



Universidad
Norbert Wiener

Powered by **Arizona State University**

FACULTAD DE INGENIERÍA Y NEGOCIOS
PROGRAMA ACADÉMICO DE INGENIERÍA DE SISTEMAS
E INFORMÁTICA

Tesis

Modelo de reconocimiento visual para identificar enfermedades del cultivo de
café en la comunidad de Tacalpo, Ayabaca, Piura 2024

Para optar el Título Profesional de
Ingeniero de Sistemas e Informática

Presentado por:

Autor: Jaramillo Castillo, Denilson


Código ORCID: <https://orcid.org/0009-0006-3904-6155>

Asesora: Mg. Menacho Navarrete, Karem

Código ORCID: <https://orcid.org/0000-0002-9677-5542>

Lima – Perú

2025

 Universidad Norbert Wiener	DECLARACIÓN JURADA DE AUTORIA Y DE ORIGINALIDAD DEL TRABAJO DE INVESTIGACIÓN	
	CÓDIGO: UPNW-GRA-FOR-033	VERSIÓN: 01 REVISIÓN: 01

Yo, Denilson Jaramillo Castillo egresado de la Facultad de **Ingeniería y Negocios**, Escuela Académica Profesional de **Ingenierías** de la Universidad privada Norbert Wiener declaro que el trabajo de investigación “Modelo de reconocimiento visual para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.” Asesorado por el docente: Karem Menacho Navarrete, DNI 24002602 ORCID: 0000-0002-9677-5542, tiene un índice de similitud de **16 (dieciséis) %** con código oid:14912:424164299 verificable en el reporte de originalidad del software Turnitin.


Así mismo:

1. Se ha mencionado todas las fuentes utilizadas, identificando correctamente las citas textuales o paráfrasis provenientes de otras fuentes.
2. No he utilizado ninguna otra fuente distinta de aquella señalada en el trabajo.
3. Se autoriza que el trabajo puede ser revisado en búsqueda de plagios.
4. El porcentaje señalado es el mismo que arrojó al momento de indexar, grabar o hacer el depósito en el turnitin de la universidad y,
5. Asumimos la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión en la información aportada, por lo cual nos sometemos a lo dispuesto en las normas del reglamento vigente de la universidad.



.....
 Firma de autor 1
 Denilson Jaramillo Castillo
 DNI: 76131029

.....
 Firma de autor 2
 Nombres y apellidos del Egresado
 DNI:



Firma
 Karem Menacho Navarrete
 DNI: 24002602

Lima, 20 de enero de 2025

**Modelo de reconocimiento visual para identificar enfermedades del cultivo de café en la
comunidad de Tacalpo, Ayabaca, Piura 2024.**

Dedicatoria

El presente trabajo de investigación está dedicado con gratitud y cariño a mis padres y hermanos, quienes, con su ejemplo y apoyo incondicional, me inculcaron valores fundamentales como la responsabilidad, la perseverancia y el amor por lo que hago. Su guía y enseñanza han sido pilares esenciales en cada paso de este camino.

Agradecimiento

Agradezco en primer lugar a Dios por darme un día más de vida y el aliento para seguir mis sueños.

A la Universidad Norbert Wiener y sus profesores por todos los conocimientos brindados.

A mis padres y hermanos por su apoyo y motivación.

A mi asesora por su paciencia y guiarme en este proceso.

Índice General

Portada	1
Título.....	2
Dedicatoria.....	3
Agradecimiento.....	4
Índice de Tablas	7
Índice de Figuras.....	9
Introducción	14
CAPÍTULO I: EL PROBLEMA.....	1
1.1 Planteamiento del problema.....	1
1.2 Formulación del problema	5
1.2.1 Problema general	5
1.2.2 Problemas específicos.....	5
1.3 Objetivos de la investigación	5
1.3.1 Objetivo general.....	5
1.3.2 Objetivos específicos	6
1.4 Justificación de la investigación	6
1.4.1 Teórica	6
1.4.2 Metodológica	6
1.4.3 Práctica.....	7
1.5 Limitaciones de la investigación.....	7
CAPÍTULO II: MARCO TEÓRICO	9
2.1 Antecedentes de la investigación	9
2.2 Bases teóricas.....	13
2.3 Formulación de hipótesis	27
2.3.1 Hipótesis general.....	27
2.3.2 Hipótesis específicas.....	27
CAPÍTULO III: METODOLOGÍA	28
3.1. Método de investigación	28
3.2. Enfoque investigativo	28

3.3. Tipo de investigación.....	28
3.4. Diseño de la investigación	28
3.5. Población, muestra y muestreo	28
3.6. Variables y operacionalización	30
3.7. Técnicas e instrumentos de recolección de datos	31
3.7.1. Técnica.....	31
3.7.2. Descripción	31
3.7.3. Validación.....	33
3.7.4. Confiabilidad.....	34
3.8. Procesamiento y análisis de datos.....	36
3.9. Aspectos éticos.....	36
CAPÍTULO IV: PRESENTACIÓN Y DISCUSIÓN DE LOS RESULTADOS	37
4.1 Resultados.....	37
4.1.1. Análisis descriptivo de resultados.....	38
4.1.2. Prueba de hipótesis	47
4.1.3. Discusión de resultados.....	54
CAPÍTULO V: CONCLUSIONES Y RECOMENDACIONES.....	55
5.1 Conclusiones.....	55
5.2 Recomendaciones	56
REFERENCIAS.....	57
ANEXOS	67
Anexo 1: Matriz de consistencia.....	67
Anexo 2: Instrumentos.....	69
Anexo 3: Validez del instrumento	91
Anexo 4: Confiabilidad del instrumento.....	99
Anexo 5: Aprobación del Comité de Ética	100
Anexo 6: Formato de consentimiento informado	101
Anexo 7: Informe del asesor de turnitin	102

Índice de Tablas

Tabla 1 Matriz de confusión	18
Tabla 2 Distribución de las hojas de café para la muestra.	30
Tabla 3 Variables y operacionalización.	30
Tabla 4 Expertos que validaron los instrumentos.	33
Tabla 5 Test – retest del resultado generado por el modelo.....	34
Tabla 6 Test – retest del tiempo tomado por el modelo para dar una respuesta.	35
Tabla 7 Resultados del modelo vs los especialistas.	37
Tabla 8 Validación de resultados.	38
Tabla 9 Tabla de frecuencias de contrastación de resultados entre el modelo y el especialista para la enfermedad antracnosis.	39
Tabla 10 Tabla de frecuencias de contrastación de resultados entre el modelo y el especialista para la enfermedad ojo de gallo.	40
Tabla 11 Tabla de frecuencias de contrastación de resultados entre el modelo y el especialista para la enfermedad roya amarilla.....	41
Tabla 12 Tabla de frecuencias de contrastación de resultados entre el modelo y el especialista para hojas sanas.....	42
Tabla 13 Tabla de frecuencias general de contrastación de resultados entre el modelo y el especialista.	43
Tabla 14 Matriz de confusión del modelo de reconocimiento visual.	44
Tabla 15 Métricas de desempeño del modelo de reconocimiento visual.....	44
Tabla 16 Efectividad del modelo para identificar enfermedades del cultivo de café.	46

Tabla 17 Tiempo promedio (tiempo en segundos) para identificar enfermedades del cultivo de café.....	46
Tabla 18 Consolidado del indicador efectividad del modelo y tipo promedio en la identificación.	47
Tabla 19 Indicadores del pre test y post test.	48
Tabla 20 Pruebas de normalidad de los indicadores efectividad del modelo y tipo promedio en la identificación en pre y post test.	49
Tabla 21 Test de Wilcoxon – Nivel de efectividad para identificar enfermedades en el cultivo de café.....	50
Tabla 22 Prueba de rangos – Nivel de efectividad para identificar enfermedades en el cultivo de café.....	51
Tabla 23 Test de Wilcoxon – Tiempo promedio para identificar enfermedades en el cultivo de café.....	52
Tabla 24 Prueba de rangos – Tiempo promedio para identificar enfermedades en el cultivo de café.....	53
Tabla 25 Confiabilidad del instrumento según el coeficiente alfa de Cronbach	99
Tabla 26 Presupuesto del proyecto	104
Tabla 27 Imágenes tomadas para el entrenamiento del modelo	106
Tabla 28 Requerimientos funcionales.....	117
Tabla 29 Requerimientos no funcionales.....	117
Tabla 30 Caso de pruebas tomar fotografía	137
Tabla 31 Caso de pruebas mostrar resultados de la predicción	138

Índice de Figuras

Figura 1 Diagrama de Ishikawa.....	4
Figura 2 Formato de la encuesta para realizar la identificación de enfermedades con los especialistas.....	32
Figura 3 Formato de la ficha de observación para comparar resultados del modelo con la respuesta del especialista.	33
Figura 4 Gráfico de contrastación de resultados entre el modelo y el especialista para la enfermedad antracnosis.....	39
Figura 5 Gráfico de contrastación de resultados entre el modelo y el especialista para la enfermedad ojo de gallo.....	40
Figura 6 Gráfico de contrastación de resultados entre el modelo y el especialista para la enfermedad roya amarilla.	41
Figura 7 Gráfico de contrastación de resultados entre el modelo y el especialista para hojas sanas.....	42
Figura 8 Gráfico de contrastación general de resultados entre el modelo y el especialista.....	43
Figura 9 Rendimiento del modelo de reconocimiento visual - Curva ROC.....	45
Figura 10 Cuestionario aplicado a los especialistas y agricultores.....	69
Figura 11 Respuestas del cuestionario aplicado a los agricultores.....	86
Figura 12 Respuestas del cuestionario aplicado a los especialistas.....	87
Figura 13 Ficha de observación del Pre Test.....	88
Figura 14 Ficha de observación del Post Test.....	89
Figura 15 Ficha de observación del Retest.....	90
Figura 16 Diagrama de actividades del proyecto.....	105

