



**Desarrollo de un sistema de visión por computadora con Raspberry Pi para la
detección temprana de la Moniliasis y la Fitóftora en el cultivo de cacao criollo de
la finca Villa Laura en el Huila**

Cristian David Andrade Becerra
Código 20441627783

Universidad Antonio Nariño
Programa Ingeniería Electrónica
Facultad de Ingeniería Mecánica, Electrónica y Biomédica
Neiva, Colombia

2022

**Desarrollo de un sistema de visión por computadora con raspberry pi para la
detección temprana de la Moniliasis y la Fitóftora en el cultivo de cacao criollo de
la finca Villa Laura en el Huila**

Cristian David Andrade Becerra

Proyecto de grado presentado como requisito parcial para optar al título de:

Ingeniero Electrónico

Directora:

Yeimi Muñoz Calderón

Universidad Antonio Nariño

Programa Ingeniería Electrónica

Facultad de Ingeniería Mecánica, Electrónica y Biomédica

Neiva, Colombia

2022

NOTA DE ACEPTACIÓN

El trabajo de grado Desarrollo de un sistema de visión por computadora con raspberry pi para la detección temprana de la Moniliasis y la Fitóftora en el cultivo de cacao criollo de la finca Villa Laura en el Huila, cumple con los requisitos para optar Al título de Ingeniero Electrónico.

Firma del Tutor

Firma Jurado

Firma Jurado

Contenido

Pág.

Resumen	23
Abstract	24
Introducción.....	25
Capitulo 1	26
1. Planteamiento del problema	26
Capitulo 2	30
2. Marco teórico.....	30
2.1. Variedades del cacao	30
2.2. Características del cultivo	31
2.3. Enfermedades	34
2.3.1. Mazorca negra (Phytophthora s.p).....	35
2.3.2. Escoba de bruja (Moniliophthora perniciosa)	35
2.3.3. Monoliasis (Moniliophthora roreri).....	36
2.4. Panorama en Colombia	37
2.7. Producción regional.....	39
2.8. Procesamiento de imágenes digitales	41
2.8.1. Definiciones.....	41
2.9. Inteligencia artificial (IA).....	42
2.9.1. Definición	42
2.9.2. Aplicaciones	44
2.9.3. Machine Learning.....	44
2.9.3.1. Definición.....	44
2.9.3.2. Clasificación.....	46
2.9.4. Redes neuronales	47
2.9.5. Transfer learning.....	49
2.9.6. Reconocimiento de objetos.....	50
2.9.7. Detección de objetos mediante SSD MobileNet V2	52
2.9.8. mAP (mean Average Precision) Para la detección de objetos.....	54

Capítulo 3	61
3 Marco referencial	61
Capítulo 4	65
4 Diseño metodológico	65
4.1 Análisis hardware	65
4.1.1 Diseño de Hardware	65
4.1.2 Diagrama general de hardware	72
4.1.3 Diagrama de primer nivel hardware	72
4.2 Análisis de software	74
4.2.1 Diseño de software	74
4.2.1.1 Recopilación de datos y etiquetado de imágenes	74
4.2.1.2 Selección de la interfaz de trabajo.....	78
4.2.1.3 Modelo de entrenamiento.....	79
4.2.1.4 Mapas de etiqueta.....	81
4.2.1.5 Registros TF	81
4.2.1.6 Configuración para el transfer learning.....	83
4.2.1.7 Entrenamiento del modelo	84
4.2.2 Diagrama general software	87
4.2.3 Diagrama de primer nivel	88
4.2.4 Algoritmo de visión artificial para detección de enfermedades	89
Capítulo 5	90
5. Análisis y resultados	90
5.1 Evaluación de modelo	90
5.1.1 Evaluación del entrenamiento	91
5.1.2 Evaluación de las métricas de rendimiento	92
5.1.3 Evaluación de detección a partir de imágenes.....	94
5.1.4 Detección con el modelo entrenado implementado en la Raspberry Pi	96
Capítulo 6	99
Conclusiones	99
Bibliografía	101

Lista de Figuras

Figura 1	<i>Vista general de la arquitectura MobileNet V2</i>	53
Figura 2	<i>Calculo para la intersección sobre la unión</i>	57
Figura 3	<i>Ejemplo de cálculo de Intersección sobre uniones para varios cuadros delimitadores.</i>	58
Figura 4	<i>Definición de IoU</i>	59
Figura 5	<i>Métricas de rendimiento de un detector de objetos en COCO</i>	60
Figura 6	<i>Cámara RPi OEM Rev. 1.3</i>	67
Figura 7	<i>Sistema de conexión de la cámara</i>	68
Figura 8	<i>Raspberry PI 4</i>	69
Figura 9	<i>Alimentación del sistema</i>	71
Figura 10	<i>Diagrama general del sistema de visión - Hardware</i>	72
Figura 11	<i>Diagrama en bloques funcionales del sistema de visión - hardware</i>	73
Figura 12	<i>Esquema electrónico detallado del sistema desarrollado</i>	74
Figura 13	<i>Etiqueta de cacao sano</i>	76
Figura 14	<i>Etiqueta de cacao con Moniliasis</i>	76
Figura 15	<i>Etiqueta de cacao con Fitoftora</i>	77
Figura 16	<i>Archivo XML resultante de la etiqueta cacao sano</i>	78
Figura 17	<i>Modelos para la detección de objetos</i>	80
Figura 18	<i>Mapa de etiqueta</i>	81
Figura 19	<i>Archivo mapa de etiqueta y TF-Records de entrenamiento y evaluación</i>	82
Figura 20	<i>Arquitectura SSD MobileNet V2 sin Transfers Learning</i>	83
Figura 21	<i>Arquitectura SSD MobileNet V2 con Transfers Learning</i>	84
Figura 22	<i>Comienzo de entrenamiento</i>	85
Figura 23	<i>Final del entrenamiento</i>	86
Figura 24	<i>Diagrama de flujo del algoritmo de entrenamiento</i>	87
Figura 25	<i>Diagrama general del sistema de visión- software</i>	88
Figura 26	<i>Diagrama de bloques funcionales del sistema de visión- Software</i>	88
Figura 27	<i>Diagrama de flujo del algoritmo del sistema de visión</i>	89
Figura 28	<i>Resultados de la evaluación del modelo</i>	91
Figura 29	<i>Total de perdidas (total_loss)</i>	92
Figura 30	<i>Precisión media (Average precisión)</i>	93
Figura 31	<i>Recuerdo promedio (Average recall)</i>	93
Figura 32	<i>Detección de phytophthora</i>	94
Figura 33	<i>Detección de Moniliasis</i>	95
Figura 34	<i>Detección de Moniliasis y cacao sano en iluminación baja</i>	95
Figura 35	<i>Prototipo de detección I</i>	96
Figura 36	<i>Prototipo de detección II</i>	97
Figura 37	<i>Prototipo de detección III</i>	98

Lista de tablas

Tabla 1	65
Tabla 2	67
Tabla 3	70
Tabla 4	71

Lista de ecuaciones

Ecuación 1	<i>Ecuación de precisión</i>	55
Ecuación 2	<i>Ecuación de recuperación</i>	56
Ecuación 3	<i>Ecuación de F1</i>	56

(Dedicatoria)

El desarrollo del presente trabajo de grado ha supuesto una importante experiencia de aprendizaje tanto para mi vida personal como profesional. Por ello, dedico este trabajo a mis padres, que supieron inculcarme actitudes positivas, hábitos y valores lo cual me ha ayudado a seguir adelante en los momentos difíciles.

Resumen

A través de esta investigación se desarrolló un sistema de visión por computadora con Raspberry Pi para contribuir en la detección temprana de la Moniliasis y la Fitóftora que actualmente son las que más afectan al cacao y a partir de allí, generar alternativas que minimicen su impacto. Para este estudio se utilizaron redes neuronales, con el fin de detectar las enfermedades en el cacao, el modelo de detección que se utilizó es el SSD MobileNet V2, una arquitectura utilizada para la detección de objetos, entrenada y evaluada por un conjunto de imágenes propio. Las imágenes provienen de la finca Villa Laura donde se extrajo un conjunto de datos de 540 imágenes, la red neuronal una vez entrenada se calcula las métricas de rendimiento obteniéndose como resultado una precisión media del 0.783, y un recuerdo promedio del 0.85. Siendo esto resultados muy favorables para el modelo entrado.

Palabras clave: Cacao, Redes Neuronales, Raspberry, enfermedades.

Abstract

Through this research, a computer vision system was developed with Raspberry Pi to contribute to the early detection of Moniliasis and Phytophthora, which currently affect cocoa the most, and from there, generate alternatives to minimize their impact. Neural networks were used for this study, in order to detect diseases in cocoa, the detection model used is the SSD MobileNet V2, an architecture used for object detection, trained and evaluated by a set of own images. The images come from the Villa Laura farm where a dataset of 540 images was extracted, the neural network, once trained, calculates the performance metrics, obtaining as a result an average accuracy of 0.783, and an average recall of 0.85. These results are very favorable for the model entered.

Keywords: Cocoa, Neural Networks, Raspberry, diseases.

Introducción

El cacao en el departamento del Huila hace parte de las apuestas productivas que marcan la economía de la región. Es sin duda un eslabón fundamental del cual decenas de familias demandan su sustento diario. Actualmente, el Huila se ubica en el quinto lugar en la producción del país, generando el 7% de la producción total en Colombia.

Las entidades gubernamentales y algunas dedicadas al fortalecimiento de la agricultura en el departamento, han centrado sus esfuerzos en elevar la calidad del grano, sin embargo, uno de los principales retos que presenta el cultivo, es la presencia de enfermedades y plagas que, en las distintas etapas del proceso, lo atacan, generando consecuencias que van desde la disminución de la calidad del fruto final hasta la pérdida total de la siembra.

En ese propósito, se diseñó un sistema de visión por computadora que permita contribuir en la detección temprana de Moniliasis y Fitóftora en el cultivo de cacao.

El trabajo está estructurado en seis capítulos. En el apartado uno, se relacionan el planteamiento del problema y los objetivos propuestos para el desarrollo de la investigación. En el segundo, se hace referencia al marco teórico mientras que en el capítulo tres, se relaciona otros estudios de investigación en los que las redes neuronales fueron fundamentales para detección de enfermedades; en el capítulo cuatro se presenta el diseño metodológico, en el quinto, análisis y resultados de la implementación del modelo, y el capítulo seis, en el que se hace referencia a las conclusiones de la investigación.

Capítulo 1

1. Planteamiento del problema

El uso eficiente de técnicas sólidas de producción y mantenimiento, con especial atención a la gestión de plagas y enfermedades, determinan la vida productiva y económicamente viable de una plantación de cacao. Por ello, es fundamental mantener un alto nivel de gestión de la plantación para garantizar que sus plantas de cacao sean menos vulnerables a los ataques de plagas y enfermedades. (Ángel & Sánchez, n.d.)

El principal motivo de pérdida de la producción mundial de cacao son las enfermedades. Por ello, mantener el control sobre ellas es esencial para el funcionamiento eficaz de los cacaotales. (Ángel & Sánchez, n.d.)

Los cultivadores deben ser capaces de identificar los signos y síntomas de enfermedades graves como la *Phytophthora* y la *Moniliasis*, que pueden reducir la producción hasta en un 52%. (Instituto Colombiano Agropecuario - ICA, 2021)

Ambas enfermedades generan una pudrición en la mazorca del cacao. La moniliasis es provocada por *Moniliophthora roreri*, un hongo anamorfo de la familia *Marasmiaceae* y una enfermedad hemibiotrófica (Aime & Rica, 2005). Cuando la enfermedad aparece, tiene una estructura contaminada con esporas blancas que pueden extenderse por toda la mazorca; estas esporas son descargadas por las corrientes de aire y las vibraciones de las plantas durante la cosecha (Evans, 1981), permitiendo que la enfermedad se multiplique en otras mazorcas. Las mayores pérdidas de producción de cacao en todo el mundo se atribuyen a *Phytophthora*, una enfermedad provocada por las especies de oomicetos *P. palmivora*, *P. megakarya* y *P. citrophthora*. Pueden aparecer

manchas marrodes que coinciden con la estructura de la infección en toda la mazorca, dañando la pulpa. La dispersión de esta enfermedad y el desarrollo de la epidemia ocurre al salpicar agua lluvia sobre los esporangios, encontrados en el suelo o en plantas infectadas, y por insectos vectores (Guest, 2004).

Por lo anterior, este proyecto propone desarrollar un sistema de visión por computadora con raspberry pi para la detección de la Moniliasis, la Fitóftora y el cacao sano en la finca Villa Laura, un terreno de 8.000 metros cuadrados en donde se cultiva tres variedades de cacao específicas: cacao criollo, forastero y trinitario. La cosecha que registra es de 30kg cada 15 días.

El cultivo está ubicado a dos kilómetros del municipio de Rivera en el departamento del Huila por la vía rural de la vereda Los Medios. Es un terreno plano correspondiente al valle del río Magdalena. Las condiciones atmosféricas de la región son de clima cálido con una temperatura promedio de 25°C y humedad relativa de 64% aproximadamente.

Esto con el fin de permitirle al agricultor detectar, reconocer y tomar decisiones relacionadas con la intervención del proceso productivo del cacao para así conseguir mejores resultados en el rendimiento del agricultor y no generar más pérdidas en la producción, por esta razón, ¿Qué beneficios tiene un sistema de visión por computadora implementado en raspberry pi para la detección de la moniliasis y la fitoftora en los cultivos de Cacao criollo de la finca Villa Laura ?.

Objetivos

Objetivo General

Diseñar un sistema de visión por computadora con Raspberry pi para la detección temprana de la Moniliasis y la Fitóftora de la finca Villa Laura en la vereda Los Medios del municipio de Rivera en el departamento del Huila.

Objetivos Específicos

- Extraer un conjunto de datos, mediante la toma de imágenes para identificar las enfermedades del cacao con Moniliasis, Fitóftora y cacaos que no presenten ninguna enfermedad.
- Determinar la presencia de mazorcas de cacao enfermas con Moniliasis y Fitóftora mediante la implementación de un algoritmo usando la visión por computadora por medio de la raspberry pi.
- Evaluar y validar el modelo del algoritmo por medio de un conjunto de datos de validación con imágenes de cacaos sanos y que presenten Moniliasis y Fitóftora, para evaluar el rendimiento del modelo con datos nuevos que nunca antes había visto el sistema.

Justificación

La pronta detección de enfermedades en las mazorcas de cacao beneficia a la producción agrícola del país, ya que evita las posibles pérdidas en la producción de cacao, causadas en un 50% por la presencia de enfermedades como la moniliasis y la phytophthora.

La detección oportuna de enfermedades en las mazorcas de cacao criollo suele ser necesaria para conseguir un alto volumen de producción y para revisar semanalmente las condiciones de crecimiento del cultivo. Las técnicas de visión por computadora permiten la portabilidad y la automatización de procesos como la inspección semanal. Por lo tanto, este proyecto se centra en el desarrollo de un sistema de visión por computadora que es un subcampo de la Inteligencia Artificial que intenta imitar las capacidades de la visión humana. No pretende simular únicamente la vista, sino la percepción, la capacidad del ser humano para interpretar lo que percibe. Se centra en el desarrollo de sistemas informáticos capaces de procesar datos visuales, como imágenes o videos, del mismo modo que las personas.

La visión por computadora, utilizando raspberry pi tiene el potencial de brindar a los agricultores una herramienta confiable que facilite la identificación de mazorcas de cacao enfermas, con lo cual será posible tomar medidas fitosanitarias en los cultivos de manera oportuna, con lo que se esperaría aumentar la productividad del cacao criollo.

Capítulo 2

2. Marco teórico

2.1. Variedades del cacao

El cacao especie diploide de ciclo vegetativo largo, registra tres variedades genéticas: Criollo (*T. cacao* spp. Criollo), Forastero (*T. cacao* spp. *Sphaerocarpum*) y Trinitario (Lopez et al., 2020).

El Criollo se les denomina a los cacaos finos de aroma y de alta calidad, se producen principalmente en México, el Caribe, Colombia, Perú, Ecuador, Venezuela, Nueva Guinea Papua, las Antillas, Sri Lanka, Timor Oriental y Java (Lopez et al., 2020)

Esta especie es conocida por su calidad organoléptica deseable, es decir, su color, olor, sabor y textura que la hacen especial. A pesar de sus características solo representa el 10% de la producción mundial de materia prima para producir chocolates de sabor fino (Ricaño-Rodríguez, 2018)

Entre tanto, los Forasteros son un tipo de cacao común que se cultiva en África del Oeste y Brasil, su sabor es poco agradable, aunque suelen utilizarse para la producción de chocolates mezclados con otros sabores, función que también cumplen los Trinitarios que dan un sabor intermedio dependiendo su producción (Lopez et al., 2020)

Luego de la colonización de los españoles, la variedad Criollo se dispersó por Suramérica y las regiones del Caribe con el fin de compensar la demanda europea. (Suarez & Hernández, 2014)

No obstante, la mayor parte de la producción total hoy de chocolate, es decir, alrededor del 80%, se hace con la variedad de cacao forastero, se destaca su resistencia a ciertas enfermedades y su notable rendimiento (Ricaño-Rodríguez, 2018)

Sumado a la clasificación desglosada anteriormente, se destaca una categorización adicional que está relacionada con la visión comercial e industrial, en la que los granos se clasifican en Cacao ordinario y Cacao Fino (Quintero & Morales, 2004).

