por subirlas a la nube para mayor respaldo y trazabilidad de la evolución de este.

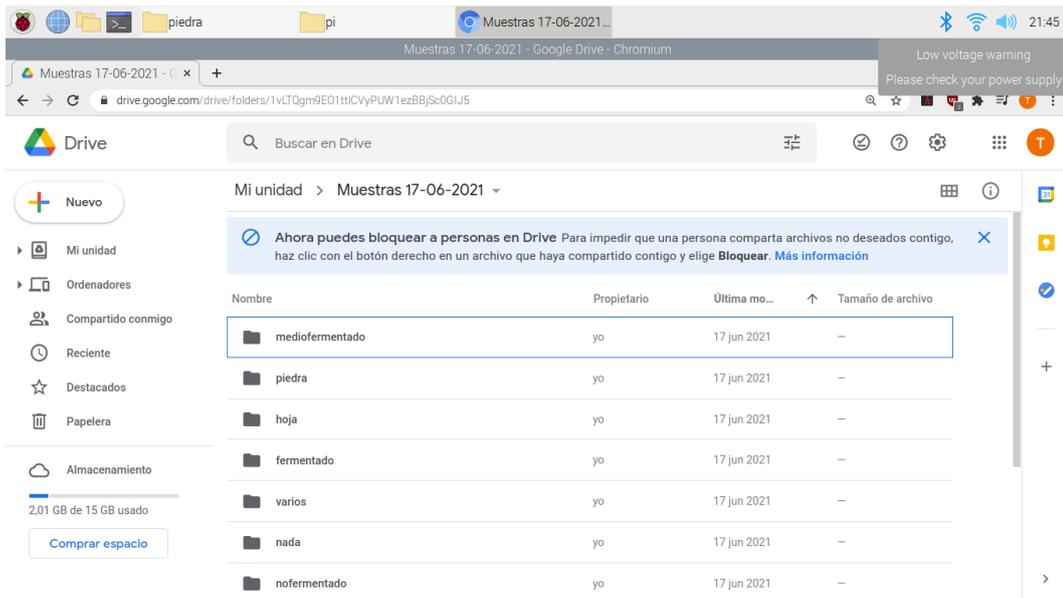


Figura 52. Recopilación de datos en la nube

En la figura 53 Se sube a la plataforma de Teachable Machine las muestras tomadas de cada categoría para la generación de la neurona.

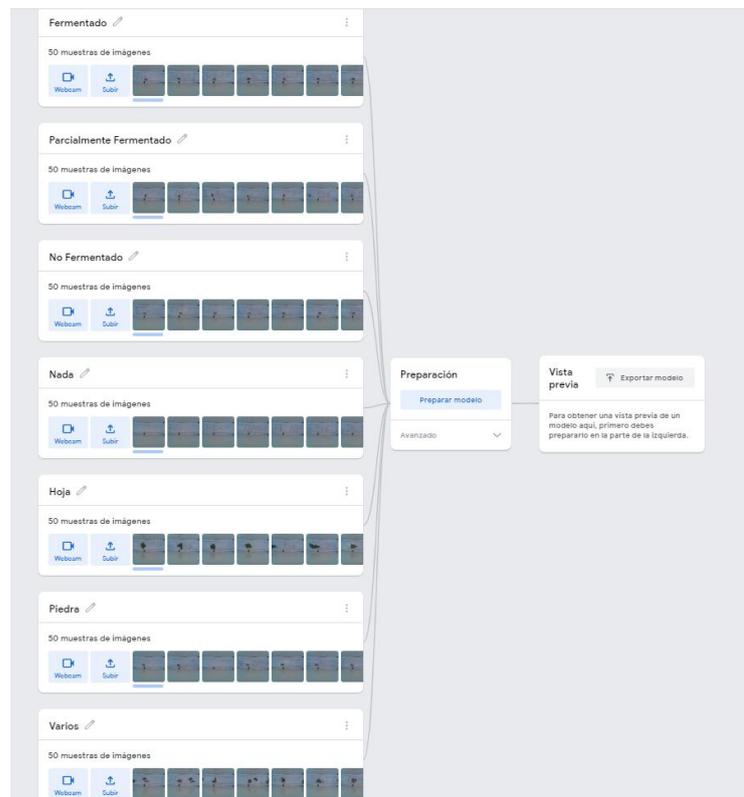


Figura 53. Plataforma Teachable Machine

En la figura 54, se procede a preparar la neurona en la plataforma.

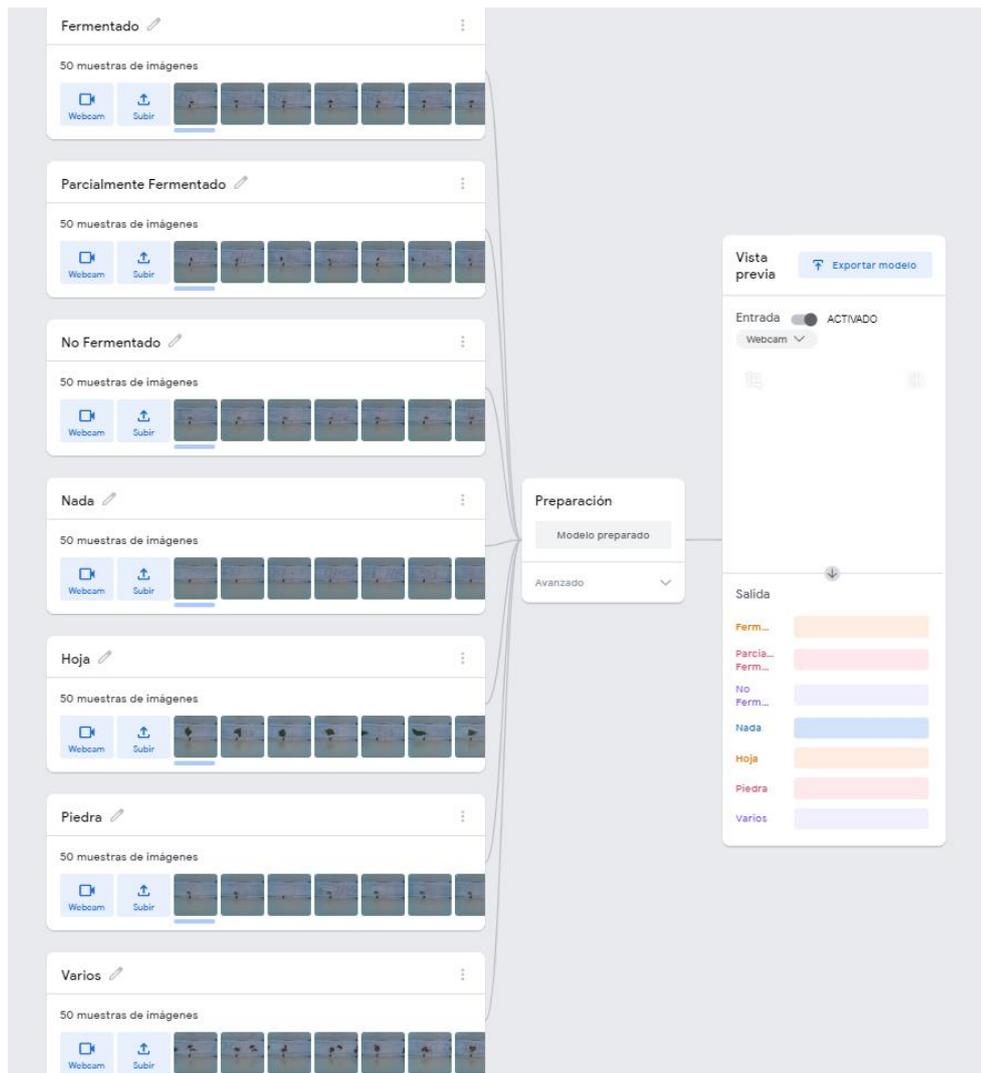


Figura 54. Neurona en preparación

En la figura 55, se muestra las opciones que da la plataforma para la obtención de la neurona. En este caso no se escogió TensorFlow.js porque no es compatible con Python y Raspberry.