Figura 17 Interfaz para crear un nuevo grupo de recursos en Custom Vision Azure.....	107
Figura 18 Interfaz para crear un nuevo recurso en Custom Vision Azure	107
Figura 19 Interfaz para crear un nuevo proyecto en Custom Vision Azure	108
Figura 20 Interfaz para subir las imágenes de entrenamiento al proyecto creado en Custom Vision Azure	110
Figura 21 Interfaz para entrenar el modelo en Custom Vision Azure	111
Figura 22 Métricas de desempeño del modelo después del entrenamiento en Custom Vision Azure.....	112
Figura 23 Rendimiento del modelo por etiqueta en Custom Vision Azure.....	112
Figura 24 Interfaz para hacer las pruebas con nuevos datos desde Custom Vision Azure.....	113
Figura 25 Interfaz para publicar el modelo desde Custom Vision Azure.....	114
Figura 26 Diagrama de entidades del negocio.....	115
Figura 27 Diagrama de actividades del negocio.....	115
Figura 28 Diagrama de secuencia del negocio.	116
Figura 29 Diagrama de comunicación del negocio.	116
Figura 30 Diagrama general de casos de uso del sistema.....	118
Figura 31 Prototipo para el caso de uso tomar imagen.....	120
Figura 32 Prototipo para el caso de uso consultar modelo	121
Figura 33 Prototipo para el caso de uso mostrar predicción.....	122
Figura 34 Boundaries del sistema.....	123
Figura 35 Controles del sistema.....	123
Figura 36 Entidades del sistema	124
Figura 37 Diagrama de actividades del caso de uso tomar imagen.....	124

Figura 38 Diagrama de actividades del caso de uso consultar modelo.	125
Figura 39 Diagrama de actividades del caso de uso mostrar predicción.	125
Figura 40 Diagrama de secuencia del caso de uso tomar imagen.	126
Figura 41 Diagrama de secuencia del caso de uso consultar modelo.	126
Figura 42 Diagrama de secuencia del caso de uso mostrar predicción.	126
Figura 43 Diagrama de comunicación del caso de uso tomar imagen.	127
Figura 44 Diagrama de comunicación del caso de uso consultar modelo.	127
Figura 45 Diagrama de comunicación del caso de uso mostrar predicción.	128
Figura 46 Diagrama de clase del sistema.	128
Figura 47 Código fuente de la interfaz de bienvenida.	129
Figura 48 Método para capturar la imagen desde la cámara del teléfono.	129
Figura 49 Método onActivityResult.	130
Figura 50 Método para ejecutar el API del modelo.	130
Figura 51 Método para enviar la imagen al modelo y generar la predicción.	131
Figura 52 Código fuente de la interfaz mostrar resultados.	132
Figura 53 Diagrama de integración del sistema con el modelo.	133
Figura 54 Interfaz de bienvenida del sistema.	134
Figura 55 Interfaz analizar del sistema.	134
Figura 56 Interfaz tomar foto del sistema.	135
Figura 57 Interfaz Confirmar fotografía del sistema.	135
Figura 58 Interfaz mostrar resultados.	136
Figura 59 Diagrama de actividades plan de capacitación.	141

Resumen

Este estudio tuvo como objetivo determinar como el modelo de reconocimiento visual permite identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024. La metodología utilizada fue de enfoque cuantitativo, de tipo aplicada y de diseño experimental. Asimismo, la muestra de esta investigación estuvo conformada por 42 plantas de café. Los instrumentos para la recolección de datos fueron el cuestionario y la ficha de observación para los indicadores, efectividad del modelo y tiempo promedio en la identificación. Se usó estadística descriptiva para analizar los datos, dando como resultado para el primer indicador una media de 71.4% en el pre-test y un 90.48% en el post-test. Del mismo modo, para el segundo indicador una media de 90.36 segundos en el pre-test y unos 2.89 segundos en el post-test. También, se empleó la estadística inferencial con la prueba de Shapiro-Wilk porque la muestra es inferior a 50. Los resultados para ambos indicadores fueron Sig. < 0.05, indicando una distribución no paramétrica. Por lo cual se empleó la prueba de Wilcoxon y la prueba de rangos obteniendo los siguientes resultados: Para el primer indicador $z=-4,512^b$ y sig <.001, para el segundo indicador $z=-5,709^b$ y sig <.001. Finalmente, se concluyó que mediante el modelo de reconocimiento visual se optimiza la efectividad en identificar enfermedades en un 19.08% y se reduce el tiempo promedio en identificar enfermedades en un 96.8%.

Palabras clave: Modelo, enfermedad, café, efectividad, tiempo.

Abstract

This study aimed to determine how the visual recognition model enables the identification of coffee crop diseases in the community of Tacalpo, Ayabaca, Piura, 2024. The methodology used was quantitative in approach, applied in nature, and experimental in design. Likewise, the sample for this research consisted of 42 coffee plants. The instruments for data collection were a questionnaire and an observation sheet, focusing on two indicators: model effectiveness and average identification time. Descriptive statistics were used to analyze the data, yielding a mean of 71.4% in the pre-test and 90.48% in the post-test for the first indicator. Similarly, for the second indicator, the mean was 90.36 seconds in the pre-test and 2.89 seconds in the post-test. Inferential statistics were also employed, using the Shapiro-Wilk test due to the sample size being less than 50. Results for both indicators showed $\text{Sig.} < 0.05$, indicating a non-parametric distribution. Consequently, the Wilcoxon test and rank test were applied, yielding the following results: for the first indicator, $z = -4.512b$ and $\text{Sig.} < .001$, and for the second indicator, $z = -5.709b$ and $\text{Sig.} < .001$. Finally, it was concluded that the visual recognition model improves effectiveness in identifying diseases by 19.08% and reduces the average identification time by 96.8%.

Keywords: Model, disease, coffee, effectiveness, time.

Introducción

El propósito de esta investigación fue determinar como un modelo de reconocimiento visual permite identificar enfermedades del cultivo de café en la comunidad de Tacalpo. Debido a que se identificó como principal problema la dificultad de los agricultores para realizar dicho proceso. Asimismo, el trabajo se compila en los siguientes capítulos:

En el **CAPÍTULO I**: Se plasmó el planteamiento y formulación del problema, así como los objetivos, la justificación y las limitaciones de la investigación.

En el **CAPÍTULO II**: Se describió los antecedentes tanto internacionales como nacionales, las bases teóricas y a formulación de hipótesis.

En el **CAPÍTULO III**: Presenta el método, enfoque, tipo y diseño de la investigación, también se describe la población, muestra y muestreo. Del mismo modo, la operacionalización de la variable, las técnica e instrumento de recolección de los datos. Finalmente, se detalló el procesamiento y análisis de datos, al igual que los aspectos éticos.

En el **CAPÍTULO IV**: Se empleó la estadística descriptiva e inferencial para el análisis, presentación, interpretación y contrastación de resultados.

En el **CAPÍTULO V**: Se incluyen las conclusiones, y recomendación.

CAPÍTULO I: EL PROBLEMA

1.1 Planteamiento del problema

A nivel mundial la Organización de las Naciones Unidas para la Alimentación y la Agricultura FAO (2022) argumenta que la presencia de plagas y enfermedades en las plantaciones agrícolas inducen daños que pueden llegar inclusive al 40% en la producción de alimentos lo cual agrava el aumento del hambre mundial y amenaza las fuentes de ingreso de las personas rurales. De la misma manera, se manifiesta que, en función a los costos y tiempos, resulta más eficaz proteger a las plantas de plagas y enfermedades que enfrentarse a una emergencia fitosanitaria, ya que esta, una vez establecida, resulta imposible erradicar.

Según FAO (2024) desde hace 30 años se calcula una pérdida de 3,8 billones de dólares solo en actividades agrícolas y pecuarias por causa de la inestabilidad del clima, la administración no sostenible de la tierra, daños ecológicos, entre otros. Esto conlleva una pérdida de 23,000 millones de dólares anuales, representado por el 5% del PBI mundial anual. Asimismo, este estudio concluyó que, si se desea implementar medidas de prevención y de resiliencia, las familias rurales resultan ganando 7 dólares por cada dólar invertido.

En Latinoamérica, según López (2015) al ser un continente cuyos países dependen en su mayoría de las actividades agrícolas y que su economía es insuficiente para implementar medidas preventivas o de adaptación, están expuestos a los efectos de la variación climática. Considerando que las condiciones meteorológicas es pieza clave en la productividad agrícola y que cualquier cambio en el ecosistema puede contribuir al incremento de enfermedades en los cultivos es de esperarse que esto provocará un aumento en el índice de pobreza y afectaría la seguridad alimentaria.

Los pueblos de América Latina han dedicado esfuerzos importantes para adaptarse a la variación climática. Martínez et al., (2021) comentan que el uso de los avances tecnológicos en el sector agrícola y alimentario resultan beneficios por permitir optimizar de forma eficiente los elementos de la cadena agroalimentaria, el desarrollo de variedades vegetales resistentes a enfermedades o la creación de insumos para la producción y el cuidado vegetal.

En el Perú, según el Instituto Nacional de Estadística e Informática INEI (2024) en el año 2023, la principal fuente de ingresos de la población pobre fue la agricultura, pesca y minería, representadas por el 40% a comparación con el año 2022, en donde hubo una participación del 41,9%. Por lo cual se infiere que una de las principales razones de la menor participación es por los bajos precios y las pérdidas en la producción por enfermedades. Todo ello, provoca que los agricultores se dediquen a otras actividades como es a la rama de los servicios, ya que esta aumentó de 18,7% en el año 2022 a 20,3% para el año 2023. La mayoría de estas familias se encuentran en la región sierra del país por las tierras de alta fertilidad y una diversidad de frutos.

En el Perú el cultivo de café es el primer producto de agroexportación y es el segundo exportador mundial de café orgánico. Posee más de 425,416 hectáreas de café en todo el país, lo cuales representan 6% del área agrícola nacional. Distribuidas en 17 regiones, 67 provincias y 338 distritos. Con más de 223,482 familias dedicadas a la producción del café. Aproximadamente el 30% de los trabajos en el sector agrícola están vinculados a la industria cafetera. Más de 2 millones de peruanos dependen de esta actividad, lo que lo posiciona con un cultivo de mucha importancia y trascendencia socioeconómica a nivel del país. Ministerio de Desarrollo Agrario y Riego Midagri (s.f.)