En el caso del cacao ordinario, se hace referencia a los granos que provienen de cacaos tipo Forastero y son utilizados para la elaboración de manteca de cacao y productos con un alto contenido de chocolate. En la segunda categoría, es decir, el cacao fino o de aroma, procede de los granos de cacao Criollos y Trinitarios, que dan las características específicas de aroma y color en chocolate finos, también suelen ser utilizados en la producción de cacao en polvo (Quintero & Morales, 2004).

Alrededor de cuatro a ocho metros de altura, suele medir la planta de cacao, el árbol tiene entre 30 y 40 semillas de color marrón-rojizo cubiertas de una pulpa blanca dulce comestible, por lo general, se producen dos cosechas durante el año. Entre el tercer y quinto año de siembra, según la variedad, inicia la producción, aunque solo entre el octavo y el décimo año se alcanza en alto rendimiento. De acuerdo con la literatura revisada, el cacao conserva sus propiedades hasta los 45 años (Quintero & Morales, 2004)

2.2.Características del cultivo

La especie *Theobroma cacao* se divide en dos subespecies, se trata de *T.Cacao* subsp.*cacao* y *T. Cacao* subsp *Shaerocarpum*, cada una registra ciertas características. Por ejemplo, *T.Cacao* subsp.*cacao* tiene un fruto más alargado, las semillas son ovadas, y los cotiledones son amarillos o blancos; mientras que la especie *Cacao* subsp *Shaerocarpum* es elíptico, redondeado en los dos extremos; su fruto es liso y las semillas son ovadas. (Dostert et al., 2011)

Uno de las principales características para el desarrollo del cacao, es la temperatura y el ambiente, que se convierten en factores importantes en el desarrollo y cultivo. Por esta razón, la temperatura recomendada mínima es de 15°C, es impensable someter al cultivo a temperaturas bajo cero y ojalá sembrarlo en un ambiente que esté entre los 25° C y 26°C (Dostert et al., 2011). Así mismo, se recomienda si es en el Caribe, una distancia de 5x5 entre semillas; 4x4 en América central y si se trata de América del Sur, 3x4; ojalá que el inicio de la siembra coincida con la época de lluvia. (Vera, 2019)

Los nutrientes también son importantes en el proceso del cultivo, contribuyen en el crecimiento y disminuyen los desórdenes nutricionales que puedan presentarse. A continuación, se registran los indispensables.

En primer lugar, el nitrógeno que promueve el crecimiento y el desarrollo del cultivo, es fundamental en la división celular al igual que en la síntesis de aminoácidos y proteínas; incrementa el número de flores, mejora el tamaño y peso de los frutos.

En segundo lugar, se encuentra el potasio, denominado como elemento de calidad que se encarga de engrosar el fruto y los granos, regula el agua en las células, promueve el mecanismo de resistencia a plagas y patógenos. En tercer lugar, se ubica el fósforo que promueve el desarrollo de raíces y es fundamental en la formación de las flores, frutos y semillas.

El siguiente nutriente es el calcio que contribuye en el crecimiento y fortaleza en tallos y raíces jóvenes, además de aumentar la vida de anaquel de frutos. En quinto lugar, el azufre, que da propiedades insecticidas a la planta, y mejora su resistencia al frío y a la sequía.

El magnesio por su parte, es necesario para la formación de azúcares, aceites y grasas, además, de activar los procesos enzimáticos.

Entre tanto, en sexto lugar, se ubica el boro que tiene una destacada importancia para el desarrollo radicular, hojas y botones florales, es, además, fundamental para la polinización, crecimiento de semillas y frutos.

Por su parte, el zinc interviene en la formación de auxinas, es decir, la hormona de crecimiento, favorece la maduración de los frutos y estimula el vigor de la planta y el desarrollo vegetativo.

Y finalmente, octavo lugar, se encuentra el hierro, asociado con la producción de clorofila y hormonas de la planta.

Una de las etapas que marcan el desarrollo de la planta, es la juventud, por esta razón, debe estar ubicada en sombra para evitar problemas de crecimiento y florecimiento; cuidar durante el sembrado, florecimiento y maduración las malezas y plaga que puedan presentarse. Una vez finaliza el período de maduración, la mazorca está lista para desprenderla del árbol e inicia la cura del cacao, proceso en el que las semillas después de extraídas del fruto se ubican en el depósito que cuenta con las condiciones apropiadas para transformaciones físicas y químicas, de esta manera el cacao mejore, facilitando su secado y conservación. (Vera, 2019)

En este proceso del desarrollo del cacao, son importantes también, las podas, consideradas una de las prácticas culturales más importantes en el sistema productivo del cultivo, ya que permite organizar la estructura principal del árbol, de tal manera que puede mantener o aumentar la productividad y calidad del fruto; contribuye también en la disminución de los costos de producción, en el manejo de plagas y enfermedades, facilita

la renovación o rejuvenecimiento de las ramas. (Instituto Colombiano Agropecuario - ICA, 2021).

2.3. Enfermedades

Aunque el cacao es originario de América Latina, su producción con el paso de los años se ha disminuido resultado de la presencia de enfermedades en diversas regiones del mundo que lo impactan de manera negativa, generando pérdidas considerables, que incluso pueden llegar en algunos casos, hasta el 30% del potencial productivo. (Suarez & Hernández, 2014)

Se registran casos de las devastadoras consecuencias de las enfermedades, uno de ellas, es la Escoba de bruja (*Moniliophthora perniciosa*) que ocasionó en 10 años, la reducción del 70% de la producción de cacao en Brasil. Por otra parte, son catastróficos los efectos de la enfermedad conocida como moniliasis (*Moniliophthora roreri*) principal preocupación en los cultivos de Centro y Sur América. (Suarez & Hernández, 2014)

Así mismo, en el oriente de África, la producción se ve amenazada por el patógeno *Phytophthora megakarya*, que origina la mazorca negra. No obstante, las enfermedades del cacao con un mayor potencial de daño son las causadas por hongos basidiomicetes del género *Moniliophthora*. Es decir, *Moniliophthora roreri* (moniliasis) y *Moniliophthora perniciosa* (escoba de bruja). (Suarez & Hernández, 2014).

En el siguiente apartado se describen las tres principales enfermedades que se registran en (Suarez & Hernández, 2014) que afectan el cacao y dos de ellas son fundamentales para el desarrollo del presente trabajo de investigación.

2.3.1. Mazorca negra (*Phytophthora* s.p)

La enfermedad se originó en África, aunque actualmente está distribuido en todo el mundo y se considera la enfermedad más común. Son siete las especies patógenas de la Mazorca negra que se registran, se trata *P. palmivora*, *P. megakarya*, *P. capsici*, *P. citrophthora*, *P. nicotianae* var. *Parasitica*, *P. megasperma* y *P. arecae*. La especie considerada más agresiva es *P. megakarya*, que causa pérdidas alrededor de 80% de la producción de grano en Nigeria, Camerún y parte de Ghana En América del Sur y Colombia, suelen tener presencia *P. capsici* y *P. nicotianae* var. *Parasítica*.

La mazorca negra, causada por especies de *Phytophthora*, comienza con una mancha descolorida en la sobre la superficie de la mazorca, luego se genera una lesión de color chocolate o negra. En un periodo de dos semanas, se dispersa por todo el fruto. Las especies de *Phytophthora* ocasionan la muerte súbita de hasta 10% de los árboles anualmente.

2.3.2. Escoba de bruja (*Moniliophthora perniciosa*)

La *Moniliophthora perniciosa* es una especie nativa del género *Theobroma* endémica de los ríos Amazonas y Orinoco; que es el agente causal de una de las tres principales enfermedades del cultivo de cacao en Latinoamérica.

Cuando el hongo infecta las ramas y los brotes vegetativos, genera hinchazón en la zona afectada, crecen pequeños brotamientos próximos a los otros, donde se forman las hojas con apariencia de una escoba de bruja. Es una enfermedad que depende y está limitado a la humedad atmosférica, es decir, lluvia, niebla y humedad relativa. Sin duda, la temperatura regula la tasa de desarrollo de la enfermedad.

2.3.3. Moniliasis (*Moniliophthora roreri*)

La moniliasis es una enfermedad producida por un hongo severo que se encuentra en once países de América Latina. Los daños que genera, oscilan entre un 25% hasta la pérdida total de la producción. Según la literatura consultada, la enfermedad se origina en Ecuador, dado que en el año de 1917 se realizó el primer reporte oficial del patógeno que lideró el fitopatólogo J. B. Rorer llegó de Trinidad a Ecuador para identificar el agente causal de la reducción de la producción de cacao. En Colombia, se indica que en el departamento de Norte de Santander en 1817 y en 1851 en el departamento de Antioquia se registraron los primeros brotes. Sin embargo, en la actualidad sigue siendo una enfermedad con el mayor grado de afectación en las áreas productoras de cacao en Colombia y en Ecuador.

La Moniliasis se encuentra en los frutos, al interior de la mazorca, los granos son sustituidos por sustancias acuosas o gelatinosas, es decir, se pudre la parte jugosa de los frutos.

Esta enfermedad es muy agresiva, al punto de sobrevivir en diversas condiciones ambientales y se caracteriza por su acelerada dispersión natural, por lo tanto, es considerada una gran amenaza para los agricultores de cacao en el mundo. Es importante resaltar que, en Colombia, la Moniliasis puede comenzar en cualquier época del año, resultado de las lluvias que suelen producirse durante el año. Por lo tanto, existe una relación entre la incidencia de la Moniliasis y las lluvias que se registran dos meses atrás. (Suarez & Hernández, 2014)

La Moniliasis se conoce también como pudrición acuosa, pasmo, neva, hielo, ceniza y pringue, según en la región cacaotera donde se presente. (Instituto Colombiano Agropecuario - ICA, 2021)

Sumado a las anteriores enfermedades que suelen convertirse en un desafío para los cacaoteros, el Instituto Colombiano Agropecuario, relaciona otras enfermedades que también atacan esta planta, aunque en una mínima proporción.

Se trata de *Rosellinia*, conocida como llaga estrellada o podredumbre negra de la raíz. Inicialmente afecta el sistema radical de la planta, y luego, el cuello del tallo, hasta causar la muerte; suele ser un habitante natural del suelo, es un parásito facultativo que afecta el cacao, y entre otros cultivos al aguacate y el café.

Otra de las enfermedades que suelen presentarse en el cultivo del cacao es *Monalonion* (*Monalonium dissimulatum*), también conocido como coclillo, chinche o chupador de fruto. Genera pérdidas representativas cuando se presentan, temperaturas elevadas, alta humedad, exceso de sombra y el mal manejo de malezas. En este caso, los insectos succionan la savia de las mazorcas generando malformaciones, reduciendo su tamaño e incluso deteniendo el crecimiento del mismo.

2.4. Panorama en Colombia

En el país, se producen cacaos comunes y de calidad premium, es decir, finos de sabor y aroma. Según la Organización Internacional de Cacao, el 25% del cacao que se produce en Colombia se clasifica de sabor y fino aroma, ideal para los chocolates finos. (Luna et al., 2004)

De acuerdo con Fedecacao, en Colombia existen tres tipos de cacao, cacao criollo, cacao forastero y el trinitario que se describieron anteriormente (Superintendencia de industria y comercio, 2011).

El cacao en el Colombia se produce en 431 municipios de 28 departamentos en donde 52.000 familias derivan de esta actividad agrícola su sustento diario. Hoy, el país se ubica en el décimo lugar como productor de cacao en el mundo (Ministerio de Agricultura y Desarrollo Rural de Colombia, 2021).

De acuerdo con las cifras del Ministerio de Agricultura, en el año 2020, el país produjo 63.416 toneladas. Se destacan como departamentos productores Santander con un 41%, Antioquia registra 9% mientras que Tolima y Huila aportan el 7% de la producción nacional. Aunque se produce en todo el territorio, existen zonas especiales.

En el país, el cacao como uno de los cultivos con proyección y así quedó registrado en el Plan Nacional de Desarrollo 2014 – 2018, sumado a ello fue priorizado en el Plan Colombia Siembra, como política agropecuaria del gobierno nacional, que, a su vez, a través del Ministerio de Industria, Comercio y Turismo, con el programa de Transformación productiva priorizó desde el año 2013 el sector agroindustrial del cacao con acciones especiales para contribuir en el fortalecimiento de su productividad, eficiencia, calidad e investigación en este sector productivo. Es importante resaltar que la Organización Mundial de Cacao, ICCO, indicó que el 95% del cacao exportado por el país, es considerado fino y de aroma (López et al., 2020).

No obstante, el último año cacaotero, es decir, de octubre 2020 a septiembre 2021 se presentó la producción más grande de toda la historia productiva del grano en el país. Se

produjeron 70.205 toneladas; es decir, un aumento del 9.2% en comparación con años anteriores (Ministerio de Agricultura y Desarrollo Rural de Colombia, 2021).

Existen algunas problemáticas que aquejan al sector cacaotero en el país y están relacionadas con la competitividad, ya que las prácticas que realizan los agricultores no son las adecuadas para generar mayores rendimientos en la producción y un grano de excelente calidad. De acuerdo con el Ministerio de Agricultura, dentro de los principales problemas está relacionado con el ámbito tecnológico; es decir, la deficiente formación del capital humano, el mejoramiento genético de las plantas, la productividad de los cultivos y las condiciones agroecológicas para el desarrollo del cultivo. Aunque los cacaoteros valoran mucho más la formación de capital humano, les restan importancia a las problemáticas sanitarias como la Monilia o escoba de bruja que genera efectos negativos en el cultivo. Por esta razón es indispensable generar herramientas que contribuyan en la detección de este tipo de enfermedades. (Luna et al., 2004)

2.7. Producción regional

En el Huila existe un gran potencial para el cultivo del cacao (*Theobroma cacao* L.), dado por el reciente interés que se ha generado por el chocolate fino hecho con este origen de cacao. En el departamento se tiene un área proyectada para la siembra de 13.000 ha y según Fedecacao, para el año 2016, se tenían sembradas 13.200 ha. El potencial productivo del Huila difícilmente aumentaría las siembras por la falta de tierras óptimas para el cultivo.

Por esta razón, según Fedecacao, los incrementos en la producción de cacao se deben enfocar en el aumento del rendimiento por hectáreas, ya que como se ha reflejado en

los cultivos modernos, se pueden lograr rendimientos superiores a los 1200 kg/ha/año, pero para ello, es fundamental la implementación de alta tecnología. En el territorio, ya existen cultivos en el país que superan los 2.000 y 3.000 kg/ha/año. (Puentes, 2017)

En ese propósito se hace necesario disminuir la baja tecnificación de los cultivos de cacao en el país, que se origina principalmente por dos causas; el primer lugar, las tecnologías para el manejo eficiente del cultivo se originarán 40 años, aunque la adopción es mínima, y, en segundo lugar, las practicas que se sugerían necesitan de modernización e investigación. (Puentes, 2017)

A pesar de este panorama, el departamento del Huila, es el primer exportador nacional y el cuarto productor nacional de cacao. El cacao con sello huilense es muy apetecido por su notable calidad en los mercados internacionales, comienza a incrementar su protagonismo y mejora su productividad, resultado de los esfuerzos del Gobierno Departamental a través de las alianzas productivas. (Ministerio de Agricultura y Desarrollo Rural de Colombia, 2019)

En el departamento, el cacao hace parte de las apuestas productivas priorizadas en el Plan Regional de Competitividad del Huila según la Cámara de Comercio del Huila. Y actualmente se consolida en los mercados internacionales resultado del sabor y aroma de su grano que es codiciado en Estados Unidos, España y Reino Unido. (Caracol radio, 2021)

2.8 Procesamiento de imágenes digitales

2.8.1 Definiciones

2.8.1.1 Imagen digital

La palabra digital está relacionada con el cálculo mediante técnicas numéricas o por unidades discretas. De este modo, una imagen digital puede caracterizarse como la representación numérica de un objeto. El procesamiento es la demostración de exponer algo a un proceso. Un proceso es un conjunto de actividades o tareas que conducen a un resultado ideal. El procesamiento digital de imágenes toma una imagen y produce una variante modificada de la misma. El análisis digital de imágenes es la forma más común de cambiar una imagen digital en algo que no es una imagen tal como un conjunto de datos de medición o de decisiones.

Una imagen que ha sido discretizada en brillo y coordenadas espaciales se denomina imágenes digitales $f(x,y)$. En consecuencia, una imagen digital puede compararse con una matriz, en la que cada índice de fila y columna identifica un punto de la imagen y cada valor de elemento de la matriz representa el nivel de gris en esa ubicación. Los elementos de la imagen, o más comúnmente los píxeles, son los componentes de esa distribución digital.

2.8.1.2 Segmentación de imágenes

La segmentación es el proceso que separa una imagen en objetos de interés. Mediante los procesos de descripción se obtienen características (tamaño, perímetro, etc.) convenientes para distinguir un objeto de otros. El reconocimiento es la forma en que se

identifica los objetos (gato, perro, mesa, etc.) Finalmente, la interpretación da un significado a un grupo de objetos reconocidos. (Universidad nacional de San Juan, 2017)

El objetivo es dividir la imagen en partes útiles. Los resultados de la partición se aplicarán en fases de descripción, identificación e interpretación.