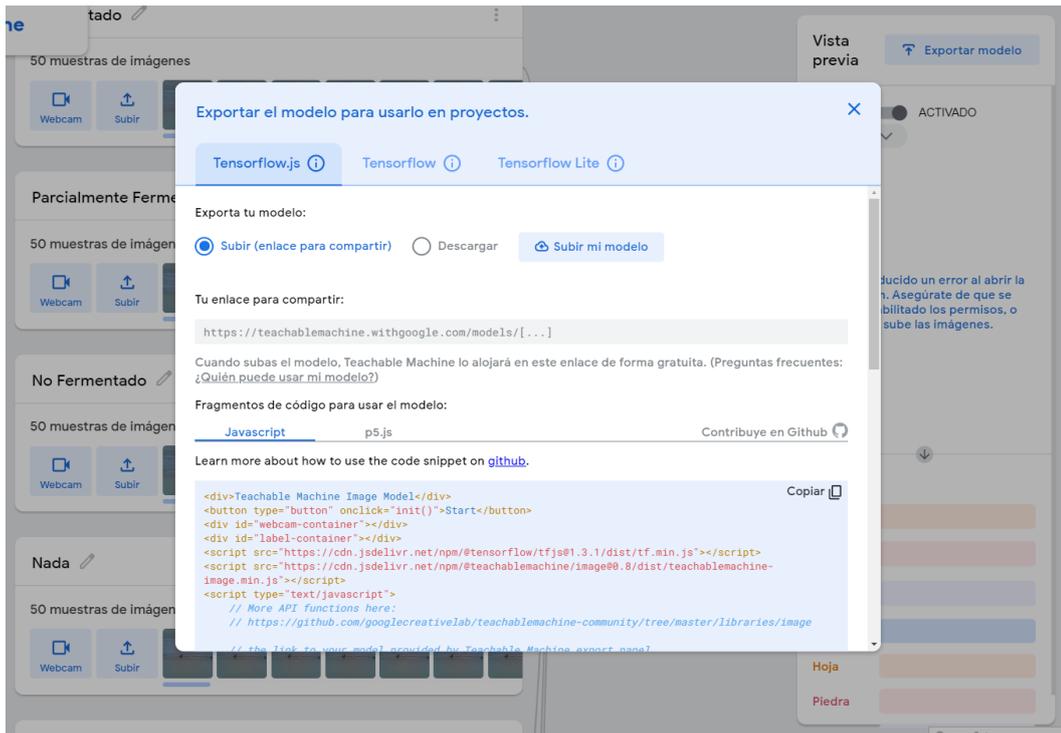


Figura 55. Opciones para exportar modelo Tensorflow.js

En la figura 56, se muestra las opciones que da la plataforma para la obtención de la neurona. En este caso se escogió TensorFlow, que genera un archivo “.h5”, mismo que es compatible con Python y Raspberry.

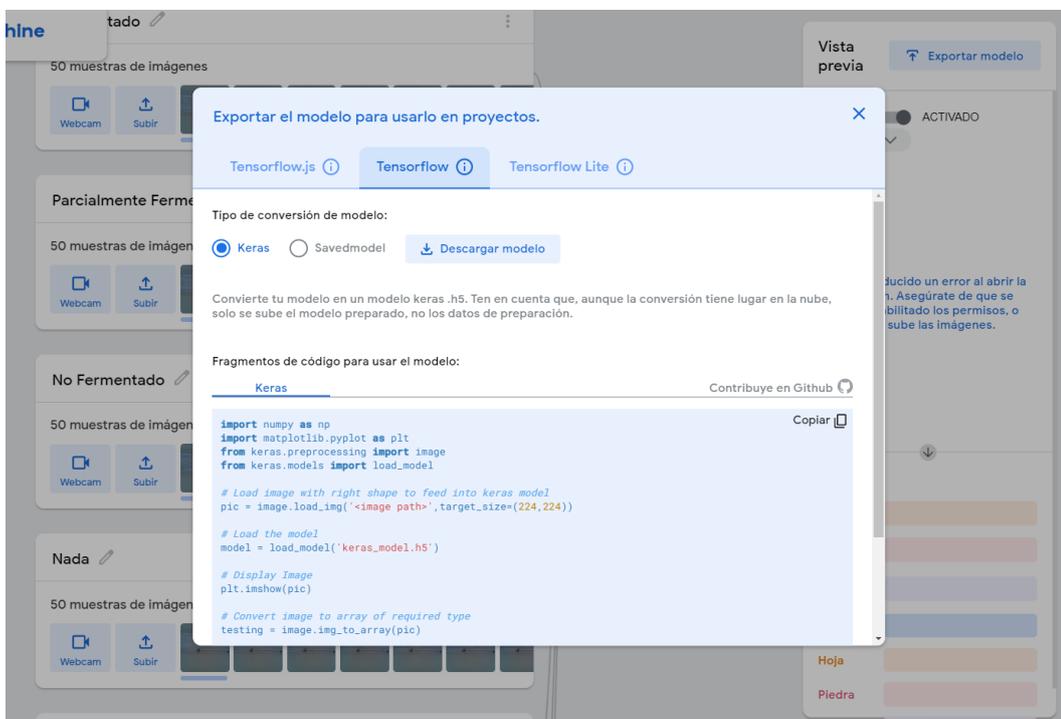


Figura 56. Opciones para exportar modelo Tensorflow

En la figura 57, se muestra las opciones que da la plataforma para la obtención de la neurona. En este caso no se escogió TensorFlow Lite porque no es compatible con la programación establecida del proyecto.

