



DIVISIÓN DE ESTUDIOS POSGRADO E INVESTIGACIÓN

Opción 1.- TESIS

TRABAJO PROFESIONAL

**SISTEMA EMBEBIDO PARA LA IDENTIFICACIÓN DE DEFECTOS
EN GRANOS DE CAFÉ VERDE, MEDIANTE PROCESAMIENTO DE
IMÁGENES Y ALGORITMOS DE INTELIGENCIA ARTIFICIAL**

QUE PARA OBTENER EL GRADO DE:

MAESTRO

EN INGENIERÍA ELECTRÓNICA

PRESENTA:


DORA ELISA MANRIQUE SANTOS

DIRECTOR DE TESIS:

DR. OSCAR OSVALDO SANDOVAL GONZÁLEZ

CODIRECTOR DE TESIS:

DRA. OFELIA LANDETA ESCAMILLA





EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Orizaba, Veracruz, 8/noviembre/2023
Dependencia: División de Estudios de
Posgrado e Investigación
Asunto: Autorización de Impresión
OPCION: I

C. DORA ELISA MANRIQUE SANTOS
Candidato(a) a Grado de Maestro(a) en:
INGENIERÍA ELECTRÓNICA
P R E S E N T E.-


De acuerdo con el Reglamento de Titulación vigente de los Centros e Institutos Tecnológicos Federales del Tecnológico Nacional de México, de la Secretaría de Educación Pública, y habiendo cumplido con todas las indicaciones que la Comisión Revisora le hizo respecto a su Trabajo Profesional titulado:

"SISTEMA EMBEBIDO PARA LA IDENTIFICACIÓN DE DEFECTOS EN GRANOS DE CAFÉ VERDE, MEDIANTE PROCESAMIENTO DE IMÁGENES Y ALGORITMOS DE INTELIGENCIA ARTIFICIAL".

Comunico a Usted que este Departamento concede su autorización para que proceda a la impresión del mismo.

ATENTAMENTE

Excelencia en Educación Tecnológica®
CIENCIA - TÉCNICA - CULTURA®



Cuauhtémoc Sánchez R.
Dr. CUAUHTÉMOC SÁNCHEZ RAMÍREZ
JEFE DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN

OG-13-F06



Av. Oriente 9 Núm.852, Colonia Emiliano Zapata. C.P. 94320 Orizaba, Veracruz.
Tel. 01 (272)1105360 e-mail: dir_orizaba@tecnm.mx tecnm.mx | orizaba.tecnm.mx



2023
Francisco
VILA



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Orizaba, Veracruz, 7/noviembre /2023
Asunto: Revisión de trabajo escrito

C. CUAUHTÉMOC SÁNCHEZ RAMÍREZ
JEFE DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN
P R E S E N T E.-

Los que suscriben, miembros del jurado, han realizado la revisión de la Tesis del (la) C.

DORA ELISA MANRIQUE SANTOS

La cual lleva el título de:

**"SISTEMA EMBEBIDO PARA LA IDENTIFICACIÓN DE DEFECTOS EN GRANOS DE CAFÉ
VERDE, MEDIANTE PROCESAMIENTO DE IMÁGENES Y ALGORITMOS DE INTELIGENCIA
ARTIFICIAL"**

Y concluyen que se acepta.

ATENTAMENTE

Excelencia en Educación Tecnológica®
CIENCIA – TÉCNICA - CULTURA®

PRESIDENTE: DR. OSCAR OSVALDO SANDOVAL
GONZÁLEZ

FIRMA

SECRETARIO: M.C. BLANCA ESTELA GONZÁLEZ
SÁNCHEZ

FIRMA

VOCAL: M.C. ENRIQUE ALEJANDRO CUELLAR
CORTÉS

FIRMA

VOCAL SUP.: DRA. OFELIA LANDETA ESCAMILLA

FIRMA

TA-09-18



Av. Oriente 9 Núm.852, Colonia Emiliano Zapata. C.P. 94320 Orizaba, Veracruz.
Tel. 01 (272)1105360 e-mail: dir_orizaba@tecnm.mx tecnm.mx | orizaba.tecnm.mx



2023
AÑO DE
Francisco
VILLA

CONTENIDO

AGRADECIMIENTOS	9
RESUMEN	10
ABSTRACT	11
INTRODUCCIÓN	12
PLANTEAMIENTO DEL PROBLEMA	13
JUSTIFICACIÓN	15
HIPÓTESIS	17
OBJETIVOS	18
OBJETIVOS ESPECÍFICOS	18
LÍMITES Y ALCANCES	19
ALCANCES	19
VINCULACIÓN	20
CAPÍTULO 1: MARCO TEÓRICO	21
1.1 ANATOMÍA DEL CAFÉ CEREZA	22
1.2 ETAPAS DEL PROCESAMIENTO DEL CAFÉ	23
1.3 CLASIFICACIÓN DE DEFECTOS SEGÚN LA SCA	25
1.4 CLASIFICACIÓN DE DEFECTOS SEGÚN LA NYBOT®	31
1.4.1 DAÑOS EN CAMPO	31
1.4.2 DAÑOS EN CAMPO O PROCESO	31
1.4.3 DAÑOS POR PROCESO	32
1.4.4 DAÑOS DE PROCESO Y ALMACENAMIENTO	32

1.4.5	DAÑOS DE ALMACENAMIENTO	33
1.5	SISTEMA EMBEBIDO	34
1.6	MICROPROCESADOR Y MICROCONTROLADOR	35
1.7	SISTEMA OPERATIVO Y LENGUAJE DE PROGRAMACIÓN.....	36
1.8	BASE DE DATOS.....	37
1.9	INTELIGENCIA ARTIFICIAL Y MACHINE LEARNING	37
1.10	REDES NEURONALES ARTIFICIALES (ANN)	37
1.11	VISIÓN ARTIFICIAL Y PROCESAMIENTO DE IMÁGENES.....	45
CAPÍTULO 2: ESTADO DEL ARTE Y ESTADO DEL CAMPO.....		47
2.1	ESTADO DEL ARTE	47
2.2	ESTADO DEL CAMPO	57
CAPÍTULO 3: METODOLOGÍA		60
3.1	ETAPA I. RECOPIACIÓN DE INFORMACIÓN	60
3.2	ETAPA II. TOMA DE DECISIONES.....	61
3.3	ETAPA III. PROTOTIPO Y EXPERIMENTACIÓN.....	62
3.4	ETAPA IV. ANÁLISIS DE RESULTADOS Y CONCLUSIÓN	67
CAPÍTULO 4: DISEÑO Y FABRICACIÓN DEL SISTEMA MECATRÓNICO		69
4.1	SECCIÓN DE RECEPCIÓN Y SURTIDOR DE LA MUESTRA	70
4.2	SECCIÓN DE RODILLOS Y PLATAFORMAS PARA CAPTURA DE IMÁ- GENES.....	73
4.3	SECCIÓN DE ENGRANES Y LEVAS	74
4.4	SECCIÓN ESTRUCTURAL Y CHAROLA DE RECOLECCIÓN	78

4.5	SECCIÓN DE LA CARCASA	80
4.6	SECCIÓN DE ADQUISICIÓN DE IMÁGENES	88
4.7	SECCIÓN DE CONTROL	89
CAPÍTULO 5: SISTEMA DE VISIÓN POR COMPUTADORA.....		92
5.1	EXPERIMENTACIÓN Y ANÁLISIS DE RESULTADOS	94
5.1.1	ALGORITMOS BASADOS EN INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE MANCHA DEL CAFÉ	94
5.1.2	MÉTRICAS DE EVALUACIÓN	97
5.2	ANÁLISIS DE RESULTADOS	99
5.2.1	INTERFAZ GRÁFICA DEL SISTEMA	108
CONCLUSIONES		113
RECOMENDACIONES		115
REFERENCIAS BIBLIOGRÁFICAS		116
ANEXOS		120

LISTA DE FIGURAS

Figura 1.	Diagrama de términos relevantes del proyecto.	21
Figura 2.	Estados productores de café en México.Fuente:(SIAP, 2023)	22
Figura 3.	Partes del café cereza.....	23
Figura 4.	Elementos de una neurona humana (izq.) y estructura de una neurona perceptrón (der.)	38
Figura 5.	Arquitectura de una CNN. Extraída de (Calvo, 2017).....	44
Figura 6.	Tabla comparativa de artículos con distintas clases de ANN en la detección e identificación de café cereza maduro.....	54
Figura 7.	Tabla comparativa de artículos con distintas clases de ANN en la clasificación de defectos de granos de café verde.	55
Figura 8.	Tabla comparativa. Artículo con enfoque distinto respecto a la extracción de características.....	56
Figura 9.	Tabla comparativa de artículos con distintos algoritmos de segmentación.....	56
Figura 10.	SORTEX ® Optical Sorting Machine.....	58
Figura 11.	PIKASEN FMS2000 ® de la empresa SATAKE.....	59
Figura 12.	TAIHO clasificador de color de granos de café.....	59
Figura 13.	Arquitectura de las redes VGG-16 y VGG-19.	63
Figura 14.	Arquitectura de la red ResNet-50.....	64
Figura 15.	Funcionamiento de la red de arquitectura YOLOv5x.	65
Figura 16.	Metodología del sistema implementado en el proyecto.	67
Figura 17.	Resumen de la metodología.....	68
Figura 18.	Vista frontal (sin cubiertas) de los elementos del sistema mecánico ensam- blado.	70
Figura 19.	Vista frontal (con cubiertas) de los elementos del sistema mecánico ensam- blado.	71
Figura 20.	Vista ortogonal posterior de los elementos del sistema mecánico ensambla- do.....	72
Figura 21.	Vista ortogonal, orientada desde el frente, con detalles del soporte del distribuidor con tolva semicircular (15).....	73
Figura 22.	Vista ortogonal de los componentes de la sección de rodillos y plataformas para captura de imágenes.	74

Figura 23. Tren de engranes compuesto por: un engrane de 10 dientes (23), un engrane de 40 dientes con buje acoplador (24), una leva con engrane de 10 dientes (25) con un eje roscado (X) y, finalmente, una rueda de Ginebra (26).....	75
Figura 24. Vista isométrica de las caras externas de la tapa izquierda de una caja de engranes (22a) con el tren de engranes y la tapa derecha de una caja de engranes (22b) con una leva simple (27), un segmento corto (28) y un segmento largo (29)	76
Figura 25. Vista isométrica de las caras internas de la tapa izquierda de una caja de engranes (22a) y la tapa derecha de una caja de engranes (22b), cada una con 7 orificios: los orificios (b), (c) y (f) para el paso de las varillas estructurales de aluminio (B), (C) y (16) respectivamente; y los orificios (a), (d), (e) y (g) destinados a los ejes (A), (D), (E) y (21) respectivamente.....	77
Figura 26. Vista isométrica orientada desde el frente y la izquierda indicando el chasis (32), el soporte de motor (33), el segundo motor (m2), la caja protectora de engranes (31) con su eje para engrane de 10 dientes (17) y el engrane de 10 dientes (23) que pertenece a la sección previa.....	78
Figura 27. Vista isométrica orientada desde el frente y la derecha donde se aprecian la charola de recolección (30), la caja protectora de engranes (31), el chasis (32), el soporte de motor (33) y el segundo motor (m2).	79
Figura 28. Vista isométrica de los elementos de las 4 primera secciones del prototipo físico.	80
Figura 29. Vista isométrica de los segmentos de aluminio del prototipo físico.....	81
Figura 30. Vista isométrica de los segmentos estructurales que conforman la base conformada por una pluralidad de segmentos de perfil angular de aluminio.	82
Figura 31. Vista isométrica de los elementos verticales, conformados por una pluralidad de segmentos de perfil angular de aluminio.....	83
Figura 32. Vista isométrica de los elementos del recuadro superior y el soporte de pantalla, conformados por una pluralidad de segmentos de perfil angular de aluminio.....	84
Figura 33. Prototipo físico integrado, sin las paredes de acrílico.....	85
Figura 34. Vista isométrica frontal y derecha de las caras de acrílico de la carcasa.....	86
Figura 35. Vista isométrica posteroinferior e izquierda de las caras de acrílico de la carcasa.....	87

Figura 36. Vista isométrica indicando la cara interna (Z) con sus espacios (z1), z(2) y (z3).....	88
Figura 37. Vista isométrica de los componentes pertenecientes a la sección de adquisición de imágenes: una cámara superior (55a), una cámara inferior (55b) y una pluralidad de luces led (56).....	89
Figura 38. Vista isométrica de los componentes de la sección de control, conformada por conforma por una fuente de alimentación (57), una unidad de control (58), un teclado (59), un mouse (60) y una pantalla (61) de 10.1”	90
Figura 39. Vista isométrica del prototipo completo final.	91
Figura 40. Metodología general del sistema de visión e implementación de AI para obtener el modelo clasificador.....	93
Figura 41. Tabla de imágenes capturadas de granos de café, según su clase, y su distribución para conformar las bases de datos de entrenamiento, validación y prueba. ...	95
Figura 42. Matriz de confusión N x N, para clasificador multiclase.....	97
Figura 43. Gráfica de curva de accuracy del entrenamiento de la red VGG-16 a 100 épocas.....	99
Figura 44. Gráfica de curva de accuracy del entrenamiento de la red VGG-19 a 100 épocas.....	100
Figura 45. Gráfica de curva de precisión de la red ResNet-50 a 100 épocas.	101
Figura 46. gráficas de Regresión Lineal para las redes VGG-16, VGG-19 y ResNet-50.....	102
Figura 47. Matriz de confusión obtenida con la red de arquitectura YOLOv5x.....	103
Figura 48. curva de precisión obtenidas con YOLO a 100 épocas.....	104
Figura 49. Resultados obtenidos en las pruebas de detección, identificación y clasificación de defectos en el café verde.	105
Figura 50. Resultados obtenidos en las pruebas de detección, identificación y clasificación de defectos en el café verde.	106
Figura 51. Resultados obtenidos en las pruebas de detección, identificación y clasificación de defectos en el café verde.	107
Figura 52. Programa Qt Designer con la ventana principal que conformará la interfaz y los objetos utilizados.	108
Figura 53. Fragmento del código generado para el control de la interfaz gráfica, donde se aprecian las librerías, variables globales y la inicialización de la ventana principal.	111

Figura 54.	GUI final basada en los datos requeridos por la empresa.	112
------------	---	-----

LISTA DE TABLAS

Tabla 1. Defectos primarios de los granos de café verde indicados por la SCA (Imágenes tomadas de la guía de defectos de la SCA).	28
Tabla 2. Defectos secundarios de los granos de café verde indicados por la SCA (Imágenes tomadas de la guía de defectos de la SCA).	30
Tabla 3. Clasificación de los defectos en granos de café verde según el contrato de café “C” de la bolsa NYBOT®, en muestras de 350 gramos. (Cantú & Mushinskie, 2020)	34
Tabla 4. Clases/Defectos de los granos de café verde a detectar (imágenes proporcionadas por CAFECOL, A.C.)	93
Tabla 5. Tabla de parámetros iniciales de las redes VGG-16, VGG-19, ResNet-50	96
Tabla 6. Tabla de parámetros finales y modificados de las redes VGG-16, VGG-19, ResNet-50	96
Tabla 7. Tabla de indicadores de desempeño en la clasificación	99
Tabla 8. Tabla con valores r2-score y MSE para el desempeño de las redes VGG-16, VGG-19 y ResNet-50	101

AGRADECIMIENTOS

En primer lugar quiero agradecer a Dios por brindarme la fuerza y tenacidad para concluir este proyecto.

A las dos instituciones que me permitieron llevar a cabo la realización de este trabajo de tesis; al CONAHCYT, por el apoyo económico otorgado durante éstos 2 años y al Instituto Tecnológico de Orizaba, por permitirme el ingreso a esta maestría y contribuir a mejorar mi formación profesional.

A mi asesor, por su confianza, apoyo, paciencia y todas sus enseñanzas que hicieron posible el concluir de manera satisfactoria este trabajo.

A mis padres, mis hermanas y mi cuñado, por estar conmigo en cada paso que doy y no permitir que nunca me rinda, por alentarme en todo momento e impulsarme siempre en mi crecimiento como ser humano, profesional y como mujer.

A mi abuelita, mis tías Marisol y Josefa, mis primas y primos maternos que siempre me brindan las mejores vibras y permanecen conmigo en los buenos y malos momentos.

A mi tía Guadalupe Manrique que me brinda su amor, comprensión y quien me apoyó durante las estancias relacionadas con este proyecto.

Y a la empresa CAFECOL, A.C., y su personal por su colaboración y orientación durante las estancias brindadas para hacer posible este proyecto.

RESUMEN

Considerando la importancia e influencia de la calidad en el café verde y apuntando a contribuir a mejorar la producción, ahorro de recursos así como disminuir costos, tiempos de producción y desperdicios de materia prima, se hace necesaria la implementación de tecnologías nuevas que permitan mejorar la calidad del café, como es el caso de las técnicas de Visión Artificial (AV, por sus siglas en inglés) para la adquisición, corrección y manejo de datos y el empleo de Inteligencia Artificial (AI, por sus siglas en inglés) como es el entrenamiento de Redes Neuronales Artificiales (ANN, por sus siglas en inglés) las cuales, para el proyecto, fueron del tipo convolucional (CNN, por sus siglas en inglés) llevando a cabo de modo automático y mediante aprendizaje de tipo profundo, la extracción e identificación de características propias de cada clase de defecto en los granos de café verde, mismas que facilitaron su correcta clasificación. Para conseguirlo se realizó una base de datos de 4000 imágenes redimensionadas a 320x320 píxeles, adquiridas con una cámara USB Arducam de 16 megapíxeles con autoenfoco, haciendo un aumento de imágenes mediante transformaciones de rotación y traslación para alcanzar una cantidad de 9600 imágenes. En dichas imágenes se identificaron y etiquetaron, en la plataforma roboflow®, 12 clases distintas que conformaron la base de datos con la cual se realizó el entrenamiento en una primera red neuronal de tipo CNN preentrenadas para clasificaciones de imágenes a gran escala tipo VGG-16, otra tipo VGG-19, otra de tipo residual ResNet-50 y una cuarta CNN empleando la arquitectura de red YOLOv5x de YOLOv5.

Como resultados, en la correcta identificación de cada una de las 12 clases, la exactitud o accuracy alcanzada con la red VGG-16 fue del 86.07 % y un f1-score del 87.51 %, con la red VGG-19 un 67.03 % y un f1-score del 73.03 %, con la red ResNet-50 un 87.76 % y un f1-score del 89.56 % y finalmente el mejor resultado se obtuvo mediante el empleo de la red de arquitectura YOLOv5x obteniéndose un 97.4 % de precisión y un f1-score del 93 %.

ABSTRACT

Considering the importance and influence of the quality of green coffee and aiming to contribute to improve production, saving resources as well as reducing costs, production times and wastage of raw material, it is necessary to implement new technologies to improve the quality of coffee, as is the case of Artificial Vision (AV) techniques for the acquisition, correction and management of data and the use of Artificial Intelligence (AI), such as the training of Artificial Neural Networks (ANN), which, for the project, were of the convolutional type (CNN), (AI), such as the training of Artificial Neural Networks (ANN) which, for the project, were of the convolutional type (CNN), carrying out automatically and through deep learning, the extraction and identification of characteristics of each class of defect in the green coffee beans, which facilitated their correct classification. To achieve this, a database of 4000 images resized to 320x320 pixels, acquired with a 16 megapixel USB Arducam camera with autofocus, was created, enlarging the images by means of rotation and translation transformations to reach a total of 9600 images. In these images, 12 different classes were identified and labeled in the roboflow© platform, which formed the database with which the training was performed in a first neural network of CNN type pre-trained for large-scale image classifications type VGG-16, another type VGG-19, another of residual type ResNet-50 and a fourth CNN using the YOLOv5x network architecture of YOLOv5.

As results, in the correct identification of each of the 12 classes, the accuracy achieved with the VGG-16 network was 86.07 % with f1-score 87.51 %, with the VGG-19 network 67.03 % with f1-score 73.03 %, with the ResNet-50 network 87.76 % with f1-score 89.56 % and finally the best result was obtained by using the YOLOv5x architecture network, obtaining 97.4 % accuracy and f1-score 93 %.

INTRODUCCIÓN

El café es un producto alimenticio de consumo básico y gran demanda a nivel mundial. Debido a su popularidad, su mercado es altamente competitivo, por lo tanto, es crucial que el proceso de producción del café sea óptimo para minimizar las pérdidas en el producto y por ende, pérdidas económicas para los caficultores.

La calidad del café tiene una gran influencia en la rentabilidad de los agricultores y en su capacidad para competir en mercados extranjeros; sin embargo, esta calidad se ve comprometida por diversos factores durante la etapa de beneficio del café, que comprende desde la siembra de la planta hasta la taza de café que disfrutamos, en el cual, por ejemplo, un proceso inadecuado de selección y clasificación incorrectas de los defectos del café verde son capaces de influir de manera negativa en el producto final.

Entonces, un beneficio del café eficiente y efectivo permitirá la obtención de un producto de excelente calidad, capaz de cumplir con los estándares impuestos por la Asociación de Café de Especialidad (SCA, por sus siglas en inglés) y la Asociación Mexicana de la Cadena de Producción del Café (AMECAFÉ).

Actualmente existen máquinas equipadas con tolvas que facilitan la descarga de granos de café verde y su separación según distintas características, ya sea el color, tamaño, forma o una combinación de estas. No obstante, estas máquinas presentan la desventaja de tener costos elevados, lo cual limita su adquisición a las pequeñas y medianas empresas cafetaleras. Debido a esto, en el presente documento se propone la implementación de técnicas de procesamiento de imágenes y CNN en un sistema embebido, portátil y de bajo costo, que permita la correcta identificación del café cereza maduro y café verde defectuoso, eliminando o disminuyendo al mínimo los errores generados en el proceso manual de selección realizado por expertos. Dicho prototipo, va dirigido al Centro Agroecológico del Café, A.C. (CAFECOL, A.C.), para ayudar a solventar la necesidad de brindar un mejor y más completo servicio a los productores que no tienen la posibilidad de adquirir maquinarias costosas.

PLANTEAMIENTO DEL PROBLEMA

La Real Academia Española define la “calidad” como la propiedad o conjunto de propiedades intrínsecas a algo, que permiten evaluar su valor. Esto implica que un producto o servicio debe ser adecuado a las características especificadas para ser considerado de buena calidad. De manera similar, el diccionario de Oxford define la calidad como el conjunto de propiedades inherentes a un objeto que permite diferenciarlo y valorarlo con respecto a otros de su misma especie. El tema tratado en este texto está estrechamente relacionado con la calidad y se detallará a continuación.