Sin embargo, un informe realizado por la Junta Nacional de café JNC (2024) menciona que el rendimiento de café sin procesar durante el 2011 antes de la enfermedad de la roya

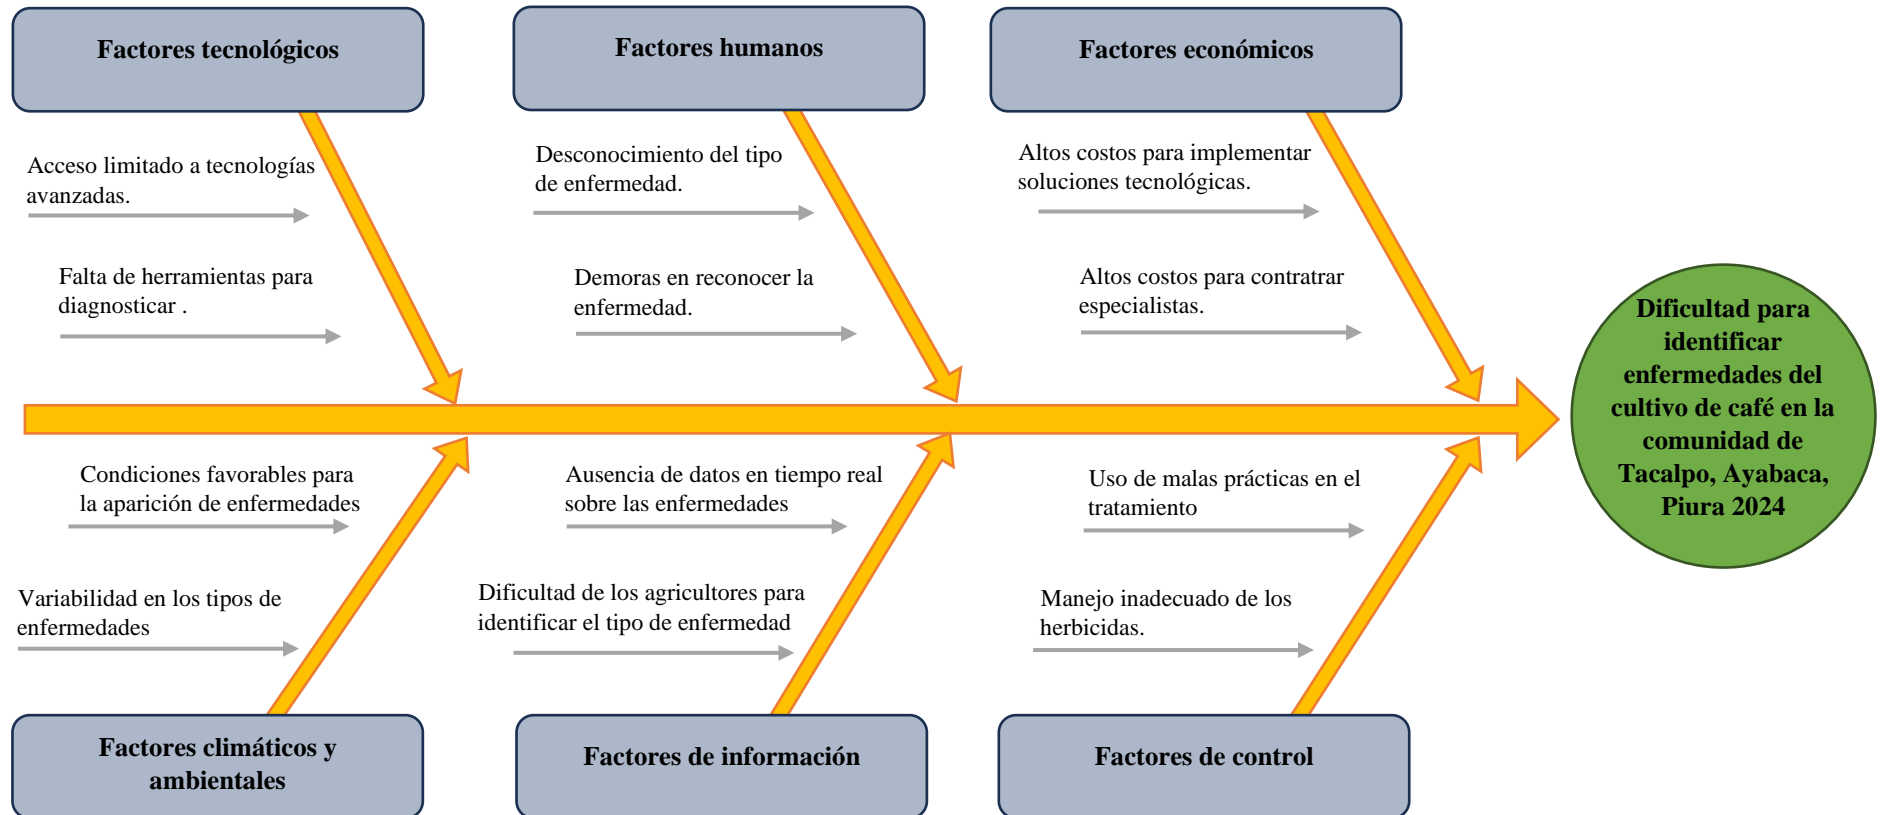
amarilla fue de 335,000 toneladas, para el 2022 se registró 223,000 toneladas, finalmente en el 2023 se obtuvo 264,000 toneladas y se estima un rendimiento de 240,000 toneladas para el 2024, estos datos indican una disminución del 9%, a causa de las condiciones meteorológicas, reaparición de enfermedades como la roya amarilla, carencia de mano de obra calificada y el declive del 70% de las fincas cafeteras.

En el departamento de Piura, según el Servicio Nacional de Sanidad Agraria del Perú, SENASA (2018) el cultivo de café abarca alrededor de 8,871 hectáreas. A pesar, de las capacitaciones en podas de producción, podas sanitarias, prácticas de fertilización y manejo integrado de plagas del café por parte del SENASA en colaboración con el MINAGRI no han sido suficientes para incrementar la calidad y el volumen productivo y sobre todo reducir la presencia de enfermedades.

En la comunidad de Tacalpo su población tiene como principal fuente de ingresos la agricultura, siendo la actividad del cultivo del café y la comercialización de este producto el sustento familiar. En el 2011, a raíz de la presencia de la roya en las plantaciones de café, se redujo en gran medida la producción, generando pérdidas monetarias y de cultivo. Pese a los esfuerzos del SENASA y el MINAGRI por mitigar las pérdidas, el problema continuo. Gran parte de los caficultores carecen de información confiable en tiempo real de las enfermedades que atacan sus cultivos y mucho menos las acciones que se deben aplicar para su prevención, erradicación o mitigación. En muchos de los casos, cuando se llega a identificar la enfermedad es demasiado tarde y si se quiere contratar los servicios de un especialista, estos costos no resultan rentables.

Figura 1

Diagrama de Ishikawa



1.2 Formulación del problema

Frente a esta problemática, con la disponibilidad de las nuevas tecnologías y el alcance de las mismas, surge la necesidad fundamental de contribuir con sistemas inteligentes que permitan reconocer imágenes que a simple vista son difíciles de identificar para el ser humano, puesto que la identificación anticipada de enfermedades en los cultivos de café a través del análisis de imágenes sería una herramienta útil para optimizar el rendimiento de las plantaciones.

1.2.1 Problema general

¿De qué manera el modelo de reconocimiento visual permite identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024?

1.2.2 Problemas específicos

PE1: ¿Cómo validar la efectividad del modelo de reconocimiento visual de enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024?

PE2: ¿En qué medida el modelo de reconocimiento visual mejora el tiempo promedio en la identificación de enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024?

1.3 Objetivos de la investigación

1.3.1 Objetivo general

Determinar como el modelo de reconocimiento visual permite identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024

1.3.2 Objetivos específicos

OE1: Validar la efectividad del modelo de reconocimiento visual de enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.

OE2: Determinar en qué medida el modelo de reconocimiento visual mejora el tiempo promedio en la identificación de enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.

1.4 Justificación de la investigación

1.4.1 Teórica

Este estudio se sustenta en 3 teorías como base teórica para las variables de investigación. Las teorías son: (a) la teoría de sistemas, la cual sostiene que es la forma en como el ser humano puede representar la realidad de forma sistémica y científica y a su vez optimizar la colaboración transdisciplinaria (Arnold & Osorio, 1998); (b) la teoría de la Percepción computacional, la cual proporciona un marco de trabajo para implementar sistemas con la capacidad de entender y procesar información como lo hacen los seres humanos. (Conde et al., 2014) (c) la teoría de redes neuronales, la cual fundamenta la existencia de elementos procesadores de información que emulan la estructura neuronal del cerebro, generando conocimiento mediante la experiencia y datos (Flórez & Fernández, 2008).

1.4.2 Metodológica

En el desarrollo de esta tesis, la metodología utilizada es de enfoque cuantitativo, de tipo aplicada y de diseño experimental. Para construir el sistema se empleó la metodología Rational Unified Process (RUP), ya que proporciona un marco de trabajo para la creación de software asegurando su calidad dentro del tiempo y el presupuesto establecido (Rueda, 2006) y para el

modelado se usó Unified Modeling Language (UML), por ser un estándar para el diseño, maquetación, visualización, construcción y documentación de un sistema de software (Rumbaugh et al., 2000).

1.4.3 Práctica

Esta investigación tuvo como propósito desarrollar un modelo de reconocimiento visual para identificar enfermedades que afectan el cultivo del café. El desarrollo del modelo busca detectar de manera precisa las enfermedades en etapas tempranas, lo cual permitirá que el agricultor de un tratamiento y tome acciones de control efectivas.

Este modelo se entrenó utilizando un conjunto de datos compuesto por imágenes de hojas de cafeto afectados por distintas enfermedades comunes en la comunidad de Tacalpo, Ayabaca, Piura.