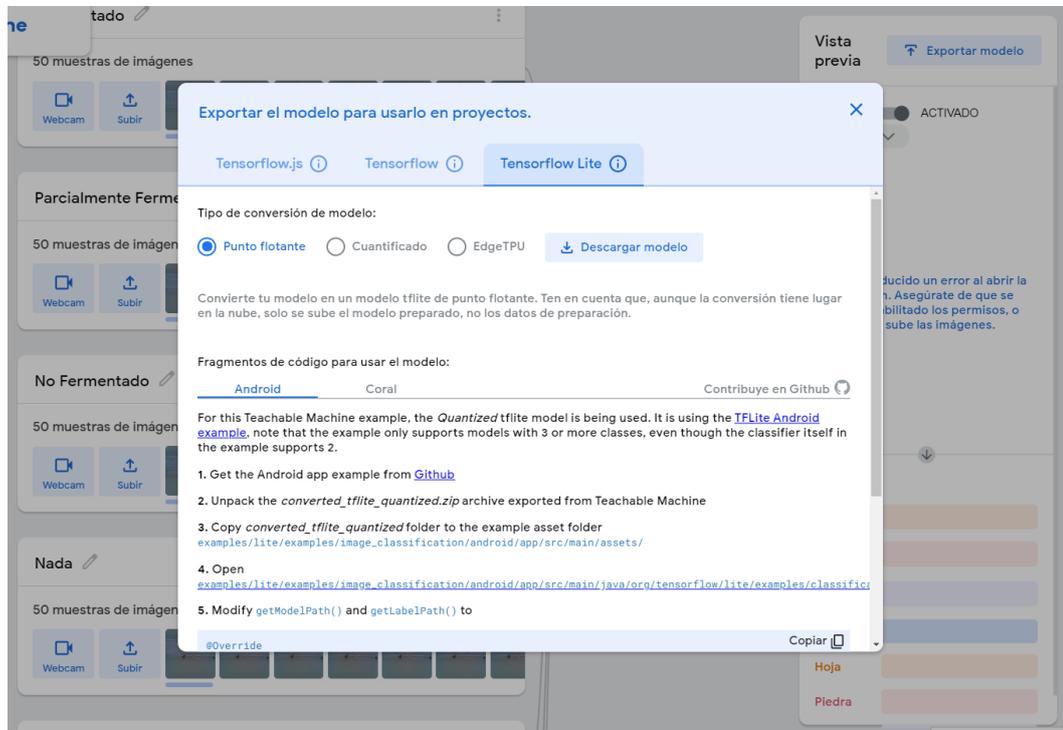


Figura 57. Opciones para exportar modelo Tensorflow Lite

Después de definir todas estas funciones de hiperparámetros, se entrena a la red, posterior a este procedimiento se guarda todo el proceso del modelo en un solo archivo cuyo formato será en Keras (.h5). Este archivo describe la topología y los pesos de la red. Las propiedades del archivo se presentan en la Figura 58.

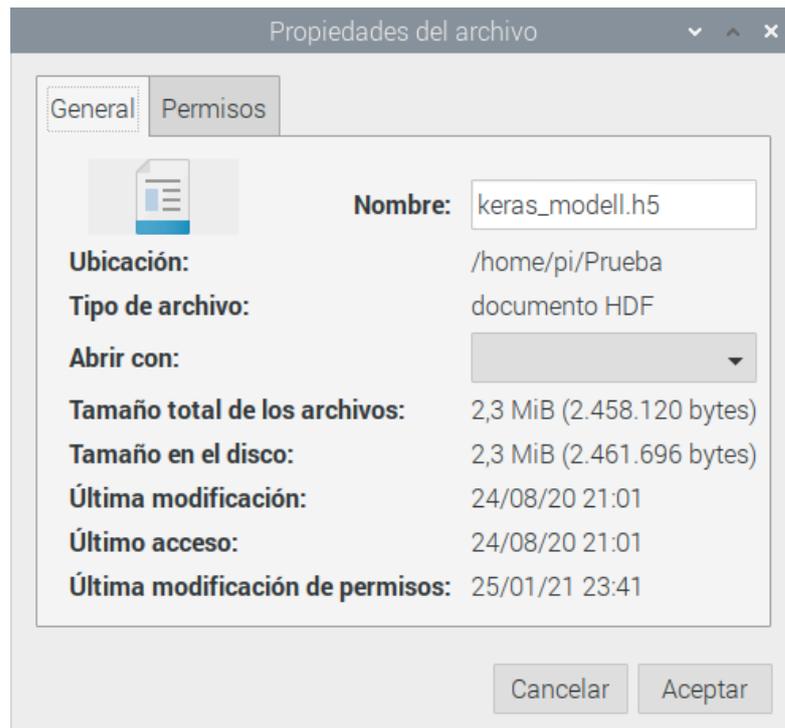


Figura 58. Propiedades del archivo

Una vez ya se tiene un modelo de red del clasificador de imágenes binario de granos de cacao fermentados, no fermentados y vacío (o nada) creado en formato compatible con Keras (.h5) hay que transformarlo, por lo que es necesario transformar dicho modelo a formato de TensorFlow, framework en el que se apoya Keras y que está diseñado para tareas de machine learning.

Para ello se necesita tener el modelo de red compatible con formato de TensorFlow en dos formatos distintos: en formato binario y en formato de texto. Para obtener estos dos archivos hace falta realizar un programa en Python que pueda transformar el archivo en formato de Keras (.h5) a formato binario de TensorFlow. Para ello es necesario que la versión de TensorFlow sea menor que la versión 2.0. Con este programa lo que se hace es cargar el modelo de Keras, escoger la salida de la red y eliminar toda la información no necesaria para la inferencia, convirtiendo el modelo en formato binario de TensorFlow.

Las limitantes recurrentes en el proyecto es que al tener las neuronas muchos datos cargados, al momento de ser procesada hay una pequeña probabilidad de que no continúe de manera correcta el programa, para evitar este tipo de novedades en el proceso es necesario cerrar todas las ventanas que no correspondan o pongan el riesgo la carga de la neurona.

3.1.4.3. Fase III: Proceso lógico para clasificación de granos de cacao

En resumen, lo que el prototipo va a hacer es detectar si la pepa de cacao está fermentada, parcialmente fermentada o no fermentada, y una vez divisado su estado se procederá a realizar una clasificación específica, tal como se lo detalla en la Figura 59.