Por ello, el problema de la segmentación puede verse como un proceso de reconocimiento de patrones (regiones deseadas) o como un proceso de decisión (si un pixel pertenece a una región de segmentación o a otra), un proceso cuya finalidad última es trazar límites entre regiones. (Universidad nacional de San Juan, 2017)

2.8.1.3 Visión por computadora

Consiste en la recopilación, el procesamiento, la clasificación y el reconocimiento de imágenes digitales. (M. C. José et al., 2002)

Es la ciencia y la tecnología que permite programar un computador para simular los mecanismos fisiológicos que subyacen a la percepción visual humana y que reproduzca el comportamiento humano al examinar el color, el contenido, la forma y la textura. (Du & Cheng, 2014)

2.9 Inteligencia artificial (IA)

2.9.1 Definición

La inteligencia artificial hace parte de uno de los avances científicos más profundos en los últimos 60 años: el estudio de la información y el conocimiento; su forma de ser adquiridos, entendidos, manipulados, usados y transmitidos. (Banda, 2014)

Es una rama de las ciencias computacionales que se encarga de estudiar modelos de cómputo capaces de realizar actividades propias de los seres humanos en base a dos de sus características primordiales: el razonamiento y la conducta. (Takeyas, 2007)

Otra de las definiciones que se registran es la capacidad de las máquinas para usar algoritmos, aprender de los datos y utilizar lo aprendido en la toma de decisiones, como lo haría un ser humano. (Rouhiainen, n.d.).

Para otros autores, como en es una ciencia que permite estudiar procesos simbólicos, razonamientos no algorítmicos y representaciones simbólicas del conocimiento. (Diez et al., 2001)

Así mismo, podría indicarse que su objetivo principal es que los ordenadores hagan las mismas cosas que puede hacer la mente humana. Bajo dos propósitos principales, uno tecnológico, enfocado en el uso de los ordenadores para cosas útiles, y uno científico, para resolver cuestiones sobre los seres humanos y demás seres vivos. (Serrano, 2012)

Igualmente, la inteligencia artificial permite diseñar herramientas informáticas que representen procesos de inteligencia humana que incluyen aprendizaje, razonamiento y autocorrección (Avila-tomás et al., 2020)

La inteligencia artificial podría definirse también como el campo que estudia cómo los sistemas artificiales realizan acciones inteligentes. En ese sentido, uno de sus propósitos es construir réplicas de la red neuronal del cerebro humano para imitar las habilidades cognitivas y funcionales a través de un equipo de cómputo, aumentando la utilidad de las máquinas y sus procesos. (Elebi, n.d.)

La inteligencia artificial es real y hace parte de las actividades cotidianas que los seres humanos realizan.

2.9.2 Aplicaciones

La inteligencia artificial inicialmente se aplicaba al desarrollo de algoritmos para juegos. Hoy, es una rama de la teoría de la computación que incluye áreas como el razonamiento automático, la demostración de teoremas, los sistemas expertos, el procesamiento del lenguaje natural, la robótica, redes neuronales y algoritmos genéticos. (Takeyas, 2007)

Dentro de las aplicaciones técnicas que son más comunes en la actualidad, se destacan, el reconocimiento de imágenes estáticas, clasificación y etiquetado, usado en varias industrias; mejoras en el desempeño de la estrategia algorítmica comercial; procesamiento eficiente y escalable de datos de pacientes; mantenimiento predictivo aplicable a sectores industriales; detección y clasificación de objetos; distribución de contenido en las redes sociales; protección contra amenazas de seguridad cibernética (Diez et al., 2001)

Así mismo, la contribuye en asuntos importantes de la vida, en escenarios como la salud, el bienestar, la educación, el trabajo y las relaciones interpersonales. Otra de las utilidades es que permite que las máquinas y robot realicen tareas que los humanos consideran difíciles o peligrosas. (Diez et al., 2001)

2.9.3 Machine Learning

2.9.3.1 Definición

Machine learning es una de las técnicas que hacen parte de la IA, en el que se da a las computadoras, la capacidad de aprender sin ser programadas para ello. Es un proceso

complejo en el que también intervienen las decisiones humanas y que en ocasiones pueden derivar en un resultado sesgado (Elebi, n.d.).

Este enfoque de la IA permite como resultado de su implementación sugerencias o predicciones en una situación en particular, resultado, de la capacidad de aprender que tienen los ordenadores para hacerlo. (Rouhiainen, n.d.)

Es decir, los computadores aprenden a realizar una determinada tarea con el objetivo de realizarla de manera autónoma sin una preconfiguración especial. En otras palabras, ML es un método mediante el cual se crea y se mejora, la inteligencia artificial de los computadores a través de unas sesiones que se denominan “enseñanza-aprendizaje”, que son entrenamientos y consisten en la exposición constante a conjuntos big-data. (Elebi, n.d.)

Machine learning usa algoritmos para aprender de los patrones de datos. (Rouhiainen, n.d.)

Es decir, que no es auto programación, sino auto aprendizaje de datos para generar patrones y de esta manera resolver o realizar nuevas tareas (Rojas, 2020).

Para ello, Machine learning analiza los datos, entre mayor sea la proporción de información, mejor será el resultado a la hora de analizar los algoritmos que han diseñado otros datos según las necesidades. Para generar más datos, se pueden utilizar técnicas que permiten reconocer patrones, extraer conocimiento, descubrir información y hacer predicciones, como es el caso de regresión lineal y polinómica; árboles de decisión; redes neuronales; red bayesiana o cadenas de Markov.

Uno de las áreas en las que mayor beneficio trae la implementación de las técnicas de Machine learning es la salud, específicamente a la hora de realizar un diagnóstico. (Banda, 2014)

Otra de los usos está relacionada con la identificación de aplicaciones de uso cotidiano, como es el caso de las redes sociales de Twitter, Facebook y YouTube.

2.9.3.2 Clasificación

Es de resaltar la importancia de conocer la clasificación de los tipos de algoritmos de aprendizaje de ML que se describen a continuación.

La técnica de Machine learning puede desarrollarse a través de tres tipos de acuerdo con (Rouhiainen, n.d.). Se trata del reinforced learning, supervised learning y unsupervised learning.

En el aprendizaje supervisado o supervised learning como se traduce en inglés. Los algoritmos utilizan datos que han sido previamente etiquetados u organizados para tener un modelo de cómo debería ser categorizada la nueva información que se obtenga. Es un método que requiere la intervención del ser humano para realizar el proceso de retroalimentación (Rouhiainen, n.d.).

Así mismo, en esta técnica se enseña al algoritmo la forma de realizar su trabajo a través de un conjunto de datos clasificados bajo una cierta idea para encontrar patrones que puedan aplicarse en un análisis y produzca una salida conocida (Rojas, 2020).

Entre tanto, en el aprendizaje no supervisado u unsupervised learning, los algoritmos no usan ningún dato etiquetado u organizado con anticipación para determinar cómo se categorizaría la nueva información, al contrario, son ellos mismos, quienes

encuentran la manera de clasificarlos. Este método no requiere intervención humana (Rouhiainen, n.d.).

Este es un modelo predictivo entrenado de manera similar al aprendizaje supervisado, pero se diferencia por la comprensión en datos no clasificados o etiquetados y descubre patrones de ejemplos similares entre grupos de datos. (Rojas, 2020)

Finalmente, se encuentra el aprendizaje por refuerzo o reinforced learning, en esta técnica, los algoritmos se aprenden a partir de la experiencia. Es decir, que cada vez que aciertan se les entrega un refuerzo positivo (Rouhiainen, n.d.).

En esta técnica no existe un aprendizaje automático o capacitación con datos clasificados o no clasificados; el sistema aprende en un entorno donde no hay información sobre la posible salida por medio de acciones y los resultados obtenidos. (Rojas, 2020) En el esquema que se aprecia a continuación, se identifican los componentes necesarios para la captura de información de las variables de temperatura, humedad y radiación solar y su posterior transmisión.

2.9.4 Redes neuronales

La técnica de Machine Learning, protagonista en la presente investigación, utiliza para su funcionamiento como se indicó en el apartado anterior, algoritmos de aprendizaje supervisado, entre los que se destacan, Máquinas de Vectores de soporte (SVM); regresión línea y logística, o incluso las redes neuronales (Géron, 2017) que serán parte fundamentales en el desarrollo de este trabajo.

Para ello, inicialmente, es importante tener claridad sobre la definición de redes neuronales, son redes interconectadas masivamente en paralelo de elementos simples y con

una organización jerárquica que interactúan con los objetos del mundo real de la misma forma en que lo realiza el sistema nervioso biológico (Calvo, 2017).

Uno de los principales usos de estas redes neuronales está enfocado en la agricultura, en donde, el control de plagas sigue siendo uno de los mayores desafíos, es así, que hoy se utilizan redes neuronales para contribuir en el proceso de identificación y detección de las mismas de forma más precisa y con un menor costo, y ese es el tema central de la investigación. (Jiao et al., 2020)

Cada red se caracteriza por estar integrada por cinco elementos; en primer lugar, el conjunto de entradas que representan como su nombre lo indica, las entradas de la red neuronal; (Calvo, 2017) en segundo lugar, cada entrada tiene un peso o longitud que se ajusta de forma automática en la medida en que la red neuronal va aprendiendo, los rangos pueden incluir valores negativos y positivos (Moreno Alvaro, 2019).

En tercer lugar, la red neuronal está integrada también por una función de agregación o función de red Σ que se encarga de sumar las entradas ponderadas por sus pesos, estas operaciones constituyen un combinador línea. En cuarto lugar, existe una función de activación F que mantiene el conjunto de valores de salida en un rango específico, y finalmente, Y que representa el valor que resulta luego de pasar por la red neuronal (Calvo, 2017).

Las redes neuronales tienen una clasificación de acuerdo al tipo de red, es decir, que existe Red neuronal Monocapa, Red neuronal Multicapa, Red neuronal Convolutiva (CNN), Red neuronal recurrente (RNN) y Redes de base radial (RBF). A esta clasificación, se suman, las Redes Neuronales Biológicas (BNN) y las Redes Neuronales

Cuánticas (QNN), Redes Neuronales Profundas (DNN) e incluso, las Redes Neuronales Artificiales (ANN). (Mani et al., 2022)

En ese sentido, los esfuerzos se concentrarán en la red neuronal convolucional (CNN) que se convierte en el modelo más convencional que se ha aplicado en diversas áreas e incluso en tareas cotidianas en la agricultura, tratamientos médicos, finanzas, entre otros (Yang et al., 2022).

Convolutional Neural Network (CNN) es una herramienta importante en Deep Learning para el reconocimiento e identificación de imágenes (Mi et al., 2022). Es de resaltar que las técnicas de Deep Learning son hoy una nueva dirección del Machine Learning, su propósito es lograr que las máquinas tengan la capacidad de análisis y aprendizaje similar a los seres humanos y pueden reconocer caracteres, imágenes, sonidos, entre otros datos.

2.9.5 Transfer learning

Se trata de una técnica de machine learning en la que un modelo diseñado para una tarea se reutiliza como punto de partida para otra, donde los modelos pre-entrenados se utilizan como punto de partida para las tareas de visión por computadora y procesamiento de lenguaje natural, dada la cantidad de recursos computacionales necesarios para desarrollar un modelo de red neuronal. (Sarkar, 2018)

Mientras que el machine learning aísla el aprendizaje de tal forma que no se guarda el conocimiento, el Transfer learning hace uso del conocimiento que la red ya ha aprendido para aprender una nueva tarea. Utilizando los pesos y sesgos de la red previamente entrenada y recalculado solo los pesos de las conexiones en la capa final, el

propósito de reentrenar la red es minimizar el número de pesos que hay que aprender.

(Sarkar, 2018)

El transfer learning tiene la ventaja de que una red pre-entrenada requiere menos datos de entrada para obtener resultados aceptables y que el periodo de entrenamiento es significativamente menor que cuando se entrena una red desde cero (teniendo en cuenta que las redes convolucionales suelen estar formadas por millones de neuronas).

2.9.6 Reconocimiento de objetos

La detección de objetos es un término general para un grupo de tareas de visión por computadora interconectadas que implican el reconocimiento de objetos en la fotografía digital. (Brownlee, 2019)

Entender las distinciones entre la clasificación de imágenes, el reconocimiento de objetos y la detección de objetos puede ser difícil para los novatos. Estas colecciones de tareas de visión artificial varían en el sentido de que la localización de objetos implica dibujar un cuadro delimitador alrededor de uno o más elementos de la imagen, mientras que la clasificación de imágenes implica proporcionar una etiqueta de clase en una imagen. La detección de objetos es la tarea más desafiante, combina estas dos tareas, crea cuadros delimitadores alrededor de cada objeto de interés en la imagen y etiqueta cada cosa según su clase. El término “Reconocimiento de objetos” se refiere a todas estas cuestiones de forma colectiva. (Brownlee, 2019)

2.9.6.1 Clasificación de imágenes:

- Predice el tipo o la clase de un objeto en una imagen.

- Los algoritmos producen una lista de categorías de objetos presentes en la imagen.
- El rendimiento se evalúa utilizando el error de clasificación media en las etiquetas de clase predichas.

Entrada: Una imagen con un solo objeto, como una fotografía.

Salida: Una etiqueta de clase (por ejemplo, uno o más números enteros que se asignan a las etiquetas de clase).

2.9.6.2 Localización de objetos:

- Localiza la presencia de objetos en una imagen e indica su ubicación con un cuadro delimitador.
- Los algoritmos producen una lista de categorías de objetos presentes en la imagen, junto con un cuadro delimitador alineado con el eje que indica la posición y la escala de una instancia de cada categoría de objeto.
- El rendimiento se evalúa utilizando la distancia entre el cuadro delimitador esperado y el predicho para la clase esperada.

Entrada: Una imagen con uno o más objetos, como una fotografía.

Salida: Uno o más cuadros delimitadores (por ejemplo, definidos por un punto, ancho y alto).

2.9.6.3 Detección de objetos:

- Localiza la presencia de objetos con un cuadro delimitador y clases de los objetos ubicados en la imagen.

- Los algoritmos producen una lista de categorías de objetos presentes en la imagen junto con un cuadro delimitador alineado con el eje que indica la posición y la escala de cada instancia de cada categoría de objeto.
- El rendimiento se evalúa utilizando la precisión y la recuperación en cada uno de los mejores cuadros delimitadores coincidentes para los objetos conocidos en la imagen.

Entrada: Una imagen con uno o más objetos, como una fotografía.

Salida: Uno o más cuadros delimitadores (por ejemplo, definidos por un punto, ancho y alto) y una etiqueta de clase para cada cuadro delimitador.

2.9.7 Detección de objetos mediante SSD MobileNet V2

La detección de objetos en una tecnología de visión por computadora relacionada con el procesamiento de imágenes que se ocupa de detectar instancias de objetos semánticos de una determinada clase en imágenes y videos digitales. Con la llegada de las redes neuronales profundas, la detección de objetos ha tomado el centro del escenario en el desarrollo de la visión por computadora con muchos modelos desarrollados como R-CNN (Red neuronal convolucional regional) y su variante (Faster-RCNN), detectores de disparo únicos (SSD). Así como los famosos modelos You Only Look once (YOLO) y sus múltiples versiones. Por lo general, los modelos de detección de objetos se clasifican en dos tipos de arquitectura principales: detector de objetos de una etapa (única) como YOLO y SSD y detectores de objetos de dos etapas (doble) como R-CNN. La principal distinción entre ambos es que, en los modelos de detección de objetos de dos etapas, solo se detecta la región de interés una vez que esta ha sido identificada. Esto implica que los modelos de

detección de objetos de dos etapas son generalmente más precisos que los de una etapa, pero requiere más recursos computacionales y son más lentos (Mehta, 2021).

SSD Mobilenet V2 es un modelo de una sola etapa para la detección de objetos que ha ganado popularidad por su red delgada y sus novedosas circunvoluciones separables en profundidad (Mehta, 2021). Es un modelo comúnmente implementado en dispositivos como Android, ios y raspberry pi con un rendimiento de alta precisión.

MobileNet V2 introdujo modificaciones en las capas cuello botella y en las conexiones residuales (las conexiones residuales ayudan a los gradientes a penetrar mucho más la red) (Sandler...et al., 2018). El diseño general de la red se ve en la figura 1.

Figura 1

Vista general de la arquitectura MobileNet V2

Input	Operator	t	c	n	s
$224^2 \times 3$	conv2d	-	32	1	2
$112^2 \times 32$	bottleneck	1	16	1	1
$112^2 \times 16$	bottleneck	6	24	2	2
$56^2 \times 24$	bottleneck	6	32	3	2
$28^2 \times 32$	bottleneck	6	64	4	2
$14^2 \times 64$	bottleneck	6	96	3	1
$14^2 \times 96$	bottleneck	6	160	3	2
$7^2 \times 160$	bottleneck	6	320	1	1
$7^2 \times 320$	conv2d 1x1	-	1280	1	1
$7^2 \times 1280$	avgpool 7x7	-	-	1	-
$1 \times 1 \times 1280$	conv2d 1x1	-	k	-	-

Nota. Adaptado de *MobileNetV2: Inverted residuals and linear bottlenecks* (p. 5). Por Sandler, Mark & Howard, Andrew & Girshick, Ross & Su, Jian, (2016).

Al transformar los puntos de datos con grandes dimensiones en tensores con dimensiones más bajas, reduce primero el número de canales. La capa de proyección se denomina “capa cuello de botella” debido a la disminución de la cantidad de información que entra en la red. Antes de que los datos se transmitan a una convolución DW, la capa de expansión PW aumenta el número de canales. Por tanto, una imagen se amplía en términos de canales cuando entra en el bloque PW, luego se aplica un DW y por último, los datos se comprimen en menos canales. Funciona de manera similar a la red de inception.

(Sandler...et al., 2018)

MobileNet V2, con 3,5 millones de parámetros, rinde mucho más que MobileNet V1 en términos de eficiencia.

2.9.8 mAP (mean Average Precision) Para la detección de objetos

La precisión de los detectores de objetos es evaluada mediante la métrica conocida como Ap (Precisión promedio). La precisión promedio determina el valor de la exactitud media del valor de recuperación, que va de 0 a 1.