Es bien sabido que el precio del café se encuentra fuertemente ligado a la calidad del mismo, y en el país no todos los caficultores han adoptado las medidas necesarias para que dicha calidad sea la más óptima. Según el Centro de Estudios de las Finanzas Públicas (CEFP), en 1992 el café mexicano alcanzó su precio mínimo de 46.65 centavos de dólar por libra, mientras que en 1995 llegó a su precio máximo de 160.75 centavos de dólar por libra. Para el año 2000, el precio del café mexicano se situó en los 64.08 centavos de dólar por libra, una cantidad menor a la que se pagó por el café de Colombia y Brasil.

Con lo anterior en mente; las grandes empresas han echado mano de las nuevas tecnologías mediante la implementación de máquinas de clasificación automatizada, para aumentar su capacidad competitiva a través de la mejora de los controles de calidad, automatizando, disminuyendo costos de mano de obra y tiempos de trabajo respecto al sistema de inspección y clasificación aplicado en la actualidad. El objetivo perseguido es la obtención de los beneficios que dicha tecnología brinda y, ante todo, mejorar la calidad de sus productos.

Aunque en el mercado existen diversos prototipos de máquinas clasificadoras; algunos de sus inconvenientes son los costos elevados, no cubrir todos los tipos de defectos del café y, además, no adaptarse a las necesidades específicas de cada productor.

La falta de desarrollo de tecnologías accesibles, eficientes y que consideren las necesidades de los productores, limita la igualdad de oportunidades en el mercado. Para abordar este problema, se ha propuesto la creación de un sistema portátil que cumpla con estas características mediante el uso de técnicas de procesamiento de imágenes y algoritmos de AI integrados en un

microcontrolador. El Instituto Tecnológico de Orizaba llevará a cabo este proyecto destinado a CAFECOL, A.C., una organización sin fines de lucro que busca fomentar la industria cafetalera nacional mediante la asistencia a agricultores locales a través de consultoría, capacitación y pruebas de calidad del producto, entre otras actividades.

Al finalizar la investigación, el prototipo propuesto deber dar respuesta a las siguientes interrogantes:

¿Será benéfico y de utilidad la generación de un sistema embebido basado en el empleo de técnicas de procesamiento de imágenes y algoritmos de AI que permitan una correcta identificación de los granos de café verde según el defecto que posean?

¿Qué variables, aspectos o características deben ser analizados por el sistema para mejorar su efectividad en las tareas de identificación y clasificación del café?

¿Podrán las técnicas de procesamiento de imágenes y los algoritmos de AI, asociarse entre sí para crear sinergia, mejorar la efectividad del sistema y conformar una alternativa 100 % funcional en su tarea principal de clasificación?

Basándonos en los trabajos previos existentes relacionados al tema principal ¿Qué novedades y beneficios aportará el sistema propuesto a la sociedad y a la industria?

JUSTIFICACIÓN

En el presente escrito se presentará la documentación del proceso de diseño y construcción de un sistema automatizado de detección e identificación de defectos del café verde. Se describirán detalladamente los pasos seguidos para su conformación, así como las pruebas realizadas y la evaluación de los resultados obtenidos. Todo ello con el objetivo de demostrar la funcionalidad del prototipo y su utilidad como herramienta de ayuda en las tareas que la empresa CAFECOL, A.C. lleve a cabo.

En México, el café es una bebida muy popular, la empresa líder en manejo de datos, Kantar Group, reportó en junio de 2022 un estimado de consumo anual, por persona, de 1.750 kg de café. Aunque durante mucho tiempo el café soluble ha sido la opción preferida por la mayoría de hogares (84 %), en los últimos años se ha observado un aumento en la popularidad del café tostado y molido. Cada vez más personas están descubriendo el sabor y el aroma únicos que ofrece este tipo de café, lo que ha llevado a un aumento en su consumo en todo el país del 20.8 %.

En vista de que el café es un producto de gran demanda en el mercado nacional y mundial, es crucial destacar que su precio puede variar según sus características, es decir, su calidad. Esta última depende, en gran medida, de la correcta selección de cerezas maduras de café y la adecuada identificación y clasificación de granos de café verde en función de su deformidad o tipo de defecto (mancha del café).

Dado que, la calidad del producto es el eje fundamental en el que se basan las diversas organizaciones como SCA, el INMECAFÉ (Instituto Mexicano del Café) y la AMCCE (Asociación Mexicana de Cafés y Cafeterías de Especialidad), entre otras, para fomentar la aceptación del mercado a nivel internacional y aumentar los porcentajes de exportación del café mexicano; es importante enfocarse en las técnicas y tecnologías que aumenten dicha calidad del café. En México, por ejemplo, la Secretaría de Agricultura, Ganadería, desarrollo Rural, Pesca y Alimentación (SAGARPA) propuso implementar una serie de estrategias enfocadas en la mejora de la calidad del café, entre ellas, las más relacionadas al proyecto propuesto son:

1. “Impulsar sistemas de producción sostenible con buenas prácticas que maximicen la calidad del producto”.
2. “Impulsar los procesos de certificación en tecnologías sustentables, distintivos en calidad y/o especialidad”.
3. “Promover la innovación y transferencia de tecnología sustentable”.

Si bien, en otros países se han publicado trabajos con fines variados, en busca de mejorar la calidad final del café, todos van abordados desde diferentes enfoques y empleando un vasto catálogo de herramientas. Es por ello que el enfoque principal del proyecto presentado será reducir al mínimo posible, la inadecuada selección de defectos del café verde, productos del error humano durante la inspección visual en su proceso de selección y clasificación, para contribuir a la mejora del control de calidad del producto.

Lo anterior se conseguirá mediante la detección e identificación de la mancha del café verde y sus deformidades, mediante técnicas de procesamiento de imágenes y algoritmos de AI implementadas en un sistema embebido y portátil, que permita identificar y catalogar las muestras; en un ambiente controlado, de manera certera y confiable, las cuales son necesidades esenciales a cubrir para la empresa CAFECOL, A.C.

Los beneficios que se pretenden alcanzar con el desarrollo del sistema son:

- Obtener un prototipo funcional, de fácil manejo y costo reducido en comparación a los existentes en el mercado.
- Minimizar errores de clasificación que se traduzcan en la mejora de la calidad del producto y por ende en la posibilidad de un aumento justificado en el precio de venta del café.
- Reducción de mano de obra.
- Reducción en tiempos empleados en la selección y clasificación aplicados actualmente.
- Todo lo anterior conducirá a menores costos de producción.

HIPÓTESIS

La implementación, en un sistema embebido, de técnicas de procesamiento de imágenes y algoritmos de AI, permiten la detección e identificación de distintos tipos de defectos en el café verde, mismos que comprometen la calidad del producto final.

OBJETIVOS

Desarrollar e implementar un sistema embebido capaz de identificar los defectos del café verde, a través de la implementación de técnicas de procesamiento de imágenes y algoritmos de AI.

OBJETIVOS ESPECÍFICOS

1. Generar una base de datos a partir de imágenes de granos de café verde, para permitir su comparación e identificación por el sistema de reconocimiento.
2. Determinar las variables de interés, útiles para la medición y la obtención de una adecuada identificación de los diferentes defectos.
3. Diseñar y construir un sistema portátil para la detección e identificación de defectos (mancha del café) y deformidades en granos de café verde analizando su forma, color y textura mediante implementación de procesamiento de imágenes y algoritmos de AI.

LÍMITES Y ALCANCES

LÍMITES

Los límites del sistema se presentan a continuación:

- Es necesario generar una base de datos de gran tamaño para mejorar las tareas de identificación de defectos y deformidades por el sistema y así ampliar la capacidad de detección de un mayor número de tipos de defectos.
- Se requiere de un ambiente con iluminación controlada y resolución estandarizada por parte del sistema de adquisición de imágenes.

ALCANCES

El sistema generado a través de la extracción de características específicas, será capaz de:

- Detectar e identificar 11 defectos propios del café verde enumerados en la guía de defectos de la SCA.

VINCULACIÓN

El proyecto propuesto va dirigido a la solución de un problema actual identificado en la empresa CAFECOL, A.C., y está enfocado en contribuir a la mejora del servicio de control de calidad del café que brinda dicha empresa a los productores de café del país.

La propuesta será implementada en la etapa posterior al proceso de despulpado, en la identificación de defectos y deformidades del café verde, acorde a sus características y de acuerdo con lo indicado en la guía de clasificación de defectos de la SCA y la guía de defectos del café basada en la New York Board of Trade®(NYBOT®).

El Dr. Gerardo Hernández Martínez, director ejecutivo y representante legal de la empresa CAFECOL, A.C., funge como contacto e intermediario con dicha organización; e igualmente, como un experto en el proceso de selección de café, participando en la supervisión y asesoría para el desarrollo del proyecto y la realización de las pruebas.

CAPÍTULO 1: MARCO TEÓRICO

El café es un producto de gran demanda a nivel mundial; sus características determinan la calidad, que a su vez influirá en el costo de compra y venta. Para adentrarse en el tema y comprenderlo mejor, es necesario conocer algunos términos que se manejarán en el desarrollo del proyecto, éstos se muestran en el diagrama presentado en la Figura 1




Figura 1: Diagrama de términos relevantes del proyecto.

La Secretaría de Agricultura y Desarrollo Rural, así como el Servicio de Información Agroalimentaria y Pesquera (SIAP), reportaron el 14 de febrero del año 2023, que en 2022 Veracruz fue quien produjo la mayor cantidad de café cereza alcanzando aproximadamente 117,834 toneladas (34.6 % de la producción total), seguida de Chiapas, Puebla y Oaxaca con 108,607 toneladas (31.9 % de la producción total), 77,313 toneladas (22.7 % de la producción total) y 30,153 toneladas (8.8 % de la producción total) respectivamente; se lograron exportar 94,581 toneladas de café (7.3 % más que en 2021) En la Figura 2 se observa un mapa de México señalando los 14 estados productores de café. (SIAP, 2023)




Figura 2: Estados productores de café en México.Fuente:(SIAP, 2023)

1.1 ANATOMÍA DEL CAFÉ CEREZA

Es imperativo conocer las partes que componen una cereza de café, como bien se expone en (Salazar et al., 1994), éstas se visualizan en la Figura 3 y están enlistadas a continuación:

1. La primera capa se denomina pericarpio o piel exterior; una cereza madura posee piel de coloración, roja en la mayoría de las especies.
2. El mesocarpio o mucílago corresponde a la capa interna de la pulpa.
3. Una capa de pectina se encuentra ubicada más internamente en el fruto, continuando después del mucílago.
4. El endospermo o semilla corresponde a los 2 granos que posee la cereza del café y que cuenta con las 2 capas siguientes:
5. Una cascarilla llamada endocarpio, comúnmente referido como pergamino.

6. Una capa de “piel plateada” o tegumento que se desprende en el proceso de tueste, dicha capa es la encargada de proteger los granos de café.




Figura 3: Partes del café cereza.

1.2 ETAPAS DEL PROCESAMIENTO DEL CAFÉ

En cuanto a la calidad del café, en (Puerta, 2000) se sostiene que dicha calidad puede ser afectada o mejorada en función del control y la manipulación que se realice durante todo su proceso productivo. El proceso productivo del café, también conocido como beneficio del café, es fundamental para obtener granos de alta calidad y sabor excepcional. Está compuesto por varias etapas, cada una de las cuales es crucial para el resultado final. Aunque el número de etapas del beneficio del café pueden variar de autor en autor, de forma general, comprenden las descritas a continuación:

1. La selección de la tierra es el primer paso en la producción del café, dicha tierra debe ser adecuada para su cultivo; debe ser rica en nutrientes y tener un buen drenaje para permitir que las raíces del café crezcan adecuadamente.
2. La selección de la variedad de café es otro paso importante. Existen muchas variedades de café, cada una con características únicas en términos de sabor, aroma y resistencia a enfermedades. En este punto es fundamental seleccionar la variedad adecuada para la región en la que se va a cultivar.

3. Una vez seleccionada la tierra, se lleva a cabo la preparación del terreno para el cultivo del café. Esto incluye la limpieza, nivelación del suelo y la preparación de las camas de cultivo.
4. La siguiente etapa es la siembra, que comienza sembrando las semillas de café en viveros y donde permanecen durante unos meses hasta que se convierten en pequeñas plántulas.
5. Una vez teniendo las plántulas, la siguiente etapa es la plantación, al sol o a la sombra, en la cual el manejo del cultivo será vital para la calidad del grano.
6. Una vez maduros los frutos del café, sigue la etapa de recolección o de cosecha, es la primera etapa del proceso productivo del café y consiste en recolectar los granos maduros de café de los árboles. La recolección puede ser manual o mecánica (picking o stripping respectivamente) para asegurar que sólo se recolecten los granos maduros y no los verdes o sobremaduros, y se realiza durante la temporada de cosecha.
 - El picking es la selección y recolección manual únicamente de las cerezas de café maduras, obteniéndose una recolección de mejor calidad y más homogénea.
 - El Stripping es un proceso mecanizado en el que se recolectan todas las cerezas de café (verdes y maduras), para una posterior selección de frutos maduros.
7. Le sigue la etapa de despulpado, que consiste en eliminar tanto la cáscara como la pulpa de las cerezas de café, por medios mecánicos o fermentación, para posteriormente lavarse para eliminar los residuos propios de la fermentación y finalmente secarse por distintos métodos (natural, húmedo, semihúmedo). El proceso de secado puede llegar a durar desde unos pocos días hasta una semana, dependiendo de las condiciones climáticas y el nivel de humedad presente.
 - El método natural o seco es una técnica simple que consiste en extender uniformemente los granos de café en superficies o camas destinadas a su exposición al sol. Durante el proceso, se debe airear el café periódicamente y protegerlo por la noche para evitar la absorción de humedad. Una vez seco, el café se despulpa mecánicamente y se separa el pergamino de los granos de café verde. Este método

se utiliza para producir café con buen cuerpo, con notas de chocolate, frutales y con un toque terroso.

- El método húmedo consiste en eliminar la pulpa del café cereza con un despulpador y una corriente de agua. Luego, los granos de café verde se remojan en un tanque de agua durante 12 a 36 horas para que fermente y se separe el mucílago. Después, los granos de café se secan bajo techo durante 4 a 10 días. El resultado de este método es el llamado "café lavado", que tiene un cuerpo menor y notas afrutadas y florales.
- El método semihúmedo, también conocido como método Honey o descascado, combina el remojo en agua de los granos de café verde utilizado en el método húmedo, con la exposición al sol de los granos de café con pulpa del método seco, hasta lograr una humedad del 12 %. Como resultado, se obtiene una mezcla de tonos provenientes de los dos métodos anteriores.

8. Como siguiente paso, los granos de café son tostados en hornos especiales, lo que les otorga su característico color marrón y aroma. El proceso de tostado también influye en el sabor, y existen distintos niveles de tostado que generan sabores diversos.
9. Posteriormente se tiene la etapa de molienda; donde, tras tostar los granos, se muelen para preparar la bebida que conocemos como café. Este proceso se lleva a cabo típicamente en un molino y se ajusta el grado de molienda en función del tipo de café que se esté preparando.
10. La etapa final es el empaquetado, donde el café previamente molido es empacado en bolsas, frascos o latas para su distribución y venta. La etiqueta del paquete debe proporcionar información sobre el tipo de café, su origen y la fecha en que se tostó.

1.3 CLASIFICACIÓN DE DEFECTOS SEGÚN LA SCA

Continuando con el tema de calidad en los granos de café verde, es necesario realizar una clasificación de los mismos según las características que posean. Para tal fin, existe una guía desarrollada por la SCA, en la cual se enumeran y describen los posibles defectos primarios

y secundarios. Estos defectos se resumen en la Tabla 1 y la Tabla 2 respectivamente.(SCA, 2019)

DEFECTOS PRIMARIOS	CAUSA	CALIFICACIÓN
Grano negro. 	Agrícola. Ennegrecimiento debido a la sobrefermentación de un pigmento, causado por microorganismos.	1 grano mayor o igual a medio grano negro = 1 defecto.
Avinagrado/Agrio. 	Agrícolas y de procesado. Provocado por fermentación por contaminación microbiana durante la cosecha y el procesado. Causa de contaminación por: Recogida de cerezas excesivamente maduras y/o cerezas caídas, contaminación del agua en el procesado o la sobrefermentación en el fruto aún unido al árbol en condiciones de humedad.	1 grano mayor o igual a medio grano agrio = 1 defecto.
Dañado por hongo o cardenillo. 	Agrícolas y de procesado. Generalmente por hongos del género <i>Aspergillus</i>, <i>Penicillium</i> y <i>Fusarium</i>, en cualquier etapa entre la recolecta hasta el almacenaje propiciado por la presencia de humedad.	1 grano dañado por hongos = 1 defecto.

Continúa en la página siguiente.

DEFECTOS PRIMARIOS	CAUSA	CALIFICACIÓN
Brocado severo (Dañado gravemente por insectos). 	Agrícola. La broca (<i>Hypothenemus hampei</i>) se presenta en la cereza cuando aún se encuentra en el árbol. A mayor altitud, menor probabilidad de incidencia de broca.	Daño grave por insectos, mayor o igual a 3 perforaciones. 5 granos dañados por insectos = 1 defecto.
Cereza seca (cascarilla). 	Procesamiento: ■ Producida durante el método de procesado húmedo, por despulpado deficiente y presencia de frutos secos en el tanque de recepción o un error de ajuste en la maquinaria. ■ Durante el método de procesado natural, resultan de un mal descascarillado y clasificación errónea.	1 cereza seca = 1 defecto.
Materia extraña. 	Variadas: La materia extraña se puede ir acumulando en las diversas etapas del proceso.	1 materia extraña = 1 defecto.

Continúa en la página siguiente.

DEFECTOS PRIMARIOS	CAUSA	CALIFICACIÓN
Granos partidos, mordidos o cortados (molienda seca o húmeda). 	Se producen por una mala calibración del equipo (fricción o presión en exceso) en la etapa de despulpado o en molienda seca.	5 granos partidos = 1 defecto.

Tabla 1: Defectos primarios de los granos de café verde indicados por la SCA (Imágenes tomadas de la guía de defectos de la SCA).

DEFECTOS SECUNDARIOS	CAUSA	CALIFICACIÓN
Grano negro parcial. 	Mismas que el grano negro.	3 granos, cada uno menor a medio grano negro = 1 defecto.
Avinagrado parcial. 	Mismas que el grano avinagrado	3 granos, cada uno menor a medio grano agrio = 1 defecto.

Continúa en la página siguiente.

DEFECTOS SECUNDARIOS	CAUSA	CALIFICACIÓN
Brocado parcial (Daño leve por insectos). 	Mismas que el brocado severo.	Daño ligero por insectos, menor o igual a 2 perforaciones, 10 granos dañados por insectos = 1 defecto.
Grano inmaduro, verde o Quaker (al tostar). 	Agrícola. Por un desarrollo incompleto causado por recolección de cerezas verdes o maduración no uniforme en algunas variedades que crecen a grandes altitudes donde sus frutos presentan una maduración tardía.	5 granos inmaduros = 1 defecto.
Averanado/Arrugado. 	Agrícola. Debido a las sequías en la etapa de desarrollo del grano, la magnitud del defecto depende directamente de la duración e intensidad de la sequía, así como de la salud del cafeto.	5 granos averanados = 1 defecto.
Concha. 	Agrícola. Fenómeno natural, de origen genético, que produce la malformación en el grano.	5 conchas = 1 defecto.

Continúa en la página siguiente.

DEFECTOS SECUNDARIOS	CAUSA	CALIFICACIÓN
Flotador. 	Procesamiento. Se generan debido a la deficiencia del secado y/o mal almacenamiento en condiciones de humedad elevada.	5 granos flotadores = 1 defecto.
Pergamino. 	Procesamiento. Se produce en la molienda seca, por error en la calibración de la máquina descascarilladora.	5 granos pergamino = 1 defecto.
Cascarilla o pulpa seca. 	Procesamiento. En 2 casos: ■ Por una limpieza incorrecta en el café de procesado seco. ■ Por error de calibración en la máquina despulpadora.	5 cascarillas = 1 defecto.

Tabla 2: Defectos secundarios de los granos de café verde indicados por la SCA (Imágenes tomadas de la guía de defectos de la SCA).

De acuerdo con la guía de defectos de la SCA, un café es considerado de especialidad si posee cero defectos primarios y hasta 5 defectos secundarios como máximo, en la prueba de calidad realizada en muestras homogeneizadas de 350 gramos (SCA, 2019).

1.4 CLASIFICACIÓN DE DEFECTOS SEGÚN LA NYBOT®

Otra forma de clasificar los defectos del café verde, de acuerdo a la etapa del proceso donde se generan, según la NYBOT®, se encuentran documentados en (Cantú & Mushinskie, 2020) y están indicadas a continuación:

1.4.1 DAÑOS EN CAMPO

Broca: Orificios y túneles de 0.3 a 1.5 mm de diámetro provocados por el insecto *Hypothenemus hampei*. El borde de dichos orificios se tiñe de negro, generando un grano negro o negro parcial acorde a la severidad del daño.

Elefante (Concha y oreja o cuerpo): Granos grandes de forma esférica, donde la parte externa se denomina concha y la interna cuerpo u oreja. Usualmente suelen separarse durante el morteo de la muestra. Sus partes por separados tendrán un tostado irregular, comparado al de granos normales.

Triangular: Provocado por un desarrollo genético anormal en el que se forman de 3 a 4 granos en una cereza, pueden llegar a asemejarse al caracolillo e incluso exageradamente deformes. Aportan un sabor similar al de los granos Quaker.

Caracolillo o peaberry: Es una malformación genética en la cual se forma 1 sólo grano, ovalado o redondo, en la cereza. El tostado es irregular comparado a los granos normales, pero no repercute de manera negativa en la taza.

Helado: Los granos se tornan marrones, negros o grisáceos interna y externamente. El tegumento está adherido al grano, aportando brillo cuando el daño es severo y manchándolo cuando el daño es ligero. Pérdida de sabor, aroma, acidez y cuerpo, pudiendo llegar a aportar sabores sucios y amargos. Su tueste es irregular ante granos normales.