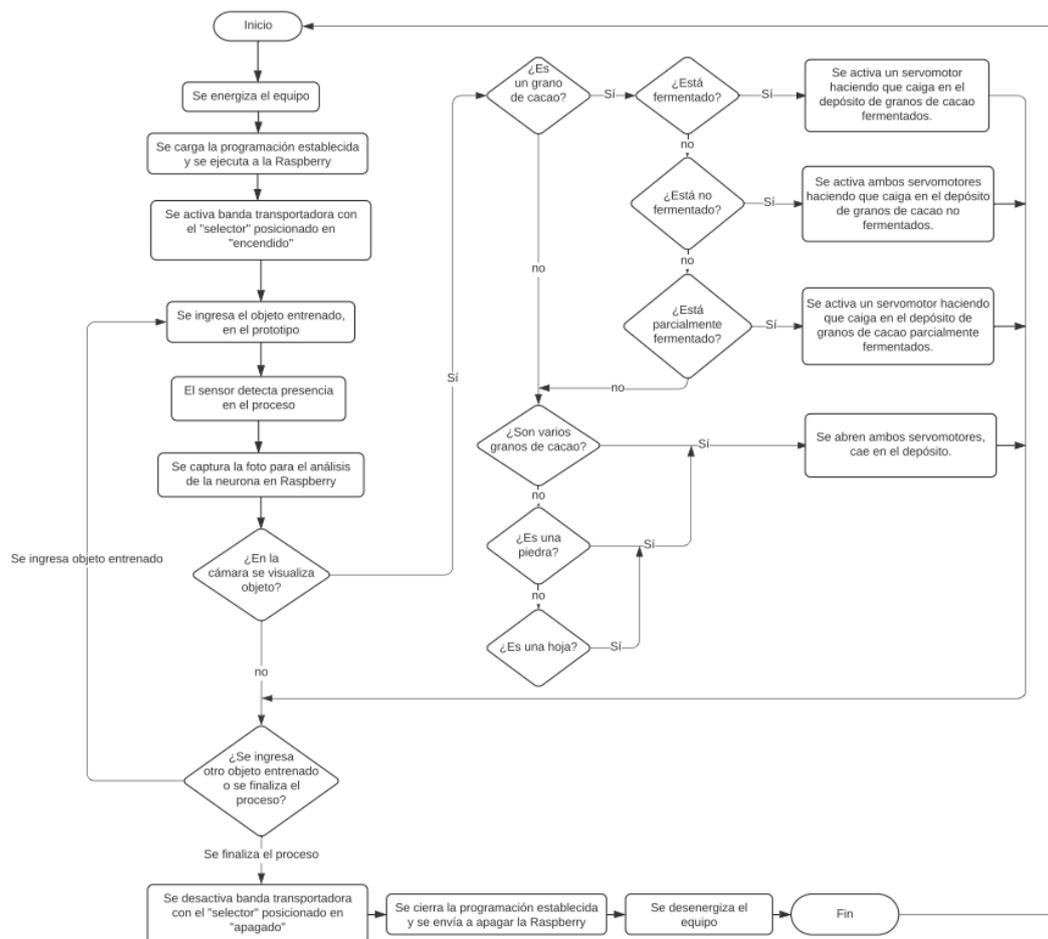


Figura 59. Diagrama de flujo del funcionamiento base del prototipo

Pero para que este proceso pueda llevarse a cabo, es justo y necesario que se realicen una serie de procesos secuenciales los cuales se verán reflejadas y explicadas de modo ipso facto:

1. Una vez que se haya capturado la neurona mediante los procesos adherentes del machine learning se debe proceder a subir dicho entrenamiento en el script desarrollado, para esto se empleó la función `load_model`, tal como se lo muestra en la Figura 60

```
model = tensorflow.keras.models.load_model('keras_modelultima.h5');
```

Figura 60. Carga del modelo entrenamiento al script desarrollado

2. Ya cargado el modelo al script se procede a capturar la imagen obtenida desde la cámara del Raspberry mediante la función `camera.capture`, como se lo indica en la Figura 61.

```
camera.capture('Luis.jpg');#capturamos foto para comprara con neurona  
camera.capture('Luis.gif');#caprura para vizualizar en GUI
```

Figura 61. Captura de imágenes desde la cámara del Raspberry Pi

3. Una vez ya capturada la imagen se la va a redimensionar a 224*224 y posteriormente se la convertirá en un array, tal como se lo muestra en la Figura 62.

```
image = Image.open('Luis.jpg');  
size = (224, 224);  
#size = (2592, 1944);  
image = ImageOps.fit(image, size, Image.ANTIALIAS);#cambiamos tamaño de la foto guardada  
image_array = np.asarray(image);#Imagen convertida en array  
normalized_image_array = (image_array.astype(np.float32) / 127.0) - 1;  
data[0] = normalized_image_array;
```

Figura 62. Pasos requeridos para la conversión de la imagen a un array

4. Vale destacar que el proceso de llevar la imagen a un array es determinante para generar la predicción necesaria y así poder realizar el post análisis del estado del grano de cacao, cabe indicar que para llevar a cabo este objetivo se requiere de la función `model.predict`, como se lo refleja en la Figura 63

```
data[0] = normalized_image_array;  
prediction = model.predict(data);#Variable para guardar respeusta de la neurona  
prediction=prediction[0];  
print("proceso imagen ok")  
print(prediction)
```

Figura 63. Procesos requeridos para generar la predicción estipulada

5. Ya realizada la predicción, se procede a desarrollar los algoritmos condicionales para indicar el estado del grano de cacao e indicar que los granos fermentados tienen que ir al lado derecho del depósito, viéndolo

desde la perspectiva entrada-salida del proceso, la programación se muestra en la figura 64

```
if(prediction[0]>0.40):
    n=0
    LI=Label(v,image=img,text = "FERMENTADO",compound=tk.CENTER,fg="white",font=("Agency FB",25)).place(x=85,y=70)
    while n <=1:
        grados=50
        grados2=183
        GPIO.output(controlservo , True)
        pwm.ChangeDutyCycle(grados*0.0555555555556+2) # rotate to 0 degrees
        pwm2.ChangeDutyCycle(grados2*0.0555555555556+2) # rotate to 0 degrees
        time.sleep(0.5)
        GPIO.output(controlservo , False)
        time.sleep(0.1)
        n=n+1
    print("Fermentado")
    fermentado = fermentado + 1
    f=1
```

Figura 64. Procesos requeridos para generar la predicción estipulada de los granos de cacao fermentados

En el código de la figura 65 se muestra el desarrollo de los algoritmos condicionales para indicar el estado del grano de cacao e indicar que los granos no fermentados tienen que caer en el depósito central.

```
if(prediction[2]>0.50):
    LI=Label(v,image=img,text = "NO FERMENTADO",compound=tk.CENTER,fg="white",font=("Agency FB",25)).place(x=85,y=70)
    n=0
    while n <=1:
        grados=34
        grados2=163
        GPIO.output(controlservo , True)
        pwm.ChangeDutyCycle(grados*0.0555555555556+2) # rotate to 0 degrees
        pwm2.ChangeDutyCycle(grados2*0.0555555555556+2) # rotate to 0 degrees
        time.sleep(0.5)
        GPIO.output(controlservo , False)
        time.sleep(0.1)
        n=n+1
    print("No Fermentado")
    nofermentado = nofermentado + 1
    f=1
```

Figura 65. Procesos requeridos para generar la predicción estipulada de los granos de cacao no fermentados

En el código de la figura 66 se muestra el desarrollo de los algoritmos condicionales para indicar el estado del grano de cacao e indicar que los granos parcialmente fermentados tienen que ir al lado izquierdo del depósito, viéndolo desde la perspectiva entrada-salida del proceso.

```

if(prediction[1]>0.50):
    LI=Label(v,image=img,text = "PARCIAL FERMENTADO",compound=tk.CENTER,fg="white",font=("Agency FB",25)).place(x=85,y=70)

    n=0
    while n <=1:
        grados=15
        grados2=150
        GPIO.output(controlservo , True)
        pwm.ChangeDutyCycle(grados*0.0555555555556+2) # rotate to 0 degrees
        pwm2.ChangeDutyCycle(grados2*0.0555555555556+2) # rotate to 0 degrees
        time.sleep(0.5)
        GPIO.output(controlservo , False)
        time.sleep(0.1)
        n=n+1
    print("Parcial Fermentado")
    mfermentado = mfermentado + 1
    f=1

```

Figura 66. Procesos requeridos para generar la predicción estipulada de los granos de cacao parcialmente fermentados

Algo importante de esta sección es que el prototipo no solo se basó en identificar los estados de los granos de cacao, sino que también fue diseñado hasta el punto de determinar si el objeto a analizar no pertenece a este grupo específico.