Los resultados de esta investigación se implementaron en una herramienta que brinda apoyo técnico a los agricultores de la zona, permitiendo un acceso rápido y eficiente a información clave. Además, se espera que el modelo contribuya a mejorar el rendimiento agrícola y la calidad de los cultivos de café en la región.

1.5 Limitaciones de la investigación

Esta investigación se llevó a cabo entre septiembre y noviembre del 2024 en la comunidad de Tacalpo, provincia de Ayabaca, región Piura. Como alcance del estudio, se enfocó en los cultivos de café de los agricultores. Por último, el costo de la investigación fue financiado por el investigador al 100%.

Una limitación fue coordinar las entrevistas debido a los horarios de trabajo y disponibilidad, Para cubrir esta limitación se optó por el uso de herramientas online logrando el objetivo del estudio.

Otra limitación fue el acceso a los cultivos de café, Para cubrir esta limitación se dialogó con el propietario explicando y argumentando el motivo de la investigación.

Limitaciones tecnológicas: Aunque el modelo se puede desarrollar con tecnología de vanguardia, su implementación práctica requerirá dispositivos (como smartphones o cámaras) que sean capaces de capturar imágenes de alta calidad en campo. En áreas rurales como Tacalpo, la disponibilidad de estos dispositivos y de la infraestructura para el uso de tecnologías avanzadas puede ser limitada. Para cubrir esta limitación se buscó que el modelo funcione en dispositivos móviles de gama baja

Limitación de acceso a la tecnología: La adopción de tecnologías digitales en áreas rurales es un desafío. Factores como el acceso a internet, el nivel de alfabetización digital de los agricultores y la disponibilidad de recursos tecnológicos pueden limitar el uso extendido de esta herramienta. Para cubrir esta limitación se buscó diseñar una interfaz de usuario simple y accesibles, con menús visuales e íconos claros.

CAPÍTULO II: MARCO TEÓRICO

2.1 Antecedentes de la investigación

Se han llevado a cabo numerosas investigaciones que han servido de ayuda para el desarrollo de un modelo de reconocimiento visual que permita identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024. A continuación, se mencionan algunos estudios relacionados con esta presente investigación.

Antecedentes internacionales

Atencio y Cueto (2024) en su investigación, tuvo como propósito, “diseñar y crear un sistema de visión artificial que, mediante aprendizaje automático, pueda identificar los diferentes tipos de plagas y enfermedades que los cultivos de sandía en el departamento de Córdoba, desde la etapa de siembra hasta la recolección”. Con una metodología cuantitativa, utilizando la encuesta como herramienta de recolección de datos, se contó con una muestra de 4 grupos de 25 agricultores. Los resultados demostraron que la implementación de un sistema de visión artificial incrementa en un 81,2% el acceso a información sobre plagas y enfermedades en el cultivo de sandía, y en un 82,6% el conocimiento de las recomendaciones de uso de pesticidas. Por ello, se concluyó que este sistema representa una solución altamente innovadora y eficaz para abordar los múltiples desafíos que enfrenta el sector agrícola, mejorando tanto el monitoreo de las condiciones del cultivo como el proceso de decisión.

Valenzuela (2022) en su investigación, tuvo como propósito, “Aplicar Deep Learning y Computer Vision para detectar y clasificar las enfermedades que afectan el cultivo de tomate.” La metodología fue de enfoque cuantitativo, de diseño experimental. En esta investigación se

utilizó dos redes neuronales preentrenadas (transfer learning). Para la detección de las hojas de tomate se utilizó la red neuronal Faster Mask R-CNN y para la clasificación de enfermedades, la red neuronal convolucional además de proporcionar información confiable de los síntomas y como prevenir o el tratamiento asociado a la enfermedad detectada. Los resultados obtenidos muestran que el sistema tiene una confiabilidad del 87% en la detección de la hoja de tomate y un 75% en la clasificación de enfermedades, aclarando que la precisión se puede mejorar aumentando la cantidad e imágenes. En conclusión, el uso de estas tecnologías permite que el agricultor pueda identificar enfermedades y su posterior tratamiento, reduciendo tiempos y costos

Ferrer (2021) en su investigación, tuvo como propósito, “Desarrollar e implementar un sistema de detección de plagas en el cultivo”. Con una metodología cuantitativa, de diseño experimental. Los hallazgos conseguidos muestran la posibilidad de implementar sensores, cámaras y diversos dispositivos para el monitoreo constante de los cultivos y poder aplicar técnicas de agricultura de precisión, tales como el riego, fertilización, pesticidas, recolección y sobre todo identificar posibles plagas y enfermedades. Asimismo, la implementación de un clasificador de imágenes utilizando una red neuronal convolucional superficial muestran buena precisión, además si estas cuentan con más capas o son más profundas se obtiene un resultado más cercano al 100%

Cusme y Loor (2019) en su investigación, tuvo como propósito, “desarrollar una aplicación móvil basada en aprendizaje automático para la detección y clasificación de la roya, en los cultivos de café robusta, con el fin de automatizar la detección de la enfermedad.”. La metodología fue de enfoque cuantitativo, con estrategia de recolección de datos basada en la observación y la entrevista informal. La investigación estaba constituida por una población de

480 plantas de café robusta con una muestra de 390 plantas de las cuales se tomaron 556 fotos entre hojas sanas e infectadas. Para la detención y clasificación se utilizó las redes neuronales convolucionales con las cuales se alcanzó un 97% de éxito en la detección y clasificación de la roya en las hojas de café robusta. Lo cual demuestra que el uso de esta aplicación proporciona información confiable en tiempo real, facilitando la toma de decisiones.

Burgos (2024) en su investigación, tuvo como propósito, “Diseñar e implementar un prototipo que ayude a la detección temprana de plagas para los cultivos de arroz”. La metodología fue de enfoque cuantitativo, de diseño experimental, utilizando como técnica la observación, se contó con 92 muestra para la plaga de cinta amarilla y mariposa blanca que afectan el cultivo de arroz. En esta investigación se llegó a la conclusión que el prototipo funciona adecuadamente al detectar las plagas de cinta amarilla y mariposa blanca en tiempo real permitiendo una respuesta temprana que ayude a minimizar los daños y optimizar las acciones de control frente a estas plagas en el cultivo de arroz.

Antecedentes nacionales

Masgo y Vergaray (2023) en su investigación, tuvo como propósito, “Determinar el nivel de eficiencia de un sistema experto basado en reconocimiento de imágenes y reglas para el diagnóstico de plagas en los cultivos de café”. La metodología empleada fue cuantitativa, con un diseño no experimental, poniendo en práctica las técnicas de entrevista y observación, con el cuestionario y la lista de cotejo como instrumentos de recolección de datos, contando con una población de 3025 y una muestra de 93 planta de café. Los resultados obtenidos muestran un nivel de precisión del 92% en el reconocimiento de tres enfermedades que son: la Roya, Ojo de gallo y la Antracnosis. Por lo cual se concluyó que el uso de un sistema experto influye de forma positiva en la detención oportuna y confiable de las enfermedades que atacan del cultivo de café.

Flores y Mejía (2023) en su investigación, tuvo como objetivo, “mejorar en la toma de decisiones en el tratamiento de enfermedades que afectan a las plantaciones de café en el distrito de Chirinos con una aplicación móvil que usa redes neuronales convolucionales”. El método seguido fue cuantitativo, aplicado, con un diseño experimental, y utilizó la entrevista y la encuesta como técnicas, contando con una población de 4010 y una selección de 72 plantas de café. Los hallazgos alcanzados revelan que la utilización de las redes neuronales convolucionales genera una precisión del 99.6% en la identificación y clasificación de las enfermedades del café. Por lo cual, se concluyó que esto ayudará a los agricultores a identificar oportunamente las enfermedades y aumentará la producción.

Del Castillo y Chávez (2023) en su investigación, tuvo como propósito, “desarrollar un sistema de detección de plaga en la hoja de uva en la costa del departamento de la Libertad, usando el algoritmo de reconocimiento de imágenes para ayudar a reducir la pérdida de cultivo”. El método seguido tuvo un enfoque cuantitativo y un diseño experimental. En los descubrimientos encontrados se muestra que el modelo empleando redes neuronales convolucionales profundas (CNN) es capaz de identificar con un 97.22 % de precisión las enfermedades en la hoja de uva. En consecuencia, con el desarrollo de este sistema amplía la efectividad en la identificación de plagas, con la posibilidad de proteger los cultivos de planta de uva de los agricultores.

Burgos (2023) en su investigación, tuvo como propósito, “Desarrollar y evaluar un sistema basado en redes neuronales que permita hacer un reconocimiento de la plaga pulgilla en el cultivo de aguaymanto”. La investigación utilizó un enfoque cuantitativo, experimental, empleando la observación y la documentación como técnicas, la ficha de aceptación y la ficha de observación como instrumentos. Los resultados obtenidos en el modelo desarrollado aplicando

un proceso de Transfer Learning mostró precisión, exactitud y sensibilidad en la localización de la plaga pulguilla en plantas de aguaymanto. Por último, se concluyó que la red neuronal más eficiente son las profundas, proporcionando una precisión del 88% en la tarea de clasificación con un tiempo de respuesta de 190 segundos.

Baquedano y Palacios (2022) en su investigación, tuvo como propósito, “implementar un sistema de reconocimiento de imagen para la detección de plaga cogollero (*Spodoptera frugiperda*) en cultivo de maíz”. Método cuantitativo, experimental - pre experimental de tipo aplicada, contando con una población y muestra de 9 evaluaciones de cultivo de maíz, utilizando como estrategia la observación y la encuesta, la guía de observación, cuestionario y lista de chequeo como herramientas de recopilación de información. Los hallazgos alcanzados muestran que la tecnología de identificación visual incrementa el número de muestras capturadas para la detención de plagas pasando de 100 a 243 muestras y mejora en un 21% el nivel de eficiencia por evaluación por lo que se concluyó que este sistema afecta de manera positiva en la detección de plaga cogollero.