1.4.2 DAÑOS EN CAMPO O PROCESO

Negro: Provocado por la cosecha de cerezas no maduras o caídas (sobremaduras). Se considera como un grano negro si es completamente negro o más del 50 % de la superficie externa e

interna del grano es de color negro mate. Implica la pérdida de sabor, aroma y acidez, aportando sabores desagradables como fermentado o mohoso. Tostado irregular ante granos normales.

Negro parcial: menos del 50 % del grano es color negro. Causado por recolectar cerezas inmaduras, dañadas o sobremaduras (caídas), un secado pobre, rehumedecimiento, sobrefermentado, exposición a temperaturas elevadas y poca higiene en el beneficio húmedo son algunas de las causas que lo propician.

1.4.3 DAÑOS POR PROCESO

Mordido (por despulpador): se da en el beneficio húmedo en la etapa de despulpado, generando manchas de coloración oscura provocadas por bacterias. Puede llegar a aportar sabor fermentado. Tostado irregular entre granos normales.

Aplastado o quebrado: el defecto se genera en el proceso de despulpado, secado o morteo. Puede generar pérdida de sabor, aroma o acidez y un tostado irregular.

Quebrado o cortado: Granos cortados, productos de un deficiente proceso de morteo durante el beneficio seco. De tueste irregular, con probabilidades altas de quemarse o carbonizarse durante el proceso.

Granza o fragmento de grano: son fragmentos de granos cortados, resultantes del proceso de morteo o despulpado. De tueste irregular, pudiendo llegar a quemarse o carbonizarse.

Cereza seca (“Guayaba”): Fruto seco cuya piel está fuertemente adherida a los granos que aún conserva en su interior y puede o no ser retirada durante el morteo. Capaz de generar granos negros proporcionando un sabor acre y amargo similar a tierra o moho. Tostado irregular llegando incluso a carbonizarse.

1.4.4 DAÑOS DE PROCESO Y ALMACENAMIENTO

Veteado: Grano de coloración desigual que varía en zonas verdosas, blancas y amarillentas; es provocado por un secado deficiente, rehumedecimiento o mal almacenaje. Proporciona un sabor a hierbas, con posible pérdida de aroma, sabor y acidez. Tostado irregular entre granos

normales.

Agrio: Se produce como resultado de la sobrefermentación, tanques de fermentación contaminados, agua contaminada, almacenamiento en condiciones de humedad elevada, y falta de higiene durante el beneficio húmedo. El grano adquiere una coloración marrón claro a rojizo, brindando un sabor agrio y fermentado de gran intensidad.

1.4.5 DAÑOS DE ALMACENAMIENTO

Dañado por insectos (picados): Granos perforados por insectos como el gorgojo. Aportan amargura y sabor desagradable. El tostado se torna irregular ante granos normales.

Otros defectos (materia extraña): la presencia de cascarilla de pergamino, cáscara de la cereza, palos y piedras, resultantes de una limpieza pobre o un beneficio seco mal implementado.

La Tabla 3 muestra un resumen de las calificaciones que otorga cada defecto.

DEFECTO	CALIFICACIÓN
Broca	Se considera como negro parcial o completo, dependiendo de la severidad del daño. 2 a 5 granos negro parcial = 1 defecto. 1 negro completo = 1 defecto. 1 daño por broca aislado NO es un defecto.
Elefante (Concha y Oreja o cuerpo)	Las orejas o cuerpos se consideran como un grano quebrado o cortado. 5 orejas = 1 defecto. 5 conchas = 1 defecto.
Triangular	No se considera un defecto.
Caracolillo (Peaberry)	No se considera un defecto.
Helado	1 grano helado = 1 grano negro = 1 defecto.
Negro	1 grano negro = 1 defecto.

Continúa en la página siguiente.

DEFECTO	CALIFICACIÓN
Negro parcial	2 a 5 granos negros parciales = 1 defecto.
Mordido (por despulpador)	1 grano mordido = 1 grano quebrado = 1 grano negro parcial. 2 a 5 granos mordidos = 1 defecto.
Aplastado o quebrado	1 grano quebrado = 1 grano cortado. 5 granos quebrados = 1 defecto.
Quebrado o cortado	5 granos quebrados o cortados = 1 defecto.
Granza o fragmentos	1 fragmento = 1 grano quebrado o cortado. 5 fragmentos = 1 defecto.
Cereza seca	1 cereza seca = 1 defecto.
Veteado	No se considera un defecto a menos que se transforme en un flotador. 5 flotadores = 1 defecto.
Agrio	1 grano agrio = 1 defecto.
Daño por insectos	1 grano dañado por insectos = 1 grano quebrado = 1 negro parcial. 2 a 5 granos dañados por insectos = 1 defecto.
Otros defectos (materia extraña)	Cascarilla equivalente a 2 pergaminos o 2 cerezas secas = 1 defecto. 3 palos o piedras = 1 defecto. 1 palo o piedra de gran tamaño = 1 defecto.

Tabla 3: Clasificación de los defectos en granos de café verde según el contrato de café “C” de la bolsa NYBOT®, en muestras de 350 gramos. (Cantú & Mushinskie, 2020)

1.5 SISTEMA EMBEBIDO

Un sistema embebido puede definirse como aquel dispositivo electrónico con capacidad computacional, compuesto por elementos de software y hardware. Dicho sistema es capaz de realizar tareas definidas en su etapa de diseño, mediante la predicción de las mismas. En

resumen, estos sistemas están compuestos por hardware y software como: microprocesadores, microcontroladores, lenguajes de programación con sus respectivos compiladores y un sistema operativo; todo esto implementado en placas de desarrollo como Arduino o computadoras de placa simple (SBC, por sus siglas en inglés) como Raspberry Pi con sus respectivas interfaces gráficas de usuario (GUI, por sus siglas en inglés) de ser necesario.

1.6 MICROPROCESADOR Y MICROCONTROLADOR

Un microprocesador es la unidad central de procesamiento de la computadora, representa su cerebro, siendo una parte integral del hardware y recibiendo el nombre de Unidad Central de Procesamiento (CPU, por sus siglas en inglés). Sus funciones principales son la comunicación, sincronización, control y supervisión de todos los elementos del sistema. Entre los componentes que lo conforman destaca la Unidad Aritmética y Lógica (ALU, por sus siglas en inglés), que se encarga de llevar a cabo operaciones matemáticas y almacenar datos de modo temporal para la toma de decisiones lógicas.

Por otra parte, los microcontroladores mini computadoras que el usuario debe programarlos en lenguaje de montaje o ensamblador. Estos dispositivos electrónicos son de pequeñas dimensiones y bajo costo. Poseen códigos que le permiten llevar a cabo diversas tareas de control mediante sus puertos de entrada y salida, puertos que se pueden conectar a distintos periféricos (sensores y actuadores). Actualmente existen en el mercado una gran cantidad de microcontroladores, al final, la elección del microcontrolador dependerá de la complejidad y necesidades de cada proyecto. (Aguayo et al., 2004)

Un ejemplo de microcontrolador, es la SBC Raspberry Pi 4, seleccionada para este proyecto y de acuerdo con (Raspberry.org, 2021), es un mini ordenador de bajo costo con sistema operativo de código abierto Raspberry Pi Os (Raspbian). Su versión más reciente permite conectarse a 2 monitores. Cuenta con un procesador Broadcom®, puertos USB 2.0 y 3.0, memoria RAM de 1, 2, 4 y hasta 8Gb, GPU, Ethernet, puerto HDMI, 40 pines GPIO, salidas de audio y video, un conector para cámara y entrada para microSD. Es compatible con los sistemas operativos Windows®, Fedora, Linux, Android, entre otros. En cuanto a algunos de los lenguajes de programación que pueden emplearse, se encuentran Python, JavaScript, Java

Scratch, etc. (Funk, 2019)

1.7 SISTEMA OPERATIVO Y LENGUAJE DE PROGRAMACIÓN

El sistema operativo constituye un grupo de aplicaciones del sistema computacional que administran los componentes físicos y brinda utilidades a los programas de software utilizados. Estas aplicaciones se ejecutan con privilegios superiores a las demás. El sistema seleccionado para el proyecto es Ubuntu MATE, ya que es de código abierto y que posee la funcionalidad MATE Desktop, la cual es una interfaz gráfica de usuario a modo de “escritorio” ejecutado en su sistema operativo capaz de aplicarse en el microcontrolador Raspberry Pi del modelo 2 en adelante.(Ubuntu-mate.org, 2022)

De forma general, el lenguaje de programación es el conjunto de directrices lingüísticas (tanto sintácticas como semánticas) que orientan al computador para que adopte una determinada conducta. El código generado se realizará en lenguaje de programación Python, pues es de código abierto, sencillo y fácil de comprender, tiene su propio Entorno de Desarrollo Integrado (IDE, por sus siglas en inglés) y es compatible con muchos otros IDE (Python.org, 2001). Además, cuenta con distintas herramientas o librerías, las cuales de acuerdo con (Immune, 2022), se definen como el conjunto de implementaciones que hacen posible la generación de código, para la creación de interfaces independientes, están compuestas de módulos diversos con fines específicos y variables según el sistema operativo que se emplee. Para una mejor funcionalidad, cuando se instala Python, viene acompañado de un grupo de librerías básicas estándar. Algunas de las librerías que serán de gran utilidad en el procesamiento de imágenes y entrenamiento de redes neuronales son TensorFlow, empleada en procesos que requieren de un certero cálculo numérico, principalmente se emplea en proyectos relacionados con el aprendizaje profundo, además de que permite la generación de ANN con enfoque matemático alternativo; Keras es otra librería especializada en aprendizaje profundo, para la creación rápida de redes neuronales eficaces, de una manera simple, gracias a su sencillez que la hace fácil de manejar y finalmente la librería OpenCV especializada en visión por computadora, es la librería más robusta y más usada actualmente para ello. (Marín, 2020)

1.8 BASE DE DATOS

Una base de datos es definida por (Rodríguez & Ferraris, 2010) como el conjunto o colección de datos (información) recopilados, interrelacionados y organizados de forma sistemática, que se encuentran almacenados en una unidad o disco.

1.9 INTELIGENCIA ARTIFICIAL Y MACHINE LEARNING

De acuerdo con (Dopico et al., 2016), el término Inteligencia Artificial engloba el ámbito científico y técnico que abarca la comprensión, desde el punto de vista informático, del comportamiento inteligente y se ocupa de la creación de artefactos que exhiben dicho comportamiento.

En el año 1959, surgió el concepto de "Machine Learning", que revolucionaría el campo de la Inteligencia Artificial, pues se trata de una disciplina que otorga a las máquinas la habilidad de aprender por sí mismas (aprendizaje autónomo), a través de complejos patrones de información para llevar a cabo diversas predicciones. Los tipos de aprendizaje que pueden generarse a través del empleo del Machine Learning son:

- Aprendizaje supervisado. Algoritmos basados de aprendizaje previo, que emplea etiquetas asociadas a información específica para permitir la toma de decisiones y/o predecir el comportamiento de un sistema.
- Aprendizaje no supervisado. Carece de aprendizaje previo, pero con los datos existentes busca extraer patrones o características que le permitan organizarlos y diferenciarlos.
- Aprendizaje por refuerzo. Donde el algoritmo deberá adquirir aprendizaje basado en su experiencia (prueba y error). (Pino-Díez. et al., 2001)

1.10 REDES NEURONALES ARTIFICIALES (ANN)

En (Neapolitan & Jiang, 2018), se menciona que una ANN está formado por un conjunto de neuronas artificiales, que tratan de imitar a las neuronas humanas y al Igual que estas últimas, cada neurona artificial se relaciona e interactúa con muchas otras, y mediante sus enlaces

sinápticos son capaces de activarse o inhibirse entre sí. La estructura básica de una ANN posee una serie de capas de neuronas que se relacionan entre sí de forma secuencial:

- Capas de entrada.
- Capas ocultas.
- Capas de salida.

La red neuronal más simple es la denominada perceptrón, que imita el funcionamiento de una sola neurona humana, como es mostrado en la Figura 4.




Figura 4: Elementos de una neurona humana (izq.) y estructura de una neurona perceptrón (der.)

Al respecto de las ANN, en (Matich, 2001) explica que existen diversos tipos como las monocapa o perceptrón simple, perceptrón multicapa (MLP, por sus siglas en inglés), CNN, recurrentes (Recurrent Neural Networks), de realimentación o base radial (Radial Basis Function - RBF), entre otras, lo cual permite diversas opciones para el desarrollo de distintas aplicaciones o proyectos. Igualmente (Matich, 2001) menciona que, una ANN es capaz de adquirir conocimiento a través de dos tipos de aprendizaje: supervisado y no supervisado.

- Aprendizaje supervisado. Es controlado y dirigido, en él, la ANN es capaz de aprender por que el supervisor va modificando los pesos de las conexiones para alcanzar la salida deseada.
- Aprendizaje por corrección del error. En éste, se ingresan en la ANN las respuestas o salidas que se tratan de obtener junto con el vector de entrada y asignando un determinado número de iteraciones entre la salida obtenida y las deseadas, se obtiene un valor de error que permite ir recalculando los pesos de la red, generando una nueva salida hasta alcanzar el objetivo deseado.

- Aprendizaje por refuerzo. Es más lento que la de corrección del error. El aprendizaje por refuerzo se da a través de la inhibición o excitación de la ANN por el supervisor, ajustando los pesos por medios probabilísticos para alcanzar la salida deseada.
- Aprendizaje estocástico. A partir de la salida deseada y probabilidad, se ingresan en la ANN pesos de forma aleatoria y se analizan los resultados en cada caso. Su principal rasgo es la asignación probabilística y el “simulated annealing”, que es un proceso donde el uso del ruido permite bloquear errores locales para hallar el error global.
- Aprendizaje No supervisado. Este tipo de aprendizaje carece de influencia externa o supervisor y se centra en la búsqueda de los patrones característicos de los datos. Este tipo de aprendizaje permite que la ANN sea capaz de adaptarse por si misma a través del aprendizaje que ha obtenido de los datos. Su salida variará según la estructura de la red y la función de activación empleada.
- Aprendizaje Hebbiano. La ANN intenta reconocer y extraer características de los datos ingresados a la red y/o su familiaridad, donde una neurona A excita a una neurona B para aumentar la eficiencia de trabajo de ésta última. El ajuste de pesos se calcula por la correlación entre los valores de salida de las dos neuronas.
- Aprendizaje cooperativo o competitivo. En éste, los datos de la entrada se clasifican, para que el número de neuronas que se activen siempre sea menor al de entrada, como las neuronas están compitiendo por ser activadas, no son forzadas a sus valores mínimos de respuesta.

Los algoritmos de aprendizaje son empleados por las redes neuronales para adquirir conocimiento y partiendo de los datos aleatorios y secuenciales que le han sido proporcionados, modifican los pesos de las conexiones y varían el umbral de cada neurona (igualmente a modo de pesos sinápticos). Algunos algoritmos de aprendizaje que existen son:

- Algoritmos de regresión. Son métodos matemáticos y estadísticos utilizados para predecir la relación entre variables. Permiten estimar valores numéricos o continuos, como la predicción de precios, tendencias económicas o ventas según temporada, etc. Los

algoritmos de regresión utilizan un conjunto de datos de entrenamiento para aprender los patrones y las relaciones existentes entre las variables, y luego utilizan esta información para realizar predicciones sobre nuevos conjuntos de datos. A través de la regresión, se intenta hallar una función matemática que describa la relación entre las variables de manera óptima, minimizando el error de predicción. este algoritmo se emplea para la toma de decisiones y comprensión de fenómenos complejos.

- Lineales.
 - No lineales.
- Algoritmos basados en instancia. Son métodos de aprendizaje automático que utilizan ejemplos individuales del conjunto de datos de entrenamiento, denominados instancias, para tomar decisiones o realizar predicciones. En lugar de buscar patrones generales en los datos, estos algoritmos se centran en la similitud entre las instancias de entrenamiento y los nuevos casos a los que se aplican. Utilizando medidas de similitud, como la distancia euclidiana, los algoritmos basados en instancia comparan las características de los casos de entrenamiento y seleccionan el resultado más similar para predecir la etiqueta o clasificación del nuevo caso. En resumen, los algoritmos basados en instancia aprovechan la información de instancias individuales para realizar predicciones o tomar decisiones basadas en similitudes.
- k-Nearest Neighbor (kNN).
 - Self-Organizing Map.
- Algoritmos de árbol de decisión. Son un método de aprendizaje automático que utiliza un enfoque basado en reglas para tomar decisiones o clasificar datos. Se construyen a partir de una estructura jerárquica en forma de árbol, donde cada nodo representa una característica y cada rama representa una posible decisión o resultado. Estos algoritmos evalúan secuencialmente las características de los datos y toman decisiones basadas en las reglas establecidas en cada nodo, hasta llegar a una hoja del árbol que proporciona la clasificación final o la decisión tomada. Los árboles de decisión son ampliamente utilizados debido a su capacidad para manejar datos de forma interpretativa y eficiente.

- Random Forest.
 - Árboles de Clasificación y Regresión (CART).
 - Árbol de decisión condicional
- Algoritmos Bayesianos. Son un conjunto de técnicas computacionales utilizadas para el análisis estadístico y la toma de decisiones basadas en la teoría de la probabilidad bayesiana. Estos algoritmos se basan en el teorema de Bayes, que establece cómo actualizar nuestras creencias o conocimientos previos a través de la evidencia observada. Utilizando modelos probabilísticos, los algoritmos bayesianos son capaces de realizar inferencias y estimaciones de manera flexible y robusta, permitiendo la incorporación de información previa y la actualización continua de las creencias a medida que se disponen de nuevos datos. Esto los convierte en herramientas poderosas para la toma de decisiones en diferentes áreas, como la inteligencia artificial, el aprendizaje automático y la ciencia de datos.
- Naive Bayes.
 - Gaussian Naive Bayes.
 - Multinomial Naive Bayes.
 - Bayesian Network.
- Algoritmos de agrupación o Clustering. Son métodos de análisis de datos utilizados en el campo de la minería de datos y el aprendizaje automático. Estos algoritmos se emplean para dividir un conjunto de datos en grupos o clusters, donde los objetos dentro de cada grupo comparten características o propiedades similares entre sí, mientras que los objetos en diferentes grupos son diferentes o no se asemejan tanto. El objetivo principal de los algoritmos de agrupación es descubrir patrones o estructuras ocultas en los datos sin la necesidad de etiquetas o categorías predefinidas. Los algoritmos de agrupación son ampliamente utilizados en diversas aplicaciones, como segmentación de clientes, análisis de imágenes, reconocimiento de patrones y muchos otros campos relacionados.
- K-Means.

- K-Medians.
 - Hierarchical Clustering.
- Algoritmos de redes neuronales. Son métodos de procesamiento de información inspirados en el funcionamiento del cerebro humano, para realizar tareas de aprendizaje y toma de decisiones. Estos algoritmos son capaces de aprender y adaptarse a partir de datos, ajustando los pesos de las conexiones entre las neuronas para mejorar su desempeño en la resolución de problemas específicos. Su aplicabilidad abarca diversas áreas, como reconocimiento de patrones, procesamiento de imágenes, procesamiento del lenguaje natural y en proyectos con AI.
- Compuerta XOR.
 - Perceptron.
 - Back-Propagation.
 - Hopfield Network.
 - MLP: Multi Layered Perceptron.
- Algoritmos de Aprendizaje profundo (Deep Learning). Son un conjunto de técnicas utilizadas en AI que permiten a las máquinas aprender y realizar tareas complejas a partir de datos. Estos algoritmos se basan en modelos de ANN con múltiples capas, que les permiten extraer características y patrones de los datos de entrada de forma automática y de mayor profundidad que los enfoques tradicionales. Se aplica con gran eficacia en áreas como el reconocimiento de imágenes, el procesamiento del lenguaje natural y la toma de decisiones en entornos complejos. (Bishop, 2006)
- CNN.
 - Long Short Term Memory Neural Networks.
- Algoritmos de reducción de dimensión. Son un conjunto de técnicas utilizadas en AI que mediante aprendizaje no supervisado permiten simplificar, reducir y comprimir datos (variables) para tener información más fácil de tratar mediante el posterior empleo de aprendizaje supervisado.

- Principal Component Analysis (PCA).
- t-SNE.
- Otros algoritmos
 - Algoritmos de Aprendizaje por Reglas de Asociación.
 - Algoritmos de Conjuntos.
 - Computer Vision.
 - Sistemas de Recomendación.
- Por corrección del error. Mediante la modificación de los pesos sinápticos a través de la identificación de un determinado patrón, se corrige el error de salida.
- Por gradiente. Modificando los pesos en dirección opuesta del gradiente de la función del error. Se modifican los pesos a partir de un patrón dado, que elimine el error cuadrático medio de todos los patrones que se tengan.

Las ANN estáticas se aplican para aquellos problemas con falta de precisión en la solución computacional o que necesitan algoritmos muy extensos como en el caso del reconocimiento de imágenes, los tipos de red adecuadas para ello son: perceptrón y multicapa (empleando la propagación inversa y el algoritmo de Chemotaxis).

Las ANN dinámicas son empleadas en la síntesis de datos variables en el tiempo, es decir, requieren de información histórica de sus variables. A este grupo pertenece la red recurrente de Hopfield (Dynamic Neural Network-Hopfield - DNN-H) que es un tipo de red autoasociativa, similar al tipo perceptrón, pero con la diferencia que las neuronas de la capa media poseen una conexión con otras neuronas de la capa media; cada neurona de entrada se comunica a una única neurona media y cada neurona media se comunica con una sola neurona de la capa de salida. En este tipo de red no se calculan pesos sinápticos ni valores umbral.

Las CNN, según la descripción de (Calvo, 2017), forman parte del campo del aprendizaje profundo y son utilizadas ampliamente en el procesamiento de imágenes, siendo una de las

mejores arquitecturas de ANN en la identificación de patrones, detección de bordes, enfocar, etc. En la Figura 5 se muestra la estructura de la CNN, que esta compuesta por:

- una capa inicial de entrada,
- seguida por capas de neuronas con función de convolución, que suma los productos de las matrices iniciales de la imagen (pixel a pixel) por la matriz Kernel (filtro),
- alternadas con capas de neuronas con función de reducción (pooling) para lograr una mayor reducción de los parámetros y extraer las características comunes.
- Finalmente convergen en una enorme capa clasificadora, donde cada patrón o clase que se detecta se encuentra ligada a su propia neurona.