En el código de la figura 67 se muestra el desarrollo de los algoritmos condicionales en caso de que el sensor detector de presencia por algún agente extraño en el contexto o por falla propia del mismo haga una captura de pantalla, siga dando una predicción acertada e indicando en la pantalla que no hay presencia de objeto en el proceso con la palabra “Nada”.

```

if(prediction[3]>0.55):
    print("Nada")
    LI=Label(v,image=img,text = "NADA",compound=tk.CENTER,fg="white",font=("Agency FB",25)).place(x=85,y=70)
    f=1

```

Figura 67. Procesos requeridos para generar la predicción estipulada del proceso cuando no hay presencia de objetos

En el código de la figura 68 se muestra el desarrollo de los algoritmos condicionales en caso de que ingrese granos de cacao juntos en el proceso y por las limitantes de este, se va a mostrar en la pantalla un mensaje de “No se puede Clasificar”, ambos servomotores reaccionan abriendo sus guías de dirección.

```

if(prediction[4]>0.5):
    LI=Label(v,image=img,text = "NO SE PUEDE CLASIFICAR",compound=tk.CENTER,fg="white",font=("Agency FB",25)).place(x=85,y=70)

    n=0
    while n <=1:
        grados=15
        grados2=180
        GPIO.output(controlservo , True)
        pwm.ChangeDutyCycle(grados*0.0555555555556+2) # rotate to 0 degrees
        pwm2.ChangeDutyCycle(grados2*0.0555555555556+2) # rotate to 0 degrees
        time.sleep(0.5)
        GPIO.output(controlservo , False)
        time.sleep(0.1)
        n=n+1
    print("No se puede Clasificar")
    noclasificada=noclasificada+1
    f=1

```

Figura 68. Procesos requeridos para generar la predicción estipulada “No se puede Clasificar”

En el código de la figura 69 se muestra el desarrollo de los algoritmos condicionales en caso de que ingrese una piedra que no es parte del proceso, pero hay la probabilidad ya que es común entre los granos de cacao, se lo reconoce en la pantalla indicando la palabra “Piedra”, ambos servomotores reaccionan abriendo sus guías de dirección para evitar posible daño o trabamamiento de estas dado que no se puede calcular el tamaño de la piedra.

```

if(prediction[5]>0.5):
    lI=Label(v,image=img,text = "PIEDRA",compound=tk.CENTER,fg="green",font=("Agency FB",25)).place(x=85,y=70)

    n=0
    while n <=1:
        grados=15
        grados2=180
        GPIO.output(controlservo , True)
        pwm.ChangeDutyCycle(grados*0.05555555555556+2) # rotate to 0 degrees
        pwm2.ChangeDutyCycle(grados2*0.05555555555556+2) # rotate to 0 degrees
        time.sleep(0.5)
        GPIO.output(controlservo , False)
        time.sleep(0.1)
        n=n+1
    print("Piedra")
    noclasificada=noclasificada+1
    f=1

```

Figura 69. Procesos requeridos para generar la predicción estipulada “Piedra”

En el código de la figura 70 se muestra el desarrollo de los algoritmos condicionales en caso de que ingrese una hoja que no es parte del proceso, pero hay la probabilidad ya que es común entre los granos de cacao, se lo reconoce en la pantalla indicando la palabra “Hoja”, ambos servomotores reaccionan abriendo sus guías de dirección para evitar posible daño o trabamamiento de estas dado que no se puede calcular el tamaño de la hoja.

```

if(prediction[6]>0.6):
    lI=Label(v,image=img,text = "HOJA",compound=tk.CENTER,fg="green",font=("Agency FB",25)).place(x=85,y=70)

    n=0
    while n <=1:
        grados=15
        grados2=180
        GPIO.output(controlservo , True)
        pwm.ChangeDutyCycle(grados*0.05555555555556+2) # rotate to 0 degrees
        pwm2.ChangeDutyCycle(grados2*0.05555555555556+2) # rotate to 0 degrees
        time.sleep(0.5)
        GPIO.output(controlservo , False)
        time.sleep(0.1)
        n=n+1
    print("Hoja")
    noclasificada=noclasificada+1
    f=1

```

Figura 70. Procesos requeridos para generar la predicción estipulada “Hoja”

6. Y como último paso se desarrolló una sencilla interfaz gráfica, diseñada con las funcionalidades de Tkinter, en dónde se indicarán ciertos índices como: cantidad de muestras de cada uno de los estados del cacao, sus porcentajes respectivos y los estados del motor y de la cámara, tal como se lo indica en la Figura 71.

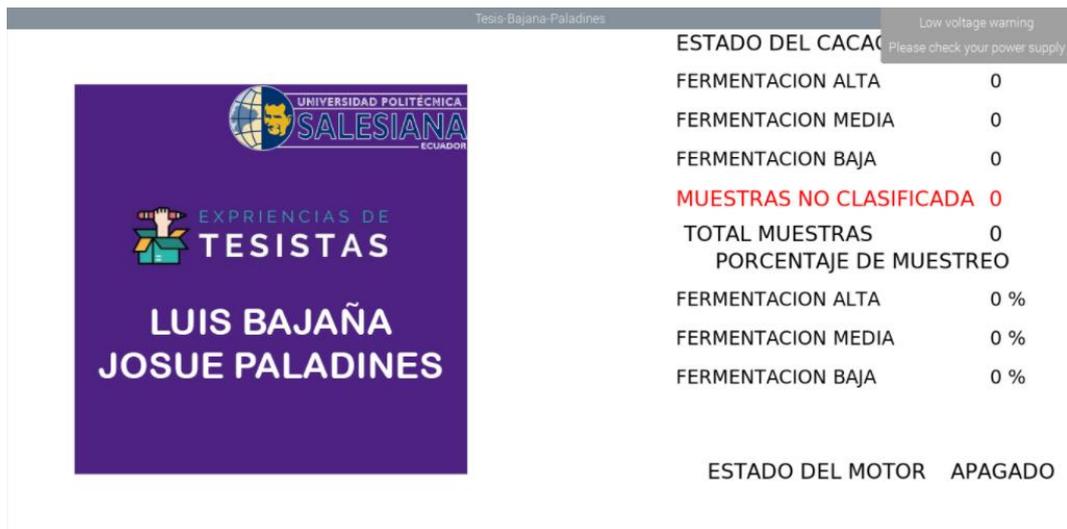


Figura 71. Interfaz desarrollada bajo Tkinter

- Para llevar a cabo el sexto paso fue necesario realizar dos procesos claves: el primero es realizar el cálculo de porcentaje total de los estados de las muestras, como se lo indica en la Figura 72 y el segundo es realizar el maquetado del interfaz GUI, tal como se lo reflejará en la Figura 78.

```
total=fermentado+nofermentado+mfermentado#Totalizador de muestras porcentual
if(total>0):
    porfermentado=(fermentado/(fermentado+nofermentado+mfermentado))*100
    pornofermentado=(nofermentado/(fermentado+nofermentado+mfermentado))*100
    pormfermentado=(mfermentado/(fermentado+nofermentado+mfermentado))*100
```

Figura 72. Cálculo de porcentaje por clasificación total de muestras

En la figura 73 se visualiza el código para mostrar el texto de “ESTADO DEL CACAO”, se configura la letra, el color y la posición en el GUI respectivamente.

```
l1=Label(v,text = "ESTADO DEL CACAO # MUESTRAS",font=("Agency FB",20),bg=color,fg="black").place(x=850,y=0)
```

Figura 73. Comando para mostrar “ESTADO DEL CACAO” en la interfaz

En la figura 74 se visualiza el código para mostrar el texto de “FERMENTACIÓN ALTA”, se configura la letra, el color y la posición en el GUI respectivamente.

```
l21=Label(v,text = "FERMENTACION ALTA",font=("Agency FB",18),bg=color,fg="black").place(x=850,y=50)
```

Figura 74. Comando para mostrar “FERMENTACIÓN ALTA” en la interfaz

En la figura 75 se visualiza el código para mostrar el texto de “FERMENTACIÓN MEDIA”, se configura la letra, el color y la posición en el GUI respectivamente.

```
l22=Label(v,text = "FERMENTACION MEDIA",font=("Agency FB",18),bg=color,fg="black").place(x=850,y=100)
```