2.2 Bases teóricas

Teoría de sistemas

Esta teoría menciona que el concepto de sistemas hace referencia a cualquier serie de elementos que interactúan clasificándolos en sistemas reales y abstractos (Navarro, 2001). Asimismo, formula la presencia de estructuras sistémicas en el entorno natural y social, generando los conceptos de sistemas cerrados, abiertos y difusos, en donde los cerrados son de esencia determinista, los abiertos de incertidumbre y los difusos cambian en función del tiempo y las relaciones. La interacción entre estos sistemas genera sistemas más complejos impactando en

la ciencia y la tecnología, provocando la aplicación de nuevas metodologías interdisciplinarias llevadas a cabo por equipos multidisciplinarios que satisfagan los objetivos desde una perspectiva sistémica. (Martínez & Esparza, 2021). Las propiedades principales de un sistema complejo es que no es posible predecir con exactitud lo que pasará, solo podemos sacar conclusiones a posteriori; además, estos sistemas siguen un ciclo de vida adaptándose al entorno (Earls, 2013). Por lo tanto, esta teoría busca explicar el comportamiento de la realidad y poder predecir bajo dos enfoques complementarios, uno que se centra en observar e identificar fenómenos para crear modelos teóricos y el otro en organizar y desarrollar un nivel de abstracción apropiado. (Zamora, 2021). Con la creación de las computadoras, la investigación de sistemas ha sido facilitado en la generación de cálculos complejos que requieren de tiempo y energía excesiva. En resumen, esta teoría aplicada al modelo de reconocimiento visual demuestra la importancia en el desarrollo de un sistema complejo que debe procesar, analizar y comprender imágenes visuales en un entorno estructurado donde diferentes módulos interactúan para cumplir una tarea más amplia y cómo mejorar su precisión mediante el monitor de los resultados y la retroalimentación.

Teoría de la Percepción Computacional

En esta teoría se propone un marco teórico para descifrar la forma en que el cerebro procesa los datos visuales y a su vez replicarlo en sistemas computacionales, estableciendo un enfoque computacional para entender la visión. Asimismo, se argumenta que la visión es un proceso que ocurre en tres niveles: Bajo nivel para extraer características básicas como bordes, esquinas, curvas; nivel medio para organizar las características en estructuras más complejas; y el alto nivel para la interpretación completa y consciente de la escena. (Marr, 2010). Aunque Marr hablaba en el contexto de la visión humana, su modelo ha influido en el modo en que se

crean las tecnologías de visión por computadora, especialmente en términos de la necesidad de múltiples niveles de procesamiento de la información visual. Además, En esta teoría se contempla el concepto de pensamiento computacional como el medio para combinar y complementar las matemáticas con la ingeniería con el fin de potenciar técnica de abstracción, análisis y representación de datos, al igual que la descomposición de problemas, reconocimiento de patrones, algoritmos, simulación y evaluación. (Vilchez & Ramón, 2024). Es decir, ayuda a identificar factores clave de un problema, descomponiéndolo en subproblemas que sean más sencillos de resolver, para finalmente evaluar el proyecto y el procedimiento. También se habla del pensamiento visual como un factor imprescindible para la formación de ideas y conceptos mentales. (Vilchez & Ramón, 2024). En otras palabras, se busca replicar la forma como el ser humano aprende, la cual es de manera visual. Por todo lo mencionado, esta teoría es altamente relevante para investigaciones en modelos de reconocimiento visual, ya que proporciona un marco para diseñar sistemas que imitan la percepción humana, desde la segmentación y reconocimiento de patrones hasta la construcción de representaciones internas y la interpretación contextual de imágenes. Además, ofrece un enfoque jerárquico para procesar la información visual, permitiendo que el sistema sea robusto frente a la variabilidad visual.

Teoría de redes neuronales

Esta teoría formula una nueva forma de computación inspirada en principios biológicos. Para desarrollar este nuevo modelo matemático se considera una vasta interconexión paralela de una gran cantidad de elementos simples, a menudo adaptativos y organizados jerárquicamente en niveles, para ser procesados e interactuar con el entorno y los objetos del mundo real (Matic, 2001). En esencia, las redes neuronales artificiales buscan replicar la interacción del sistema

nervioso biológico (neuronas biológicas) con el mundo real. Asimismo, Las redes neuronales artificiales (RNA) tienen un uso marcado para tareas de segmentación, en especial para segmentar formas, color, textura, movimiento y bordes tales como estructuras biológicas, características biométricas, inspección de producto, etc. (Ramírez & Chacon, 2011). En estos campos donde es necesario la clasificación y segmentación de imágenes la RNA con una capacidad mayor para generar resultados estables y consistentes son las redes neuronales convolucionales (CNN) debido a su flexibilidad en la detección de bordes y segmentación de formas y mediante el uso del deep learning permiten robustez ante la variabilidad visual. (Verdeguer, 2020). Por lo manifestado, esta teoría es altamente relevante para la investigación, ya que proporciona una base robusta para el desarrollo de modelos computacionales que pueden aprender patrones visuales complejos, generalizar a nuevas situaciones, realizar tareas de clasificación visual, ajustarse automáticamente a los datos a través de técnicas como la retropropagación y la transferencia de aprendizaje (Transfer Learning).

Variable independiente: Modelo de reconocimiento visual

Modelo:

Real Academia Española (s.f.) lo define como “arquetipo o punto de referencia para imitarlo o reproducirlo”.

Según Moschner, (2021) es aquel que permite “describir patrones y comportamientos a partir de los datos con el fin de tomar decisiones o hacer predicciones” (p.5).

Para Microsoft (s.f) son aquellos que permiten “establecer o detectar patrones que los usuarios puedan usar para hacer predicciones o clasificar información”

Reconocimiento visual:

Para Correa, (2011) desde una perspectiva visual lo define como la “sensación interior de conocimiento aparente que resulta de un estímulo o impresión luminosa registrada en nuestros ojos” (p.6).

Para García, (2024) desde una perspectiva tecnológica “es una rama clave de la inteligencia artificial que persigue el objetivo principal de capacitar a las máquinas para interpretar y reconocer objetos de manera análoga a cómo el cerebro humano procesa la información visual captada por el ojo” (p.2).

Con lo mencionado anteriormente puede definirse al modelo de reconocimiento visual como un sistema arquetípico dentro del campo de la inteligencia artificial que está diseñado para detectar y analizar patrones visuales en imágenes. A partir de datos previamente procesados, este tipo de modelo permite clasificar objetos o características visuales, imitando el proceso de percepción humana. Además, su propósito principal es interpretar la información captada visualmente, ofreciendo predicciones o decisiones automatizadas basadas en los patrones reconocidos.

Dimensiones:

Métricas de desempeño del modelo:

Flores et al., (2023) las métricas de desempeño permiten evaluar el rendimiento del modelo y obtener una visión más precisa de su comportamiento. Para ello hay que tener en cuenta los siguientes indicadores:

Indicadores:

Matriz de confusión: Es una herramienta para evaluar el rendimiento de un modelo. Esta matriz compara los resultados reales con los predichos por el modelo, mostrando cuántas predicciones fueron correctas o incorrectas en las diferentes categorías.

Tabla 1

Matriz de confusión

	Predicción Positiva	Predicción Negativa
Real Positivo	Verdaderos Positivos (TP)	Falsos Negativos (FN)
Real Negativo	Falsos Positivos (FP)	Verdaderos Negativos (TN)

a) Sensibilidad: Mide la proporción de verdaderos positivos sobre el total de positivos reales

$$\text{Sensibilidad} = \frac{\text{Verdaderos Positivos (TP)}}{\text{Verdaderos Positivos (TP)} + \text{Falsos Negativos (FN)}}$$

b) Especificidad: Mide la capacidad del modelo de identificar correctamente los casos negativos

$$\text{Especificidad} = \frac{\text{Verdaderos Negativos (TN)}}{\text{Verdaderos Negativos (TN)} + \text{Falsos Positivos (FP)}}$$

c) Precisión: Mide la proporción de verdaderos positivos sobre el total de predicciones positivas

$$\text{Precisión} = \frac{\text{Verdaderos Positivos (TP)}}{\text{Verdaderos Positivos (TP)} + \text{Falsos Positivos (FP)}}$$

d) Exactitud: Proporción de predicciones correctas (positivas y negativas) sobre el total de predicciones.

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

e) Rendimiento del modelo: Área Bajo la Curva (AUC) esta métrica se evalúa comparando diferentes umbrales de FPR (abscisas) y TPR (ordenadas). El área que se calcula bajo la curva generada es la que se reporta, y cuanto más cerca esté de 1, mejor será el rendimiento del modelo; por el contrario, cuanto más cerca esté de 0, peor será su desempeño.

AUC < 0.5: Modelo clasifica incorrectamente más a menudo de lo esperado.

AUC = 0.5: Modelo aleatorio, no distingue entre las clases.

AUC > 0.7: Buen rendimiento.

AUC cerca de 1.0 : Excelente rendimiento, modelo casi perfecto.

Variable dependiente: Enfermedades del cultivo de café

Enfermedad:

Real Academia Española (s.f) define la enfermedad como el “estado producido en un ser vivo por la alteración de la función de uno de sus órganos o de todo el organismo”.

Según el Decreto Legislativo 1059 (2008) la enfermedad “es el desequilibrio fisiológico en el animal que altera el entorno de este, pudiendo propagarse a otros animales”.

Cultivo de café:

Para Tablas et al., (2021) el cultivo de café es una actividad significativa para las comunidades indígenas y campesinas, ya que ofrece una opción viable para mejorar las condiciones de vida de los pequeños productores de café.

Con los conceptos mencionados puede definirse a las enfermedades del cultivo de café como las alteraciones fisiológicas que afectan a las plantas de café, generadas por la presencia de factores patógenos o condiciones adversas. Estas enfermedades afectan el desarrollo y la productividad del cultivo, alterando su equilibrio natural y pudiendo propagarse, lo cual repercute directamente en los ingresos de los pequeños productores.