Figura 5: Arquitectura de una CNN. Extraída de (Calvo, 2017).

Retomando el tema del entrenamiento de las ANN, como bien se explica en (Rosebrock, 2019), el procesamiento de grandes cantidades de datos suele ser excesivamente lento. Para acelerar este proceso, se recurre al empleo de múltiples unidades de procesamiento gráfico (GPU, por sus siglas en inglés), así como a tecnologías backends que utilizan diversos lenguajes de programación y librerías como TensorFlow, Keras y MxNet, entre otras. Estas herramientas tienen como objetivo mejorar la escalabilidad, velocidad y capacidad de respuesta de los sistemas.

Es fundamental comprender que, a pesar de su similitud, la AV y el procesamiento de imágenes son disciplinas diferentes. Aunque ambas tratan con imágenes como entrada, la salida de la AV puede contener características o información relevante de una imagen, mientras que en

el procesamiento de imágenes la salida es simplemente otra imagen. Con el fin de mejorar y corregir imágenes para resaltar y extraer características útiles en un proyecto específico, se requiere utilizar diversas técnicas de procesamiento de imágenes disponibles en la actualidad, las cuales se basan en modelos y análisis matemáticos variados.(Taquía-Gutiérrez, 2017)

1.11 VISIÓN ARTIFICIAL Y PROCESAMIENTO DE IMÁGENES

La visión artificial busca imitar la visión humana con su respectiva asociación, análisis, correlación e interpretación de la información propia de los objetos. se puede dividir la metodología de la AV como sigue:

1. Visión de bajo nivel. Éste primer paso es donde se lleva a cabo el procesamiento de las imágenes para extraer sus características mediante la segmentación de dichas imágenes identificando bordes, regiones e incluso texturas. En esencia, el procesamiento de imágenes comprende una serie de pasos enlistados a continuación:

- a) Teniendo en cuenta que el primer paso tras contar con una base de datos de imágenes robusta, mismas que, dependiendo su formato, tamaño, color, etc. contendrán mayor o menor cantidad de información dando lugar a la dificultad y mayor tiempo en su análisis; es lógico que dichas imágenes se sometan a una etapa en la cual se les de uniformidad, para ello se reescalarán a una misma dimensión, de menor tamaño, para facilitar su análisis futuro.
- b) El siguiente paso en el preprocesamiento, consiste en aplicar una serie de transformaciones a dichas imágenes respecto al color; acorde al objetivo de dicha base de datos, éstas transformaciones de color pueden ser a escala de grises, RGB, BGR, HSL, etc.
- c) Continúa el proceso de filtrado, que es una etapa fundamental en el procesamiento de imágenes, permitiendo realizar diversas operaciones para mejorar su calidad. Durante esta fase, se aplican una variedad de filtros con el objetivo de eliminar el ruido, detectar bordes y realzar detalles importantes. Entre los filtros lineales más utilizados se encuentran el filtro Gaussiano, el filtro Gauss-Sobel, el filtro de

Frangi, el filtro de Prewitt, el filtro de Laplace y el filtro de la media. Además, también se emplean filtros no lineales estadísticos, como el filtro mínimo, el filtro máximo y el filtro mediana. Otro enfoque comúnmente utilizado es el filtro del mínimo error cuadrático. Estas técnicas de filtrado, combinadas adecuadamente, permiten obtener imágenes más nítidas y con mayor claridad, mejorando así su interpretación y análisis.

- d) Como paso siguiente, se tiene la posibilidad de segmentar las imágenes. La segmentación de imágenes es un proceso esencial en el análisis de imágenes, que tiene como objetivo dividir una imagen en regiones significativas y coherentes. Mediante técnicas avanzadas de procesamiento de imágenes, se busca identificar y separar objetos o áreas de interés del fondo o de otras regiones. Esto se logra mediante la detección de bordes, cambios de intensidad, colores o texturas, y la aplicación de algoritmos de agrupamiento o clasificación.
- e) Continúa la extracción de características, donde, gracias a la segmentación de imágenes se logran resaltar las características relevantes en la información que guarda cada imagen, lo cual facilita el extraer información valiosa para el análisis, reconocimiento de patrones y toma de decisiones automatizadas; esto se logra mediante diversos métodos matemáticos como el análisis probabilístico y la desviación estándar.
- f) Finalmente, se realiza la clasificación de las regiones de interés (ROI, por sus siglas en inglés) empleando algoritmos de aprendizaje como, por ejemplo, k-Nearest Neighbors (kNN) o de vecinos más cercanos.

- 2. Visión intermedia. Teniendo en cuenta la segmentación de las imágenes, se lleva a cabo una representación espacial tridimensional (bosquejo 2 ½-D), hallando formas y distancias observador-objeto.
- 3. Visión de alto nivel. Finalmente, con el conocimiento adquirido de los pasos previos, se genera un proceso de aprendizaje que permite crear una base de datos de diversos objetos, relacionando la información obtenida y la capacidad para ir relacionando propiedades, características, funciones, etc. de cada objeto que se va analizando.

CAPÍTULO 2: ESTADO DEL ARTE Y ESTADO DEL CAMPO

2.1 ESTADO DEL ARTE

Los artículos revisados representan la evidencia de lo desarrollado en referencia al problema planteado, con distintos enfoques, por ejemplo; aquellos cuya relevancia se encuentra en el tipo de red neuronal implementado, ya sea multicapa de retropropagación (MLP), de base radial (RBFN), profundas (DNN) o convolucionales (CNN) en la detección de madurez del café cereza:

De una manera muy similar a lo que se pretende conseguir en la investigación actual, en (Serrano-Fuentes et al., 2020), se propone la creación de un sistema capaz de realizar las tareas de identificación y clasificación de los frutos de café maduros, con la finalidad de mejorar la calidad final del producto, así como disminuir costos, tiempos y mano de obra durante la cosecha. Para la conformación del sistema se requirió de un ambiente con iluminación controlada y una cámara de alta definición para permitir la correcta separación del fruto respecto al fondo y además se creó un algoritmo de enfoque cualitativo, utilizando visión artificial y redes neuronales de aprendizaje profundo, mediante el empleo del software Visual Studio y la librería OpenCV, entrenado con 196 imágenes (108 de frutos maduros “positivas” y 88 “negativas”) en lenguaje de programación C++, realizando 42 pruebas con un test dataset distinto (17 con frutos maduros, 20 con frutos verdes y 5 con frutos pintos), alcanzando una eficiencia del 97.6 % en la correcta clasificación.

En (Eustaquio & Jr., 2020) se clasificaron los granos de café maduros e inmaduros mediante el empleo de los colores rojo, verde y azul como variables, en una red neuronal MLP; con el objetivo de comparar con un estudio previo (realizado con la misma base de datos) usando procesamiento de imágenes para la extracción de características, algoritmos de minería de datos para la clasificación y MATLAB classification Learner, todo con la finalidad de determinar cuál brinda mejores resultados. El estudio concluyó que la red neuronal es más precisa en la clasificación con un 95 % respecto al 94 % obtenido en MATLAB, pero requiere mayor tiempo de entrenamiento (5 minutos) respecto a la máquina cuadrática de vectores en MATLAB obtenidos en un estudio previo (0.62 segundos).

En (Prieto & Hernández, 2005), con la finalidad de evitar que la calidad del café se vea afectada al realizar una cosecha en frutos no aptos para su procesamiento; se desarrolló y evaluó un sistema capaz de clasificar los granos de café maduros según la tonalidad que posean a través del empleo de redes neuronales artificiales de tipo MLP en C++ y utilizando el algoritmo de aprendizaje con retropropagación del error y el modelo en red neuronal basado en bloques (BBNN) para implementar los arreglos de compuerta programable por campo (FPGAs), en una tarjeta Altera Flex 10K FPGAs. El prototipo alcanzó con la MLP un 91.7 % de efectividad y con el BBNN un 89.5 % de efectividad.

En (de Jesús Beleño Saenz et al., 2016), se crearon 2 algoritmos de procesamiento de imágenes, el primero para detectar el estado de maduración ideal haciendo uso de las redes neuronales de base radial RBFN, utilizando diversas imágenes de frutos verdes y maduros y el segundo para identificar la plaga de la broca mediante la aplicación de un criterio de binarización (segmentación por el método del valor umbral - Otsu), se logró la detección de las zonas negras en las imágenes correspondientes a dicha plaga, lo anterior con la intención de eliminar errores humanos en la producción y procesamiento del café, reducir el esfuerzo de los caficultores y por consecuencia, mejorar la calidad del producto. Presentó un área bajo la curva ROC de 0.975, que indica un excelente rendimiento en la identificación de cerezos de café maduros y una adecuada identificación de frutos con plaga de la broca.

En (Herrera et al., 2016) debido a que la clasificación del café mediante técnicas de procesamiento de imágenes no compromete la integridad del producto al no ser invasiva, se desarrolló un sistema basado en visión artificial, apoyado de dos algoritmos de clasificación para identificar frutos maduros (Bayesiano) y presencia de broca (distancia euclidiana del centroide del café), ARN de tipo multicapa y además provisto de un mecanismo de transporte y otro de separación de los frutos del café. El sistema, en un ambiente controlado, constó de varias etapas: preprocesado (limpieza), filtro de ruido, segmentación (por umbralización y RGB), extracción de características del color y finalmente reconocimiento-interpretación (usando el algoritmo de interpretación). Obteniéndose como resultado para la detección de brocas, una detección de falsos positivos en 0.76 y para la detección por color alcanzó un rendimiento del 100 %; finalmente, empleando en conjunto los dos algoritmos se logró un 87 % de efectividad.

En (Zulma et al., 2007) se empleó visión artificial para agrupar los cerezos de café en 11 categorías según su madurez; dado que, en una clasificación visual tradicional, la textura y forma del café parecen no aportar gran ayuda en la clasificación; sin embargo, dichas características proporcionan valores exactos en un sistema de clasificación computarizado. es por ello que mediante 9 (de entre 208) características basadas en la forma, el color y textura de los frutos, a través de un método univariado y otro multivariado, evaluadas con 2 técnicas de clasificación: Bayesiano y el empleo de RNA de tipo multicapa. Los resultados obtenidos con el método Bayesiano fueron de un 5.43 % de error a una velocidad de clasificación de 5.5 ms y con redes neuronales el error fue mayor (7.46 %), pero con un tiempo de clasificación menor, de 0.8ms.

Para contribuir a la mejora de calidad del café, así como agilización del proceso de selección de café cereza maduro, disminución de tiempo, costos y mano de obra, en (Tamayo-Monsalve et al., 2022), se elaboró un sistema de clasificación de madurez del café desarrollando un sistema de visión multispectral implementando CNN , Transfer Learning (TL) Hiperparameter Optimization usando la función de activación ReLu y optimizador Adam; además de Cross-Validation (CV) y Métrica probabilística (precisión, Average Recall, F1-score y desviación estándar). Generando una base de datos de 640 imágenes multispectrales (de 15 canales) adquiridas con una cámara de espectro electromagnético de banda ancha (Flea3 FL3-GE-03S1M-C) monocromática, en un ambiente de iluminación controlada para facilitar la detectación de positivos (frutos maduros) y negativos. El sistema desarrollado obtuvo una eficiencia del 97.6 % en la identificación y clasificación de los frutos maduros.

De la misma manera, se revisaron algunos artículos que evaluaban la calidad de los granos de café verde, según la presencia de defectos, ésto de acuerdo al tipo de red neuronal empleada:

En (Turi et al., 2013) se optó por llevar a cabo la clasificación de los granos de café de 4 regiones de Etiopía (Hararge, Jimma, Wollega y Yirgacheffe) de acuerdo a su calidad, empleando técnicas de imágenes y ANN de tipo MLP; debido a que el método de clasificación tradicional visual, carece de imparcialidad, es complicado y está sujeto a errores humanos. Para llevar a cabo el proyecto se recopilieron 40 imágenes de cada región (160 imágenes en total) que permitieron definir 29 características o variables críticas (11 colores, 6 respecto a

la morfología, 12 según textura) para crear 4 configuraciones de clasificación del café: color, morfología, textura y la combinación morfología-color. Como resultado del estudio se obtuvo una precisión en la clasificación del 95 % para el color, 100 % en morfología, 87.5 % en textura y 100 % en la combinación morfología-color; probándose así, que dicha técnica podría ser muy eficaz para determinar las cualidades de los granos de café verde.

Ya que la calidad del café se ve completamente ligada y comprometida por la selección de los granos de café verde; y tanto los métodos manuales, así como algunas máquinas de clasificación representan opciones de coste elevado y poco confiables para dicha tarea de gran relevancia, en (Dos-Santos et al., 2020) el enfoque se dio en el análisis, identificación y valoración de la forma y color de los granos de café, implementando machine learning a través de la generación de un sistema basado en la máquina de vectores de apoyo (SVM), red neuronal profunda (DNN) y Random Forest (RF), usando lenguaje de programación Python y R. al final se demostró que la visión por ordenador y las redes neuronales son capaces de alcanzar una elevada precisión (>88 %) en la clasificación de granos de café, además de reconocerse la importancia de las variables de color en la precisión para el mismo fin.

En (Huang et al., 2019), se desarrolló un sistema automático capaz de llevar a cabo la selección de granos de café verde en tiempo real, mediante el empleo de procesamiento de imágenes (72000, en escala de grises) y la capacidad de aprendizaje profundo de una CNN, con una cámara web (con imagen de entrada en gris) y ajustando parámetros de luminosidad en API Video4Linux previamente al reconocimiento de imágenes; con la meta de brindar una alternativa al contratiempo que implica la selección manual de granos de café (en productos de café especiales), que demandan mucho tiempo, trabajo y la presencia de errores que comprometen la calidad del producto. Al final del estudio, se consiguió una tasa de falsos positivos (FPR) de 0.1007 y una tasa global de éxito del 93.34 % en la correcta identificación de granos de café, con una reducción de tiempo y costos de mano de obra.

Un sistema automático de clasificación de granos de café verde mediante imágenes a color fue desarrollado en (Pinto et al., 2017) para apoyar a los productores de café de Timor-Leste en disminuir el trabajo, tiempo y errores, productos de la clasificación manual subjetiva y permitirles ofrecer granos de café de mejor calidad, dándoles la oportunidad de destacar entre

la competencia. El estudio se llevó a cabo empleando una CNN, apoyada de procesamiento de imágenes, para detectar defectos en 6 categorías (negro, agrio, desteñido, peaberry, dañado y normal), alcanzando una precisión que oscila entre el 72.4 % y 98.75 % siendo el color negro, el determinante de un buen resultado.

En (Gope & Fukai, 2020) se generó un sistema low-cost para detectar de modo automático peaberries, para apoyar a los productores de café de países en desarrollo; para ello, se empleó procesamiento de imágenes, CNN y SVM (en una Raspberry Pi) como parte del trabajo de clasificación. Obteniéndose mejores resultados con la CNN (precisión >97 %) que con Kernel SVM en cuanto a clasificación y velocidad de procesamiento.

En (Wang et al., 2021) se propone un sistema de inspección óptica automatizada de los granos del café verde, para suprimir los errores humanos causados por fatiga que tienen un impacto negativo en la calidad del producto final. Basado en la implementación de CV, Deep Learning para obtener una CNN, misma que se logró aligerar y aumentar su rendimiento mediante Knowledge Distillation (KD) y un sistema basado en AI explicable (XAI, por sus siglas en inglés). De esa manera se alcanzó una buena tasa de identificación, baja complejidad y bajo consumo de energía.

A modo de un nuevo enfoque, para detectar las características de importancia en los granos de café verde mediante la adecuada identificación de sus bordes, en (Arboleda et al., 2020), buscando mejorar la relación señal ruido y la velocidad de ejecución de los algoritmos de Roberts, Prewitt y Sobel, mediante procesamiento de imágenes, utilizando un microcontrolador Raspberry Pi, cambiando dichos algoritmos por un discriminante basado en la formación de pares de píxeles para la identificación de las características de morfología, variaciones de color y de textura de los granos del café. Como resultados, respecto a los algoritmos Roberts, Prewitt y Sobel, la discriminante logró mejoras en: la relación señal/ruido pico (PNSR) (en un 2.091 %, 1.16 % y 2.47 % respectivamente); el error cuadrático medio (MSE) (en un 13.06 %, 7.48 % y 15.31 % respectivamente) y también en la velocidad del tiempo de ejecución (69.02 %, 67.40 % y 65.46 % respectivamente).

Por otra parte, algunas investigaciones se enfocaron y otorgaron mayor importancia en la

búsqueda de la calidad en los granos de café verde, mediante la selección de los algoritmos de segmentación y clasificación que brindasen los mejores resultados, como, por ejemplo:

Para prevenir alteraciones en el sabor y gusto del café debidos a una mala clasificación, en (Carrillo & Peñaloza, 2009) se creó un software capaz de clasificar los granos de café de acuerdo a la forma, el color y el tamaño partiendo de la generación de algoritmos (uno para los contornos, otro para distancia de mahalanobis y Flood fill para el crecimiento) cuya base fue el procesamiento de imágenes en un ambiente controlado, para poder identificar granos de café defectuosos; al final del estudio se concluyó la necesidad de un mayor número de imágenes bien definidas, un mejor uso de la luz y ampliar la base de datos de afecciones del café para alcanzar una correcta identificación de defectos de los granos de café.

En (Susanibar et al., 2021), para cubrir la necesidad de tener una correcta clasificación del café verde para optimizar el uso del tiempo y mejorar la calidad del producto obtenido, se diseñó e implementó una máquina de clasificación automatizada de granos de café verde (por tamaño y defectos) para pequeñas agroindustrias. El prototipo primero clasificó por tamaño; posteriormente, mediante visión artificial y algoritmos discriminantes se separaron los granos defectuosos en tiempo real y, por último, empleando un sistema de control integrado, sensores, actuadores y un panel de control se seleccionaron los granos de café según su calidad. Finalmente, se alcanzó una precisión del 96 % en la clasificación por tamaño y un 80 % de precisión en la clasificación por defectos físicos, con un flujo de salida de café de 5 kg/hora aproximadamente.

En (Condori et al., 2014), se buscó la detección y clasificación de defectos en la evaluación de granos de café mediante textura y forma de manera automatizada, con mínima intervención humana; puesto que dicha tarea realizada por expertos resulta demandante, exhaustiva y con alto grado de fatiga para el personal que provoca un mayor número de errores, mismos que contribuyen a disminuir la calidad del producto y la productividad, así como las ganancias. Para el sistema desarrollado, se empleó un modelo de clasificación con una base de datos (3367 imágenes), aplicando matrices de co-ocurrencia en escala de grises y colores (CGLCM) con un clasificador SVM (máquina de vectores soporte) para 12 categorías de defectos alcanzando un 86 % de precisión en la correcta clasificación.

En (Portugal-Zambrano et al., 2017) se desarrolló un prototipo para evaluar la calidad en los granos de café verde (13 categorías de defectos SCA), con un banco de datos de 1930 imágenes, para mejorar la calidad del café minimizando tiempos, mano de obra y errores propios de la fatiga de los expertos en clasificación. Para ello, empleó un sistema de visión computarizada, con un hardware desarrollado para capturar las imágenes y estabilizar la iluminación y un software que usa un algoritmo White-Patch (mejora de imágenes), histogramas de color y SVM para mejorar la clasificación. Los resultados obtenidos arrojaron un 98.8 % de precisión, demostrando eficacia en la detección global de defectos de granos de café verde.

Finalmente y de manera similar a los estudios anteriores, resaltando el hecho de que las técnicas de inspección y clasificación visuales (humanas) están sujetas a la generación de múltiples errores y no son suficientes para garantizar la calidad del producto, en (García et al., 2019) se desarrolló un sistema para la calidad y la clasificación de los granos del café verde; el prototipo se creó mediante el empleo de CV, algoritmo K-nearest-neighbor y algoritmos de aprendizaje programados con MATLAB en una placa Arduino Mega2560. Los resultados fueron en general muy buenos, 94.79 % de precisión en la evaluación de calidad, en la de defectos un 95.78 %, en la detección de granos de café muy largos un 98.05 % de precisión, alcanzando el sistema una precisión general >90 %, respaldada por desviación estándar del 1.87 % en la inspección de calidad y 2.03 % en la de defectos, garantizando un bajo porcentaje de errores.

A continuación, se presentan una serie de figuras de tablas comparativas (de la Figura 6 a la Figura 9), en las cuales se pueden visualizar los puntos más relevantes de cada proyecto:

1.) Aquellos en los cuales se empleó un tipo específico de red neuronal, para la identificación de café cereza maduro.