Figura 75. Comando para mostrar “FERMENTACIÓN MEDIA” en la interfaz

En la figura 76 se visualiza el código para mostrar el texto de “FERMENTACIÓN BAJA”, se configura la letra, el color y la posición en el GUI respectivamente.

```
l23=Label(v,text = "FERMENTACION BAJA",font=("Agency FB",18),bg=color,fg="black").place(x=850,y=150)
```

Figura 76. Comando para mostrar “FERMENTACIÓN BAJA” en la interfaz

En la figura 77 se visualiza el código para mostrar el texto de “TOTAL MUESTRAS”, se configura la letra, el color y la posición en el GUI respectivamente.

```
l31=Label(v,text = "TOTAL MUESTRAS",font=("Agency FB",20),bg=color,fg="black").place(x=860,y=245)
```

Figura 77. Comando para mostrar “TOTAL MUESTRAS” en la interfaz

En la figura 78 se visualiza el código para mostrar el texto que se desea en el GUI, se configura la letra, el color y la posición respectivamente.

```
l1=Label(v,text = "ESTADO DEL CACAO # MUESTRAS",font=("Agency FB",20),bg=color,fg="black").place(x=850,y=0)
l21=Label(v,text = "FERMENTACION ALTA",font=("Agency FB",18),bg=color,fg="black").place(x=850,y=50)
l22=Label(v,text = "FERMENTACION MEDIA",font=("Agency FB",18),bg=color,fg="black").place(x=850,y=100)
l23=Label(v,text = "FERMENTACION BAJA",font=("Agency FB",18),bg=color,fg="black").place(x=850,y=150)
l31=Label(v,text = "TOTAL MUESTRAS",font=("Agency FB",20),bg=color,fg="black").place(x=860,y=245)
l5=Label(v,text="PORCENTAJE DE MUESTREO",bg=color,fg="black",font=("Agency FB",20)).place(x=900,y=280)
l21=Label(v,text = "FERMENTACION ALTA",font=("Agency FB",18),bg=color,fg="black").place(x=850,y=330)
l22=Label(v,text = "FERMENTACION MEDIA",font=("Agency FB",18),bg=color,fg="black").place(x=850,y=380)
l23=Label(v,text = "FERMENTACION BAJA",font=("Agency FB",18),bg=color,fg="black").place(x=850,y=430)
l8=Label(v,text="ESTADO DEL MOTOR",bg=color,fg="black",font=("Agency FB",20)).place(x=890,y=550)
l9=Label(v,text="ENCENDIDO",bg=color,fg="black",font=("Agency FB",20)).place(x=1200,y=550)
```

Figura 78. Maquetado para GUI (del inglés Graphical User Interface)

RESULTADOS

Una vez diseñado y desarrollado el prototipo se procedió a realizar una validación del funcionamiento del equipo con la detección del estado de las pepas de cacao con granos que previamente ya habían sido catalogados como no fermentado, fermentado y parcialmente fermentado; al ver los resultados que arrojó el prototipo no cabe duda el grado de asertividad y eficiencia que ofrece el sistema propuesto, tal como se lo reflejará de modo ipso facto en las siguientes figuras.



Figura 79. Detección de un grano de cacao fermentado



Figura 80. Detección de un grano de cacao no fermentado



Figura 81. Detección de un grano de cacao parcialmente fermentado

Adicional al proceso, se categorizaron las siguientes detecciones que pueden ser frecuentes en el proceso de postcosecha de cacao como agrupación de granos de cacao mostrado en la Figura 82, detección de piedras mostrado en la Figura 83 y la detección de hojas mostrado en la Figura 84.



Figura 82. Detección de objetos que no se pueden clasificar



Figura 83. Detección de una piedra



Figura 84. Detección de una hoja

Como prueba de la efectividad del modelo clasificador estipulado se empleó la matriz de confusión con un total de 70 muestras, en dónde 55 eran granos de cacao, 5 eran hojas y 10 eran piedras.

		Positivos	Negativos
Observación	Positivos	55	13
	Negativos	2	0

Tabla 2. Matriz de Confusión de Selección de Muestras

Antes de la realización de los cálculos de *Exactitud*, *Tasa de Error* Y *Sensibilidad*, es determinante interpretar la Tabla 2 un punto a destacar es que el sistema detectó a dos piedras como como que, si fuesen granos de cacao, por lo que se catalogó esas muestras como falso positivo, en cuanto a los granos de cacao los detectó a todos como tal, por lo que no se generaron falsos negativos. Ya con la recolección de data

solo quedaría demostrar el porcentaje de datos que han sido clasificados correctamente, cuántas han sido incorrectas y asimismo se podrá mostrar la tasa de verdaderos positivos y la tasa de verdaderos negativos.

$$\textit{Exactitud} = \frac{\textit{Verdadero Positivo} + \textit{Verdadero Negativo}}{\textit{Total de Muestras}}$$

$$\textit{Exactitud} = \frac{55 + 2}{70}$$

$$\textit{Exactitud} = \frac{57}{70}$$

Exactitud = 0.8142; Llevándolo a porcentaje quedaría:

$$\textit{Exactitud} = 81.42\%$$

$$\textit{Tasa de Error} = \frac{\textit{Falso Positivo} + \textit{Falso Negativo}}{\textit{Total de Muestras}}$$

$$\textit{Tasa de Error} = \frac{13 + 0}{70}$$

$$\textit{Tasa de Error} = \frac{13}{70}$$

Tasa de Error = 0.185; Llevándolo a porcentaje quedaría:

$$\textit{Tasa de Error} = 18.57\%$$

$$\textit{Sensibilidad} = \frac{\textit{Verdadero Positivo}}{\textit{Total Positivo}}$$

$$\textit{Sensibilidad} = \frac{55}{57}$$

Sensibilidad = 0.9649; Llevándolo a porcentaje quedaría:

$$\textit{Sensibilidad} = 96.49\%$$

CONCLUSIÓN

En el presente trabajo de titulación se propuso diseñar un prototipo capaz de clasificar los granos de cacao de acuerdo a su nivel de fermentación, para esto se requirió tanto el uso del paradigma de Machine Learning como el de Visión artificial; puesto que el primero fue empleado para realizar el entrenamiento de la neurona a estaba a cargo de llevar a cabo el proceso de identificación, mientras que el segundo tecnicismo fue empleado como nexo comparativo de la data capturada desde la cámara del Raspberry Pi con la predicción obtenida por el Teachable Machine.

De acuerdo con los resultados conseguidos se puede concluir que el sistema cuenta con un 81% de efectividad al realizar la clasificación de muestra, en cuanto al grado de clasificación incorrecta es de un 18% y para finiquitar el grado de efectividad en de detección de verdaderos positivos es de 96%. En conclusión, se puede determinar que a pesar de su gran efectividad en la clasificación del grano, se debe evitar que muestras que compartan los mismos patrones con el cacao, como son las piedras, que ya sea por su tan variable textura y su color el sistema lo puede confundir como el target a analizar.

Al evaluar la eficacia del prototipo en el mejor escenario posible, se logró concluir que el tópico propuesto tiene la capacidad de conseguir lo que se deseaba de manera muy asertiva, demostrando de este modo el gran aporte que puede incidir el uso de conceptos como Machine Learning y Visión Artificial en áreas que se los podría considerar ajenas a estos nichos informáticos y/o digitales; por lo que se puede intuir la posibilidad de que más sectores productivos se inclinen por este auge tecnológico y así abrir la posibilidad de mejorar sus procesos operativos y a su vez optimizar sus recursos.