La métrica más común utilizada para la evaluación en un problema de clasificación de imágenes es Precisión, Recuperación, Matriz de confusión, Curva PR, etc. Mientras que, en la segmentación de imágenes, se utiliza la intersección media sobre la unión, también conocida como IoU (Sharma, 2022).

La métrica de elección más común utilizada para los problemas de detección de objetos es la precisión media promedio (también conocida como mAP). Dado que, en la detección de objetos, el objetivo no es solo clasificar correctamente el objeto (u objetos) en la imagen, sino también encontrar en qué parte de la imagen se encuentra, no se puede

simplemente usar las métricas de clasificación de imágenes como Precisión y Recuperación. Por lo tanto, la métrica de evaluación de detección de objetos debe considerar tanto la categoría como la ubicación de los objetos en su formulación, y ahí es donde entra en juego mAP. Y para entender mAP, es necesario entender IoU, Precisión y Recuerdo (Sharma, 2022).

2.9.8.1 Precisión y recuperación

La precisión: Es la relación de muestras categorizadas positivamente con respecto a todas las muestras que se identificaron correctamente como positivas (incorrectas y correctas). En resumen, Precisión responde a la pregunta de cuán precisas fueron las conjeturas cuando el modelo adivinó, o mide la precisión / exactitud del modelo al clasificar las muestras como positivas (Sharma, 2022).

Recordar (recall): Es la relación de muestras positivas correctamente identificadas respecto al total de muestras positivas reales. El recall responde si su modelo adivinó cada vez que debería estar adivinando. Cuanto mayor sea el recall, más muestras positivas se detectan (Sharma, 2022).

TP= Verdaderos positivos

TN=Verdaderos negativos

FP= Falsos positivos

FN= Falsos negativos

Ecuación 1

Ecuación de precisión

$$\mathbf{Precision} = \frac{TP}{TP + FP}$$

Ecuación 2*Ecuación de recuperación*

$$\text{Recuperacion} = \frac{TP}{TP + FN}$$

Ecuación 3*Ecuación de F1*

$$F1 = 2 \cdot \frac{\text{precision} \cdot \text{recuperacion}}{\text{precision} + \text{recuperacion}}$$

Si el modelo tiene alta precisión y recuerdo, entonces predice correctamente las muestras como positivas y predice la mayoría de las muestras positivas (no pierde las muestras ni las predice como negativas). Sin embargo, si el modelo tiene alta precisión y baja recuperación, predice con precisión las muestras como positivas, pero solo unas pocas muestras positivas (más falsos negativos) (Sharma, 2022).

2.9.8.2 IoU (Intersección sobre unión)

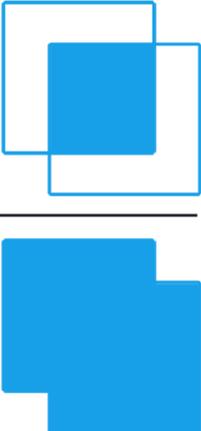
Es una métrica de evaluación para medir la precisión con la que un detector de objetos coincide con un conjunto de datos determinado. Este enfoque solo puede utilizarse si las etiquetas que definen las coordenadas de los objetos en las imágenes y las coordenadas previstas por el detector están presentes. (Rosebrock, 2016)

Iou mide como se solapan dos límites. Esto permite medir que parte del límite real se solapa con nuestra precisión (el límite del objeto real). En determinados conjuntos de datos, predefinimos un umbral de IoU (por ejemplo, 0,5) para clasificar si la predicción es

una autentico positivo o un falso positivo. La fórmula de cálculo de la intersección sobre la unión (IoU) se representa en la figura 2.

Figura 2

Calculo para la intersección sobre la unión

$$\text{IoU} = \frac{\text{Area of Overlap}}{\text{Area of Union}}$$


Nota. Adaptado de *Intersection over union (IoU) for object detection*. Por Adrian Rosebrock, (2016), <https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>.

El sistema favorece las predicciones que mejor superpongan las verdades absolutas. En la Figura 3 se muestra diferentes “overlapping” así como las puntuaciones que les otorga IoU.

Figura 3

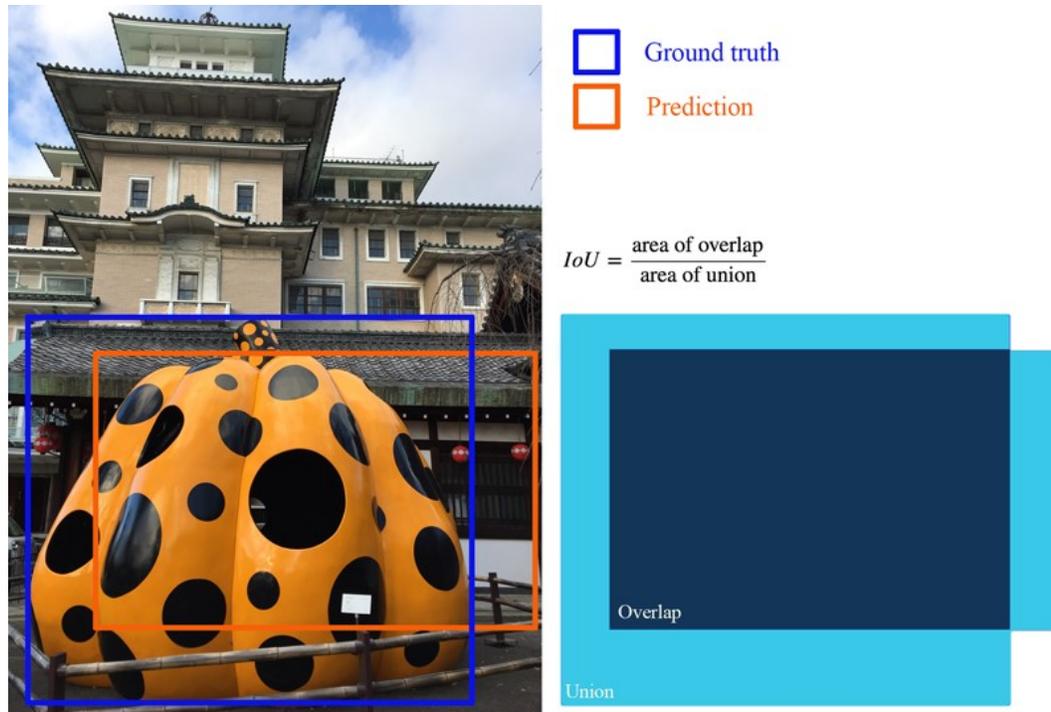
Ejemplo de cálculo de Intersección sobre uniones para varios cuadros delimitadores.



Nota. Adaptado de *Intersection over union (IoU) for object detection*. Por Adrian Rosebrock, (2016), <https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>.

La figura 3 ilustra que las puntuaciones son mayores para los cuadros delimitadores proyectados que se superponen fuertemente con los cuadros delimitadores reales que para los cuadros delimitadores predichos que se superponen menos. Esto hace que la intersección sobre la unión sea una fantástica métrica para evaluar los detectores de objetos personalizados. (Rosebrock, 2016)

Como se puede apreciar en la figura 4, La imagen proporciona una manera eficaz para ayudar a entender cómo funciona el IoU.

Figura 4*Definición de IoU*

Nota. Adaptado de *Map (mean average precision) for object detection*. Por Jonathan Hui, (2018), <https://jonathan-hui.medium.com/map-mean-average-precision-for-object-detection-45c121a31173>.

2.9.8.3 COCO mAP

En COCO mAP, se utiliza una definición de AP interpolada de 101 puntos en el cálculo. Para COCO, AP es el promedio sobre múltiples IoU (el mínimo IoU para considerar una coincidencia positiva). $AP@[.5:.95]$ corresponde al AP promedio para IoU de 0.5 a 0.95 con un tamaño de paso de 0.05. Para la competencia COCO, AP es el promedio de más de 10 niveles de IoU en 80 categorías ($AP@[.50:.05:.95]$: comienza de 0.5 a 0.95 con un tamaño de paso de 0.05). Las siguientes son algunas otras métricas

recopiladas para el conjunto de datos COCO. En la figura 5 se puede ver las 12 métricas que se utilizan para caracterizar el rendimiento de un detector de objetos en COCO.

Figura 5

Métricas de rendimiento de un detector de objetos en COCO

Average Precision (AP):	
AP	% AP at IoU=.50:.95 (primary challenge metric)
AP ^{IoU=.50}	% AP at IoU=.50 (PASCAL VOC metric)
AP ^{IoU=.75}	% AP at IoU=.75 (strict metric)
AP Across Scales:	
AP ^{small}	% AP for small objects: area < 32 ²
AP ^{medium}	% AP for medium objects: 32 ² < area < 96 ²
AP ^{large}	% AP for large objects: area > 96 ²
Average Recall (AR):	
AR ^{max=1}	% AR given 1 detection per image
AR ^{max=10}	% AR given 10 detections per image
AR ^{max=100}	% AR given 100 detections per image
AR Across Scales:	
AR ^{small}	% AR for small objects: area < 32 ²
AR ^{medium}	% AR for medium objects: 32 ² < area < 96 ²
AR ^{large}	% AR for large objects: area > 96 ²

Nota. Adaptado de *Detection evaluation/Metrics*. Por COCO, <https://cocodataset.org/#detection-eval>.

Capítulo 3

3 Marco referencial

Las redes neuronales se han utilizado para detectar enfermedades y plagas en diversos cultivos, sin duda, uno de los grandes desafíos en la agricultura y una de las principales problemáticas que enfrentan los campesinos en las distintas zonas del mundo.

A continuación, se relacionan algunos trabajos de investigación en los que se han implementado redes neuronales con ese propósito, específico en diversos cultivos.

En un cultivo de palma de aceite se implementó una Red Neuronal Convolutiva (CNN) para la detección de enfermedades de rápida propagación como lo es la marchitez letal. Inicialmente, las imágenes fueron tomadas por una cámara multiespectral MicaSense Rededge R y procesadas con el software especializado Pi4D Mapper y Agisoft Metashape. Luego se aplicó el algoritmo de procesamiento de imágenes básico para aumentar el conjunto de datos; se pasó de 3.016 imágenes de la palma de aceite sanas y 848 enfermas. En este estudio, se utilizó la red convolutiva codificada en un Notebook de Colab de Google R, el cual se conectó al repositorio en Drive donde se almacenó el conjunto de imágenes enfermas y sanas. La precisión de este modelo registró un 98% (Torres-galindo & Torres-leon, n.d.).

Entre tanto, otro equipo de investigadores, desarrolló un sistema de diagnóstico de enfermedades en las hojas de la planta de maíz, se emplearon dos arquitecturas de Redes Neuronales Convolutivas (CNN) como son AlexNet y GoogleNet; y se utilizaron algoritmos de detección faster R-CNN. Este modelo alcanzó una exactitud de 99.35% en la detección de enfermedades de hojas (Frayre et al., 2005).

El cultivo de papa es uno de los más representativos en Colombia, sin embargo, la presencia de gota o tizón tardío producido por el Oomiceto *Phytophthora infestans*, es una limitante en los niveles de producción. En este estudio, se diseñó una red neuronal propia para identificar y detectar esta plaga en épocas tempranas. Se utilizaron los datos aumentados del conjunto de datos PlantVillage y las arquitecturas AlexNet y ZFNet, en las versiones VGG16 y VGG19. Este modelo registró un 90% de precisión (Lozada-portilla et al., 2021).

Prevenir para optimizar la calidad del cultivo del tomate, es una de las prioridades para los agricultores dedicados a esta siembra. En este estudio, se diseñó un modelo basado en las arquitecturas AlexNet, GoogleNet, Inception V3, ResNet 18 y ResNet 50. Las imágenes fueron extraídas del conjunto de datos PlantVillage. Sin embargo, GoogleNet fue el modelo que mejor resultado obtuvo en la clasificación de enfermedades en tomate, llegó a 99.72% de precisión (Maeda, 2019).

Otro modelo creado con este mismo propósito, permitió el diseño de un sistema de reconocimiento eficaz para las lesiones necróticas causadas por la plaga de los Thrips en los guisantes. En este en particular, se implementó un modelo CNN que utilizó la estructura yolov4-tiny, un algoritmo que detecta objetos y se usa sobre la red Darknet. Las imágenes fueron guardadas en un repositorio digital, allí se identificaron y etiquetaron a través de uso de Roboflow. La efectividad llegó al 86% en la detección del objeto de estudio (Guerrero-andrade et al., 2022).

Otro de los cultivos que ha sido estudiado para contribuir en su proceso de detección de plagas, es el aguacate Hass, en este estudio en particular, se utilizó la red

neuronal Faster RCNN-ResNet50, que hace posible la detección de objetos dentro de una imagen y registró una precisión del 80%.

Sumado a estas investigaciones, se registra una más en Colombia, que ocupa el tercer lugar en producción de café en el mundo, para mantener esta posición ha tenido que combatir las plagas y enfermedades que suelen afectarlo, como la Roya y Minador; se usó un algoritmo de clasificación desarrollado en Python y a partir de una CNN crean el modelo que permitió identificar la aparición de esta plaga.

En otra investigación, se utilizaron las CNN para el mapeo de plantaciones de eucalipto en grandes extensiones a través de la arquitectura DeepLabv3p y el codificador Eff-b7 (Costa, 2021).

Esta misma red troncal eficiente, EFDet fue implementada como modelo de fusión de características y un predictor para detectar en las hojas de pepino, la mancha angular bacteriana y el mildiú veloso. Inicialmente, se realizó la extracción eficiente de las características en la red EfficientNet; luego, se diseñaron capas adicionales para obtener mapas de características de alta semántica que contribuyen a detectar mejor el pepino hojas con varias escamas y se aplicó la fusión de mapas de características. Se logró una precisión de 85.53% (Liu et al., 2021).

Así mismo, la red EfficientDet es una alternativa de detección automatizada de enfermedades de las plantas. En este estudio se recogieron más de 3.000 imágenes de un conjunto de datos públicos y está integrada en tres componentes principales, Red troncal; Red BiFPN, y Red de predicción de clase/caja. A las CNN se les reconoce su mejor precisión y la reducción de los parámetros. Se logró una precisión de 74.10%

Entre tanto, en la Universidad Antonio Nariño se han realizado investigaciones utilizando redes neuronales aplicadas en distintas áreas del conocimiento como es el caso de un clasificador para la detección de escoliosis en imagen RX de columna o el sistema usado para la detección a través de imágenes que permite clasificar el estrabismo, es decir, un trastorno de los ojos; incluso hay un trabajo más enfocado en predecir el riesgo de desarrollar la enfermedad de Parkinson.

Específicamente relacionadas con la agricultura, se destaca, la investigación realizada desde la Facultad de Ingeniería Mecánica que permitió el diagnóstico de la enfermedad *Phythora Infestas*, conocida como Tizón tardío que afecta notablemente los cultivos papa. A través de este estudio se construyó una herramienta computacional NeuroPI – 2105 que basó su funcionamiento en una red neuronal convolucional creada por los estudiantes y en la que se analizaron 1304 imágenes y permitió identificar, las hojas sanas y enfermas con un nivel de precisión de 99.18%.(UAN, 2021)

Se concluye que las redes neuronales son hoy protagonistas en la tarea de contribuir en el proceso de fortalecimiento de la agricultura de precisión.

Capítulo 4

4 Diseño metodológico

En el presente apartado se describe el componente de Hardware y Software del sistema de visión artificial implementado.

4.1 Análisis hardware

4.1.1 Diseño de Hardware

A continuación, se especifica la cámara, la placa de desarrollo, el sistema de alimentación y la pantalla táctil, de igual forma la puesta en marcha del sistema de visión artificial en el cultivo de la Cacao.

- **Cámara web**

En el desarrollo de la investigación se revisó varias cámaras web compatibles con la tarjeta de control cada uno con características especiales.

Tabla 1

Comparaciones características de cámaras

Sensor	RPi OEM Rev.1.3	RPi Original V2
Referencia	RA073	RA053
Sensor	OV5647 OmniVision	IMX219PQ SONY
Megapíxeles	5MP	8MP
Resolución	2592x1944 pixeles para imágenes estáticas	3280 x 2464
Video	1080p30 fps codec H.264 (AVC) 90 fps vídeo VGA	1080p30, 720p60 y VGA90

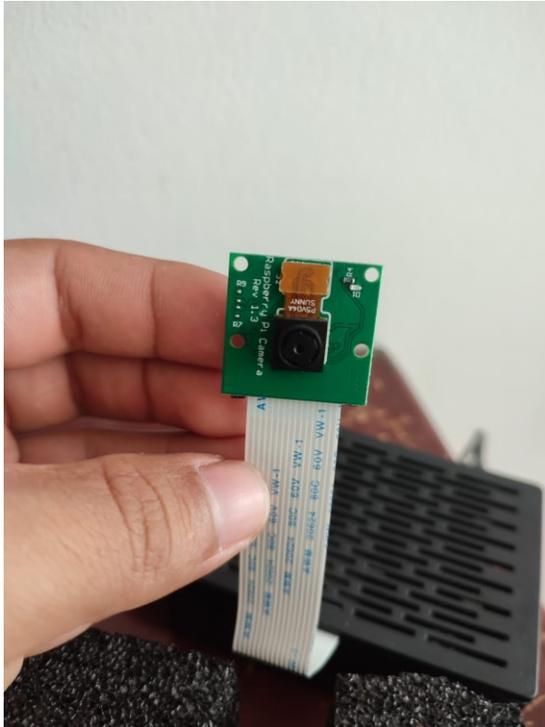
Tamaño sensor	3,67 x 2,74 milímetros	3.68 x 2.76 mm (4.6 mm diagonal)
Lente	f = 3,6 mm, f / 2.9	1/4 "
Campo visual	2,0 x 1,33 m, a 2 m	
Full-frame SLR	35 milímetros	
Dimensiones	2,5 x 2,4 cm	23.86 x 25 x 9mm
Peso	3g	3g

Nota: Autor

Finalmente, y luego de una comparación de las cámaras, se determinó que la cámara RPi OEM Rev. 1.3 es la más indicado para el desarrollo del proyecto porque permite la adecuada detección de la enfermedad al tener un lente y campo visual superior. Así mismo, otra de las razones está relacionada con el bajo costo del dispositivo en el mercado.