REFERENCIA	¿QUÉ SE HIZO?	HERRAMIENTAS UTILIZADAS	VARIABLES	VENTAJAS Y DESVENTAJAS	RESULTADOS/ CONCLUSIONES
En (Serrano, 2020)	Se propuso la creación de un sistema capaz de realizar las tareas de identificación y clasificación de los frutos de café maduros, desarrollando un algoritmo con enfoque cualitativo.	• RNA de aprendizaje profundo. • Algoritmo de enfoque cualitativo desarrollado. • Visión artificial. • Visual Studio (software). • Librería OpenCV. • Lenguaje de programación C++. • 196 imágenes.	Variables: - Positivos. - Negativos.	• Requiere del empleo de una cámara de alta definición y condiciones de iluminación controlada. • Banco de imágenes reducido.	• El sistema desarrollado alcanzó una eficiencia del 97.6% en la identificación y clasificación de los frutos maduros.
En (Eustaquio, 2020)	Se clasificaron granos de café según su madurez usando procesamiento de imágenes para la extracción de características y algoritmos de minería de datos para la clasificación.	• RNA MLP de retropropagación. • Neural Network Toolbox: MatLab. • MS Excel. • MatLab classification Learner. • 200 imágenes: 100 de café maduro (80 base de datos, 20 para pruebas). 100 de café verde (80 base de datos, 20 para pruebas).	Madurez (a través del color R, G y B como variables)	• Tiene un banco de imágenes pequeño al igual que la muestra usada para evaluar el dispositivo.	• La RNA alcanzó un 95% de precisión, con un tiempo de entrenamiento de 5 minutos. • SVM cuadrático: alcanzó un 94% de precisión, con un tiempo de entrenamiento de 0.62 s
En (Prieto, 2005)	Se desarrolló y evaluó un sistema capaz de clasificar los granos de café maduros según la tonalidad que posean.	• RNA perccion multicapa MLP. • RNA basado en bloques (BBNN), con arreglos de compuerta programable por campo (FPGAs) mediante lenguaje VHDL. • Lenguaje de programación C++. • Tarjeta Altera Flex K FPGAs. • Matriz de confusión para obtención de resultados. • Se evaluaron 5800 fotografías de "un solo grano de café" en diferentes condiciones (6 clases de luz, 3 fondos y 2 cámaras distintas) un total de 11 muestras en 8 semanas.	Cantidad de etapas de maduración asignadas de acuerdo a la coloración.	• Requiere de un ambiente controlado. • A > no. de etapas de maduración, < precisión en ambos sistemas.	Se logró una efectividad del 97% con MLP y del 89.5% con el BBNN. (para 3 etapas de maduración)
En (Beleño, 2016)	Se crearon 2 algoritmos de procesamiento de imágenes, uno para detectar el estado de maduración ideal y el otro para identificar la plaga de la broca.	• RNA de base radial (RBFN) con "Neural Network Toolbox" de MatLab. • Cámara de 5 MP. • MatLab (Imagen Processing Toolbox). • Segmentación: método de Otsu. • RGB a HSI y de HSI a CIE L*a*b. • Segmentación (broca): método del valor umbral (Otsu). • Curva ROC • 248 frutos, 60 imágenes.	Color.	• Método NO invasivo. • Elimina errores humanos en la producción y procesamiento del café • Reduce el esfuerzo de los cafeicultores. • Requiere de ambiente controlado, fondo blanco.	• Resalta la importancia de los clasificadores RGB. • Presentó un área bajo la curva ROC de 0.975, que indica un excelente rendimiento (El rendimiento perfecto = 1). • Adecuada identificación de frutos con plaga de la broca.
En (Herrera, 2016)	Se desarrolló un sistema basado en visión artificial para identificar frutos maduros y presencia de broca, transportar y separar los frutos de café.	• ARN multicapa • 2 cámaras paralelas (320x240) e iluminación con tira Led. • Python, OpenCV 2.4.9. • Espacio RGB a HSV y CIEL L*a*b*. • Segmentación: método de Otsu. • Clasificador en OpenCV: Algoritmo bayesiano (madurez) y SVM. • Broca: Umbralización e histograma. Distancia Euclidiana del centroide del café. • Morfológico: Dilatación, erosión, apertura. • Extracción de características: Media, desviación estándar. • 216 imágenes.	Forma. Color. Café bueno o malo.	• Funciona, pero no es totalmente efectivo. • El sistema detecta algunas sombras como broca. • Se debe perfeccionar el sistema de adquisición de imágenes. • Banco de imágenes reducido.	• Detección de falsos positivos de broca en 0.76 • Detección por color con rendimiento al 100% (Bayesiano). El sistema en conjunto obtuvo un 87% de efectividad.
En (Liliana, 2007)	Se empleó visión artificial para agrupar los cerezos de café en 11 categorías según su madurez.	• RNA multicapa. • Cámara de video a color (3 CDD), tarjeta digitalizadora, y dos lámparas de luz blanca). • Método Bayesiano. • Segmentación para contornos - RGB a grises. • Relación discriminante de Fisher y método multivariado. • 3300 imágenes.	9 (de entre 208) características, las cuales están basadas: 2 en forma, 3 en el color y 4 en la textura.	Se hace énfasis en la necesidad de un adecuado control de la luz (para evitar sombras y brillos) para mayor efectividad.	• Con el método de clasificación Bayesiano, el error en la clasificación fue de un 5.43% a una velocidad de clasificación de 5.5 ms. Con RNA el error fue de 7.46%, pero el tiempo de clasificación de sólo 0.8 ms.
En (Tamayo, 2022)	Se elaboró un sistema de clasificación de madurez del café desarrollando un sistema de visión multispectral, CNN y aprendizaje de transferencia.	• CNN • Imágenes multispectrales • 640 imágenes de cerezas de café tipo Arábica de variedad Caturra con 15 canales. (70% train, 30% test y 20% del train dataset para validación) • Sistema de visión multispectral (400 a 1000 nm). • Cámara de espectro electromagnético de banda ancha (Flea3 FL3-GE-0351M-C) monocromática. • Transfer Learning (TL) • Hiperparameter optimization, usando la función de activación ReLu y optimizador Adam. • Cross-Validation (CV). • Métrica (precisión, average recall, F1-score y desviación estándar) • VGG-16 network, VGG-19 network, Inception-ResNet-V2 e Inception V3DenseNet201	Mediante los cambios de tonalidad en la piel de las cerezas: -Inmaduro -Semi-maduro -Maduro -Sobremaduro -Seco	• Para mejorar los resultados se requiere de un banco de imágenes más grande. • Requiere de iluminación controlada. • Requiere cámara de espectro electromagnético.	Los mejores resultados de la CNN se dieron empleando DenseNet201 con TL, alcanzando una precisión superior al 98% y un 100% de precisión con Cross-Validation.

Figura 6: Tabla comparativa de artículos con distintas clases de ANN en la detección e identificación de café cereza maduro.

2.) Aquellas que emplearon redes neuronales diversas en la detección e identificación de defectos de los granos de café verde.

REFERENCIA	¿QUÉ SE HIZO?	HERRAMIENTAS UTILIZADAS	VARIABLES	VENTAJAS Y DESVENTAJAS	RESULTADOS/ CONCLUSIONES
En (Turi, 2013)	Se clasificó el café de acuerdo a su calidad, empleando técnicas de procesamiento de imágenes y redes neuronales artificiales (RNA).	• MLP • Cámara digital Nikon 3100 a 15 cm sobre la muestra. • Procesamiento de imágenes • Ajuste de contraste de imágenes RGB, HSL/HSI • 160 imágenes.	Color, morfología, textura y la combinación color-morfología.	• Ambas técnicas probaron, en conjunto, eficacia en la correcta clasificación. • Banco de imágenes reducido que limitó el trabajo de reconocimiento.	• Precisión 95% en color, 100% en morfología, 87.5% en textura y 100% en color-morfología.
En (DosSantos, 2020)	Se llevó a cabo el análisis, identificación y valoración de la forma y color de los granos de café, implementando machine learning y CV.	• Red neuronal profunda (DNN). • Escáner de superficie plana modelo Epson L210. • SVM (Support Vector Machine). • RF (Random Forest). • Jupyter Notebook, OpenCV, Python y R. • 635 muestras.	-Forma. -Color. Para clasificar en: Agrio, Cáscara, Regular, Negro y Roto.	• El uso de variables RGB es de gran relevancia.	• En condiciones ideales, la eficacia alcanzada es: DNN 94.8%, RF 88.5% y SVM 94.7% • En condiciones reales, la eficacia alcanzada es: DNN 71.4%, RF 88.2% y SVM 66.7% • El modelo propuesto alcanzó un 92% de precisión de café agrio. • En conjunto DNN, y CV alcanzaron una precisión mayor del 88% en la identificación y clasificación de granos de café.
En (Huang, 2019)	Se desarrolló un sistema automático de selección de granos de café, en tiempo real.	• CNN. • Videocámara web. API Video4Linux • Segmentación. Escala de gris (Threshold). • 72000 imágenes.	Color. Forma.	• Reducción en tiempo, costos y mano de obra. • Base de datos principal de 2 mil imágenes que al rotarse dieron las 72000 finales. Por lo que es limitada.	• Tasa de falsos positivos (FPR) de 0.1007 • Tasa global de éxito del 93.34%.
En (Pinto, 2017)	Se desarrolló un sistema automático de clasificación de granos de café, a partir de imágenes a color; para los productores de café de Timor-Leste.	• CNN. • Cámara digital F/16, 1 metro por encima del área de muestra. Fondo blanco. • Método de agrupación máxima. • 13000 imágenes de 6500 granos de café.	6 categorías: -negro, -agrio, -deseñido, -peaberry (color y gris) -dañado, roto (color y gris) -normal.	• Cuenta con un banco de imágenes reducido. • Requiere ambiente controlado.	• Precisión del 67.5% – 98.75% según el tipo de defecto. • -negro: 98.75% • -agrio: 92.93% • -deseñido: 72.41% • -peaberry: color 80.76% y gris 78.07% • -dañado/roto: color 72.5% y gris 67.5% • Se determinó que la detección del color negro es primordial en la detección de los defectos.
En (Gope, 2020)	Se creó un sistema de bajo costo para detectar automáticamente Peaberries, para apoyar a productores de café de países en desarrollo.	• CNN. • Cámara digital Nikon F/16 f-number, tiempo de exposición de 1/60 s, ISO200, compensación de exposición de 1.3, autoenfoco automático. 1 metro de distancia de la charola de prueba. • Procesamiento de imágenes. • Análisis de Componentes Principales (PCA) para extraer características. • SVM lineal convencional. • 3338 muestras de café normal (1900) y peaberry (1438).	-Color. -Morfología. -Forma. -Tamaño.	• Número de muestras reducido. • Poco uso de etiquetas.	• Precisión >97% (97.26%-98.53%) con el empleo de CNN en la clasificación y velocidad de procesamiento; respecto al uso de SVM (96.41%-96.71%).
En (Wang, 2021)	Sistema de inspección óptica automatizada (AOI) de granos de café.	• CNN: Con ResNet18, con KD y LIME. • CV. • Knowledge Distillation (KD). • Método basado en IA explicable (XAI) – LIME • 4626 imágenes.	Color y forma. -Agrio -Mohoso -Aplastado -Picado por insectos Judías buenas y malas.	• Banco de imágenes pequeño. • Pocos defectos identificados. • No especifica las condiciones de adquisición de las imágenes. • Resultados poco detallados.	• Buena tasa de identificación. • Baja complejidad. • Bajo consumo de energía.

Figura 7: Tabla comparativa de artículos con distintas clases de ANN en la clasificación de defectos de granos de café verde.

3.) Nuevo enfoque de extracción de características.

REFERENCIA	¿QUÉ SE HIZO?	HERRAMIENTAS UTILIZADAS	VARIABLES	VENTAJAS Y DESVENTAJAS	RESULTADOS/ CONCLUSIONES
En (Arboleda, 2020)	Se desarrolló un nuevo enfoque, en la discriminante, para detectar los bordes en los granos de café verde.	• A4 web cam PK-835G. • Iluminación con tiras Led. • Microcontrolador (Raspberry Pi). • Procesamiento de imágenes. • Python - OpenCV • Se cambiaron los algoritmos Roberts, Prewitt y Sobel, por un discriminante, basado en la formación de pares de píxeles. • Más de 2000 granos de café Robusta se examinaron.	Morfología (11). Color (6). Textura (4). • Área, Perímetro, Longitud, Anchura, Relación de aspecto rectangular, Relación de aspecto, Eje mayor, Eje menor, Redondez, Diámetro de hurón, Excentricidad para la morfología, Rojo medio, Azul medio, Verde medio, Tono medio, saturación media, Valores medios para el color, Entropía, Contraste, Energía, Homogeneidad para la textura.	• Las muestras deben acomodarse manualmente en el espacio de análisis. • El área de muestra no está aislada, por lo que podría generarse sombras causadas por el operador. • La cámara es de baja resolución. • Requiere ambiente controlado.	• Respecto a los algoritmos Roberts, Prewitt y Sobel, la discriminante desarrollada logró mejoras en: • La relación señal/ruido pico (PNSR) en un 2.091%, 1.16% y 2.47% respectivamente. • El error cuadrático medio (MSE) en un 13.06%, 7.48% y 15.31% respectivamente. • La velocidad del tiempo de ejecución en un 69.02%, 67.40% y 65.46% respectivamente.

Figura 8: Tabla comparativa. Artículo con enfoque distinto respecto a la extracción de características.

4.) Búsqueda de calidad mediante algoritmos diversos de segmentación y clasificación.

REFERENCIA	¿QUÉ SE HIZO?	HERRAMIENTAS UTILIZADAS	VARIABLES	VENTAJAS Y DESVENTAJAS	RESULTADOS/ CONCLUSIONES
En (Carrillo, 2009)	Se desarrollaron algoritmos basados en procesamiento de imágenes para clasificar los granos de café excelso acorde a su calidad.	• Algoritmo para los contornos. Ecuación de la elipse. • Binarización/ probabilidad de pertenencia mediante la distancia de Mahalanobis. • Canny algorithm (algoritmo inteligente). • Covarianza (fuerza de correlación entre variables). • Algoritmo Flood Fill para el crecimiento. • Color Features Analysis. • Desviación estándar para canales RGB.	Forma. Color. Tamaño.	• Requiere de un ambiente controlado. • Posee un banco de imágenes reducido y de baja resolución. • Énfasis en el control de la iluminación (ambiente controlado).	• Se evaluó el sistema y se determinó que el prototipo funciona, pero su base de datos es insuficiente como para identificar más clases de defectos.
En (Susanibar, 2021)	Se creó una máquina de clasificación automatizada de granos de café verde, para pequeñas agroindustrias.	• 2 cámaras (una arriba y la otra abajo). • Mediante visión artificial y algoritmos discriminantes (k-nearest neighbor y de segmentación RGB y HSV). • Arduino y Raspberry Pi.	Tamaño. Defectos.	• Propone usar algoritmos de visión computarizada más avanzados; así como un sistema embebido con un procesamiento más veloz y cámaras de mayor definición. • Separación de granos de café en tiempo real.	• Precisión del 96% en la clasificación por tamaño. • Precisión del 80% en clasificación de defectos físicos. • El flujo de salida de café del prototipo fue de 5kg/hora aprox.
En (Condori, 2014)	Identificación automática de granos de café defectuosos, con mínima intervención humana.	• Cámara de 12 MP. • Segmentación por método de Otsu. • Técnica de seguimiento de contornos. • Matrices de co-ocurrencia de niveles de gris y colores CGLCM (RGB-Extracción de características). • Clasificador SVM (para clasificar los defectos físicos) • 3367 imágenes.	12 categorías de defectos. - Textura. - Forma. - Color.	• La posición de la luz eliminó las sombras, pero originó brillos que afectan el estudio.	• 86% de precisión en la clasificación correcta.
En (Portugal, 2017)	Se diseñó y construyó un prototipo capaz de evaluar e identificar la calidad de granos de café verde.	• Procesamiento de imágenes. • HSV. • White-Patch. • Hardware desarrollado para capturar imágenes y estabilizar la iluminación. • Histogramas de color • Segmentación: algoritmo de Otsu. • SVM. • Validación: cruza K-Fold.	13 categorías (defectos SCAA): Brocado leve, Brocado severo, Cereza seca, Concha, Daño por hongo, Flotador, Inmaduro, Marrón (agrio) o vinagre, Negro, Negro parcial, Normal, Pergamino, Partido/ mordido/ cortado.	• Para mejorar la precisión propone el uso de algoritmos de segmentación para identificar granos dañados por forma y tamaño. • Colocación manual de los granos de café en la bandeja. • Bandeja que permite granos solapados/ encimados.	• 82.5% de precisión en la detección global de defectos en granos de café verde SIN corrección de imagen. • 98.8% de precisión en la detección global de defectos en granos de café verde con corrección de imagen White- Patch.
En (García, 2019)	Se generó un sistema automatizado de inspección para identificar y clasificar los granos del café verde.	• Cámara Canon PowerShot Sx420 de 20 MP con sensor CCD. • Luces Led. • CV: Matlab, Filtro Gaussiano, segmentación: HSV (Hue, Saturación y valores) y LUV (Coordenadas de luminancia y cromaticidad UV) • Extracción de características: área de superficie, redondez, • Relación de área o característica de color, excentricidad. • Clasificación: Algoritmo K-nearest-neighbor. Con distancia Euclidiana. • Análisis estadístico: media y desviación estándar. • Algoritmos de aprendizaje (MatLab). • Arduino Mega2560, 16 MHz. • EEPROM memory 24LC32 de 32Kbit. • 444 granos de café Árabeica. 220 imágenes.	-calidad. -Defectos. -Longitud. A través de análisis de: Color. Morfología. Textura. Tamaño.	• Requiere 96 ms para adquirir una imagen, procesarla y brindar los resultados del análisis. • Puede procesar 625 imágenes por minuto. • Garantiza un bajo porcentaje de errores. • Ayuda a reducir costos en producción y tiempos de inspección. • Base de datos reducida. • No incluye la detección de todos los defectos indicados en SCAA.	• Alta precisión media del 94.79% en evaluación de calidad, respaldada por 1.87% de desviación estándar. • 95.78% de precisión en evaluación del tipo de defecto, respaldada por 2.03% de desviación estándar. • 98.05% de precisión en la identificación de granos de café muy largos. • Precisión general del sistema de más del 90%.

Figura 9: Tabla comparativa de artículos con distintos algoritmos de segmentación.

2.2 ESTADO DEL CAMPO

BUHLER es una empresa de origen suizo que se enfoca en la creación de tecnología integral que asegure la calidad y seguridad en el manejo de diversos productos alimenticios; entre sus máquinas, se encuentra un clasificador de café que separa los defectos denominada SORTEX (Figura 10), un clasificador óptico que no sólo evalúa color, sino también, forma, claridad y oscuridad, defectos causados por plagas y cuerpos extraños, entre otros. Para el caso del café Arábica se enfoca en la eliminación de defectos según la coloración de granos de café verde en agrios, vinagre, inmaduros y descoloridos, igualmente es capaz de separar aquellos dañados por insectos como la broca. Para el café Robusta posee la capacidad de separar los granos de café (verde) en oscuros, claros, descoloridos y dañados por insectos. Y por último para el café tostado puede remover granos de café que se encuentren poco o demasiado tostados, además de separar cuerpos extraños como varas, piedras y vidrios. Entre las características presentadas en su ficha técnica, destacan:

- MultiVision y ColorVision gracias al sensor InGaAs.
- Alta capacidad de alimentación desde 1 hasta 5 tolvas.
- Cámaras en color a medida.
- Tecnología InGaAs mejorada (alta sensibilidad).
- Tecnología PROfile (forma, tamaño y color).
- Tecnología SmartEject.
- Iluminación LED de banda ancha.
- Capacidad de reordenación.
- Software operativo ProSortX.



Figura 10: SORTEX ® Optical Sorting Machine.

La empresa japonesa SATAKE, una de las empresas líderes en sistemas de procesamiento de cereales, desarrolló un procesador óptico RGB denominado Satake PIKASEN FMS2000 (Figura 11), cuyas principales características y beneficios se enlistan a continuación:

- Alta resolución de imagen 0.14mm/pixel. (2 cámaras RGB full color - 16 millones de colores).
- Interfaz intuitiva Portátil, compacto (158 kg peso neto).
- Bajo consumo de energía, que garantizan eficiencia y rentabilidad (0.6 kW/h).
- Consumo de aire (8-10 cfm).
- Fácil programación (Sistema inteligente de sensibilidad).
- Sistema recolector de polvo integrado.
- Gran eficiencia en defectos difíciles.
- Capacidad de 1 -2000 kg/h.
- Lámpara fluorescente de cátodo frío (CCFL 20,000 h).
- Dimensiones (mm) 1773 x 476 x 1203.



Figura 11: PIKASEN FMS2000 ® de la empresa SATAKE.

La empresa china TAIHO especializada en I+D y aplicaciones basadas en IA, visión artificial y en general enfocados en el desarrollo de equipos inteligentes de clasificación, embalaje, almacenamiento, etcétera; cuenta con un prototipo de separación de granos de café por color (Figura 12) con las siguientes características:

Está provisto de un sistema conectado a la nube (Sistema JARVIS), una red de sensores autónomos, visión inteligente, eliminación selectiva inteligente, y funciones infrarrojo personalizables para brindar la mayor precisión en la clasificación de granos de café.



Figura 12: TAIHO clasificador de color de granos de café.

CAPÍTULO 3: METODOLOGÍA

A continuación se presenta la metodología propuesta para la realización de las tareas definidas en las cuatro etapas del proyecto. La división en etapas tiene como objetivo proporcionar un control sistemático que ayude a propiciar un avance adecuado del trabajo.

3.1 ETAPA I. RECOPIACIÓN DE INFORMACIÓN

Esta primera etapa, consiste primordialmente en la recopilación de información de utilidad a través de la selección de artículos científicos, libros, sitios web, etc, así como datos proporcionados por la empresa CAFECOL, A.C., que permitan la generación de una base de datos que brinde sustento al proyecto propuesto. Ésta etapa se divide en tres tareas principales detalladas a continuación:

- Redacción del estado del arte. Esta tarea tiene por objetivo esclarecer y simplificar conceptos, así como poner en evidencia nuevas ideas o enfoques que permitan estar al tanto de los avances más recientes relacionados con el tema de tesis. El producto a obtener es una base de datos bibliográfica de artículos científicos y registros de patentes de invenciones existentes que faciliten el entendimiento de los diversos enfoques abordados y desarrollados por otros autores, en lo que se refiere a temas de procesamiento de imágenes e AI, aplicados en la extracción de características para la detección de objetos.
- Redacción del marco teórico. Tras una exhaustiva investigación en fuentes bibliográficas será posible la selección meticulosa de la información y conceptos fundamentales necesarios para respaldar, fortalecer y mejorar la comprensión del tema central y la problemática abordada en el proyecto.
- Análisis de las técnicas de procesamiento de imágenes y algoritmos de AI. El objetivo principal de esta tarea es la revisión de técnicas relacionadas con el procesamiento de imágenes, así como los diversos algoritmos de AI que pueden llegar a aplicarse en la construcción del sistema desarrollado. Para lograrlo, es necesario recopilar y seleccionar

la información que mejor se adapte a los objetivos específicos del proyecto. Algunas de las técnicas de preprocesamiento que se pondrán a prueba durante el desarrollo del proyecto, son: las transformaciones de tamaño en píxeles (escalas), la normalización de la imagen indicada en el código como 1/255, transformaciones de color en formatos BGR a RGB, RGB a GRAY, GRAY a HSV y GRAY a HSL, filtros de mediana, Gaussiano, etc; en cuanto a la segmentación de la imagen, determinar Regiones de Interés (ROI, por sus siglas en inglés) delimitando los objetos mediante el empleo de cuadros delimitadores (bounding boxes) o el método Circle Detection en el reconocimiento y detección de objetos por variaciones de gradiente o patrones, así como el método Find Contour, de la librería OpenCV, para hallar contornos en las imágenes por diferencias de gradientes; además, el uso de histogramas para hallar relaciones y patrones, así como el empleo de máscaras o filtros del tipo Blur, Mean, binary, threshold, Otsu y finalmente, técnicas de generación de imágenes, a partir de las existentes, realizando variaciones en la rotación y traslación de las mismas.