Dimensiones:

En la presente investigación se estudió 3 tipos de enfermedades que afectan el cultivo de café:

Roya amarilla:

La roya amarilla del café, causada por el hongo *Hemileia vastatrix*, es clasificada como una de las 10 enfermedades más destructivas del mundo, generando en las hojas postulas que alcanzar 3 mm de diámetro y su cantidad depende de la intensidad de la infección (Leyva, 2018). Su síntoma más representativo es la aparición de pequeñas manchas traslúcidas en la cara superior de las hojas, tomando un color amarillento, más oscuras y finalmente marrones terminando por su desprendimiento entre 3 a 4 meses, normalmente una hoja sana se desprende entre 14 a 16 meses. (Benito, 2009).

Síntomas:

- Manchas Amarillas en las Hojas con un tamaño entre 1 y 1.5 mm.

- Polvillo naranja o amarillo en el envés: En la parte inferior de las hojas, se forma un polvo de color anaranjado o amarillo. Este es el signo más distintivo de la presencia del hongo *Hemileia vastatrix*.
- Caída prematura de Hojas: A medida que la enfermedad progresa, las hojas afectadas caen prematuramente, lo que debilita la planta al reducir su capacidad para realizar la fotosíntesis.
- Reducción del rendimiento: Con la caída de hojas, la planta pierde vigor y la producción de granos de café se reduce significativamente.
- Muerte de la planta en casos severos: En infecciones graves, la planta puede morir debido al debilitamiento extremo.

Ojo de gallo:

El ojo de gallo es una enfermedad del café causada por el hongo *Mycena citricolor*, Se caracteriza por la aparición de manchas circulares en las hojas, ramas y frutos de la planta, con un centro de color marrón claro y bordes más oscuros, lo que les da la apariencia de un “ojo de gallo”. Esta enfermedad puede reducir significativamente la productividad del café, ya que provoca la caída prematura de hojas y afecta el desarrollo de los frutos. (Masgo & Vergaray, 2023)

Síntomas:

- Aparecen manchas redondeadas en las hojas, de color marrón claro con tonalidades grises.
- Las manchas tienen bordes bien definidos y un tono rojizo cuyo diámetro aproximado es de 3 a 10 mm.

- En algunas situaciones, el tejido dañado de las manchas se desprende, creando agujeros en las hojas.
- En casos graves, la infección causa la muerte de las hojas.
- Caída prematura de las hojas, que al acumularse en el suelo forman un colchón de hojas enfermas.
- El patógeno se reproduce en estas hojas caídas, fructificando y generando nuevas infecciones en la planta afectada y en plantas cercanas.

La Antracnosis:

La antracnosis es causada por el hongo *Colletotrichum gloeosporioides*, el cual puede afectar la planta de café durante todas sus etapas de crecimiento, dañando tanto las hojas como las flores y los frutos. Provocando pérdidas significativas en la producción y calidad de los granos. Esta enfermedad es común en regiones tropicales con alta humedad y puede ser devastadora si no se controla adecuadamente. (Masgo & Vergaray, 2023)

Síntomas:

- **Manchas negras o marrones:** Las hojas afectadas desarrollan manchas oscuras, que avanzan hacia el centro de la hoja y pueden volverse necróticas (muerte del tejido).
- **Lesiones en las ramas:** Las ramas también pueden mostrar manchas negras, lo que provoca la muerte de las puntas de las ramas y afecta el crecimiento de nuevas hojas.
- **Caída prematura de hojas y frutos:** Las hojas infectadas caen prematuramente, debilitando la planta. En los frutos, aparecen manchas negras que luego se expanden, afectando la calidad de los granos. Estos frutos infectados pueden caerse prematuramente o desarrollar pudrición.

- Afectación de los granos de café: El hongo puede penetrar en los frutos de café, dañando los granos y provocando la pérdida de su calidad. Los frutos severamente afectados pueden no ser aptos para la cosecha.

Indicadores:

- a) Validar la efectividad del modelo en identificar enfermedades:

$$\text{Efectividad del modelo} = \frac{\text{Número total de coincidencias correctas}}{\text{Número total de muestras}} \times 100$$

- b) Eficiencia del modelo en la identificación. Permite medir el tiempo que se tarda en realizar cada identificación. Este cálculo permite evaluar la eficiencia y rapidez del modelo.

$$\text{Tiempo promedio en la identificación} = \frac{\text{Suma de los tiempos de identificación}}{\text{Número total de muestras}}$$

Conceptos complementarios

Inteligencia artificial:

Para Incio et al., (2021) es la capacidad computacional que tiene un sistema entrenado con datos e información externa para imitar el comportamiento humano y con base en ese aprendizaje, cumplir los objetivos por lo cuales fue entrenado.

Visión artificial:

Para Flores & Mejía, (2023) Es una rama de la inteligencia artificial que facilita el análisis y procesamiento de imágenes digitales, involucra varios procesos como la captura de imágenes, su preprocesamiento para mejorar la calidad, la segmentación para identificar objetos

o regiones de interés, la representación y descripción de las características extraídas, y finalmente el reconocimiento e interpretación de lo que aparece en las imágenes.

Visión Computacional:

Según Aramendiz et al., (2020) es una técnica que busca replicar la capacidad visual del ser humano, empleando para ello diversos dispositivos que permitan recibir imágenes que luego serán procesadas. Es decir, se busca elaborar máquinas capaces de interpretar, reconocer y localizar objetos de entorno.

Procesamiento de imágenes digitales:

Para Morales y Guzmán, (2020) “es el conjunto de técnicas que se aplica a las imágenes digitales con el objetivo de mejorar la calidad o facilitar la búsqueda de información, usando como herramienta principal una computadora” (p.876).

Machine learning:

Según Manrique, (2020) es una rama de la inteligencia artificial que permite a las máquinas aprender y mejorar automáticamente a partir de la experiencia. Utilizan algoritmos que analizan grandes cantidades de datos para identificar patrones, tomar decisiones y realizar predicciones basadas en la información que han procesado. De tal manera que las máquinas al recibir más datos, su capacidad de análisis y precisión mejora, ya que ajustan sus modelos y predicciones en función de los nuevos datos. Existen diferentes tipos de aprendizaje automático, como el aprendizaje supervisado, no supervisado.

Aprendizaje supervisado:

Para González, (2015) es un tipo de aprendizaje en donde “se busca inducir modelos capaces de predecir el valor de ciertas variables dependientes a partir de variables independientes” (p.77). Es decir, el modelo se entrena con datos que ya tienen una respuesta o categoría conocida. El objetivo del modelo es aprender la relación entre los datos de entrada y la salida correcta, para luego poder predecir o clasificar nuevas entradas.

Aprendizaje no supervisado:

Para González, (2015) “en los modelos de aprendizaje no supervisado no hay una distinción entre variables dependientes y no dependientes, en este caso se pretende encontrar la estructura subyacente que explique la estructura de los datos” (p.77). Es decir, el modelo se entrena con datos que no tienen una respuesta o categoría conocida, por lo tanto, el modelo debe encontrar patrones, agrupaciones, relaciones o características interesantes dentro de los datos.

Deep learning:

Para Solutions, (2018) desde un aspecto básico se puede definir como “un sistema de probabilidad que permite a modelos computacionales que están compuestos de múltiples capas de procesamiento aprender sobre datos con múltiples niveles de abstracción” (p.23). Llevando esta definición a un aspecto específico de reconocimiento visual, el deep learning o aprendizaje profundo es una técnica que se utiliza para que las máquinas puedan identificar y clasificar objetos dentro de imágenes de manera automática y precisa. En este contexto, el deep learning se basa principalmente en redes neuronales convolucionales (CNNs).

Transfer Learning

Para Sinno, (2014) es una técnica en el aprendizaje automático que permite utilizar un modelo previamente entrenado en una tarea específica y adaptarlo para una nueva tarea relacionada. En lugar de comenzar desde cero y entrenar un modelo completamente nuevo, se toma el conocimiento que ya ha sido adquirido por el modelo original y se ajusta a la nueva tarea con un conjunto de datos más pequeño.

Microsoft Azure:

Para Castillo, (2020) es un entorno computacional en la nube de Microsoft en donde brinda diversos servicios tales como computación, analítica, almacenamiento y redes. Permitiendo a las organizaciones utilizar la infraestructura y los servicios de Microsoft para ejecutar sus aplicaciones sin necesidad de invertir en hardware físico, lo que facilita la escalabilidad y flexibilidad.

Azure Cognitive Services:

Para Moniz et al., (2021) son un conjunto de servicios que brinda Microsoft Azure para que los desarrolladores puedan incorporar capacidades de inteligencia artificial (IA) en sus aplicaciones. Por lo tanto, son servicios basados en la nube accesibles a través de API REST y SDK que permiten integrar IA o ciencia de datos. Incluyen modelos de inteligencia artificial pre-entrenados y listos para integrarse en aplicaciones y bots. En otras palabras, son endpoint al cual le pasamos parámetros y nos regresa una respuesta

Custom vision:

Para El Maghraby, (2021) es un servicio de Microsoft Azure que permite personalizar el reconocimiento de imágenes aplicando etiquetas a las imágenes en función de sus características visuales y por medio del uso de algoritmo de aprendizaje automático busca entrenar modelos, los cuales puedan adaptarse a las necesidades empresariales.

2.3 Formulación de hipótesis**2.3.1 Hipótesis general**

El modelo de reconocimiento visual es estadísticamente eficiente para la identificación de enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024

2.3.2 Hipótesis específicas

HE1: La validación del modelo de reconocimiento visual confirma su efectividad para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.

HE2: El modelo de reconocimiento visual mejora significativamente el tiempo promedio en la identificación de enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura en 2024.

CAPÍTULO III: METODOLOGÍA

3.1. Método de investigación

El método de investigación es hipotético-deductivo, porque consiste en generar afirmaciones asumidas como hipótesis y teniendo como objetivo refutar o desmentir dichas hipótesis, extrayendo de ellas conclusiones generales que deben ser contrastadas con la realidad (Bernal, 2016).

3.2. Enfoque investigativo

El enfoque de la investigación es cuantitativo, donde se aplicó técnicas estadísticas para medir, analizar, describir, explicar, predecir y controlar objetivamente su causa y dar respuesta a las hipótesis (Sánchez, 2019).