- **Cámara RPi OEM Rev. 1.3**

Para el sistema de visión artificial se implementó una cámara, se trata de la cámara RPi OEM Rev. 1.3. que se aprecia en la figura. Esta es una pequeña cámara que cuenta con una resolución de 5 MP e interfaz de conexión CSI y MIPI (S2)

Figura 6*Cámara RPi OEM Rev. 1.3**Nota:* Autor

De acuerdo con sus fabricantes se destacan las siguientes características.

Tabla 2*Características de la cámara RPi OEM Rev. 1.3.*

Modelo:	Cámara Raspberry Pi Rev 1.3
Chip fotosensible	OV5647
Píxeles	500 millones
Resolución de imagen:	5 MP 2592 × 1944
Interface:	Camera Serial Interface (CSI)
	Puerto serial de 15 pines MIPI (S2)
Compatibilidad:	Raspberry Pi: Zero 3B 3B+ 4B
Sistema Operativo:	Raspbian

Cable Flex:	AWM 20624 15 Pines
Longitud de cable:	15cm

Nota: Autor

Las características de la cámara descritas anteriormente son apropiadas para la detección de las imágenes en el cultivo del cacao y un posterior procesamiento en la red convolucional.

- **Conexión de la cámara**

La cámara RPi OEM Rev. 1.3. se conecta a la tarjeta de control por medio de la interfaz MIPI (S2), una vez se conecta y se habilita en la configuración de la Raspberry, se prueba por medio del comando `raspistill -o imagen.jpg`.

Figura 7

Sistema de conexión de la cámara



Nota: Autor

- **Tarjeta de control Raspberry PI**

Esta tarjeta de control permite entrenar y procesar una red neuronal usando lenguaje de programación Python y diversas librerías de etiquetado de imágenes, entrenamiento y validación de modelos.

De igual forma, la Raspberry PI hace posible la conexión con diversas cámaras pertinentes para aplicaciones de visión artificial.

La Raspberry está integrada por una CPU acelerada, soporte de WiFi de doble banda, soporte Gigabit Ethernet y un disipador ubicado sobre el SoC controlando así las temperaturas que puedan generarse (Pastor, 2018).

Figura 8

Raspberry PI 4



Nota: Autor

En la siguiente tabla se describen las especificaciones técnicas de la Raspberry PI 4.

Tabla 3

Características técnicas de la Raspberry PI

Características técnicas	
Procesador	Broadcom BCM2711, Quad core Cortex-A72 (ARM v8) SoC de 64 bits
Frecuencia de reloj	1,5 GHz
Memoria	SDRAM LPDDR4-3200 de 4 GB
Conectividad inalámbrica	2.4 GHz y 5.0 GHz IEEE 802.11ac inalámbrico, Bluetooth 5.0, BLE Gigabit Ethernet
Conectividad de red	Gigabit Ethernet over USB 2.0 - (300 Mbps de máximo teórico)
Puertos	GPIO 40 pines
	2 puertos micro-HDMI (hasta 4kp60 compatibles)
	4 x USB 2.0
	CSI (cámara Raspberry Pi)
	DSI (pantalla tácil)
	Tomas auriculares / vídeo compuesto
	Micro SD
	Micro USB (alimentación)
Power-over-Ethernet (PoE)	

Nota: Autor

- **Sistema de alimentación**

El sistema utilizado está integrado por una batería de almacenamiento de 100.000 mAh a 5V con 2.6A. Este dispositivo permite al sistema de visión artificial una portabilidad y desplazamiento por todo el cultivo.

Tabla 4*Consumo de energía*

Consumo de energía	
Elemento	watts
Raspberry pi 4 b+	1,8
Camara RPi Rev 1.3	0,02
TOTAL	1,82

Nota: Autor

Como se describe en la tabla 4, el consumo del sistema es de 1.82 Watts, teniendo en cuenta que el suministro de energía de la Power Bank es de 13 Watts/hora, se tiene la potencia necesaria para la alimentación del sistema.

Figura 9*Alimentación del sistema*

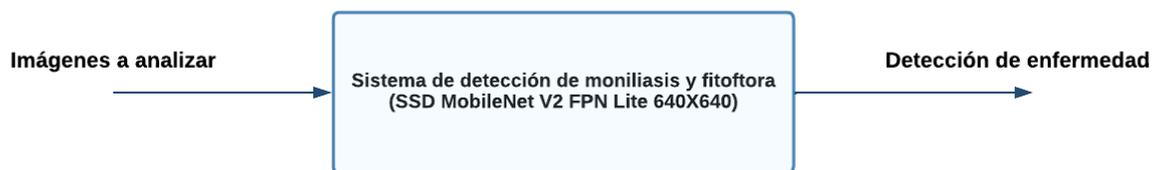
Nota: Autor

4.1.2 Diagrama general de hardware

En la figura 10 se representa el diagrama general de hardware que se requiere para la implementación del sistema visión artificial para la detección temprana de la Moniliasis y la Fitóftora en el cultivo de cacao criollo.

Figura 10

Diagrama general del sistema de visión - Hardware



Nota: Autor

4.1.3 Diagrama de primer nivel hardware

En la figura 11 se identifican los componentes necesarios para la detección de la Moniliasis y la Fitóftora a partir de las imágenes obtenidas en el cultivo de cacao criollo de la finca Villa Laura.

Figura 11

Diagrama en bloques funcionales del sistema de visión - hardware



Nota: Autor

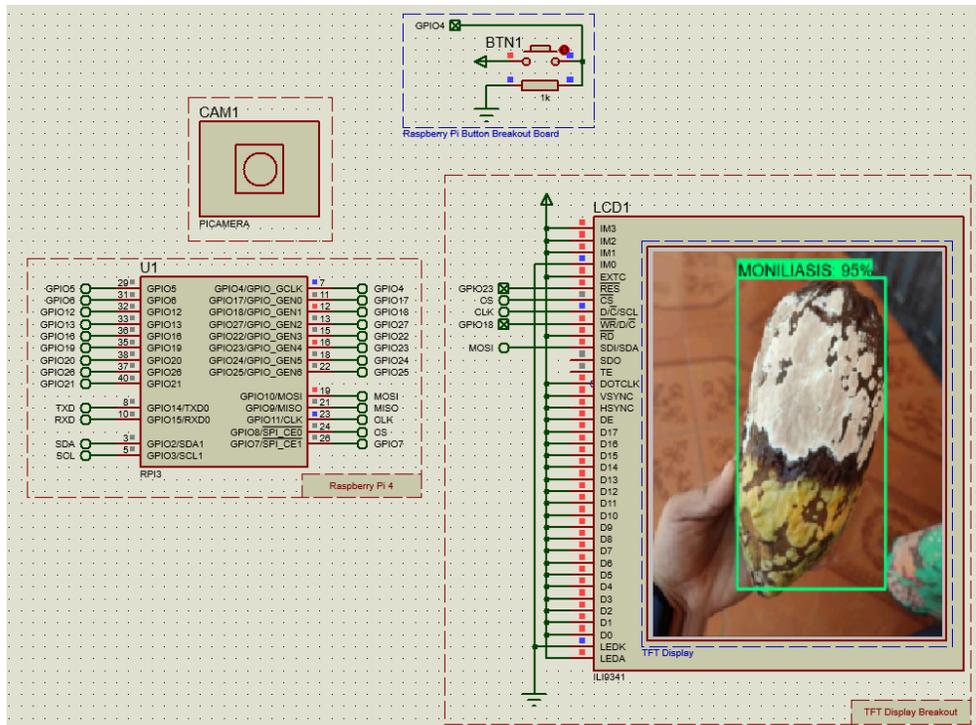
La cámara procesa las imágenes seleccionadas y las convierte en un archivo digital tipo RGB, que es enviada a la tarjeta principal.

La tarjeta de control y procesamiento es el dispositivo que toma la información de las imágenes, realiza su procesamiento a partir de un modelo ya establecido y envía el mensaje de detección pertinente.

Finalmente, la pantalla táctil permite visualizar el tipo de detección realizada en el bloque anterior. En la figura 12 se observa el esquema electrónico del sistema de visión por computadora implementado en la Raspberry Pi.

Figura 12

Esquema electrónico detallado del sistema desarrollado.



Nota: Autor

4.2 Análisis de software

4.2.1 Diseño de software

Para determinar la presencia de mazorca de cacao enfermas con Moniliasis y Fitoftora mediante la implementación de un algoritmo usando la visión por computadora por medio de la raspberry pi, se realizaron las siguientes actividades:

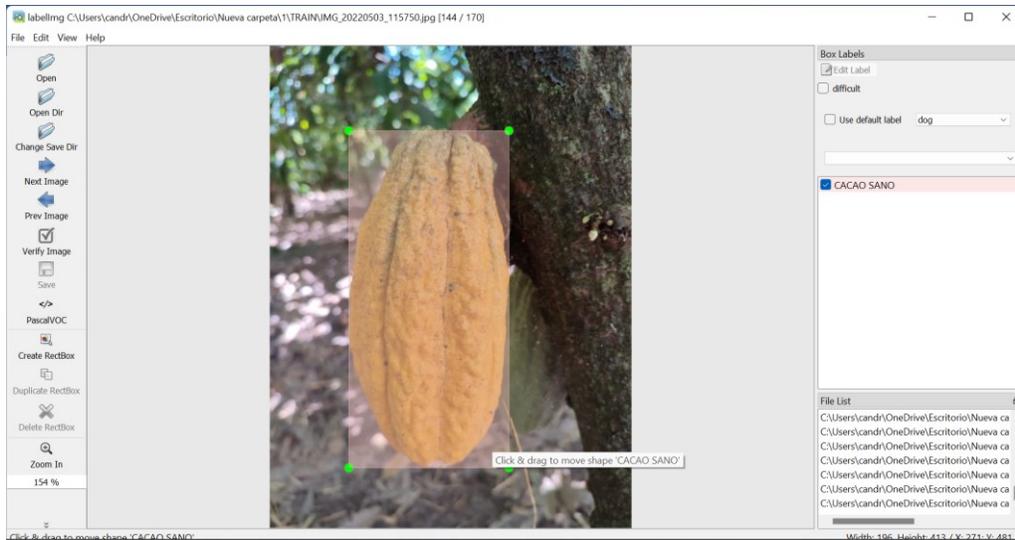
4.2.1.1 Recopilación de datos y etiquetado de imágenes

La adquisición de datos es el primer paso en el proceso de entrenamiento de un modelo de detección de objetos. Aunque el proceso puede automatizarse de muchas

maneras, en este escenario de entrenamiento concreto, las imágenes con ruido se eliminaron manualmente para garantizar la calidad del conjunto de datos. Las imágenes escogidas provienen de la finca Villa Laura donde se extrajo un conjunto de datos de 540 imágenes, donde se dividieron en 3 clases, 170 imágenes de cacao sano, 170 imágenes de cacao con Moniliasis y 170 imágenes de cacao con Fitoftora para un total de 510 imágenes para el entrenamiento y para la evaluación se escogieron 30 imágenes con diferentes ángulos y bajo diferentes condiciones de iluminación para así poder evaluar el modelo de la mejor manera posible y se dividieron de la siguiente forma, 10 imágenes de cacao sano, 10 imágenes de Moniliasis y 10 imágenes de cacao con Fitoftora para un total de 30 imágenes. Todas estas imágenes fueron tomadas con dimensiones de 443x591 por un celular de marca Xiaomi, modelo Redmi note 10 pro, por su calidad en su cámara de 16 Mpx. Las imágenes de la base de datos luego de haber sido divididas en entrenamiento y evaluación, como segundo paso deben ser etiquetadas. Para completar el etiquetado de las imágenes se utilizó el software Labellmg, este software es una implementación de código abierto en Python de un sistema que etiqueta los cuadros delimitadores y los registra en un archivo XML. Como se puede apreciar en la figura 13, 14 y 15 se puede evidenciar el etiquetado de las imágenes en el software Labellmg.

Figura 13

Etiqueta de cacao sano



Nota: Autor

Figura 14

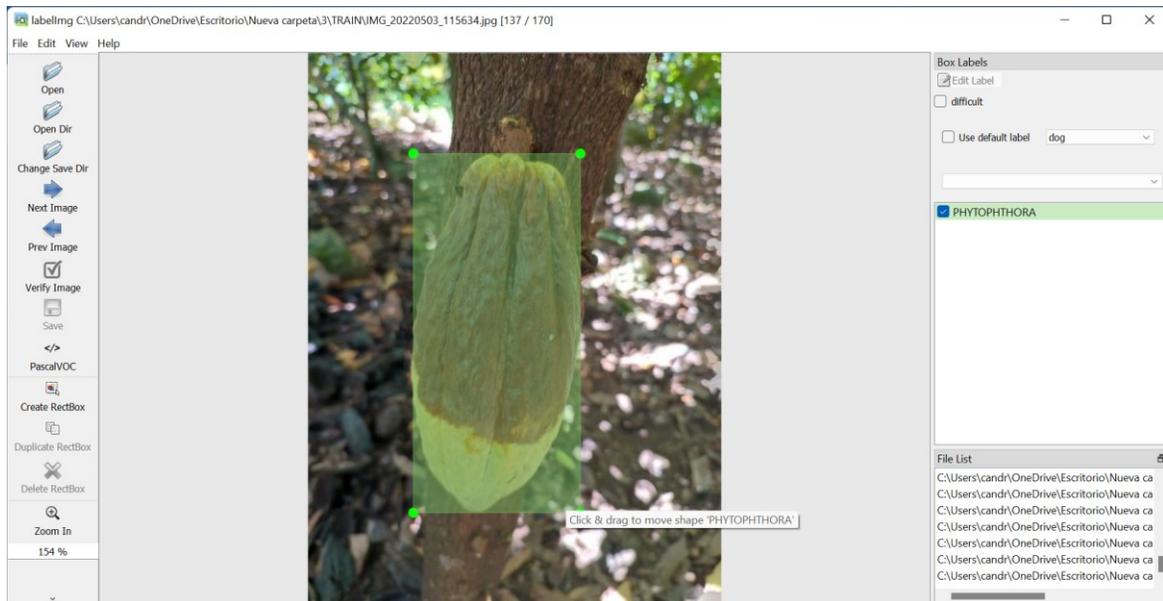
Etiqueta de cacao con Moniliasis



Nota: Autor

Figura 15

Etiqueta de cacao con Fitoftora



Nota: Autor

El resultado de las operaciones de etiquetado de imágenes es un archivo XML que contiene los cuadros delimitadores de las imágenes etiquetadas. A continuación, en la figura 16. Se muestra un archivo XML de ejemplo.

Figura 16

Archivo XML resultante de la etiqueta cacao sano

```

<annotation>
  <folder>cacao sano</folder>
  <filename>241.jpg</filename>
  <path>C:\Users\candr\OneDrive\Escritorio\IMAGENES\1\1\cacao sano\241.jpg</path>
  <source>
    <database>Unknown</database>
  </source>
  <size>
    <width>443</width>
    <height>591</height>
    <depth>3</depth>
  </size>
  <segmented>0</segmented>
  <object>
    <name>CACAO SANO</name>
    <pose>Unspecified</pose>
    <truncated>0</truncated>
    <difficult>0</difficult>
    <bndbox>
      <xmin>329</xmin>
      <ymin>202</ymin>
      <xmax>435</xmax>
      <ymax>515</ymax>
    </bndbox>
  </object>
</annotation>

```

Nota: Autor

4.2.1.2 Selección de la interfaz de trabajo

4.2.1.2.1 TensorFlow

Para la tarea de detección de objetos. Dado que entrenar una red neuronal por completo es costoso desde el punto de vista computacional, se opta por volver a entrenar solo parcialmente una red pre-entrenada. TensorFlow tiene variedad de redes convolucionales, cada una de las cuales se distinguen por el número de capas, la velocidad de detección, la precisión y el conjunto de datos con el que han sido entrenadas.

4.2.1.2.2 TensorFlow Lite

TensorFlow Lite (TFLite) son herramientas para optimizar y convertir los modelos de TensorFlow para que puedan funcionar en dispositivos portátiles y auxiliares. Google lo creó para uso interno antes de hacerlo de código abierto. Actualmente, TFLite está instalado en más de 4.000 millones de dispositivos. Para este proyecto se convierte el modelo entrenado de TensorFlow a TensorFlow Lite para así poder correr el modelo de detección de objetos en la raspberry pi.

4.2.1.3 Modelo de entrenamiento

Hay una serie de modelos diferentes que se puede elegir para entrenar un modelo de detección de objetos normalmente hay una compensación:

- Detecciones más rápidas menor precisión.
- Mayor precisión detecciones más lentas.

En Tensorflow model zoo tf2 se puede encontrar muchos modelos diferentes, cada una de estas representan diferentes arquitecturas de redes neuronales que se utilizan para la detección de objetos, usar diferentes modelos va a dar como resultado diferentes niveles de precisión, así como diferentes niveles de velocidad.

Como se puede apreciar en la figura 17. El modelo escogido para este estudio fue el SSD MobileNet V2 FPN Lite 640X640.