3.2 ETAPA II. TOMA DE DECISIONES

La segunda etapa consiste en la toma de decisiones, basada en la información obtenida, dándose de manera lógica, sistemática y teniendo en cuenta los objetivos planteados; entonces, será posible determinar el enfoque a seguir respecto al ¿cómo? realizar el proyecto. Esta etapa implica la realización de las siguientes tres tareas:

- Determinación del método de instrumentación para el sistema. Tarea enfocada en la determinación y selección de las variables a medir en los granos de café verde, como las tonalidades, formas y texturas, que serán determinadas y extraídas directamente por la ANN seleccionada. Éstas variables conformarán los parámetros clave en el funcionamiento del software del prototipo. El objetivo final de esta tarea es tener una idea de los medios que la red neuronal pudiese llegar a calificar y evaluar para determinar las características de cada uno de los defectos a detectar.
- Diseño del sistema. Esta tarea depende totalmente de las previas; para obtener las bases que permitan proponer el diseño del sistema a desarrollar. El objetivo de esta tarea es

generar un sistema de detección e identificación de algunos defectos en el café verde, mediante la realización de algunas pruebas empleando las técnicas de procesamiento de imágenes y algoritmos de AI que sean capaces de brindar la mayor precisión posible. Como base, se propone que el sistema esté conformado por 3 secciones o sistemas:

1. Software.
2. Sistema electrónico.
3. Sistema mecánico.

3.3 ETAPA III. PROTOTIPO Y EXPERIMENTACIÓN

En la tercera etapa, el objetivo es diseñar y construir el prototipo de detección final, así como la realizar pruebas de funcionamiento del sistema mecánico, el software y el hardware.

Base de datos de imágenes. En esta etapa de manera inicial deberá crearse una base de datos de imágenes, capturadas bajo las mejores condiciones posibles utilizando una cámara USB Arducam de 16 megapíxeles (4656 x 3496 píxeles) con autoenfoco, en un ambiente controlado de iluminación y fondo blanco que faciliten la diferenciación de los objetos. Las imágenes serán tomadas en las mismas condiciones que deberá poseer el dispositivo final, a una distancia entre los 130mm a 160 mm 100mm, para permitir el autoenfoco. Tras obtener las imágenes, es necesario realizar el proceso de etiquetado manual en proporciones del 70 % para entrenamiento, 20 % para validación y 10 % para la realización de pruebas, utilizando la plataforma Roboflow©, que brinda herramientas de fácil manejo y servicios de conversión y conformación de bases de datos que facilitan el desarrollo de proyectos de visión artificial.

Software. En lo que respecta al software, utilizando lenguaje de programación Python para desarrollar los códigos base para la modificación y adaptación de las arquitecturas de las redes de tipo convolucional VGG-16, VGG-19, ResNet-50 y YOLOv5x.

Las redes VGG-16 y VGG-19 son CNN preentrenadas especializadas en la clasificación de imágenes a gran escala, es decir, son capaces de asimilar grandes cantidades de datos contenidos en las imágenes en a color, con dimensiones de 224 x 224 píxeles y poseen 16 y 19 capas de profundidad de convolución y densas, respectivamente, con pesos preasignados.

Funcionan a través de un preprocesamiento donde se resta el valor RGB medio, obtenido del set de entrenamiento, a cada píxel. Su arquitectura, mostrada en la Figura 13, consiste de capas alternadas de convolución de tamaño 3 x 3, encargadas de extraer las características discriminantes que permitirán identificar los objetos; también cuenta con capas de Maxpooling de tamaño 2 x 2 que permitirán la reducción del tamaño de los filtros y por último poseen 3 capas de conexión completa o Fully Connected layers (FC) donde la primera y la segunda capa cuentan con 4096 neuronas cada una y la tercera capa, de salida, tiene 1000 neuronas. Para prevenir el sobreentrenamiento, este tipo de redes incluye en su código un aumento de los datos.




Figura 13: Arquitectura de las redes VGG-16 y VGG-19.

La red ResNet-50. ResNet-50 es una red convolucional de tipo residual especializada para el reconocimiento de imágenes, localización, detección y segmentación de objetos; está conformada por bloques de tipo residual apilados obteniendo un total de 50 capas de profundidad. La arquitectura de la red ResNet-50, se observa en la Figura 14, y muestra que 49 de sus capas son de convolución y la capa número 50 es FC densa con 1000 neuronas; además posee una capa de Maxpool, una de Average pool previa a la capa FC y una capa con función de activación Softmax.




Figura 14: Arquitectura de la red ResNet-50.

YOLOv5 es un algoritmo de detección de objetos, cuya base es el Aprendizaje Profundo, mediante el uso de una CNN. Actualmente existen diversas versiones del algoritmo que se siguen desarrollando y mejorando; sin embargo, la versión YOLOv5 es una de las más estables, escrita en lenguaje de programación Python y utiliza la librería Pytorch que permite el uso de bases de datos personalizadas desde PyTorchHub. En la Figura 15 se observa el funcionamiento de la red de arquitectura YOLOv5, cuya función primordial implica la segmentación de las imágenes de entrada en cuadrículas de $S \times S$ celdas, prediciendo mediante técnicas probabilísticas para cada celda de “N” número de cuadros delimitadores o bounding boxes una operación del tipo $S \times S \times N$ bounding boxes logrando determinar sus valores; dichos valores obtenidos se comparan con el valor umbral. Los bounding boxes que superan dicho umbral se conservan, mientras que el resto se descartan y eliminan gracias al método "Non-Max Supression". Aquellas que se encuentran por encima del umbral corresponden a la clasificación y detección dentro de la imagen lo más exacta posible del objeto que se quiere identificar. (Ángel, 2022)




Figura 15: Funcionamiento de la red de arquitectura YOLOv5x.

En este punto, además del prototipo mecánico, deberá contarse con una base de datos de imágenes óptima creada desde cero, el código con la CNN que permita hacer uso de los datos para el entrenamiento y posterior a éste, extrayendo automáticamente las características y patrones que caractericen y diferencien cada uno de los defectos; el código debe incluir el funcionamiento del sistema mecánico de transporte de los granos de café verde, la captura y preprocesamiento de las imágenes, la detección e identificación de los defectos y finalmente, el código correspondiente a la interfaz gráfica diseñada en Qt Designer®, para que el usuario sea capaz de visualizar los resultados obtenidos e introducir datos que le permitan identificar y calificar cada muestra de café analizada.

Electrónica y periféricos. La parte electrónica, debe conformarse de una unidad central de control, como la SBC Raspberry Pi 4 y sus periféricos como cámaras, hub, motores, pantalla, el sistema de iluminación y la elaboración de una placa de circuito impreso (PCB, por sus siglas en inglés) para la alimentación del sistema.

Mecánica. Consiste en el desarrollo de un sistema mecánico correspondiente al prototipo físico, basado en el empleo de rodillos que permitan visualizar ambas caras de los granos de café verde y en el cual se integren los dispositivos electrónicos, periféricos y el software

desarrollado.

Las tareas correspondientes a la etapa 3 son:

- Integración del sistema. El sistema, en conjunto, conformada por una CNN preentrenada con la base de datos de imágenes etiquetadas, con una distribución del 70 % para entrenamiento, 20 % para validación y 10 % para la realización de pruebas; esto implementado en la SBC Raspberry Pi 4 de 8 gb, 2 periféricos usb Arducam de 16 mp con autoenfoco, tiras leds, un hub usb y una touch-screen de 10.1 pulgadas en la cual se puede visualizar una interfaz gráfica desarrollada en Qt Designer® para permitir al operador llevar a cabo las tareas programadas según su conveniencia; finalmente, la construcción de un prototipo mecánico de distribución de la muestra utilizando 2 motorreductores de 5V y 12V.
- Puesta en marcha, análisis y ajustes del sistema. En este punto será posible evaluar el funcionamiento del sistema creado a través del prototipo construido e integrado. Esta fase de experimentación resultará en la comprobación respecto a la funcionalidad y precisión del sistema, así como la identificación de errores para la realización de actividades correctivas y mejoras a fin de obtener una identificación y clasificación de los defectos en granos de café más precisa.

En cuanto al sistema integrado, la metodología y funcionamiento en la tarea de adquisición de imágenes de la segunda etapa y en las tareas de la tercera etapa, se encuentran resumidas en la Figura 16:




Figura 16: Metodología del sistema implementado en el proyecto.

3.4 ETAPA IV. ANÁLISIS DE RESULTADOS Y CONCLUSIÓN

La cuarta y última etapa, corresponde al capítulo que incluye la descripción de los sistemas desarrollados, así como los resultados obtenidos tanto en el entrenamiento de las CNN, como en las pruebas de identificación de defectos en los granos de café verde y tras evaluar los resultados de funcionamiento de los modelos de redes ya entrenados, el sistema electrónico y el sistema mecánico, poder implementar las medidas necesarias para realizar ajustes y correcciones pertinentes.

Con el análisis e interpretación de los datos recabados y los inconvenientes surgidos, se determina el cumplimiento o incumplimiento de los objetivos e hipótesis planteados inicialmente; en este punto, será posible la redacción del apartado de resultados y conclusiones correspondientes.

De forma resumida se puede observar la metodología propuesta en la Tabla mostrada en la Figura 17:

ETAPA	TAREAS	META	EXPECTATIVA
Recopilación de información	Redacción del estado del arte y estado del campo.	Reunir información relevante para la producción de nuevos conceptos e ideas.	Recolectar datos, ideas y conceptos de fuentes de relevancia que enriquezcan y propicien la obtención de un buen producto.
	Redacción del marco teórico.	Redacción de la teoría que dará sustento y base firme al proyecto por realizar.	Compilar información de fuentes confiables que permitan la elaboración de un buen marco teórico.
	Análisis de las técnicas de procesamiento de imágenes y algoritmos de IA.	Revisión teórica de herramientas útiles de procesamiento de imágenes y aprendizaje automático.	Analizar las posibles herramientas a utilizar para seleccionar la que mejor se ajuste al proyecto.
Toma de decisiones.	Determinación del método de instrumentación para el sistema.	Seleccionar las variables a medir, así como parámetros y herramientas de medición para las mismas.	Identificar las variables centrales y sus herramientas de medición para cuantificar los avances y funcionalidad del prototipo.
	Diseño del sistema.	Proponer el diseño del sistema basado en las decisiones previas.	Generar el diseño de un sistema de clasificación e identificación de defectos en los granos de café verde, empleando procesamiento de imágenes y algoritmos de IA.
	Adquisición de imágenes.	Crear una librería de imágenes con los distintos grupos de defectos por identificar, así como elementos sanos y café cereza maduro.	Lograr una adecuada identificación de cada caso mediante la obtención de fotografías nítidas, en ambiente controlado y real, para emplearlas en el entrenamiento, validación y pruebas del sistema.
Experimentación.	Implementación del sistema.	Realizar un prototipo para verificar funcionalidad.	Construcción de una maqueta o prototipo funcional.
	Puesta en marcha, análisis y ajustes del sistema.	Iniciar pruebas del sistema a través del prototipo generado.	Comprobar la funcionalidad, detectar errores y realiza correcciones para la mejora en el funcionamiento del prototipo.
Obtención de resultados.	Elaboración de tesis y producto académico.	Redactar de manera formal el archivo que contendrá tanto aspectos teóricos como experimentales obtenidos del proyecto realizado, la metodología empleada para llegar a los resultados obtenidos, evaluando el cumplimiento de los objetivos planteados, tras la elaboración del producto académico.	Presentar un trabajo profesional en la modalidad de producto académico y tesis.

Figura 17: Resumen de la metodología.

CAPÍTULO 4: DISEÑO Y FABRICACIÓN DEL SISTEMA MECATRÓNICO

En éste capítulo se abordará el sistema mecatrónico, que se dividió en 7 secciones, donde las primeras 5 secciones corresponden al sistema mecánico y las últimas 2 son una combinación de los sistemas mecánico y electrónico:

- Sección de recepción y surtidor de la muestra, presentada en la Figura 18 a la Figura 21.
- Sección de rodillos y plataformas para captura de imágenes, mostrada en la Figura 22.
- Sección de engranes y levas, mostrada en la Figura 23 a la Figura 25.
- Sección estructural y charola de recolección, mostrada en la Figura 26 y Figura 27.
- Sección de la carcasa, mostrada en la Figura 30 a la Figura 36.
- Sección de adquisición de imágenes, cuyos elementos que la conforman se muestran en la Figura 37.
- Sección de control, mostrando sus componentes en la Figura 38

4.1 SECCIÓN DE RECEPCIÓN Y SURTIDOR DE LA MUESTRA




Figura 18: Vista frontal (sin cubiertas) de los elementos del sistema mecánico ensamblado.

Esta sección se encarga de recibir en la tolva de alimentación (1) los 250 a 350 gramos de granos de café verde, dicha muestra pasará al rodillo surtidor (3) impulsado por un primer motor (m1) y protegido por la cubierta cilíndrica (2) como se aprecia en la Figura 18, permitiendo el paso de 5 granos que, por gravedad, caerán al segmento triangular del distribuidor (10) con aletas dispuestas en zig-zag, protegida por la cubierta triangular (11), continuando su trayecto hacia el segmento rectangular del distribuidor (12) también con aletas en zigzag y con su cubierta rectangular (13) elaborada en acrílico transparente de 3mm de espesor que pueden observarse en la Figura 19.




Figura 19: Vista frontal (con cubiertas) de los elementos del sistema mecánico ensamblado.

En la Figura 20 se tiene una vista ortogonal posterior donde se observa un refuerzo posterior (14) elaborado en acrílico transparente de 6mm de espesor cuyo propósito es brindar soporte al segmento rectangular del distribuidor (12), un soporte del distribuidor con tolva semicircular (15) con una pluralidad de orificios (b2), (c2) y (e2) que serán atravesados por las varillas estructurales de aluminio (B y (C) y el eje de la leva con engrane de 10 dientes (E) respectivamente su función es brindar soporte a los elementos de la primera y segunda sección. Finalmente, los granos pasan a la siguiente sección del sistema.




Figura 20: Vista ortogonal posterior de los elementos del sistema mecánico ensamblado.

En resumen, ésta primera sección está compuesta por la tolva de alimentación (1), la cubierta cilíndrica (2), el rodillo surtidor (3), el soporte lateral izquierdo (4) con una pluralidad de baleros (5), el soporte para un primer motor (7); entre el soporte lateral izquierdo (4) y el soporte para un primer motor (7), se posiciona un buje de acoplamiento (8); el eje surtidor (9) pasa a través de la pluralidad de baleros (5) del soporte lateral izquierdo (4) y el soporte lateral derecho (6); el segmento triangular del distribuidor (10) con su cubierta triangular (11), la sección rectangular del distribuidor (12) con su cubierta rectangular (13), el refuerzo posterior (14) y finalmente el soporte del distribuidor con tolva semicircular (15) con una pluralidad de orificios (b2), (c2) y (e2) que serán atravesados por la varilla estructural de aluminio (B), la varilla estructural de aluminio (C) y el eje de la leva con engrane de 10 dientes (E) respectivamente; el soporte del distribuidor con tolva semicircular (15) se observa a detalle en la Figura 21 y se encarga de resguardar al rodillo distribuidor (18) y brindar soporte a los

elementos de la primera y segunda sección.




Figura 21: Vista ortogonal, orientada desde el frente, con detalles del soporte del distribuidor con tolva semicircular (15).

4.2 SECCIÓN DE RODILLOS Y PLATAFORMAS PARA CAPTURA DE IMÁGENES

Es la encargada de transportar los granos de café desde que descenden hacia los orificios del rodillo distribuidor (18) que se encuentra rodeado por el soporte del distribuidor con tolva semicircular (15) durante el trayecto de la muestra hacia el rodillo volteador (19) quien, con movimientos intermitentes, lleva la muestra hasta el rodillo con plataformas (20) que gira mediante gracias al eje del rodillo con plataformas (21); el espacio destinado a la captura de imágenes se haya comprendido en el rodillo volteador (19) y el rodillo con plataformas (20). Finalmente, los granos de café caerán desde el rodillo con plataformas (20) hacia la charola de recolección (30) perteneciente a la sección estructural y charola de recolección. De forma resumida, los elementos que constituyen esta segunda sección y que se observan en la Figura 22 son: la varilla estructural de aluminio (B), la varilla estructural de aluminio (C) y la varilla estructural de aluminio (16), 4 ejes de acero inoxidable, donde, el eje del rodillo distribuidor (D) atraviesa longitudinalmente el rodillo distribuidor (18), el eje del rodillo volteador (A)

atraviesa longitudinalmente el rodillo volteador (19), el eje de la leva con engrane de 10 dientes (E) que servirá para transmitir movimiento al eje del rodillo con plataformas (21) que atraviesa longitudinalmente el rodillo con plataformas (20).




Figura 22: Vista ortogonal de los componentes de la sección de rodillos y plataformas para captura de imágenes.

4.3 SECCIÓN DE ENGRANES Y LEVAS

Esta sección se muestra en la Figura 23, 24 y 25, tiene como objetivo la trasmisión de movimiento a partir de un segundo motor ubicado en el soporte de motor (33) por fuera de la caja protectora de engranes (31).




Figura 23: Tren de engranes compuesto por: un engrane de 10 dientes (23), un engrane de 40 dientes con buje acoplador (24), una leva con engrane de 10 dientes (25) con un eje roscado (X) y, finalmente, una rueda de Ginebra (26).

En la Figura 23 se muestran los engranes se encuentran ubicados en la cara externa de la tapa izquierda de una caja de engranes (22a). El motor se acoplará al buje del engrane de 40 dientes con buje acoplador (24), encargado de girar el eje del rodillo distribuidor (D); dicho engrane, con ayuda del engrane de 10 dientes (23) cuyo eje para engrane de 10 dientes (17) se encuentra, a presión, en un balero (5) fijo a la caja protectora de engranes (31), transmitirán el movimiento a la leva con engrane de 10 dientes (25) que a su vez hará girar el eje de la leva con engrane de 10 dientes (E) al cual están fijos una leva simple (27), el segmento corto (28) con una longitud de 1.5 veces la de la leva simple (27) y el segmento largo (29) cuya longitud es 3 veces la de la leva simple (27) y que une a esta última con el segmento corto (28) colocados en la cara externa de la tapa derecha de una caja de engranes (22b) indicados en la Figura 24 y que moverán, a su vez, al eje del rodillo con plataformas (21).




Figura 24: Vista isométrica de las caras externas de la tapa izquierda de una caja de engranes (22a) con el tren de engranes y la tapa derecha de una caja de engranes (22b) con una leva simple (27), un segmento corto (28) y un segmento largo (29)

En la Figura 25 se observa que la tapa izquierda de una caja de engranes (22a) y la tapa derecha de una caja de engranes (22b) están provistas de 7 orificios cada una (f, b, c, a, d, e, g) para permitir el paso de las varillas estructurales de aluminio (16, B, C) y el movimiento del eje del rodillo volteador (A), el eje del rodillo distribuidor (D), el eje de la leva con engrane de 10 dientes (E) y el eje del rodillo con plataformas (21) respectivamente; los orificios (a, d, e, g) poseen una pluralidad de baleros (5). La leva con engrane de 10 dientes (25) tiene en su extremo más distal un pequeño orificio en el cual va un eje roscado (X) que permite el movimiento intermitente de la rueda de Ginebra (26) encargada de transmitir el movimiento al eje del rodillo volteador (A).




Figura 25: Vista isométrica de las caras internas de la tapa izquierda de una caja de engranes (22a) y la tapa derecha de una caja de engranes (22b), cada una con 7 orificios: los orificios (b), (c) y (f) para el paso de las varillas estructurales de aluminio (B), (C) y (16) respectivamente; y los orificios (a), (d), (e) y (g) destinados a los ejes (A), (D), (E) y (21) respectivamente.

De forma resumida, los elementos pertenecientes a esta sección son, en orden numérico: un eje para engrane de 10 dientes (17), la tapa izquierda de una caja de engranes (22a) y la tapa derecha de una caja de engranes (22b), un engrane de 10 dientes (23), un engrane de 40 dientes con buje acoplador (24), una leva con engrane de 10 dientes (25), una rueda de Ginebra (26), una leva simple (27), un segmento corto (28), un segmento largo (29) y finalmente un eje roscado (X).

4.4 SECCIÓN ESTRUCTURAL Y CHAROLA DE RECOLECCIÓN




Figura 26: Vista isométrica orientada desde el frente y la izquierda indicando el chasis (32), el soporte de motor (33), el segundo motor (m2), la caja protectora de engranes (31) con su eje para engrane de 10 dientes (17) y el engrane de 10 dientes (23) que pertenece a la sección previa.

Esta sección se visualiza en las Figuras 26 y 27, es la encargada de albergar todo el sistema. El mecanismo compuesto por las secciones previas, va colocado en el extremo posterior del chasis (32) elaborado en acero inoxidable calibre 12, el cual servirá para realizar el montaje de los componentes electrónicos y de control como la cámara superior (55a), la cámara inferior (55b) y la pluralidad de luces led (56). Del lado izquierdo se tiene la caja protectora de engranes (31) que protege y da firmeza al ensamble del tren de engranes, del mismo lado, un soporte de motor (33) elaborado también en acero inoxidable cuya función es la de fijar y dirigir el eje del segundo motor (m2) hacia el buje del engrane de 40 dientes con buje acoplador (24), finalmente entre el dispositivo montado en el chasis (32) y la pared frontal de este último, se coloca la charola de recolección (30). Resumiendo, los elementos pertenecientes a esta sección son la charola de recolección (30), la caja protectora de engranes (31), el chasis (32), el soporte de motor (33), un segundo motor (m2) y un eje para engrane de 10 dientes (17)

como se muestra en la Figura 27.




Figura 27: Vista isométrica orientada desde el frente y la derecha donde se aprecian la charola de recolección (30), la caja protectora de engranes (31), el chasis (32), el soporte de motor (33) y el segundo motor (m2).

Hasta este punto, en la Figura 28, se puede observar el prototipo físico con los elementos que integran las 4 primeras secciones correspondientes a la sección de recepción y surtidor de la muestra, la sección de rodillos y plataformas para captura de imágenes, la sección de engranes y levas resguardadas en su mayoría en la caja protectora de engranes (31) y elementos de la sección estructural.



Figura 28: Vista isométrica de los elementos de las 4 primera secciones del prototipo físico.