RECOMENDACIONES

- Para futuras actualizaciones llevar el script de desarrollo tanto a entornos webs como móviles para aumentar el grado de portabilidad y dinamismo del sistema.
- A mediano y largo plazo se sugiere entrenar las redes neuronales convolucionales con métodos de aprendizaje no supervisado y así evitar inconsistencia de datos.
- Si se desea llevar el sistema en un ambiente de producción se sugiere tomar muestras como pH, humedad y temperatura, para así establecer relación de acuerdo con el grado de fermentación capturado por el método de visión por computador.
- Se sugiere plantear nuevos procesos en las redes neuronales para lograr determinar la textura de las semillas de cacao y así evitar el análisis de objetos no adherentes al proceso
- Cada una de las muestras deben estar separadas por 25 cm de distancia para un mejor resultado.
- Se recomienda diseñar un filtro a nivel de prototipado que garantice la entrada únicamente de granos de cacao para así realizar el post análisis determinado con el target deseado.

REFERENCIAS

- Academica. (15 de Mayo de 2017). *Academica*. Obtenido de https://www.youtube.com/watch?v=MKDNmW_ckjE
- Acosta, A., Aguilar, V., Carreño, R., Patiño, M., Patiño, J., & Martínez, M. A. (2020). Nuevas tecnologías como factor de cambio ante los retos de la inteligencia artificial y la sociedad del conocimiento. *ESPACIOS*, *41*(05).
- Alonso, A., & Jara, E. (2016). Visión por computadora: identificación, clasificación y seguimiento de objetos. *FPUNE Scientific*, (10).
- Alpaydin, E. (2020). *Introduction to machine learning*. MIT press.
- Angelia, R., & Linsangan, N. (2018). Fermentation Level Classification of Cross Cut Cacao Beans Using k-NN Algorithm. *5th International Conference on Bioinformatics Research and Applications*, (págs. 64-68).
- Arefi, A., Motlagh, A., & Khoshroo, A. (2011). Recognition of weed seed species by image processing. *Journal of Food, Agriculture and Environment*, *1*(9), 379-383.
- Arias, N. (2019). *Mejora en la exactitud en la clasificación de la fermentación de cacao mediante el diseño de un prototipo de control automático de calidad de cacao usando imágenes hiperespectrales*.
- Azabache, P. (2019). *Optimización del margen comercial de préstamos de consumo: algoritmo de optimización con Machine Learning*.
- Azizi, A. (2019). *Applications of Artificial Intelligence Techniques in Industry 4.0*. Berlin, Germany: Springer.
- Barrezueta, S., & González, A. (2017). Indicadores de sostenibilidad para la producción de cacao Nacional y CCN51 en la provincia El Oro-Ecuador. *Educatconciencia*, *13*(14), 16-26.
- Brico Geek . (s.f.). *Brico Geek* . Obtenido de <https://tienda.bricogeek.com/accesorios-raspberry-pi/822-camara-raspberry-pi-v2-8-megapixels.html>

- Cádiz, M., Fernández, Á., Leyva, F., Guerrero, N., Villegas, M., Pimentel, S., & Segura, A. (2020). LC-MS and Spectrophotometric Approaches for Evaluation of Bioactive Compounds from Peru Cocoa By-Products for Commercial Applications. *Molecules*, *14*(25), 3177.
- Challenger-Pérez, I., Díaz-Ricardo, Y., & Becerra-García, R. (2014). El lenguaje de programación Python/The programming language Python. *Ciencias Holguín*, 1-13.
- Cheng, G., & Guo, W. (2017). Rock images classification by using deep convolution neural network. In *Journal of Physics: Conference Series* (Vol. 887, No. 1, p. 012089).
- Collins, G., & Moons, K. (2019). Reporting of artificial intelligence prediction models. *The Lancet*, *393*(10181), 1577-1579.
- de la Hoz, E., & Fontalvo, T. J. (2019). Metodología de Aprendizaje Automático para la Clasificación y Predicción de Usuarios en Ambientes Virtuales de Educación. *Información tecnológica*, *30*(1), 247-254.
- De Vuyst, L., & Weckx, S. (2016). The cocoa bean fermentation process: from ecosystem analysis to starter culture development. *Journal of Applied Microbiology*, *121*(1), 5-17.
- Díaz Herrera, S. A. (junio de 2012). *uaeh*. Obtenido de https://www.uaeh.edu.mx/docencia/P_Presentaciones/prepa3/hardware.pdf
- EC Robotics . (s.f.). Obtenido de <https://www.ecrobotics.com.bo/producto/camara-raspberry-v2-8-megapixeles/>
- Electronicalab. (s.f.). *Electroniclab*. Obtenido de <https://electronilab.co/tienda/camara-para-raspberry-pi-v2-8-mpx/>
- Electronilab. (s.f.). *Electronilab*. Obtenido de <https://electronilab.co/tienda/sensor-detector-de-obstaculos-infrarrojo-fc-51-fc51/>
- Erazo, C. (2019). *Diseño de un fermentador y secador solar piloto, para dos variedades de cacao (Theobroma cacao L), en el cantón El empalme provincia Guayas*.

- ESPAC. (2019). Obtenido de https://www.ecuadorencifras.gob.ec/documentos/web-inec/Estadisticas_agropecuarias/espac/espac-2019/Tabulados%20ESPAC%202019.xlsx
- Espinoza, D. A. (2019). *Manejo de la escoba de bruja (Moniliophthora Perniciosa) en el Cultivo de Cacao CCN-51 (Theobroma cacao L.) en la Hacienda " San José zona de Babahoyo .*
- Feng, X., Jiang, Y., Yang, X., Du, M., & Li, X. (2019). Computer vision algorithms and hardware implementations: A survey. *Integration*, 69, 309-320.
- García González, A. (2016). *¿Qué es y como funciona un servomotor?*
- Giraldo, J., Salazar, A., & Daza, J. (2016). Semi-supervised recognition of the *Diploglossus millepunctatus* lizard species using artificial vision algorithms. . *arXiv preprint arXiv:1611.02803*.
- Grealtec. (s.f.). *Grealtec*. Obtenido de <http://www.grealtec.com/blog/todo-lo-que-necesitas-saber-sobre-las-tiras-led/>
- Greene, D., Hoffmann, A. L., & Stark, L. (2019). Better, nicer, clearer, fairer: A critical assessment of the movement for ethical artificial intelligence and machine learning. *Proceedings of the 52nd Hawaii International Conference on System* .
- Guerreo, F. (2018). *Análisis y desarrollo de una herramienta tipo Marketplace utilizando técnicas de aprendizaje automático bajo algoritmos no supervisados .*
- Hernández, C., Alejos, J., & Cázares, N. (2019). Instrumento virtual para estudiar la representación de color RGB en máquinas de visión con labview . *Pistas Educativas*, 41(134), 134(41).
- Humston, E., Knowles, J., McShea, A., & Synovec, R. (2010). Quantitative assessment of moisture damage for cacao bean quality using two-dimensional gas chromatography combined with time-of-flight mass spectrometry and chemometrics. *Journal of Chromatography*, 12(1217), 1963-1970.