Figura 17*Modelos para la detección de objetos*

Nombre del modelo	Velocidad (ms)	COCO mAP	Salidas
CenterNet HourGlass104 512x512	70	41.9	Buzones
CenterNet HourGlass104 Puntos clave 512x512	76	40.0/61.4	Cajas/Puntos clave
CenterNet HourGlass104 1024x1024	197	44.5	Buzones
CenterNet HourGlass104 Puntos clave 1024x1024	211	42.8/64.5	Cajas/Puntos clave
CenterNet Resnet50 V1 FPN 512x512	27	31.2	Buzones
CenterNet Resnet50 V1 FPN Puntos clave 512x512	30	29.3/50.7	Cajas/Puntos clave
CenterNet Resnet101 V1 FPN 512x512	34	34.2	Buzones
CenterNet Resnet50 V2 512x512	27	29.5	Buzones
CenterNet Resnet50 V2 Puntos clave 512x512	30	27.6/48.2	Cajas/Puntos clave
CenterNet MobileNetV2 FPN 512x512	6	23.4	Buzones
CenterNet MobileNetV2 FPN Puntos clave 512x512	6	41.7	Puntos clave
EfficientDet D0 512x512	39	33.6	Buzones
EfficientDet D1 640x640	54	38.4	Buzones
EfficientDet D2 768x768	67	41.8	Buzones
EfficientDet D3 896x896	95	45.4	Buzones
EfficientDet D4 1024x1024	133	48.5	Buzones
EfficientDet D5 1280x1280	222	49.7	Buzones
EfficientDet D6 1280x1280	268	50.5	Buzones
EfficientDet D7 1536x1536	325	51.2	Buzones
SSD MobileNet v2 320x320	19	20.2	Buzones
SSD MobileNet V1 FPN 640x640	48	29.1	Buzones
SSD MobileNet V2 FPNLite 320x320	22	22.2	Buzones

Nota. Adactado de *TensorFlow 2 Detection Model Zoo*. Por Vighnesh Birodkar, (2021), https://github.com/tensorflow/models/blob/master/research/object_detection/g3doc/tf2_detection_zoo.md.

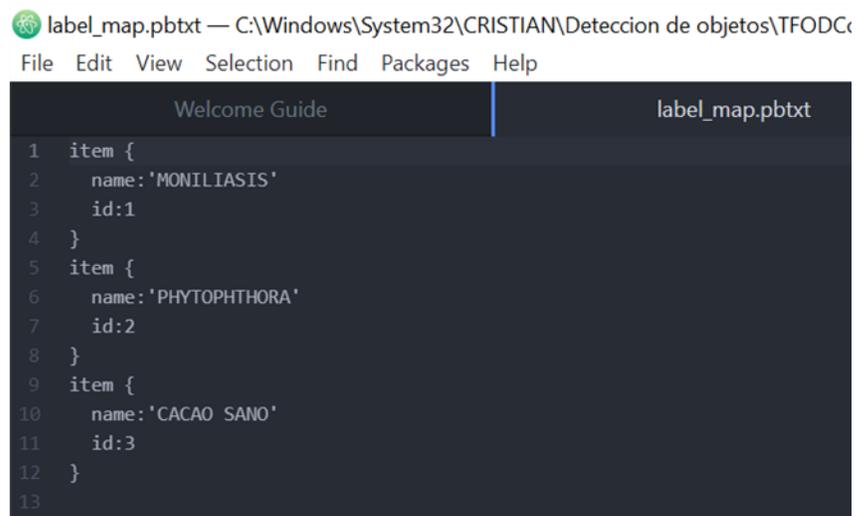
El modelo SSD MobileNet V2 fue escogido principalmente porque es un modelo que se implementa comúnmente en dispositivos de bajo computo como lo es la raspberry pi, este modelo entrega una precisión mAP de 29.1 a una velocidad de 48 milisegundos por cuadro de detección, siendo esto favorable para la implementación en la raspberry pi.

4.2.1.4 Mapas de etiqueta

Dado que la red neuronal solo puede predecir en números después de la última capa sigmoidea, el mapa de etiqueta es efectivamente un codificador para las clases que necesitan ser entradas. En este caso se tiene en el mapa tres etiquetas con los nombres de MONILIASIS, PHYTOPHTHORA y CACAO SANO. Este mapa de etiquetas lo que hará es que separara las clases de las imágenes de entrenamiento que se etiquetaron con el programa LabelImg para poder iniciar con el entrenamiento de la red neuronal.

Figura 18

Mapa de etiqueta



```
label_map.pbtxt — C:\Windows\System32\CRISTIAN\Deteccion de objetos\TFODC
File Edit View Selection Find Packages Help
Welcome Guide label_map.pbtxt
1 item {
2   name:'MONILIASIS'
3   id:1
4 }
5 item {
6   name:'PHYTOPHTHORA'
7   id:2
8 }
9 item {
10  name:'CACAO SANO'
11  id:3
12 }
13
```

Nota: Autor

4.2.1.5 Registros TF

Un archivo XML que contiene las coordenadas del cuadro delimitador de las imágenes etiquetadas manualmente es el resultado producido por el conjunto de datos de

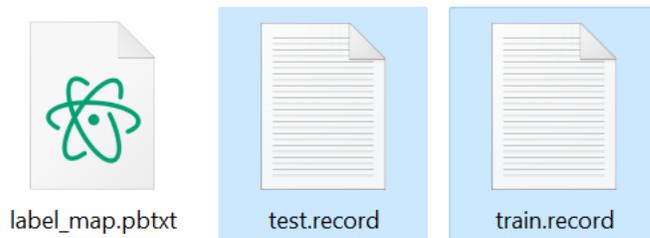
imágenes etiquetadas. Sin embargo, los modelos de redes neuronales necesitan un formato particular, TF-Records, porque no pueden comprender los archivos XML.

Los archivos XML de todas las imágenes para el entrenamiento se convierten primero a una salida intermedia CSV para luego ya convertirla a TF-Records.

El siguiente paso es producir el archivo de texto de detección de objetos después de que hayan producido los archivos de registro del TF. El texto del cuadro delimitador debe coincidir con la etiqueta del elemento y será determinado por el modelo utilizando el archivo de texto de detección de objetos. A continuación, en la figura 19 se muestran los archivos de detección de objetos para la instrucción del problema de detección y evaluación de enfermedades en el cacao.

Figura 19

Archivo mapa de etiqueta y TF-Records de entrenamiento y evaluación



Nota: Autor

Así, el proceso de construcción de la fase de preparación de los datos del modelo ha terminado.

4.2.1.6 Configuración para el transfer learning

La selección y los parámetros del modelo, como el tamaño del lote, el número de pasos y los directorios de los TF-Records de entrenamiento y evaluación, forman parte de la configuración del entrenamiento. Afortunadamente, el proceso de identificación de objetos proporcionado por TensorFlow incluyen un archivo preestablecido que optimiza la mayoría de las opciones de configuración para un rápido entrenamiento del modelo.

Figura 20

Arquitectura SSD MobileNet V2 sin Transfers Learning

```

model {
  ssd {
    num_classes: 90
    image_resizer {
      fixed_shape_resizer {
        height: 640
        width: 640
      }
    }
  }
  train_input_reader {
    label_map_path: "PATH_TO_BE_CONFIGURED"
    tf_record_input_reader {
      input_path: "PATH_TO_BE_CONFIGURED"
    }
  }
  eval_config {
    metrics_set: "coco_detection_metrics"
    use_moving_averages: false
  }
  eval_input_reader {
    label_map_path: "PATH_TO_BE_CONFIGURED"
    shuffle: false
    num_epochs: 1
    tf_record_input_reader {
      input_path: "PATH_TO_BE_CONFIGURED"
    }
  }
}

```

Nota: Autor

En la figura 20, el archivo de configuración de la arquitectura del modelo, se puede ver que hay una serie de ajustes que requieren ser actualizados. Para que el modelo conozca la etiqueta que se aplicara a la imagen una vez que se haya identificado un elemento, se debe establecer en primer lugar la ruta del mapa de etiquetas. A continuación,

hay que indicar la ruta de los archivos TF-Records de entrenamiento y evaluación. Se ha elegido un tamaño de lote por defecto de 16 para el entrenamiento, y el número de clases se establece en 3. El número de pasos de entrenamiento se establece en 20.000, que es simplemente el número de épocas de entrenamiento. Como se puede observar en la figura 21. La arquitectura ya ha sido actualizada con los datos de entrenamiento.

Figura 21

Arquitectura SSD MobileNet V2 con Transfers Learning

```

model {
  ssd {
    num_classes: 3
    image_resizer {
      fixed_shape_resizer {
        height: 640
        width: 640
      }
    }
  }
  train_input_reader {
    label_map_path: "Tensorflow\\workspace\\annotations\\label_map.pbtxt"
    tf_record_input_reader {
      input_path: "Tensorflow\\workspace\\annotations\\train.record"
    }
  }
  eval_config {
    metrics_set: "coco_detection_metrics"
    use_moving_averages: false
  }
  eval_input_reader {
    label_map_path: "Tensorflow\\workspace\\annotations\\label_map.pbtxt"
    shuffle: false
    num_epochs: 1
    tf_record_input_reader {
      input_path: "Tensorflow\\workspace\\annotations\\test.record"
    }
  }
}

```

Nota: Autor

4.2.1.7 Entrenamiento del modelo

Una vez el conjunto de datos ha sido seleccionado y preparado se procede a entrenar el modelo.

En la figura 22 y 23. Se puede observar el comienzo y el final del entrenamiento con un step de 20.000 con una pérdida total inicial del 0,7107.

Figura 22

Comienzo de entrenamiento

```

Administrator: Anaconda Powershell Prompt (Anaconda3)
2022-10-09 09:36:18.423367: W tensorflow/core/framework/dataset.cc:769] Input of GeneratorDatasetOp::Dataset will not be optimized because the dataset does not implement the AsGraphDefInternal() method needed to apply optimizations.
C:\WINDOWS\system32\CRISTIAN\Deteccion de objetos\TFODCourse\tfod\lib\site-packages\keras\backend.py:450: UserWarning: `tf.keras.backend.set_learning_phase` is deprecated and will be removed after 2020-10-11. To update it, simply pass a True/False value to the `training` argument of the `__call__` method of your layer or model.
  warnings.warn("`tf.keras.backend.set_learning_phase` is deprecated and ")
WARNING:tensorflow:From C:\WINDOWS\system32\CRISTIAN\Deteccion de objetos\TFODCourse\tfod\lib\site-packages\tensorflow\python\util\deprecation.py:629: calling map_fn_v2 (from tensorflow.python.ops.map_fn) with dtype is deprecated and will be removed in a future version.
Instructions for updating:
Use fn_output_signature instead
W1009 09:36:35.878188 17448 deprecation.py:554] From C:\WINDOWS\system32\CRISTIAN\Deteccion de objetos\TFODCourse\tfod\lib\site-packages\tensorflow\python\util\deprecation.py:629: calling map_fn_v2 (from tensorflow.python.ops.map_fn) with dtype is deprecated and will be removed in a future version.
Instructions for updating:
Use fn_output_signature instead
INFO:tensorflow:Step 100 per-step time 3.558s
I1009 09:42:31.506020 14168 model_lib_v2.py:705] Step 100 per-step time 3.558s
INFO:tensorflow:{"Loss/classification_loss": 0.32325396,
'Loss/localization_loss': 0.235783,
'Loss/regularization_loss': 0.15174264,
'Loss/total_loss': 0.71077955,
'learning_rate': 0.0319994}
I1009 09:42:31.521638 14168 model_lib_v2.py:708] {"Loss/classification_loss": 0.32325396,
'Loss/localization_loss': 0.235783,
'Loss/regularization_loss': 0.15174264,
'Loss/total_loss': 0.71077955,
'learning_rate': 0.0319994}
INFO:tensorflow:Step 200 per-step time 3.263s
I1009 09:47:57.716053 14168 model_lib_v2.py:705] Step 200 per-step time 3.263s
INFO:tensorflow:{"Loss/classification_loss": 0.26350436,
'Loss/localization_loss': 0.104364045,
'Loss/regularization_loss': 0.15165398,
'Loss/total_loss': 0.51952237,
'learning_rate': 0.0373328}
I1009 09:47:57.716053 14168 model_lib_v2.py:708] {"Loss/classification_loss": 0.26350436,
'Loss/localization_loss': 0.104364045,
'Loss/regularization_loss': 0.15165398,
'Loss/total_loss': 0.51952237,
'learning_rate': 0.0373328}
INFO:tensorflow:Step 300 per-step time 3.257s
I1009 09:53:23.441722 14168 model_lib_v2.py:705] Step 300 per-step time 3.257s
INFO:tensorflow:{"Loss/classification_loss": 0.4152645,

```

Nota: Autor

Figura 23

Final del entrenamiento

```

Administrador: Anaconda Powershell Prompt (Anaconda3)
'learning_rate': 0.054534025}
INFO:tensorflow:Step 19800 per-step time 4.698s
I1010 05:01:44.017625 14168 model_lib_v2.py:705] Step 19800 per-step time 4.698s
INFO:tensorflow: {'Loss/classification_loss': 0.09245094,
'Loss/localization_loss': 0.016009899,
'Loss/regularization_loss': 0.08455976,
'Loss/total_loss': 0.1930206,
'learning_rate': 0.0542948}
I1010 05:01:44.017625 14168 model_lib_v2.py:708] {'Loss/classification_loss': 0.09245094,
'Loss/localization_loss': 0.016009899,
'Loss/regularization_loss': 0.08455976,
'Loss/total_loss': 0.1930206,
'learning_rate': 0.0542948}
INFO:tensorflow:Step 19900 per-step time 4.668s
I1010 05:09:30.834089 14168 model_lib_v2.py:705] Step 19900 per-step time 4.668s
INFO:tensorflow: {'Loss/classification_loss': 0.057652242,
'Loss/localization_loss': 0.017292377,
'Loss/regularization_loss': 0.084333405,
'Loss/total_loss': 0.15927802,
'learning_rate': 0.054054994}
I1010 05:09:30.834089 14168 model_lib_v2.py:708] {'Loss/classification_loss': 0.057652242,
'Loss/localization_loss': 0.017292377,
'Loss/regularization_loss': 0.084333405,
'Loss/total_loss': 0.15927802,
'learning_rate': 0.054054994}
INFO:tensorflow:Step 20000 per-step time 3.753s
I1010 05:15:46.108542 14168 model_lib_v2.py:705] Step 20000 per-step time 3.753s
INFO:tensorflow: {'Loss/classification_loss': 0.07360321,
'Loss/localization_loss': 0.07986897,
'Loss/regularization_loss': 0.084171996,
'Loss/total_loss': 0.23764418,
'learning_rate': 0.0538146}
I1010 05:15:46.108542 14168 model_lib_v2.py:708] {'Loss/classification_loss': 0.07360321,
'Loss/localization_loss': 0.07986897,
'Loss/regularization_loss': 0.084171996,
'Loss/total_loss': 0.23764418,
'learning_rate': 0.0538146}
(tfod) (base) PS C:\WINDOWS\system32\CRISTIAN\Deteccion de objetos\TFODCourse> python TensorFlow\models\research\object_detection\model_main_tf2.py --model_dir=TensorFlow\workspace\models\Deteccion_Efermedades_Cacao2 --pipeline_config_path=TensorFlow\workspace\models\Deteccion_Efermedades_Cacao2\pipeline.config --checkpoint_dir=TensorFlow\workspace\models\Deteccion_Efermedades_Cacao2

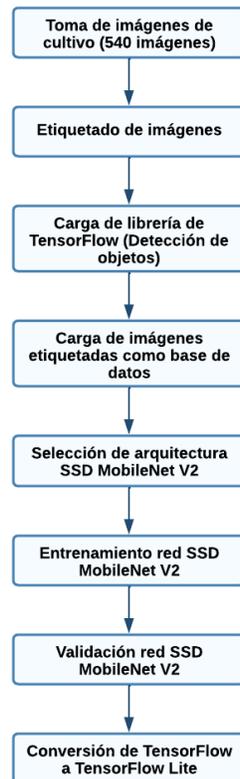
```

Nota: Autor

En la Figura 24 se describe el diagrama de flujo del proceso de entrenamiento de modelo SSDMobileNet V2

Figura 24

Diagrama de flujo del algoritmo de entrenamiento



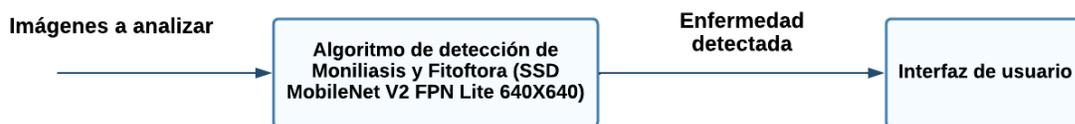
Nota: Autor

4.2.2 Diagrama general software

La Figura 25, se muestra el diagrama general de software para la implementación del sistema de visión artificial para la detección temprana de la Moniliasis y la Fitóftora en el cultivo de cacao criollo. Se capta la imagen que se desea analizar; se realiza el proceso de validación de la imagen en el modelo SSD MobileNet V2 FPN Lite 640x640 entrenado, luego se presenta en una interfaz diseñada la detección de la enfermedad obtenida.