4.5 SECCIÓN DE LA CARCASA

La sección de la carcasa, consta de una serie segmentos de perfil angular de aluminio de lados iguales de $\frac{1}{2}$ " y también de $\frac{3}{4}$ " como se muestra en las Figuras 30, 31 y 32, así como paredes de acrílico de 3mm de espesor como se observa en la Figura 34, 35 y 36. En la Figura 29 se muestra una imagen del prototipo real, donde se muestra la pluralidad de segmentos de perfil angular de aluminio de la sección de la carcasa.



Figura 29: Vista isométrica de los segmentos de aluminio del prototipo físico.

En la construcción de la base, mostrada en la Figura 30, se emplearon tres segmentos de perfil angular de aluminio de $\frac{3}{4}$ " de 45 cm de longitud (34a), (34b) y (34c), dos segmentos de perfil angular de aluminio de $\frac{3}{4}$ " de 30 cm de longitud (35a) y (35b) y dos segmentos (36a) y (36b) de perfil angular de aluminio de $\frac{3}{4}$ " de 26.9 cm de longitud.




Figura 30: Vista isométrica de los segmentos estructurales que conforman la base conformada por una pluralidad de segmentos de perfil angular de aluminio.

Los segmentos verticales constan de cuatro segmentos de perfil angular de aluminio de $\frac{1}{2}$ " de 40 cm de longitud (37a), (37b), (37c) y (37d), dos segmentos frontales de perfil angular de aluminio de $\frac{1}{2}$ " de 23.5 cm de longitud (38a) y (38b) y dos segmentos inclinados de perfil angular de aluminio de $\frac{1}{2}$ " de 23.5 cm de longitud (39a) y (39b). Figura 31.




Figura 31: Vista isométrica de los elementos verticales, conformados por una pluralidad de segmentos de perfil angular de aluminio.

En la Figura 32 se observa que, para conformar el recuadro superior, se requirió cortar dos segmentos (40a) y (40b) de perfil angular de aluminio de $\frac{3}{4}$ " de 27.9 cm de longitud correspondientes a los laterales superior derecho e izquierdo, respectivamente; por último, se cortaron dos segmentos (41a) y (41b) de perfil angular de aluminio de $\frac{1}{2}$ " de 30 cm de longitud que corresponden al segmento frontal y posterior del recuadro superior.




Figura 32: Vista isométrica de los elementos del recuadro superior y el soporte de pantalla, conformados por una pluralidad de segmentos de perfil angular de aluminio.

Posteriormente, se puede apreciar también en la Figura 32 que se agregó un soporte de pantalla conformado por dos segmentos de perfil angular de aluminio de $\frac{1}{2}$ " de 30 cm de longitud (42a) y (42b), un segmento (43) de perfil angular de aluminio de $\frac{1}{2}$ " de 24 cm de longitud, dos segmentos de perfil angular de aluminio de $\frac{1}{2}$ " de 15.2 cm de longitud (44a) y (44b), dos segmentos de perfil angular de aluminio de $\frac{1}{2}$ " cortados y doblados a 90° de 3.5 x 2 cm de longitud (45a) y (45b) y dos soleras de aluminio, de $\frac{1}{2}$ ", dobladas a 90° de 3.5 x 2 cm de longitud (46a) y (46b). Ahora bien, en la figura 33 se muestra el prototipo físico donde se encuentran todos los elementos del sistema encargados del transporte y distribución de los granos de café verde que estarán protegidos por el chasis (32), los segmentos de perfil angular de aluminio y las paredes de acrílico.



Figura 33: Prototipo físico integrado, sin las paredes de acrílico.

Las paredes de acrílico de la carcasa consisten en siete caras externas y una cara interna del modelo; como se observa en la Figura 34 la carcasa consta de una cara frontal vertical (48), una cara frontal inclinada (49) que sirve de cubierta a la pantalla, una cara lateral derecha (50) y una cara superior (53) con una abertura en la que se inserta y descansa la tolva de alimentación (1).




Figura 34: Vista isométrica frontal y derecha de las caras de acrílico de la carcasa.

En la Figura 35 se aprecian el resto de las caras externas desde una perspectiva posterior e izquierda donde se encuentran señaladas una cara inferior (47), una cara lateral izquierda (52), una cara posterior (54) con una tapa (51) para la entrada desde la que se tendrá acceso a la charola de recolección (30).




Figura 35: Vista isométrica posteroinferior e izquierda de las caras de acrílico de la carcasa.

Por último, en la Figura 36 se muestra una cara interna (Z) que separa el sistema mecánico del resto de los componentes electrónicos, ésta cara de acrílico posee una pluralidad de espacios, como el espacio (z1) para el cable del primer motor (m1), el espacio rectangular (z2) para el paso de los cables pertenecientes a las cámaras (55a) y (55b) y la pluralidad de luces led (56) y el espacio (z3) a través del cual pasa la caja protectora de engranes (31).




Figura 36: Vista isométrica indicando la cara interna (Z) con sus espacios (z1), z(2) y (z3).

4.6 SECCIÓN DE ADQUISICIÓN DE IMÁGENES

En la figura 37 se observan los elementos que constituyen esta sección, éstos son: una cámara superior (55a) y una cámara inferior (55b) ambas de tipo USB Arducam de 16 megapíxeles con autoenfoco colocadas sobre en el chasis (32) donde, además, se tiene un ambiente con iluminación controlada mediante el empleo de una pluralidad de luces led (56).




Figura 37: Vista isométrica de los componentes pertenecientes a la sección de adquisición de imágenes: una cámara superior (55a), una cámara inferior (55b) y una pluralidad de luces led (56).

4.7 SECCIÓN DE CONTROL

Ésta sección, mostrada en la Figura 38, se conforma por una fuente de alimentación (57) correspondiente a una placa amplificadora de corriente que requiere un Voltaje de entrada de 110 Voltios que entrega hasta 10 Amperios, 12 Voltios y 5 Voltios, una unidad de control (58) compuesta por un microcontrolador de tipo Raspberry Pi 4 de 8Gb, en el cual, se encuentra embebida la unidad discriminante compuesta por una Red Neuronal Convolucional clasificadora previamente entrenada capaz de determinar si los granos de café verde son normales o defectuosos a partir de la imagen de los granos de café verde proporcionada, utilizando un algoritmo de aprendizaje por imágenes y técnicas de Visión Artificial, empleando lenguaje

de programación Python y usando librerías especializadas en clasificación como Tensorflow, Keras y torch; finalmente, esta sección cuenta con unos periféricos correspondientes a un teclado (59), un mouse (60) y una pantalla (61) con una dimensión de 10.1” para visualizar una interfaz gráfica desarrollada con QtDesign© que permite al usuario vigilar el proceso de clasificación y guardar los resultados obtenidos.




Figura 38: Vista isométrica de los componentes de la sección de control, conformada por conforma por una fuente de alimentación (57), una unidad de control (58), un teclado (59), un mouse (60) y una pantalla (61) de 10.1”.

Finalmente, en la Figura 39 se aprecia el prototipo final, cuyos componentes internos se hallan protegidos por los segmentos de aluminio y la carcasa de acrílico.



Figura 39: Vista isométrica del prototipo completo final.

CAPÍTULO 5: SISTEMA DE VISIÓN POR COMPUTADORA

El actual capítulo corresponde al tercer sistema de la invención, el software, que incluye la elaboración de una base de datos de imágenes, el uso de Redes Neuronales Artificiales de tipo Convolutacional, así como el código python para el control de los dispositivos de captura de imágenes, iluminación y motores; éste sistema se apoya en gran medida de los sistemas electrónico y mecánico abordados en el capítulo previo del diseño y fabricación del sistema mecatrónico. Los tipos de mancha del café que conforman la base de datos se aprecian en la Tabla 4 .

	CLASES A DETECTAR	
 Normal	 Negro	 Agrio
 Brocado	 Cereza seca	 Partidos, mordidos o cortados
 Elefante	 Concha	 Oreja

CLASES A DETECTAR		
		
Helado	Caracolillo	Triángulo

Tabla 4: Clases/Defectos de los granos de café verde a detectar (imágenes proporcionadas por CAFECOL, A.C.)

En la Figura 40 se observa de forma general en qué consiste la metodología del sistema de Visión Artificial o visión por computadora.




Figura 40: Metodología general del sistema de visión e implementación de AI para obtener el modelo clasificador.

En primera instancia, la visión de bajo nivel está conformada por el preprocesamiento, donde se indica un resize de las imágenes que conforman la base de datos a una dimensión de 320 x320 x3, una segmentación mediante algoritmos clasificadores, de gradiente, canny detection,

laplacianos y de tipo thresholding binario Gaussiano inverso, se elimina el ruido empleando una combinación de filtro Gaussiano, de media y Laplaciano, por último se realiza un aumento de los datos mediante rotación y traslación de las imágenes a 90° , 15° y -15° . La visión intermedia ocurre teniendo en cuenta el preprocesamiento, hasta el punto en el cual el sistema es capaz de reconocer la distancia y forma de los objetos. La visión de alto nivel se da mediante la visión de bajo nivel e intermedia, donde es capaz de comparar y relacionar la información obtenida con la finalidad de extraer las características propias de cada objeto. La base de datos de imágenes final, etiquetadas según la clase a la cual pertenezcan, se divide en sets para entrenamiento, validación y prueba en proporciones de 70 % train, 20 % validation y 10 % test. En este punto se implementarán algoritmos de AI con los sets de la base de datos final mostrada en la Tabla 41, entrenando el sistema clasificador con distintas arquitecturas de CNN explicadas en la siguiente sección.

5.1 EXPERIMENTACIÓN Y ANÁLISIS DE RESULTADOS

5.1.1 ALGORITMOS BASADOS EN INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE MANCHA DEL CAFÉ

Para el entrenamiento de las ANN, fue necesaria la creación de una base de datos de imágenes, llevándose a cabo la adquisición de 4,000 imágenes de ejemplos de distintos granos de café verde sanos y con defectos, se contó con un total de 12 clases a detectar, siendo 1 clase para granos de café verde normales y 11 clases correspondientes a los defectos: agrio, broca, caracolillo, concha, elefante, helado, negro, normal, oreja, partido, seca y triángulo; se hizo un aumento de dicha base de datos en el preprocesamiento mediante rotación y traslación, obteniéndose un total de 9,600 imágenes finales, mismas que fueron etiquetadas mediante la herramienta de polígono de la plataforma Roboflow©. Se redimensionaron las imágenes a un tamaño de 320 x 320 píxeles y finalmente la distribución de imágenes se asignó en una proporción del 70 % para entrenamiento, 20 % para validación y 10 % para pruebas, como se observa en la tabla 41.

CLASE	DEFECTO	IMÁGENES	CLASE	DEFECTO	IMÁGENES
1	Agrio	333	7	Negro	98
2	Broca	239	8	Normal	463
3	Caracolillo	522	9	Oreja	218
4	Concha	320	10	Partido	127
5	Elefante	331	11	Seca	782
6	Helado	214	12	Triángulo	353
Total: 4000 imágenes - Train 2800 (70%), Val 800 (20%) y Test 400 (10%)			Tras aumento por transformaciones: 9600 imágenes - Train 8400, Val 800 y Test 400		

Figura 41: Tabla de imágenes capturadas de granos de café, según su clase, y su distribución para conformar las bases de datos de entrenamiento, validación y prueba.

Como parte del desarrollo del software se adaptaron las CNN, tomando como referencia la bibliografía revisada donde se destaca la obtención de los mejores resultados mediante el empleo de redes neuronales de tipo convolucionales. De forma resumida, las estructuras de las CNN utilizadas se compusieron de distintos números de capas según su arquitectura y distintos tamaños de batch para las arquitecturas preentrenadas VGG-16 y VGG-19 y para la residual ResNet-50.

Para las redes VGG-16 y VGG-19 requieren el empleo de imágenes redimensionadas a 224 x 224 píxeles a 100 épocas, utilizando Adam como optimizador de la tasa de aprendizaje en las capas de convolución, empleando la función de activación ReLu para las 2 primeras capas densas y softmax para la capa densa de salida, agrupando y reduciendo los datos mediante el uso de Max Pooling y empleando la estrategia de regularización Dropout para evitar el sobreentrenamiento.

En el caso de la red ResNet-50 las imágenes se dejaron a un tamaño de 224 x 224 píxeles, a 100 épocas, utilizando Adam como optimizador de la tasa de aprendizaje en las capas de convolución, empleando la función de activación ReLu para las 2 primeras capas densas y softmax para la capa densa de salida, agrupando y reduciendo los datos mediante el uso de Average Pooling y empleando como estrategia de regularización Dropout con la finalidad

de evitar el sobreentrenamiento. Los parámetros originales de las redes VGG-16, VGG-19 y ResNet-50 se muestran en la Tabla 5.

PARÁMETROS	VGG-16(original)	VGG-19(original)	ResNet-50 (original)
TOTALES	138,357,544	143,667,240	25,636,712
ENTRENABLES	138,357,544	143,667,240	25,583,592
NO ENTRENABLES	0	0	53,120

Tabla 5: Tabla de parámetros iniciales de las redes VGG-16, VGG-19, ResNet-50

Tanto para las redes VGG-16, VGG-19 como para ResNet-50, se realizó una reducción de parámetros mediante la modificación de las capas FC donde los parámetros originales de la Tabla 5 pueden compararse con los modificados mostrados en la Tabla 6. El código con dichas modificaciones, así como las capas que hacen diferencia en el número de parámetros, se encuentran en la sección de Anexos.

PARÁMETROS	VGG-16(modificada)	VGG-19(modificada)	ResNet-50 (modificada)
TOTALES	17,944,140	23,253,836	25,782,900
ENTRENABLES	3,229,452	3,229,452	146,188
NO ENTRENABLES	14,714,688	20,024,384	25,636,712

Tabla 6: Tabla de parámetros finales y modificados de las redes VGG-16, VGG-19, ResNet-50

Para la red de arquitectura YOLOv5x, las imágenes se dejaron en una dimensión de 320 x 320 píxeles, con un tamaño de batch de 32, un kernel de 5 y 100 épocas.

5.1.2 MÉTRICAS DE EVALUACIÓN

En la evaluación del desempeño de las tareas de clasificación de las CNN entrenadas es requisito calificar el funcionamiento mediante la aplicación de los diversos indicadores estadísticos como por ejemplo, los indicadores de Accuracy, Precision (P), Recall (R), f1-score y mean Average Precision (mAP).

En primera instancia, es necesario saber que una matriz de confusión es una herramienta que nos permite evaluar cuán bueno es un modelo de clasificación, comparando valores de predicción contra los valores reales; en una matriz de confusión se muestran el número de imágenes de prueba que han sido clasificados de manera correcta e incorrectamente, dividiéndose en True Positives (TP), False Positives (FP), True Negatives (TN) y False Negatives (FN). En la Figura 42 se muestra un ejemplo de matriz N x N, con los objetos A, B y C; indicando los espacios o celdas a las que corresponderían los (TP), (FP), (TN) y (FN) si se realizara la discriminación en función del objeto A.

		Actual values		
		x	y	z
Predicted values	x	TP	FP	FP
	y	FN	TN	TN
	z	FN	TN	TN

Figura 42: Matriz de confusión N x N, para clasificador multiclase.

Accuracy. La exactitud es la obtención, de forma experimental, de un valor muy cercano al valor real. Para calcular la exactitud del modelo se hace una división de la suma de (TP + TN) entre la suma de (TP + TN + FP + FN).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

Precision (P). La precisión es la obtención de mediciones constantes (iguales) y no dispersas de un mismo fenómeno de estudio. Éste indicador muestra el porcentaje de imágenes de

prueba que fueron correctamente clasificadas por la red. Es el cociente resultante de dividir (TP) entre la suma de (TP + FP).

$$P = \frac{TP}{TP+FP}$$

Recall (R). Es un indicador de sensibilidad que muestra el porcentaje de resultados relevantes que han sido correctamente clasificados, es decir, señala los verdaderos positivos. Corresponde al valor resultante de dividir (TP) entre la suma de (TP + FN).

$$Sensitivity = Recall = \frac{TP}{TP+FN}$$

F1-score. Es un indicador muy utilizado en problemas de clasificación ante bases de datos que no son uniformes y por tanto están desbalanceados. Representa el promedio de precisión dado y se obtiene utilizando los valores de Precision y Recall. resulta de dividir el producto de $(2 \cdot P \cdot R)$ entre la suma de $(P + R)$.

$$F1 = \frac{(2 \cdot P \cdot R)}{P+R}$$

El desempeño de un modelo de detección de objetos como, por ejemplo, en el caso de YOLOv5 puede evaluarse mediante las métricas de Average Precision (AP) y/o mean Average Precision (mAP). (AP) se obtiene de la siguiente fórmula, donde M es el número total de imágenes, P es la precisión, ΔR son los cambios en el Recall y N es el número total de clases:

$$AP = \sum_{m=1}^M (P_m \cdot \Delta R_m)$$

$$mAP = \frac{\sum_{n=1}^N (AP_n)}{N}$$

5.2 ANÁLISIS DE RESULTADOS

Empleando la base de datos generada para entrenar las 4 arquitecturas de CNN seleccionadas para su comparación, se hicieron evidentes las diferencias en cuanto al desempeño de las CNN de acuerdo a los resultados alcanzados por cada una de éstas.

ANN	Precision(%)	Accuracy(%)	R(%)	f1-score	mAP(%)
VGG-16	–	86.07	89	0.8751	–
VGG-19	–	67.03	80.22	0.7303	–
ResNet-50	–	87.76	91.45	0.8956	–
YOLOv5x	97.4	–	99.6	0.93	96.5

Tabla 7: Tabla de indicadores de desempeño en la clasificación

Observando la Tabla 7 se observa que utilizando la CNN de arquitectura VGG-16 se alcanzó un f1-score de 0.8751, un Recall del 89 % y un accuracy del 86.07 % en la correcta identificación de defectos en granos de café verde y cuya curva de desempeño se muestra en la Figura 43.




Figura 43: Gráfica de curva de accuracy del entrenamiento de la red VGG-16 a 100 épocas.

Con la red de arquitectura VGG-19, se obtuvo un f1-score de 0.7303, un Recall del 80.22 % y un accuracy del 67.03 % en la correcta identificación de defectos en granos de café verde y cuya curva de desempeño se muestra en la Figura 44.




Figura 44: Gráfica de curva de accuracy del entrenamiento de la red VGG-19 a 100 épocas.

Con la red ResNet-50 se logró un f1-score de 0.8956, un Recall del 91.45 % y un accuracy del 87.76 % en la correcta identificación de defectos en granos de café verde y cuya curva de desempeño se muestra en la Figura 45.




Figura 45: Gráfica de curva de precisión de la red ResNet-50 a 100 épocas.

Al respecto del desempeño de los modelos VGG-16, VGG-19 y ResNet-50, en la Tabla 8 se aprecian los valores obtenidos respecto a dos indicadores que permiten comparar lo real contra lo obtenido, estos son, el coeficiente de determinación o R²-score, el cual debe ser lo más cercano a 1 y explica la variabilidad existente entre 2 factores relacionados entre sí y el Mean Squared Error (MSE) obtenido de la media de la suma de los errores, los mejores valores deben acercarse al valor 0, e indica variación en los datos; para ambos casos los mejores resultados se obtuvieron con la red ResNet-50 con un R²-score de 0.926 y un MSE de 1.001.

ANN	$R^2 - score$	MSE
VGG-16	0.859	1.381
VGG-19	0.678	2.209
ResNet-50	0.926	1.001

Tabla 8: Tabla con valores r2-score y MSE para el desempeño de las redes VGG-16, VGG-19 y ResNet-50.

de igual forma, para las redes VGG-16, VGG-19 y ResNet-50, en la Figura 46 se presentan las distintas gráficas obtenidas mediante Regresión Lineal, las cuales nos permiten evaluar los

valores reales contra aquellos predcidos por los algoritmos discriminantes o clasificadores.




Figura 46: gráficas de Regresión Lineal para las redes VGG-16, VGG-19 y ResNet-50.

En la implementación de la red convolucional YOLOv5 de arquitectura YOLOv5x, se definieron parámetros como el resize de las imágenes a 320x320 píxeles, un tamaño de muestra o batch de 32 y el número de iteraciones del entrenamiento definida en 100 épocas; la matriz de confusión se muestra en la Figura 47 observándose poca desviación de los resultados en cuanto a la obtención de falsos positivos y falsos negativos.




Figura 47: Matriz de confusión obtenida con la red de arquitectura YOLOv5x.

Con la red YOLOv5x, como se observa en la Tabla 7 se obtuvieron valores del f1-score de 0.93, Recall del 99.6 %, precisión del 97.4 % y mean Average Precision (mAP) del 96.5 % como se observa en las Figuras 48, 49, 50 y 51 respecto a la correcta identificación de defectos en granos de café verde.




Figura 48: curva de precisión obtenidas con YOLO a 100 épocas




Figura 49: Resultados obtenidos en las pruebas de detección, identificación y clasificación de defectos en el café verde.




Figura 50: Resultados obtenidos en las pruebas de detección, identificación y clasificación de defectos en el café verde.



Figura 51: Resultados obtenidos en las pruebas de detección, identificación y clasificación de defectos en el café verde.

5.2.1 INTERFAZ GRÁFICA DEL SISTEMA

La interfaz gráfica o Graphical User Interface (GUI) se elaboró utilizando un programa especializado en ello, llamado Qt Designer® que cuenta con una serie de objetos virtuales que pueden comunicarse con sus objetos pares en el mundo real, algunos de los objetos empleados para la interfaz creada se muestran en la Figura 52 son:

- Labels, para colocar nombres a los diversos elementos, colocar imágenes y video.
- Push buttons y radio buttons, como indicadores o desencadenadores de eventos.
- Line edits y text edits, para el ingreso de texto, según el caso, ya sea por el sistema o por el usuario.




Figura 52: Programa Qt Designer con la ventana principal que conformará la interfaz y los objetos utilizados.