- IArtificial. (10 de Octubre de 2020). *IArtificial*. Obtenido de <https://www.iartificial.net/librerias-de-python-para-machine-learning/#TensorFlow>
- Informática IV. (s.f.). *Fcasua*. Obtenido de http://fcasua.contad.unam.mx/apuntes/interiores/docs/98/4/informatica_4.pdf
- La electrónica. (s.f.). *La Electrónica*. Obtenido de <https://laelectronica.com.gt/motores/servo/motor-servo-mg995-de-360-grados---15-kgcm>
- Lachenaud, P., & Motamayor, J. C. (2017). The Criollo cacao tree (*Theobroma cacao* L.): a review. *Genetic Resources and Crop Evolution*, 64(8), 1807-1820.
- León, N., Abderrahim, M., Nuñez, L., Arribas, S. M., & Condezo, L. (2016). Prediction of fermentation index of cocoa beans (*Theobroma cacao* L.) based on color measurement and artificial neural networks. *Talanta*(161), 31-39.
- López Arenales, J. C. (s.f.). *Biblio 3*. Obtenido de <http://biblio3.url.edu.gt/Libros/2013/ing/pim/3.pdf>
- Medium. (17 de Noviembre de 2019). *medium.com*. Obtenido de <https://medium.com/@di3cruz/detecci%C3%B3n-de-objetos-en-tiempo-real-con-python-y-opencv-e760fdaad58e>
- Melo, T. S., Pires, T. C., Engelmann, J., Monteiro, A., Maciel, L., & da Silva Bispo, E. (2020). Evaluation of the content of bioactive compounds in cocoa beans during the fermentation process. *Journal of Food Science and Technology*, 1-11.
- Mohri, M., Rostamizadeh, A., & Talwalkar, A. (2018). *Foundations of machine learning*. MIT press.
- Monk, S. (2016). *Raspberry Pi cookbook: Software and hardware problems and solutions*. O'Reilly Media, Inc.

- O'Mahony, N., Campbell, S., Carvalho, A., Harapanahalli, S., Hernandez, G. V., Krpalkova, L., & Walsh, J. (2019). Deep learning vs. traditional computer vision. *Science and Information Conference*, (págs. 128-144).
- Ortega, R., García, A., & Bautista, O. M. (2019). El cultivo de cacao. Su optimización empleando analítica de datos e inteligencia artificial para el mejoramiento su producción y comercialización. *Infometric@-Serie Ingeniería, Básicas y Agrícolas*, 2(2), 80-92.
- Parra, P., Negrete, T., Llaguno, J., & Vega, N. (2018). Computer vision Methods in the Process of fermentation of the Cocoa Bean. *IEEE*, 1-6.
- Pastor, J. (25 de Abril de 2018). *Xataka*. Obtenido de <https://www.xataka.com/ordenadores/raspberry-pi-3-model-b-analisis-mas-potencia-y-mejor-wifi-para-un-minipc-que-sigue-asombrando>
- Patrício, D., & Rieder, R. (2018). Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. . *Computers and electronics in agriculture*(153), 69-81.
- Pérez, F. A. (2019). El enfoque probabilístico en Inteligencia Artificial. *Análisis GESI*, (14), 1.
- Pesántez Erazo, A. A. (2012). *Diseño y construcción de un módulo de laboratorio con variador de frecuencia para el control de un sistema de bombeo y determinación del ahorro energético*. Riobamba.
- Plaza, M., & Cardozo, D. (2018). Implementación de algoritmo K-medias y modelo RGB para la Clasificación de Café Cereza. . *Congreso Internacional de Tecnología, Ciencia y Sociedad*. Lisboa.
- Pypi. (21 de Julio de 2019). *Pypi*. Obtenido de <https://pypi.org/project/RPi.GPIO/>
- Python. (2021). Obtenido de <https://docs.python.org/es/3/library/time.html?highlight=time#module-time>
- Python. (2021). *Docs pyhton* . Obtenido de <https://docs.python.org/es/3/library/tk.html>

- Raspberry Pi Foundation. (2020). *Raspberry* . Recuperado el 20 de Agosto de 2020, de <https://www.raspberrypi.org/help/what-%20is-a-raspberry-pi/>
- Recursos Python. (s.f.). *Recursos Python*. Obtenido de <https://recursospython.com/guias-y-manuales/instalar-pil-pillow-efectos/>
- Rodríguez De Luis, E. (18 de Septiembre de 2018). *Xataka*. Obtenido de <https://www.xataka.com/makers/cero-maker-todo-necesario-para-empezar-raspberry-pi>
- Rodríguez, S., & Camacho, J. (2018). *Los métodos de aprendizaje automático supervisado en la clasificación textual según el grado de especialización*.
- Rojas, E. (2020). Machine Learning: análisis de lenguajes de programación y herramientas para desarrollo. *Revista Ibérica de Sistemas e Tecnologías de Informação*(28), 586-599.
- Rudkowskyj, S. (2019). *APRENDIZAJE POR REFUERZO EN SISTEMAS ROBÓTICOS*.
- Ruiz , C. A., & Basualdo, M. S. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Rosario.
- Samaniego, C. (2020). *Determinación de la Calidad de Cacao Criollo (Theobroma Cacao L.) Fermentado Mediante Visión Computacional*.
- Sánchez López, J. (s.f.). *Proyecto Círculos*. Obtenido de proyectocirculos
- Sandoval, M. (2017). *Prototipo de un proceso industrial de control de calidad con visión artificial* .
- Schneider Electric. (2021). *Schneider Electric*. Obtenido de Schneider Electric: <https://www.se.com/co/es/product/ATV312H075M2/variador-de-velocidad-atv312---0%2C75-kw---1%2C8-kva---60-w---200..240-v--monof%C3%A1sico/>
- SPS Export. (2021). *SPS Export*. Obtenido de <https://spsexport.com/producto/cacao-sur-del-lago-fermentado-al-90/>
- Teachable Machine. (s.f.). *Teachable Machine*. Obtenido de <https://teachablemachine.withgoogle.com/>

- Teneda, W. (2016). *Mejoramiento del Proceso de Fermentación del Cacao.(Theobroma cacao L.) Variedad Nacional y Variedad CCN51.*
- Teye, E., Huang, X., Sam-Amoah, L. K., Takrama, J., Boison, D., Botchway, F., & Kumi, F. (2015). Estimating cocoa bean parameters by FT-NIRS and chemometrics analysis. *Food chemistry*(176), 403-410.
- Ullah, Z., Al-Turjman, F., Mostarda, L., & Gagliardi, R. (2020). Applications of Artificial Intelligence and Machine learning in smart cities. *Computer Communications.*
- Universidad de Coimbra. (Julio de 2017). *premium light pro.* Obtenido de http://www.premiumlightpro.es/fileadmin/es/4_Conceptos_Basicos_del_LED.pdf
- Valverde, S. (2019). *Aplicaciones de la inteligencia artificial en la empresa.*
- Viera, G. (2018). *Aplicación de procesamiento de imágenes para clasificación de granos de cacao según su color interno.*
- Vulcabar. (s.f.). *Vulcabar.* Obtenido de <http://vulcabar.com/producto/banda-rugosa/>
- Yro, A., N'zi, C. E., & Kpalma, K. (2018). Cocoa Beans Fermentation Degree Assessment For Quality Control Using Machine Vision and Multiclass SVM Classifier. *International Journal of Innovation and Applied Studies, ISSR Journals, 4*(24), 1711-1717.