Figura 25

Diagrama general del sistema de visión- software



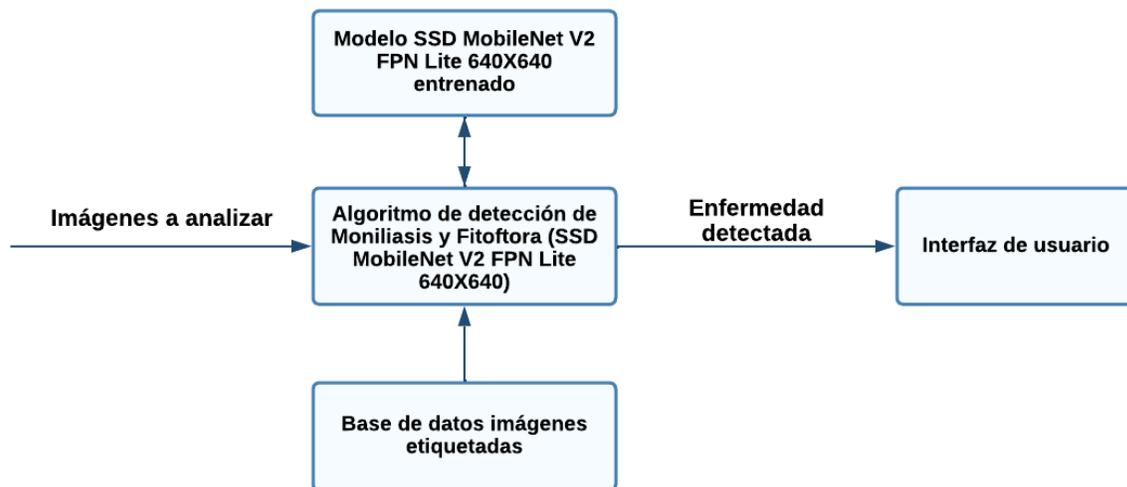
Nota: Autor

4.2.3 Diagrama de primer nivel

En figura 26 se muestran los bloques funcionales del sistema de visión artificial desde la captación de las imágenes hasta la visualización de la enfermedad detectada en la interfaz de usuario.

Figura 26

Diagrama de bloques funcionales del sistema de visión- Software



Nota: Autor

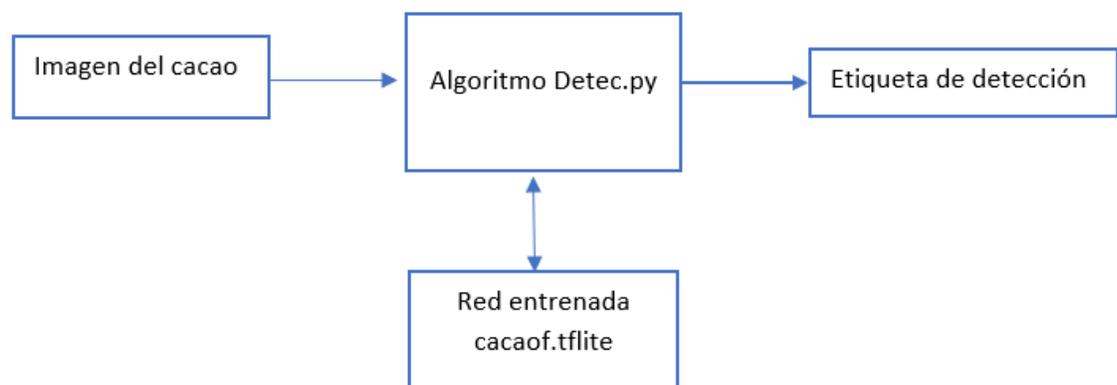
En primer lugar, el algoritmo de detección realiza el entrenamiento de la red SSD MobileNet V2 a partir la base de datos de imágenes previamente etiquetadas y luego de validar el modelo, las imágenes a analizar se capturan y son procesadas por esta red entrenada. Por último, la detección de la enfermedad es entregada a la interfaz de usuario para su visualización.

4.2.4 Algoritmo de visión artificial para detección de enfermedades

En la figura 27. Se muestra el diagrama de flujo del sistema de detección del prototipo de visión artificial. El sistema toma la imagen de la cámara web conectada y realiza la validación con la red entrenada en cacaof.tflite para luego generar una etiqueta de la enfermedad analizada.

Figura 27

Diagrama de flujo del algoritmo del sistema de visión



Nota: Autor

Capítulo 5

5. Análisis y resultados

En el siguiente apartado se describen los análisis y resultados de la evaluación del funcionamiento del sistema de visión por computadora con Raspberry pi para la detección temprana de la Moniliasis y la Fitóftora en el cultivo de cacao criollo de la finca Villa Laura.

5.1 Evaluación de modelo

Una vez ya entrenado se pasa a evaluar el modelo con las métricas de evaluación de detección de objetos, donde se utilizaron las métricas de coco. Y para la visualización de la evaluación se utilizó Tensorboard, esta es una herramienta de monitoreo interactivo. En la figura 28 se puede observar los resultados de evaluación de las métricas de coco.

Figura 28

Resultados de la evaluación del modelo

```

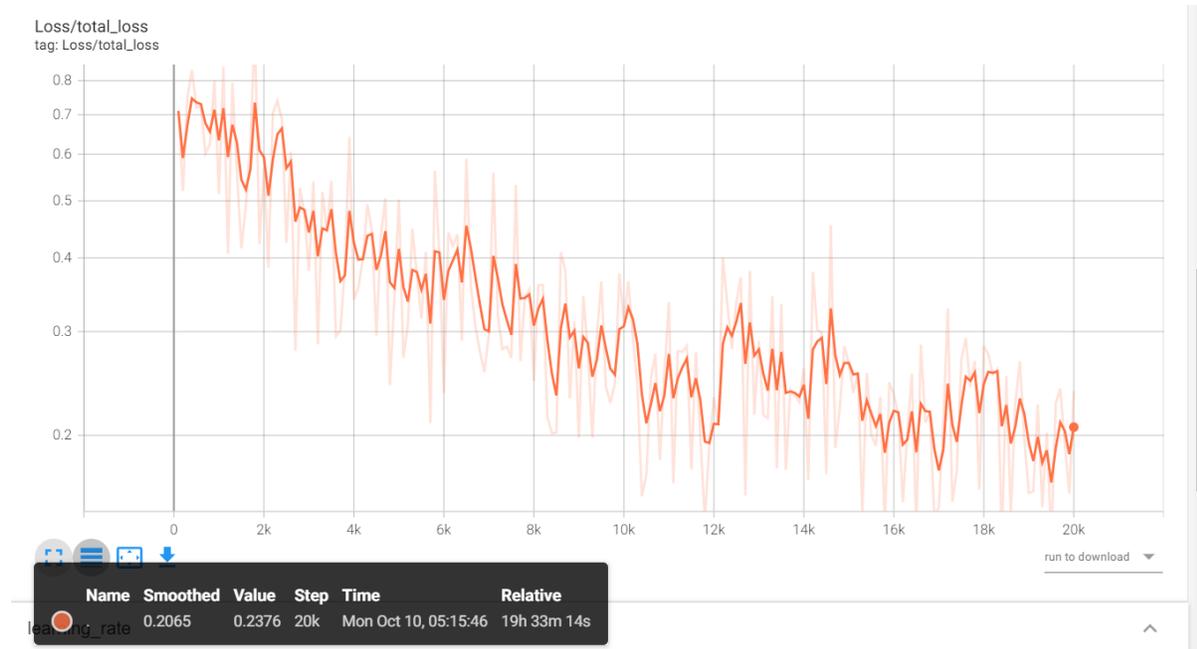
Administrator: Anaconda Powershell Prompt (Anaconda3)
DONE (t=0.05s).
Accumulating evaluation results...
DONE (t=0.03s).
Average Precision (AP) @[ IoU=0.50:0.95 | area= all | maxDets=100 ] = 0.783
Average Precision (AP) @[ IoU=0.50 | area= all | maxDets=100 ] = 0.909
Average Precision (AP) @[ IoU=0.75 | area= all | maxDets=100 ] = 0.890
Average Precision (AP) @[ IoU=0.50:0.95 | area= small | maxDets=100 ] = -1.000
Average Precision (AP) @[ IoU=0.50:0.95 | area=medium | maxDets=100 ] = -1.000
Average Precision (AP) @[ IoU=0.50:0.95 | area= large | maxDets=100 ] = 0.783
Average Recall (AR) @[ IoU=0.50:0.95 | area= all | maxDets= 1 ] = 0.850
Average Recall (AR) @[ IoU=0.50:0.95 | area= all | maxDets= 10 ] = 0.850
Average Recall (AR) @[ IoU=0.50:0.95 | area= all | maxDets=100 ] = 0.850
Average Recall (AR) @[ IoU=0.50:0.95 | area= small | maxDets=100 ] = -1.000
Average Recall (AR) @[ IoU=0.50:0.95 | area=medium | maxDets=100 ] = -1.000
Average Recall (AR) @[ IoU=0.50:0.95 | area= large | maxDets=100 ] = 0.850
INFO:tensorflow:Eval metrics at step 20000
I1010 05:18:25.544663 13916 model_lib_v2.py:1015] Eval metrics at step 20000
INFO:tensorflow: + DetectionBoxes_Precision/mAP: 0.782788
I1010 05:18:25.591593 13916 model_lib_v2.py:1018] + DetectionBoxes_Precision/mAP: 0.782788
INFO:tensorflow: + DetectionBoxes_Precision/mAP@.50IOU: 0.908631
I1010 05:18:25.607128 13916 model_lib_v2.py:1018] + DetectionBoxes_Precision/mAP@.50IOU: 0.908631
INFO:tensorflow: + DetectionBoxes_Precision/mAP@.75IOU: 0.890200
I1010 05:18:25.607128 13916 model_lib_v2.py:1018] + DetectionBoxes_Precision/mAP@.75IOU: 0.890200
INFO:tensorflow: + DetectionBoxes_Precision/mAP (small): -1.000000
I1010 05:18:25.607128 13916 model_lib_v2.py:1018] + DetectionBoxes_Precision/mAP (small): -1.000000
INFO:tensorflow: + DetectionBoxes_Precision/mAP (medium): -1.000000
I1010 05:18:25.607128 13916 model_lib_v2.py:1018] + DetectionBoxes_Precision/mAP (medium): -1.000000
INFO:tensorflow: + DetectionBoxes_Precision/mAP (large): 0.782788
I1010 05:18:25.622749 13916 model_lib_v2.py:1018] + DetectionBoxes_Precision/mAP (large): 0.782788
INFO:tensorflow: + DetectionBoxes_Recall/AR@1: 0.850000
I1010 05:18:25.622749 13916 model_lib_v2.py:1018] + DetectionBoxes_Recall/AR@1: 0.850000
INFO:tensorflow: + DetectionBoxes_Recall/AR@10: 0.850000
I1010 05:18:25.622749 13916 model_lib_v2.py:1018] + DetectionBoxes_Recall/AR@10: 0.850000
INFO:tensorflow: + DetectionBoxes_Recall/AR@100: 0.850000
I1010 05:18:25.622749 13916 model_lib_v2.py:1018] + DetectionBoxes_Recall/AR@100: 0.850000
INFO:tensorflow: + DetectionBoxes_Recall/AR@100 (small): -1.000000
I1010 05:18:25.638366 13916 model_lib_v2.py:1018] + DetectionBoxes_Recall/AR@100 (small): -1.000000
INFO:tensorflow: + DetectionBoxes_Recall/AR@100 (medium): -1.000000
I1010 05:18:25.638366 13916 model_lib_v2.py:1018] + DetectionBoxes_Recall/AR@100 (medium): -1.000000
INFO:tensorflow: + DetectionBoxes_Recall/AR@100 (large): 0.850000

```

Nota: Autor

5.1.1 Evaluación del entrenamiento

Como se puede observar en la figura 29. Se tubo una pérdida total en el entrenamiento de 0.2376 en un step de 20.000, el tiempo total de entrenamiento fue de 19h 33m 14s.

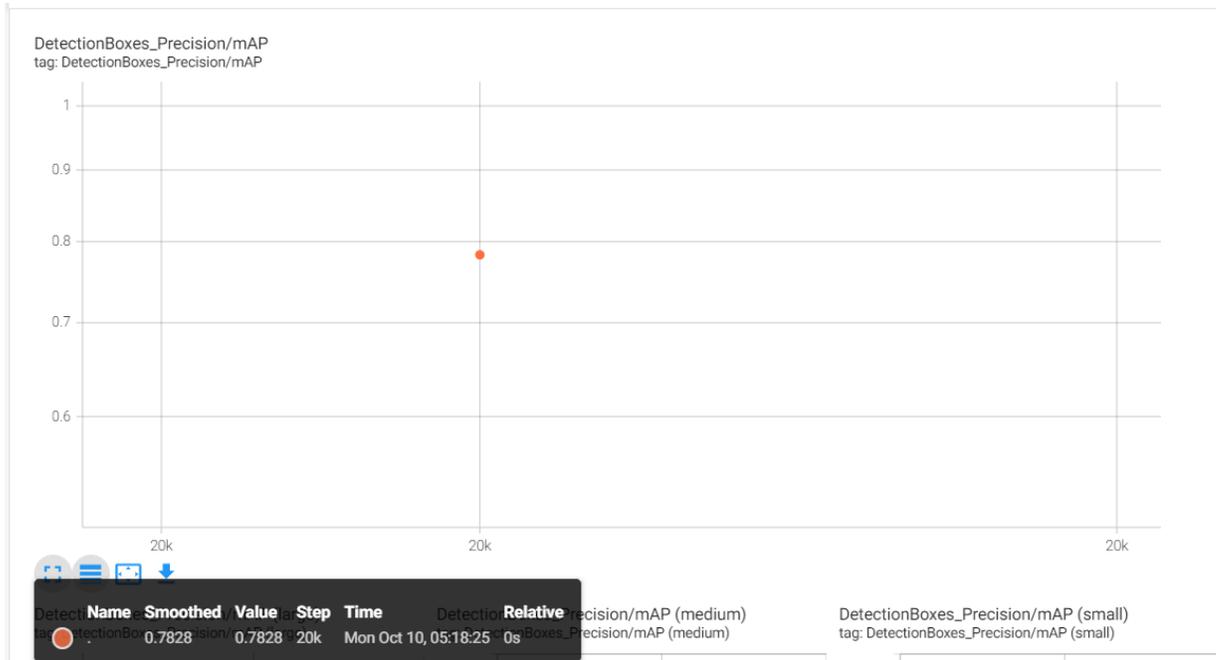
Figura 29*Total de perdidas (total_loss)**Nota: Autor*

5.1.2 Evaluación de las métricas de rendimiento

En la figura 30 y 31 se puede observar los resultados de la evaluación, donde se obtuvo una precisión media del 0.783 y un recuerdo promedio de 0.85 evaluadas en una IoU=0.50:0.95.

Figura 30

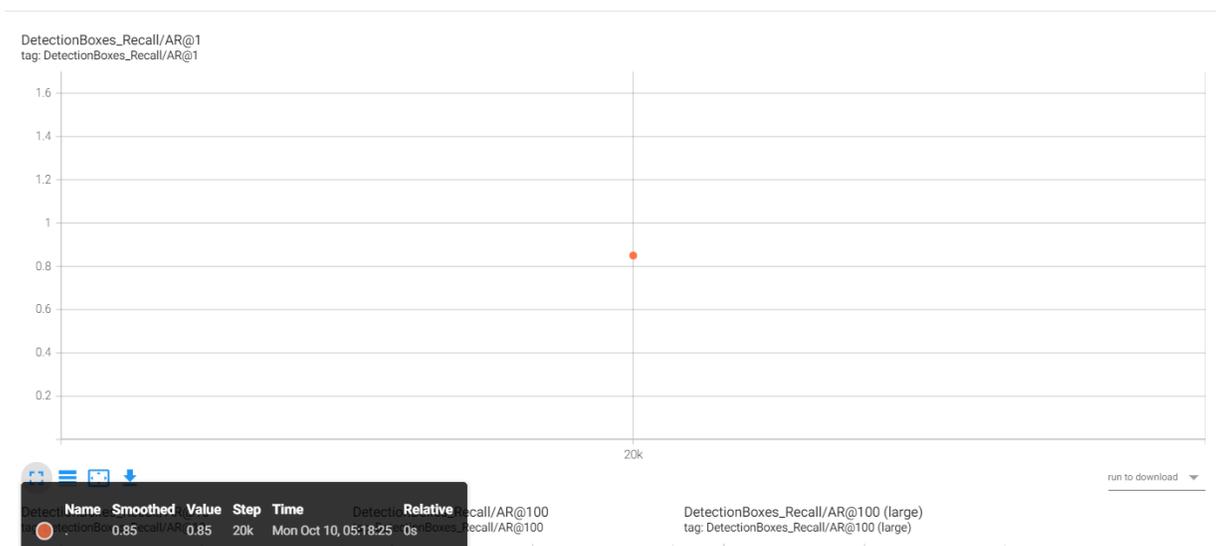
Precisión media (Average precisión)



Nota: Autor

Figura 31

Recuerdo promedio (Average recall)



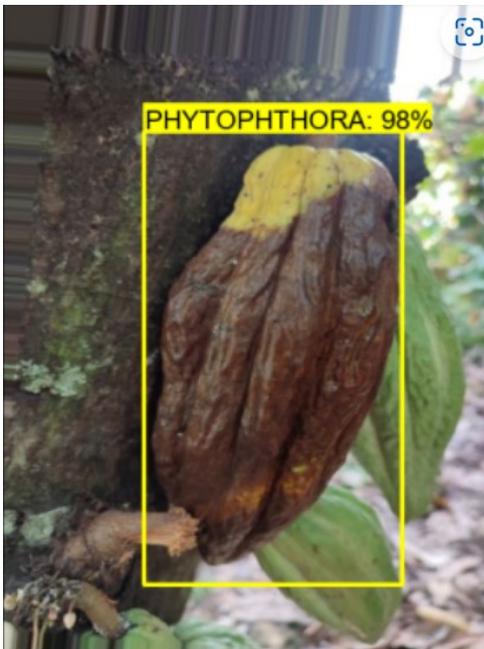
Nota: Autor

5.1.3 Evaluación de detección a partir de imágenes

Una vez entrenado y evaluado el modelo, se hace pruebas de detección con imágenes que nunca allá visto el modelo, para evaluar que tan preciso es detectando el modelo.