3.3. Tipo de investigación

El tipo es aplicada, debido a que posibilita resolver problemas. Es decir, mediante la identificación de desafíos o necesidades, haciendo uso de los conocimientos existentes se busca mejorar un aspecto de la vida humana (Hernández et al., 2014).

3.4. Diseño de la investigación

El diseño de esta investigación es experimental porque permite evidenciar que las modificaciones en una variable independiente (modelo de reconocimiento visual) generan un cambio predecible en la variable dependiente (Enfermedades del cultivo de café). (Bernal, 2016).

3.5. Población, muestra y muestreo

Población:

La población es “el conjunto de todos los elementos a los cuales se refiere la investigación. Se puede definir también como el conjunto de todas las unidades de muestreo” (Fracica, 1988, p.36 citado por Bernal, 2016, p.210), considerando elementos, unidades de muestreo, alcance y tiempo.

La población es compuesta por 2000 plantas de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.

Muestra:

La muestra “es la parte de la población que se selecciona, de la cual realmente se obtiene la información para el desarrollo de la investigación y sobre la cual se efectuarán la medición y la observación de las variables objeto de estudio” (Bernal, 2016, p.211).

La muestra de esta investigación está conformada por 42 plantas de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.

Debido a que la población es finita se utilizó la siguiente fórmula:

$$n = \frac{K^2 p q N}{E^2(N - 1) + k^2 p q} = 42 \text{ plantas de cafe}$$

Donde:

n = Muestra poblacional a obtener.

N = Tamaño de la población. 2000

K = Nivel de confianza. (95%) 1.96

q = Probabilidad de fracaso (0.5) 0.5

p = probabilidad de éxito (0.5) 0.5

E = Error de muestra (0.15) 0.15

Tabla 2*Distribución de las hojas de café para la muestra.*

Hojas	Porcentaje	Hojas a diagnosticadas
Con Antracnosis	26%	11
Con Ojo de Gallo	33%	14
Con Roya	33%	14
Hojas sanas	7%	3

Muestreo:

Para esta investigación se usó la técnica de muestreo aleatorio probabilístico, ya que garantiza que cada elemento de la población objetivo tenga la misma oportunidad de ser incluido en la muestra (Otzen & Manterola, 2017).

3.6. Variables y operacionalización**Tabla 3***Variables y operacionalización.*

Variables	Definición conceptual	Definición operacional	Dimensiones	Indicador	Escala de medición	Escala valorativa
V1: Modelo de reconocimiento visual.	Sistema automatizado basado en tecnologías de visión por computadora que permite adquirir, procesar, analizar y entender imágenes	Implementación de un modelo entrenado con imágenes de café afectado por distintas enfermedades, capaz de detectar y clasificar automáticamente las	Métricas de desempeño del modelo.	- Sensibilidad. - Especificidad. - Precisión. - Exactitud. - Rendimiento del modelo.	Nominal	Escala de Likert

<p>V2: Enfermedades del cultivo de café</p>	<p>digitales. (Redolfi & Pucheta, 2018)</p> <p>Conjunto de patologías que se presentan en diferentes etapas del desarrollo de la planta, las cuales afectan la producción del cultivo de café, causando deterioro en las hojas, tallos, frutos y raíces, (Tablas, et al. 2021).</p>	<p>enfermedades a partir de fotos de las hojas.</p> <p>Presencia de síntomas visibles en las plantas de café que indican infecciones por hongos, bacterias, virus u otros agentes patógenos. Estas enfermedades pueden ser detectadas visualmente o mediante el uso de tecnologías de reconocimiento visual.</p>	<p>- Roya amarilla - Ojo de gallo - Antracnosis.</p>	<p>- Efectividad del modelo - Tiempo promedio en la identificación.</p>
--	---	--	--	---

3.7. Técnicas e instrumentos de recolección de datos

3.7.1. Técnica

La técnica que se aplicó es la encuesta y la observación. Como instrumentos de obtención de datos, el cuestionario y la ficha de observación.

3.7.2. Descripción

El cuestionario está conformado por 42 preguntas cerradas, incluyendo en cada pregunta una imagen de una hoja de café y 4 alternativas a) antracnosis, b) roya amarilla, c) ojo de gallo c) hoja sana.

Figura 2

Formato de la encuesta para realizar la identificación de enfermedades con los especialistas.

Clasificación Enfermedades cultivo de café


Este cuestionario permite identificar y clasificar enfermedades en los cultivos de café en la comunidad de Tacalpo, Ayabaca, Piura.

Nombres completos *

Profesión *

Grado Académico *

1. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

Ojo de gallo

Roya amarilla

Antracnosis

Hoja sana

La ficha de observación cuenta con el número de la muestra, la respuesta del modelo, el porcentaje de probabilidad de dicha respuesta, el tiempo que se tarda en generar la predicción vs la respuesta del especialista.

Figura 3

Formato de la ficha de observación para comparar resultados del modelo con la respuesta del especialista.

Descripción:			Ficha Observación N°
Muestra	Respuesta Modelo	Probabilidad Respuesta Modelo	Tiempo Respuesta Modelo	Respuesta Especialista

3.7.3. Validación

Los instrumentos fueron validados por personas con experiencia en el tema de investigación, tal como se puede apreciar en la tabla 4. Del mismo modo, se manifiesta que la información expuesta está sustentada por tesis, libros y artículos científicos.

Tabla 4

Expertos que validaron los instrumentos.

N.º	Nombre y Apellido	Grado
1	Joel Martin Visurraga Agüero	Doctor
2	Julio Alfredo Martin Córdova Forero	Magíster
3	Charlen Maximo Calero Huaman	Magíster

3.7.4. Confiabilidad

Se utilizó el método **test-retest**, siendo una técnica para evaluar la fiabilidad o consistencia de una medición a lo largo del tiempo. Para llevar a cabo este método se aplicó la misma prueba a los mismos sujetos en dos ocasiones, con un intervalo de tiempo adecuado entre ellas, con el objetivo de determinar si los resultados son similares en ambas pruebas, lo que indicaría que la medición es estable y confiable. Del mismo modo, se utilizó el **coeficiente de correlación de Pearson** para medir la fuerza y dirección de la relación lineal del test-retest. Toma valores entre -1 y 1 donde 1 es una correlación perfecta positiva -1 una correlación perfecta negativa y 0 no hay correlación (Chávez, 2023).

La tabla 5 revela una correlación de Pearson extremadamente alta entre el resultado del modelo test y el resultado del modelo retest, con un valor de correlación de 1.000. Esto indica que de la muestra de 42 observaciones existe una concordancia perfecta entre los dos momentos de medición (test y retest), lo que sugiere que el modelo genera resultados de probabilidad idénticos en ambos casos.

Tabla 5

Test – retest del resultado generado por el modelo.

Correlaciones		Resultado Modelo Test	Resultado Modelo Retest
Resultado Modelo Test	Correlación de Pearson	1	1,000**
	Sig. (bilateral)		<.001
	N	42	42
Resultado Modelo Retest	Correlación de Pearson	1,000**	1
	Sig. (bilateral)	<.001	
	N	42	42

** . La correlación es significativa en el nivel 0,01 (bilateral).

La tabla 6 revela una correlación de Pearson positiva fuerte entre el tiempo tomado por el modelo para dar una respuesta test y el tiempo tomado por el modelo para dar una respuesta retest, con un valor de correlación de 0,856. Esto indica que de la muestra de 42 observaciones existe una concordancia positiva fuerte entre los dos momentos de medición (test y retest), lo que sugiere que si el tiempo aumenta en el test tiende a aumentar en el retest y viceversa.

Tabla 6

Test – retest del tiempo tomado por el modelo para dar una respuesta.

Correlaciones		Tiempo Resultado Modelo Test	Tiempo Resultado Modelo Retest
Tiempo Resultado Modelo Test	Correlación de Pearson Sig. (bilateral) N	1 42	,856** 42
Tiempo Resultado Modelo Retest	Correlación de Pearson Sig. (bilateral) N	,856** 42	1 42

** . La correlación es significativa en el nivel 0,01 (bilateral).

Asimismo, se aplicó el **coeficiente alfa de Cronbach** para medir la consistencia interna de los ítems del cuestionario. La fiabilidad se representa por un valor numérico entre 0 y 1 en donde 0 significa una falta de fiabilidad y 1 una fiabilidad perfecta (Castañeda et al., 2010, como se citó en Rodríguez y Reguant, 2020). En este estudio se obtuvo un valor de $\alpha=0.979$ con ello se refleja que el instrumento es altamente fiable. Ver Anexo 4.

3.8. Procesamiento y análisis de datos

Se revisó investigaciones similares para sustentar el marco teórico y plantear indicadores y dimensiones. Con los instrumentos mencionados anteriormente se recolectó los datos teniendo en cuenta la muestra seleccionada. Posteriormente, con los datos obtenidos se realizó un análisis estadístico del Test – retest. Se aplicó análisis descriptivo, usando SPSS Statistics V30 y Excel como herramientas, además de buscar la confiabilidad de los instrumentos empleando el coeficiente de correlación de Pearson. Finalmente, para la prueba de normalidad se utilizó el test Shapiro Wilkes en donde si el valor de $P > 0.05$ (nivel de significancia) existe normalidad.

3.9. Aspectos éticos

Esta investigación, al ser realizada en una propiedad privada dedicada al cultivo de café, cuenta con el consentimiento informado de los propietarios para examinar las plantas, tomar fotografías y realizar la recolección de los datos necesarios para el estudio. Se garantiza el respeto a los productores agrícolas y la confidencialidad de los datos recolectados, siguiendo las normativas éticas vigentes en el estudio científico.

Asimismo, se obtuvo la aprobación del Comité Institucional de Ética e Integridad Científica de la universidad Norbert Wiener asegurar el cumplimiento con los lineamientos éticos y de integridad científica establecidos. Ver Anexo 5.