En la Figura 52 se aprecia que se generaron los campos necesarios, acorde a los formatos físicos de información requeridos por la empresa destino, para el manejo y control de las

muestras, siguiendo la lógica de la comunicación entre los elementos de la interfaz y los elementos físicos que permiten el desarrollo del código, mediante lenguaje de programación Python que cuenta con su propio entorno de desarrollo y aprendizaje integrado (IDLE, por sus siglas en inglés). La lógica a seguir inicia tras colocar la muestra en la tolva de alimentación, a partir de lo cual, el usuario tiene que realizar una serie de pasos según lo requiera, dichos pasos son:

- Ingresar el número de identificación de la muestra, pulsando el botón que habilita el campo para ello.
- Escribir el tipo de análisis que se llevará a cabo.
- Visualizar los granos de café verde mediante la primera cámara del sistema.
- Ingresar los valores previamente medidos de Humedad y Densidad.
- Habilitar, si lo requiere, el botón de café pergamino que le indicaría al sistema que se tuvo una muestra inicial de 350 gramos antes de mortearla, debiendo llenar los campos bola, rendimiento y bajo z1 que se encuentran bajo la opción "pergamino".
- Si se trata de una muestra de 250 gramos de granos de café verde limpios, se llenarán los campos correspondientes al cribado z19, z18, z17, z16, z15 y bajo z1.
- Las muestras con un secado poco uniforme, fácilmente detectables a simple vista, se indicarán marcando la opción "muestra veteada".
- Agregar anotaciones durante el proceso de clasificación o después de éste, en el espacio correspondiente.
- Escribir el nombre del especialista que realiza el análisis activando el campo correspondiente y al finalizar esto se presiona el botón ok.
- Cuando el sistema termina la clasificación:
 - Los datos se guardan automáticamente.
 - Se podrá realizar la captura de pantalla con los datos mostrados en la interfaz con el botón captura".

- Acceder a un resumen en una ventana nueva mediante el botón "resumen".
- Realizar un nuevo análisis cargando una nueva muestra en la tolva de alimentación y presionando el botón "nuevo".
- Cerrar todo y salir del sistema con el botón "salir".

Como parte del desarrollo del programa en el IDLE de Python, se emplearon diversas librerías, mostradas en la Figura 53 y enlistadas a continuación:

- La librería sys para funcionalidades de Interprete ventana.
- Para el funcionamiento del sistema y el ambiente QT se utiliza la librería PyQt5 de la cual se importan los módulos de:
 - QtWidgets como QDialog, QMainWindow, QApplication, QWidget, QLineEdit, QRadioButton, QPushButton, QCalendarWidget, QSpinBox, QLabel, QCheckBox, QVBoxLayout, QFileDialog que hacen referencia a los objetos y clases de la ventana de la interfaz, QtCore con todos sus módulos, QtGui de la que a su vez se importan los módulos QIcon, QPixmap, QScreen, además de algunos módulos como QtPrintSupport, QPrinter, QPrintDialog, QTextDocumentWriter, csv y xlswriter.
- La librería datetime.
- La librería pandas con su módulo PandasModel.
- La librería openCV.

```

1  # Libreria para funcionalidades de interprete ventana
2  import sys # Librerias del sistema
3  from PyQt5 import QtGui
4  #Librerias ambiente QT
5  import PyQt5
6  from PyQt5.QtWidgets import *
7  from PyQt5 import QtCore
8  #from PyQt5.QtGui import QIcon, QPixmap, QScreen
9  from PyQt5.QtGui import *
10 from PyQt5.QtCore import *
11 #Referencia a la clase de la ventana
12 from PyQt5.QtWidgets import QDialog, QMainWindow, QApplication,
13 QWidget, QLineEdit, QRadioButton, QPushButton, QCalendarWidget,
14 QSpinBox, QLabel, QCheckBox, QVBoxLayout, QFileDialog
15 from PyQt5.QtPrintSupport import QPrinter, QPrintDialog
16 from PyQt5.QtGui import QTextDocumentWriter
17 import csv
18 import xlswriter
19 from datetime import datetime
20 import pandas as pd
21 from PandasModel import PandasModel
22 import cv2
23
24 # Importar la Interfaz gráfica de QT
25 from mainwindow_auto import *
26 from ventana2_auto import *
27
28 # Variables globales
29 Id=0
30 Den=0
31 Hum=0
32 Date=""
33 Obs=""
34 Cal=""
35 Vet=""
36 Exp=""
37 #Variables globales que ocupará la CNN para los defectos
38 Ag=0
39 Agp=0
40 Br=0
41 Cas=0
42 Con=0
43 Cor=0
44 He=0
45 Mon=0
46 N=0
47 Np=0
48 Or=0
49 Tri=0
50 #####
51 # Generar la venta principal
52 class VentanaPrincipal(QMainWindow): # Ventana principal
53     def __init__(self, parent=None):
54         super(VentanaPrincipal, self).__init__(parent)
55         self.InitUI()

```

Figura 53: Fragmento del código generado para el control de la interfaz gráfica, donde se aprecian las librerías, variables globales y la inicialización de la ventana principal.

Se importan además las ventanas principal y secundaria generadas en el programa QtDesigner®, para mandarlas a llamar y programarlas según lo requerido. En la Figura 54 se observa el resultado final obtenido.

ID DE LA MUESTRA 1111 **TIPO DE ANÁLISIS**

DENSIDAD 1 0.00 HUMEDAD 1 0.00
 DENSIDAD 2 0.00 HUMEDAD 2 0.00
 DENSIDAD 3 0.00 HUMEDAD 3 0.00
 DENSIDAD PROMEDIO g/cc HUMEDAD PROMEDIO %

CONTEO / PESO POR MUESTRA

AGRIO BROCA MONSTRUO g BOLA
 AGRIO PARCIAL HELADOS CONCHA g RENDIMIENTO
 NEGRO CARACOLILLO g OREJA g BAJO Z1
 NEGRO PARCIAL TRIÁNGULO g CORTADOS/MORDIDOS/PARTIDOS g

☐ MUESTRA VETEADA

CALIFICACIÓN

OBSERVACIONES

18/10/2023

ANALIZADO POR: OK
 CAPTURA RESUMEN NUEVO **SALIR**

Figura 54: GUI final basada en los datos requeridos por la empresa.

CONCLUSIONES

Se cumplieron los objetivos planteados, siendo uno de ellos la determinación de las variables de interés, las cuales fueron identificadas y empleadas por la CNN en su proceso de aprendizaje, es decir, mediante la extracción de características; y posteriormente estas características distintivas de cada una de las 12 clases seleccionadas fueron la base del sistema de reconocimiento y clasificación (software) desarrollado en lenguaje de programación Python.

Otro de los objetivos paralelo al desarrollo del software clasificador y la generación de la interfaz de usuario utilizando Qt Designer®, fue el diseño y construcción del prototipo mecánico de dimensiones reducidas, adecuadas para su implementación en un laboratorio de control de calidad, dicho dispositivo mecánico está compuesto por una tolva, una sección de distribución de granos, una sección de engranaje es impulsada por 2 motorreductores, la sección de transporte por rodillos en donde se realizaron las capturas de imágenes para la identificación y clasificación de las muestras y una sección de recolección; en dicho prototipo se agregaron además la SBC Raspberry pi 4, 2 cámaras USB Arducam de 16 megapíxeles con autoenfoco, un hub multipuertos, una pantalla touch de 10.1 pulgadas y luces led.

Después de un amplio análisis de los dispositivos clasificadores existentes, así como los artículos revisados al respecto, se coincide sobre las grandes ventajas en el empleo de sistemas clasificadores basados en técnicas de Visión Artificial e Inteligencia Artificial por sobre aquellos que únicamente se basan en la clasificación por color.

Otro de los objetivos se logró tras crear una base de datos de imágenes de granos de café verde con 11 clases pertenecientes a los defectos agrio, broca, caracolillo, concha, elefante, helado, negro, oreja, partido, seca y triángulo; así como una clase número 12 perteneciente a los granos de café normales. Se hace hincapié en el tamaño de la base de datos, que debe ser del mayor tamaño posible, pues al haberse empleado redes preentrenadas específicas para grandes cargas de datos de imágenes como VGG-16, VGG-19 y ResNet-50, se obtendrán mejores resultados a con cantidades de datos mucho mayores a la empleada en este proyecto.

Por último, comparando los resultados obtenidos tras los entrenamientos y puesta en marcha del sistema de clasificación de defectos, en cuanto a su desempeño, con el empleo de la red

VGG-16 se logró una exactitud del 86.07 %, con la red VGG-19 una exactitud del 67.03 %, con la red ResNet-50 una exactitud del 87.76 % y finalmente, el mejor resultado se logró implementando la red yolov5x, logrando una precisión del 97.4 % y alcanzando un mAP del 96.5 %.

RECOMENDACIONES

Con la finalidad de mejorar el prototipo presentado, se hacen las siguientes recomendaciones:

- Elaborar una base de datos de imágenes de grandes dimensiones, ya que, de acuerdo a lo investigado, se obtienen mejores resultados con bases de datos bastas de por lo menos 10,000 a 20,000 usando redes preentrenadas y residuales.
- Emplear las versiones de YOLO más recientes como YOLOv7 y YOLOv8 que también hacen uso de la librería Torch.
- Ampliar el número de clases de defectos por identificar, buscando abarcar todos los defectos de la guía de la SCA.
- en el prototipo, aumentar el número de granos de café que se puedan evaluar en el mismo ciclo para reducir tiempo de clasificación.
- Ingresar fórmulas con los criterios de evaluación y clasificación propios de cada variedad de café, los distintos procesos del beneficio y variables relacionadas a la región del café, con la finalidad de brindar un resultado interpretado más exhaustivo, con mayor exactitud y precisión en la detección y clasificación de la mancha del café.
- Agregar al sistema sensores de medición de humedad en la muestra y de peso (de cada grano de café), para incluir los datos finales en el reporte.
- Por último, escalar el prototipo, para analizar mayores volúmenes de muestras, enfocándose ahora en las grandes empresas productoras de café.

REFERENCIAS BIBLIOGRÁFICAS

- Aguayo, P., Torres, E., & Torres, A. (2004). Introducción Al Microcontrolador. *Accelerated Academy*, 16.
- Ángel, A. E. L. (2022). Análisis de algoritmos de visión para la detección de aves de corral mediante redes neuronales convolucionales. Analysis of vision algorithms for poultry detection using convolutional neural networks. *Journal CIM*, 10, 10-19.
- Arboleda, E., Fajardo, A., & Medina, R. (2020). Green coffee beans feature extractor using image processing. *Telkomnika (Telecommunication Computing Electronics and Control)*, 18(4), 2007-2034. <https://doi.org/10.12928/TELKOMNIKA.V18I4.13968>
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. EAI/Springer. https://doi.org/10.1007/978-3-030-57077-4_11
- Calvo, D. (2017, 20 de julio). *Red Neuronal Convolucional CNN*. Consultado el 18 de marzo de 2022, desde <https://www.diegocalvo.es/red-neuronal-convolucional/>
- Cantú, D., & Mushinskie, K. (2020). *Guía de defectos del café* (Vol. 2). United Nations Coffee Company S.A. de C.V.
- Carrillo, E., & Peñaloza, A. A. (2009). Artificial vision to assure coffee-excelso beans quality. *Proceedings of the 2009 Euro American Conference on Telematics and Information Systems: New Opportunities to Increase Digital Citizenship, EATIS '09*, (35), 1-8. <https://doi.org/10.1145/1551722.1551757>
- Condori, R. M., Humari, J. H., Zambrano, C. P., Cáceres, J. C. G., & Castañón, C. A. B. (2014). Automatic classification of physical defects in green coffee beans using CGLCM and SVM. *Proceedings of the 2014 Latin American Computing Conference, CLEI 2014*, 1-9. <https://doi.org/10.1109/CLEI.2014.6965169>
- de Jesús Beleño Saenz, K., Pérez, J. C. H., Ortiz, S. M. M., Llano, G. E. M., & Pérez, J. S. B. (2016). Clasificación de los frutos de café según su estado de maduración y detección de la broca mediante técnicas de procesamiento de imágenes. *Prospectiva*, 14(1), 15-22. <https://doi.org/10.15665/rp.v14i1.640>
- Dopico, J. R., Calle, J., & Sierra, A. (2016). *Encyclopedia of Artificial Intelligence* (Vol. 2). Information Science Reference.

- Dos-Santos, F. F. L., Rosas, J. T. F., Martins, R. N., de Moura Araújo, G., de Arruda Viana, L., & de Paula Gonçalves, J. (2020). Quality assessment of coffee beans through computer vision and machine learning algorithms. *Coffee Science*, 15, 1-9. <https://doi.org/10.25186/v15i.1752>
- Eustaquio, W. R., & Jr., J. L. D. (2020). Artificial neural network for classification of immature and mature coffee beans using rgb values. *International Journal of Emerging Trends in Engineering Research*, 8(8), 4301-4305. <https://doi.org/10.30534/ijeter/2020/41882020>
- Funk, B. (2019, 24 de junio). *Raspberry Pi 4 sports a faster SoC and dual displays for \$35*. Consultado el 9 de marzo de 2022, desde <https://techreport.com/news/34650/raspberry-pi-4-sports-a-faster-soc-and-dual-displays-for-35/>
- García, M., Candelo-Becerra, J. E., & Hoyos, F. E. (2019). Quality and defect inspection of green coffee beans using a computer vision system. *Applied Sciences*, 9(19), 2-5.
- Gope, H. L., & Fukai, H. (2020). Normal and Peaberry Coffee Beans Classification from Green Coffee Bean Images Using Convolutional Neural Networks and Support Vector Machine. *International Journal of Computer and Information Engineering*, 14(6), 189-196.
- Herrera, J., Medina, S., de J. Beleño, K., & Gualdrón, O. (2016). Diseño de un sistema automático de selección de frutos de café mediante técnicas de visión artificial. *Revista UIS Ingenierías*, 15(1), 7-14. <https://doi.org/10.18273/revuin.v15n1-2016001>
- Huang, N. F., Chou, D. L., & Lee, C. A. (2019). Real-Time Classification of Green Coffee Beans by Using a Convolutional Neural Network. *2019 3rd International Conference on Imaging, Signal Processing and Communication, ICISPC 2019*, 107-111. <https://doi.org/10.1109/ICISPC.2019.8935644>
- Immune, T. I. (2022, 17 de marzo). *Librerías de Python, ¿qué son y cuáles son las mejores?* Consultado el 3 de mayo de 2022, desde <https://immune.institute/blog/librerias-python-que-son/>
- Marín, R. (2020, 12 de febrero). *¿Qué es OpenCV? Instalación en Python y ejemplos básicos*. Consultado el 25 de mayo de 2022, desde <https://www.inesem.es/revistadigital/informatica-y-tics/opencv/>

- Matich, D. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Universidad Tecnológica Nacional.
- Neapolitan, R. E., & Jiang, X. (2018). *Artificial intelligence With An Intro To ML* (R. V. Yampolskiy, Ed.; 2.^a ed.). CRC, Chapman Hall.
- Pino-Díez, R., Gómez-Gómez, A., & de Abajo-Martínez, N. (2001). *Introducción a la Inteligencia Artificial: Sistemas expertos, Redes Neuronales artificiales y computación evolutiva*. Servicio de Publicaciones, Universidad de Oviedo.
- Pinto, C., Furukawa, J., Fukai, H., & Tamura, S. (2017). Classification of Green coffee bean images basec on defect types using convolutional neural network (CNN). *Proceedings - 2017 International Conference on Advanced Informatics: Concepts, Theory and Applications, ICAICTA 2017*. <https://doi.org/10.1109/ICAICTA.2017.8090980>
- Portugal-Zambrano, C. E., Gutiérrez-Cáceres, J. C., Ramirez-Ticona, J., & Beltrán-Castañón, C. A. (2017). Computer vision grading system for physical quality evaluation of green coffee beans. <https://doi.org/10.1109/CLEI.2016.7833383>
- Prieto, F., & Hernández, J. (2005). Clasificación de Granos de Café usando FPGA. *Ingeniería Y Competitividad*, 7(2), 35-42. <https://doi.org/10.25100/iyv.v7i2.2516>
- Puerta, G. I. (2000). Beneficie Correctamente Su Café Y Conserve La Calidad De La Bebida. *Cenicafé*. <https://www.cenicafe.org/es/publications/avt0276.pdf>
- Python.org. (2001). *Python*. Consultado en 2022, desde <https://www.python.org/>
- Raspberry.org. (2021). *Raspberry Pi 4 Computer Model B: Product Brief*. <https://datasheets.raspberrypi.com/rpi4/raspberry-pi-4-product-brief.pdf>
- Rodríguez, J. A., & Ferraris, D. L. (2010). *Fundamentos de informática y programación en C*. Ediciones Paraninfo, S.A.
- Rosebrock, A. (2019). *Deep Learning for Computer Vision with Python, practitioner bundle* (1.^a ed.). PyImageSearch.
- Salazar, M., Riaño-Herrera, N., Arcila-pulgarín, J., & Ponce-D, C. (1994). Estudio morfológico anatómico y ultraestructural del fruto de café *Coffea arabica* L. *Cenicafé*, 45(3), 93-105. <https://biblioteca.cenicafe.org/bitstream/10778/795/1/arc045%2803%2993-105.pdf>

- SCA, S. C. A. (2019). *El café Arábica lavado Guía de defectos del café verde* (3.ª ed.). SCA. https://bootcoffee.com/wp-content/uploads/2019/09/SCA_The-Arabica-Green-Coffee-Defect-Guide_Spanish_updated.pdf.
- Serrano-Fuentes, M., Lizardo-Zelaya, N. A., & Ordoñez-Ávila, J. L. (2020). Coffee Fruit Recognition Using Artificial Vision and neural NETWORKS. *2020 the 5th International Conference on Control and Robotics Engineering (ICCRE)*, 224-228.
- SIAP. (2023). Escenario mensual de productos agroalimentarios. *Gobierno de México, SIAP*.
- Susanibar, G., Ramirez, J., Sanchez, J., Ramirez, R., & Arroyo, D. (2021). Development of an Automated Machine for Green Coffee Beans Classification by Size and Defects. *Journal of Advanced Agricultural Technologies*, 8(1), 17-24. <https://doi.org/10.18178/joaat.8.1.17-24>
- Tamayo-Monsalve, M. A., Mercado-Ruiz, E., Villa-Pulgarin, J. P., Bravo-Ortíz, M. A., Arteaga-Arteaga, H. B., Mora-Rubio, A., Alzate-Grisales, J. A., Arias-Garzon, D., Romero-Cano, V., Orozco-Arias, S., Osorio, G., & Tabares-Soto, R. (2022). Coffee Maturity Classification Using Convolutional Neural Networks and Transfer Learning. *IEEE Access*, 10, 42971-42982.
- Taquía-Gutiérrez, J. A. (2017). El procesamiento de imágenes y su potencial aplicación en empresas con estrategia digital. *Interfases*, (10), 11-29. <http://repositorio.ulima.edu.pe/handle/ulima/5416>
- Turi, B., Abebe, G., & Goro, G. (2013). Classification of Ethiopian Coffee Beans Using Imaging Techniques. *East African Journal of Sciences*, 7(1), 1-10.
- Ubuntu-mate.org. (2022). *Ubuntu Mate*. Consultado en 2022, desde <https://ubuntu-mate.org/about/>
- Wang, P., Tseng, H. W., Chen, T. C., & Hsia, C. H. (2021). Deep convolutional neural network for coffee bean inspection. *Sensors and Materials*, 33(7), 2299-2310. <https://doi.org/10.18494/SAM.2021.3277>
- Zulma, L., Sandoval, N., & Ortiz, F. A. P. (2007). Caracterización de café cereza empleando técnicas de visión artificial. *Revista Facultad Nacional de Agronomía Medellín*, 60(2), 4105-4127. <http://www.redalyc.org/pdf/1799/179914078015.pdf>


ANEXOS

Anexo A. Fragmento del código donde se reemplazan y modifican algunas capas del modelo de red VGG-16 comparadas en las tablas inferiores.

```
custom_model = Model(image_input, out)
custom_model.summary()
for layer in custom_model.layers[:-3]:
    layer.trainable = False
```

Model: "vgg-16"

Layer (type)	Output Shape	Param #
=====		
fc1 (Dense)	(None, 4096)	102764544
fc2 (Dense)	(None, 4096)	16781312
predictions (Dense)	(None, 1000)	4097000
=====		
Total params: 138,357,544		
Trainable params: 138,357,544		
Non-trainable params: 0		



Model: "vgg-16_modificada"

Layer (type)	Output Shape	Param #
=====		
fc1 (Dense)	(None, 128)	3211392
fc2 (Dense)	(None, 128)	16512
output (Dense)	(None, 12)	1548
=====		
Total params: 17,944,140		
Trainable params: 3,229,452		
Non-trainable params: 14,714,688		


Anexo B. Fragmento del código donde se reemplazan y modifican algunas capas del modelo de red VGG-19 comparadas en las tablas inferiores.

```
out = Dense(num_classes, activation='softmax', name='output')(x)
custom_model = Model(image_input, out)
custom_model.summary()
for layer in custom_model.layers[:-6]:
    layer.trainable = False
```

Model: "vgg-19"

Layer (type)	Output Shape	Param #
fc1 (Dense)	(None, 4096)	102764544
fc2 (Dense)	(None, 4096)	16781312
predictions (Dense)	(None, 1000)	4097000

=====
Total params: 143,667,240
Trainable params: 143,667,240
Non-trainable params: 0




Model: "vgg-19_modificada"

Layer (type)	Output Shape	Param #
flatten (Flatten)	(None, 25088)	0
fc1 (Dense)	(None, 128)	3211392
dropout (Dropout)	(None, 128)	0
fc2 (Dense)	(None, 128)	16512
dropout_1 (Dropout)	(None, 128)	0
output (Dense)	(None, 12)	1548

=====
Total params: 23,253,836
Trainable params: 3,229,452
Non-trainable params: 20,024,384

Anexo C. Fragmento del código donde se reemplazan y modifican algunas capas del modelo de red ResNet-50 y tabla con parámetros obtenidos con las 6 capas nuevas modificadas, agregadas a la arquitectura de la red.

```
out = Dense(num_classes, activation='softmax', name='output')(x)
custom_model = Model(image_input, out)
custom_model.summary()
for layer in custom_model.layers[:-6]:
    layer.trainable = True
```



Model: "ResNet-50_modificado"

Layer (type)	Output Shape	Param #
=====		
flatten (Flatten)	[(None, 100352)]	0
fc1 (Dense)	[(None, 128)]	1284518
dropout (Dropout)	[(None, 128)]	0
fc2 (Dense)	[(None, 128)]	16512
dropout_1 (Dropout)	[(None, 128)]	0
output (Dense)	[(None, 12)]	1548
=====		
Total params: 36,450,956		
Trainable params: 12,863,244		
Non-trainable params: 23,587,712		