Figura 32

Detección de phytophthora



Nota: Autor

Figura 33

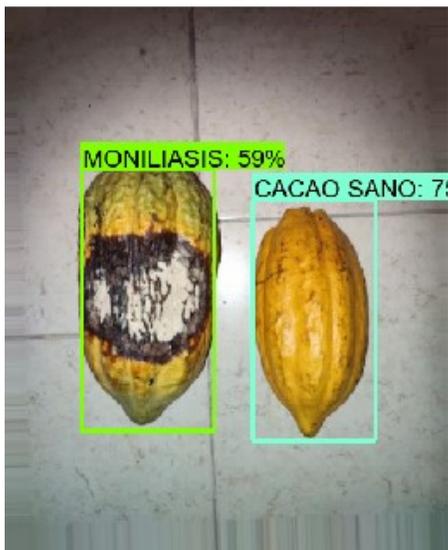
Detección de Moniliasis



Nota: Autor

Figura 34

Detección de Moniliasis y cacao sano en iluminación baja



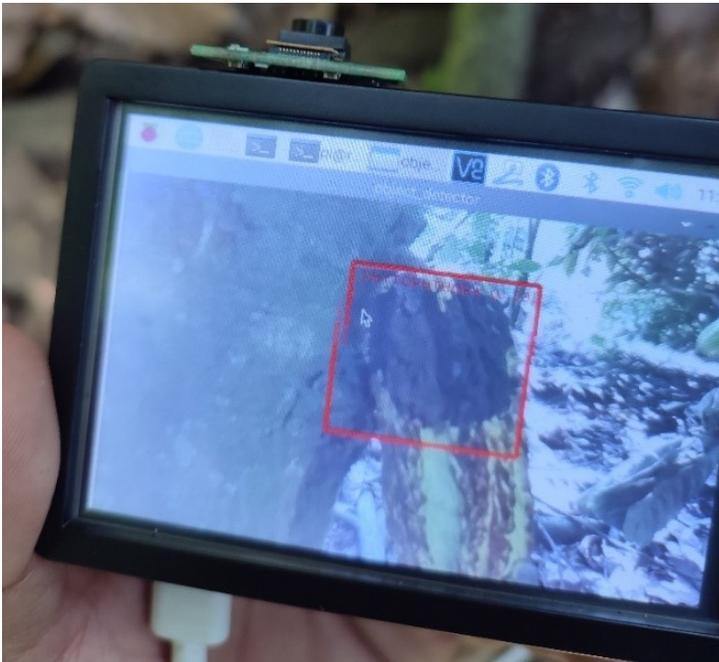
Nota: Autor

5.1.4 Detección con el modelo entrenado implementado en la Raspberry Pi

En la figura 35, 36 Y 37. Se evidencia el prototipo final implementado, en el cual se realizan pruebas de campo, para garantizar el correcto funcionamiento del prototipo a diversas condiciones climatológicas.

Figura 35

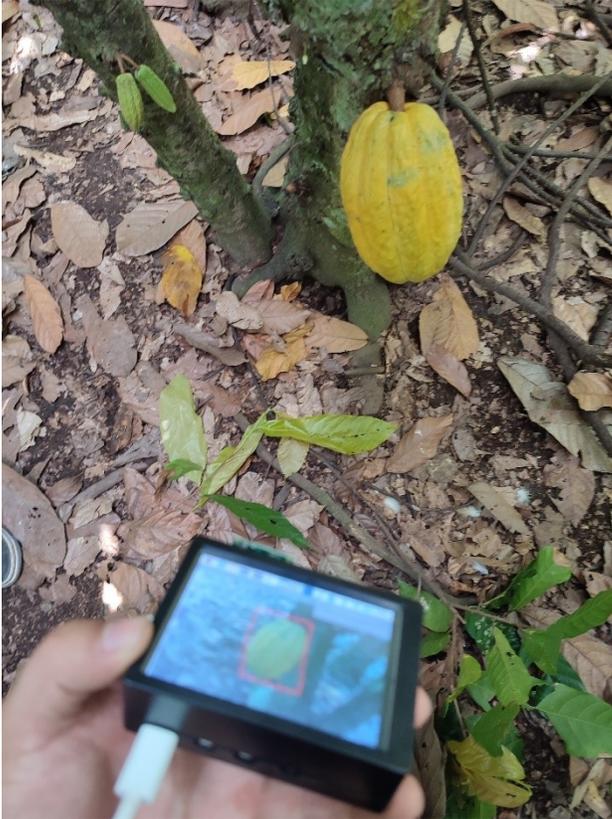
Prototipo de detección I



Nota: Autor

Figura 36

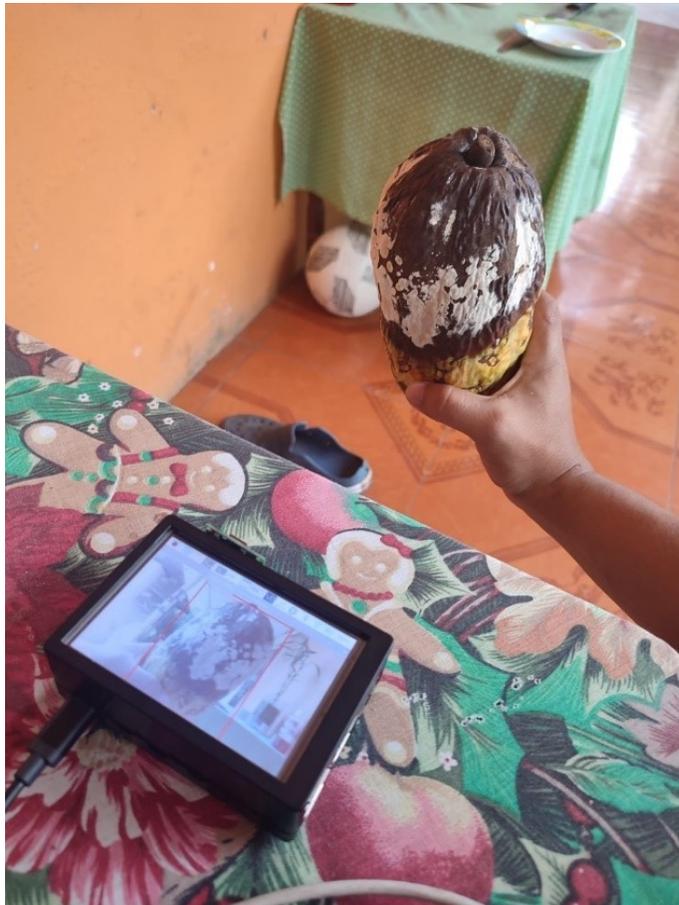
Prototipo de detección II



Nota: Autor

Figura 37

Prototipo de detección III



Nota: Autor

Capítulo 6

Conclusiones

Según en el análisis de las cámaras compatibles con Raspberri Pi, la cámara Rev 1.3., es la más pertinente para la captura de imágenes en el cultivo del cacao en la vereda Los Medios del municipio de Rivera en el departamento del Huila, por su gran ángulo de visión y su valor económico.

La tarjeta de control Raspberri Pi 4 modelo B, permite una implementación de un modelo de visión artificial funcional y portable dentro de todo un cultivo agrícola. Sus características técnicas permiten el correcto entrenamiento, validación y detección del modelo desarrollado en este proyecto.

Las imágenes analizadas para el desarrollo de este proyecto son etiquetadas de forma efectiva por el software Labellmg y son compatibles con las librerías de Deep Learning de TensorFlow. Para el desarrollo de este primer modelo, la base de datos se implementó con 540 imágenes, las cuales son pertinentes para el estudio.

La red neuronal SSD MobileNet V2, una vez entrenada con un step de 20.000, se tuvo como resultado una precisión media del 0.783 y un recuerdo promedio del 0.85 evaluadas en una IoU=0.5:0.95, con una pérdida total en el entrenamiento de 0.2784, siendo esto como resultado muy favorable para la detección de enfermedades en el cacao criollo de la finca Villa Laura.

La implementación de la visión por computadora en la Raspberry Pi teniendo como punto de partida la detección de las enfermedades como la Moniliasis y la Fitoftora en los cultivos de Cacao criollo, es muy beneficioso ya que, al ser una alternativa de bajo costo,

portátil y con valores de precisión y recuerdo alto, puede ser asequible a los agricultores que deseen hacer detección y separación temprana de cacaos enfermos que puedan afectar toda la plantación.

Como impacto se reconoce el valor económico dado que es posible el ahorro de posibles pérdidas de cultivo, adicional del impacto social de implementar tecnologías en el ámbito agrícola.

Bibliografía

- Aime, M. C., & Rica, C. (2005). *The causal agents of witches ' broom and frosty pod rot of cacao (chocolate , Theobroma cacao) form a new lineage of Marasmiaceae*. 97(5), 1012–1022.
- Ángel, M., & Sánchez, A. (n.d.). *Manual Técnico del Cultivo de Cacao Prácticas Latinoamericanas*.
- Ávila-Tomás, J. F., Mayer-pujadas, M. A., & Quesada-varela, V. J. (2020). *Atención Primaria La inteligencia artificial y sus aplicaciones en medicina I : introducción antecedentes a la IA y robótica*. *Atención Primaria*, 52(10), 778–784. <https://doi.org/10.1016/j.aprim.2020.04.013>
- Banda, H. (2014). *Inteligencia Artificial: Principios y Aplicaciones*. May.
- Bravo, L., Vaquero, M. P., & Bastida, S. (2011). *Efectos beneficiosos del chocolate en la salud cardiovascular*. 26(2), 289–292. <https://doi.org/10.3305/nh.2011.26.2.5016>
- Calvo, D. (2017). *Diego Calvo. Definición de Red Neuronal Artificial*. <https://www.diegocalvo.es/definicion-de-red-neuronal/>
- Caracol radio. (2021). *Cacaoteros se benefician de inversión que mejorará la producción del grano*.
- Diez, R. P., Gómez, A. G., & Martínez, N. de A. (2001). *Introducción a la inteligencia artificial*.
- Dostert, N., Roque, J., Cano, A., Torre, M. I. La, & Weigend, M. (2011). *Hoja botánica : Cacao*.
- Elebi, C. M. (n.d.). *Inteligencia Artificial y Salud*.
- Evans, H. C. (1981). *Pod rot of cacao caused by Moniliophthora (Monilia) roreri*. *Phytopathological Papers*, 44.
- Frayre, A. O. G., Méndez, C. A. G., Olvera, C. A. O., Eneldo, F., Monteagudo, L., Betancur, D. L., Gutiérrez, V. M., & Barraza, S. V. (2005). *Estudio y comparativa de algoritmos de detección de objetos con redes neuronales artificiales convolucionales para la detección de enfermedades en hojas*. 1–6.
- Géron, A. (2017). *Hands-on Machine Learning*. In O'Reilly Media, Inc (Vol. 53, Issue 9).

- Instituto Colombiano Agropecuario - ICA. (2021). *Manejo fitosanitario del cultivo del cacao*.
- Jiao, L., Dong, S., Zhang, S., Xie, C., & Wang, H. (2020). *AF-RCNN: An anchor-free convolutional neural network for multi-categories agricultural pest detection*. *Computers and Electronics in Agriculture*, 174(November 2019), 105522. <https://doi.org/10.1016/j.compag.2020.105522>
- Kalvatchev, Z., Garzaro, D., & Guerra, F. (1998). *Theobroma Cacao L. : Un nuevo enfoque para nutrición y salud*. *Agroalimentaria*, 6, 23–25.
- López, A. M., Méndez, G., & Arrazate, A. (2020). *El mundo del cacao*. *Agro Productividad*, 5, 261–276.
- Luna, D. R., Soler, M. S., Iraizoz, M. T., & Hermida, L. X. O. (2004). *Observatorio Agroclimas Colombia*. 13.
- Mani, V. R. S., Saravanaselvan, A., & Arumugam, N. (2022). *Performance comparison of CNN, QNN and BNN deep neural networks for real-time object detection using ZYNQ FPGA node*. *Microelectronics Journal*, 119(October 2021). <https://doi.org/10.1016/j.mejo.2021.105319>
- Mendo, B., Aaron, J., Marlene, I., & Jacinto, R. P. (2021). *No Title*.
- Mi, J. X., Feng, J., & Huang, K. Y. (2022). *Designing efficient convolutional neural network structure: A survey*. *Neurocomputing*, 489, 139–156. <https://doi.org/10.1016/j.neucom.2021.08.158>
- Ministerio de Agricultura y Desarrollo Rural de Colombia. (2021). *Colombia registró la mayor producción de cacao de la historia, en el último año cacaotero*.
- Ministerio de Agricultura y Desarrollo Rural de Colombia. (2019). *Se fortalecerá la producción de cacao en Huila*. *Agronet*.
- Moreno Álvaro. (2019). *Clasificación de imágenes usando redes neuronales convolucionales en Python*. *Universidad de Sevilla*, 1, 1–60.
- Puentes, D. B. (2017). *Proyección de la producción de cacao en el departamento del Huila en Colombia*. *Revista de Investigaciones Agroempresariales*, 7.
- Quintero, M. L., & Morales, K. M. D. (2004). *Mercado mundial de cacao*. *Revista Agroalimentaria*, 10(18), 48–60. <https://dialnet.unirioja.es/servlet/articulo?codigo=2110856>

- Ricaño-Rodríguez, J. (2018). *El estudio genómico del cacao (Theobroma cacao L.)*; breve recopilación de sus bases conceptuales. *Agro Productividad*, 11(9), 29–35. <https://doi.org/10.32854/agrop.v11i9.1211>
- Rouhiainen, L. (n.d.). *Inteligencia artificial* 101.
- Rojas, E. M. (2020). *Machine Learning : análisis de lenguajes de programación y herramientas para desarrollo*. 586–600.
- Serrano, A. G. (2012). *Inteligencia Artificial. Fundamentos, práctica y aplicaciones*. Rc Libros.
- Suárez, Y. J., & Hernández, F. A. (2014). *Manejo de las enfermedades del cacao en Colombia con énfasis en Monilia*. In *Paper Knowledge . Toward a Media History of Documents*. Corpoica.
- Superintendencia de Industria y Comercio. (2011). *Cadena productiva del cacao: Diagnostico de libre competencia*. Superintendencia De Industria Y Comercio, 1–6. https://www.sic.gov.co/recursos_user/documentos/promocion_competencia/Estudios_Economicos/Cacao.pdf
- Takeyas, B. L. (2007). *Introducción a la inteligencia artificial*.
- Tan, M., & Yu, A. (2020). *EfficientDet: Hacia una detección de objetos escalable y eficiente*. Google AI Blog. <https://ai.googleblog.com/2020/04/efficientdet-towards-scalable-and.html>
- Torres-galindo, A., & Torres-leon, J. (n.d.). *Análisis preliminar de detección de patologías en cultivos de palma aceitera usando Redes Neuronales Convolucionales*.
- UAN. (2021). *Universidad Antonio Nariño*. <http://repositorio.uan.edu.co/simple-search?query=Redes+neuronales&scope=>
- Vera, A. P. (2019). *Facultad Artes y Humanidades carrera de Gastronomía tema: estudio del cacao fino de aroma Chef Gabriel Galarraga*.
- Yang, J., Guo, X., Li, Y., Marinello, F., Ercisli, S., & Zhang, Z. (2022). *A survey of few-shot learning in smart agriculture: developments, applications, and challenges*. *Plant Methods*, 18(1), 1–12. <https://doi.org/10.1186/s13007-022-00866-2>
- Universidad nacional de san juan. (2017). *DEA- Departamento de electrónica automática, Facultad de Ingeniería, UNSJ. Procesamiento digital de imágenes. Capitulo1.pdf (unsj.edu.ar)*

- M. C. José Jaime Esqueda Elizondo. Conatec. (2002). *Fundamentos de procesamiento de imágenes*
- Khanh LeViet. (2021). *Detención de objetos*. <https://developers.google.com/codelabs/tflite-object-detection-android#1>
- Gaudenz Boesch. *Labelling para anotación de imágenes*. <https://viso.ai/computer-vision/labelimg-for-image-annotation/>
- Arturo Fernandez. (2013). *Python 3 al descubierto*. Alfaomega grupo editor, S.A de C.V. Mexico
- Brownlee, J. (2019). *Deep learning for computer*. <https://machinelearningmastery.com/object-recognition-with-deep-learning/>
- Mehta, V. (2021). *Object detection using SSD Mobilenet V2*. <https://vidishmehta204.medium.com/object-detection-using-ssd-mobilenet-v2-7ff3543d738d>
- Sandler, Mark & Howard, Andrew & zhu, Menglong & Zhmoginov, Andrey & Chen, Liang-Chieh. (2018). *MobileNet V2. Inverted Residuals and Linear Bottlenecks*. 4510-4520.
- Sarkar, Dipanjan. (2018). *A comprehensive Hands-on guide to transfer learning with real-world applications in deep learnind*. <https://towardsdatascience.com/a-comprehensive-hands-on-guide-to-transfer-learning-with-real-world-applications-in-deep-learning-212bf3b2f27a>
- Rosebrock, Adrian. (2016). *Intersection over union (IoU) for object detection*. <https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>
- Hui, Jonathan. (2018). *mAP (mean average precision) for object detection*. <https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>
- Sharma, Aditya. (2022). *Mean average precision (mAP)using the COCO evaluator*. <https://pyimagesearch.com/2022/05/02/mean-average-precision-map-using-the-coco-evaluator/>