CAPÍTULO IV: PRESENTACIÓN Y DISCUSIÓN DE LOS RESULTADOS

4.1 Resultados

De la muestra de 42 hojas de café se procedió al análisis de los resultados tanto del modelo como los especialistas, obteniendo lo siguiente:

Tabla 7

Resultados del modelo vs los especialistas.

ID Muestra	Probabilidad Resultado Modelo	Resultado Modelo	Tiempo Resultado Modelo	Respuesta Especialista
1	0.99	Antracnosis	1.83	Antracnosis
2	1.00	Antracnosis	7.39	Antracnosis
3	0.88	Ojo de gallo	7.78	Antracnosis
4	1.00	Antracnosis	5.09	Antracnosis
5	0.97	Antracnosis	3.65	Antracnosis
6	0.98	Antracnosis	3.21	Antracnosis
7	0.99	Antracnosis	7.08	Antracnosis
8	0.97	Antracnosis	3.80	Antracnosis
9	0.91	Antracnosis	5.92	Antracnosis
10	0.98	Antracnosis	3.46	Antracnosis
11	0.99	Antracnosis	3.32	Antracnosis
12	0.85	Roya amarilla	2.12	Ojo de gallo
13	0.76	Ojo de gallo	2.67	Ojo de gallo
14	1.00	Ojo de gallo	2.90	Ojo de gallo
15	0.98	Ojo de gallo	2.44	Ojo de gallo
16	1.00	Roya amarilla	0.77	Ojo de gallo
17	0.98	Ojo de gallo	4.34	Ojo de gallo
18	1.00	Ojo de gallo	4.33	Ojo de gallo
19	1.00	Ojo de gallo	2.92	Ojo de gallo
20	0.99	Ojo de gallo	3.56	Ojo de gallo
21	1.00	Ojo de gallo	5.56	Ojo de gallo
22	0.99	Ojo de gallo	3.03	Ojo de gallo
23	1.00	Ojo de gallo	5.59	Ojo de gallo
24	1.00	Ojo de gallo	5.43	Ojo de gallo
25	1.00	Ojo de gallo	2.17	Ojo de gallo
26	1.00	Roya amarilla	1.28	Roya amarilla

27	0.99	Roya amarilla	1.14	Roya amarilla
28	0.98	Roya amarilla	2.08	Roya amarilla
29	0.99	Roya amarilla	0.92	Roya amarilla
30	1.00	Roya amarilla	0.93	Roya amarilla
31	0.99	Roya amarilla	1.04	Roya amarilla
32	0.99	Antracnosis	2.29	Roya amarilla
33	1.00	Hoja sana	2.49	Hoja sana
34	1.00	Hoja sana	0.73	Hoja sana
35	1.00	Hoja sana	0.66	Hoja sana
36	1.00	Roya amarilla	2.20	Roya amarilla
37	1.00	Roya amarilla	1.25	Roya amarilla
38	1.00	Roya amarilla	0.69	Roya amarilla
39	1.00	Roya amarilla	0.66	Roya amarilla
40	1.00	Roya amarilla	0.62	Roya amarilla
41	1.00	Roya amarilla	1.09	Roya amarilla
42	0.98	Roya amarilla	0.84	Roya amarilla

Tabla 8

Validación de resultados.

N.º Muestras	N.º Coincidencias	
	correctas	incorrectas
11 antracnosis	10	1
14 ojo de gallo	12	2
14 roya amarilla	13	1
3 hojas sanas	3	0

4.1.1. Análisis descriptivo de resultados

En esta sección, se realizó el análisis estadístico con el objetivo de consolidar los datos de los indicadores de la presente investigación.


Tabla 9

Tabla de frecuencias de contrastación de resultados entre el modelo y el especialista para la enfermedad antracnosis.

	Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Coincidencias incorrectas	1	9,1	9,1	9,1
Coincidencias correctas	10	90,9	90,9	100,0
Total	11	100,0	100,0	

Figura 4

Gráfico de contrastación de resultados entre el modelo y el especialista para la enfermedad antracnosis.



Interpretación: en la figura 4 y tabla 9 se muestra que el 90.91% de las respuestas generadas por el modelo para identificar la enfermedad antracnosis coincide con la respuesta de los especialistas. Mientras que el 9.09% no coincidió.

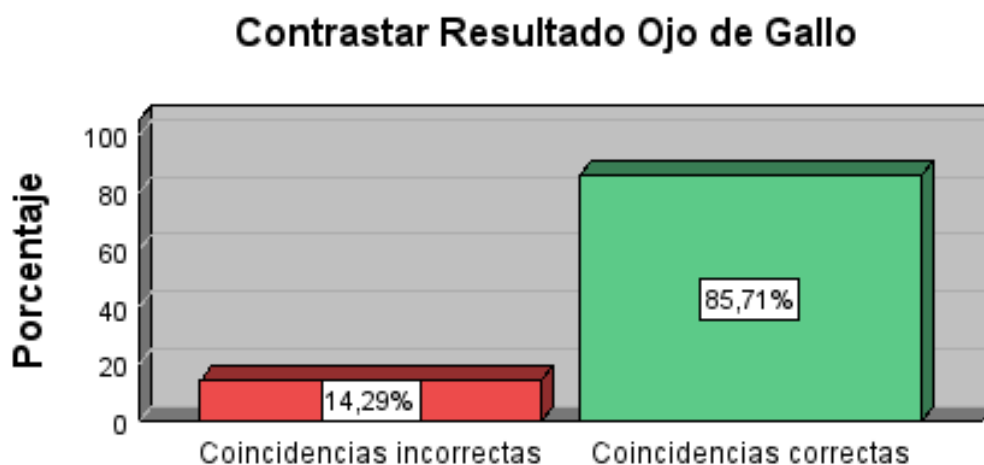
Tabla 10

Tabla de frecuencias de contrastación de resultados entre el modelo y el especialista para la enfermedad ojo de gallo.

	Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Coincidencias incorrectas	2	14,3	14,3	14,3
Coincidencias correctas	12	85,7	85,7	100,0
Total	14	100,0	100,0	

Figura 5

Gráfico de contrastación de resultados entre el modelo y el especialista para la enfermedad ojo de gallo.



Interpretación: en la figura 5 y tabla 10 se muestra que el 85.71% de las respuestas generadas por el modelo para identificar la enfermedad ojo de gallo coincide con la respuesta de los especialistas. Mientras que el 14.29% no coincidió.


Tabla 11

Tabla de frecuencias de contrastación de resultados entre el modelo y el especialista para la enfermedad roya amarilla.

	Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Coincidencias incorrectas	1	7,1	7,1	7,1
Coincidencias correctas	13	92,9	92,9	100,0
Total	14	100,0	100,0	

Figura 6

Gráfico de contrastación de resultados entre el modelo y el especialista para la enfermedad roya amarilla.



Interpretación: en la figura 6 y tabla 11 se muestra que el 92.86% de las respuestas generadas por el modelo para identificar la enfermedad roya amarilla coincide con la respuesta de los especialistas. Mientras que el 7.14% no coincidió.


Tabla 12

Tabla de frecuencias de contrastación de resultados entre el modelo y el especialista para hojas sanas.

	Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Coincidencias correctas	3	100,0	100,0	100,0

Figura 7

Gráfico de contrastación de resultados entre el modelo y el especialista para hojas sanas.



Interpretación: en la figura 7 y tabla 12 se muestra que el 100% de las respuestas generadas por el modelo para identificar una hoja sana coincide con la respuesta de los especialistas.

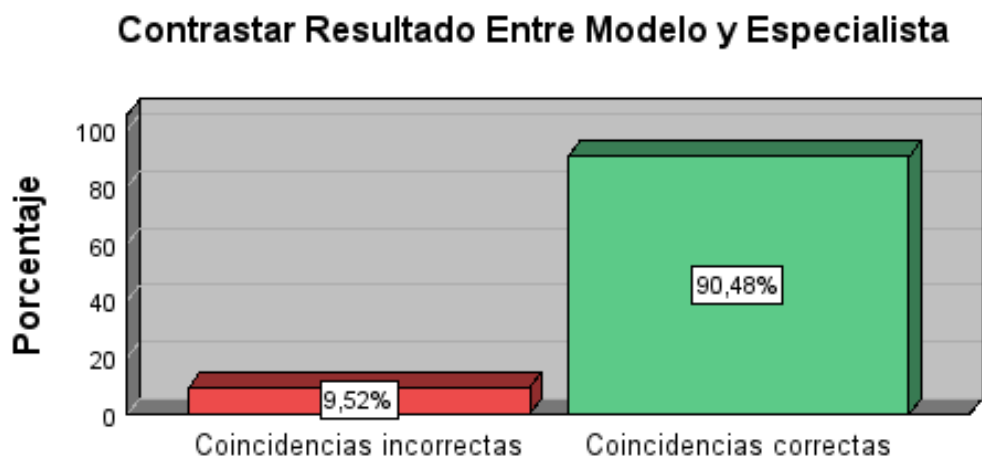
Tabla 13

Tabla de frecuencias general de contrastación de resultados entre el modelo y el especialista.

	Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Coincidencias incorrectas	4	9,5	9,5	9,5
Coincidencias correctas	38	90,5	90,5	100,0
Total	42	100,0	100,0	

Figura 8

Gráfico de contrastación general de resultados entre el modelo y el especialista.



Interpretación: en la figura 8 y tabla 13 se muestra que el 90.48% de las respuestas generadas por el modelo coincide con la respuesta de los especialistas. Mientras que el 9.52% no coincidió.

Tabla 14

Matriz de confusión del modelo de reconocimiento visual.

	Predicción Positiva	Predicción Negativa
Real Positivo	35	4
Real Negativo	0	3

Interpretación: En la tabla 14 se aprecia los verdaderos positivos (TP) = 35 casos en los que el modelo predice correctamente una clase positiva (coincidencias exactas entre modelo y especialista). Falsos negativos (FN) = 4 casos en los que el modelo predice una clase negativa, pero en realidad es positiva (especialista dijo una cosa, pero el modelo dijo otra cosa). Falsos positivos (FP) = 0 Casos en los que el modelo predice erróneamente una clase positiva cuando en realidad es negativa (Modelo no coinciden en predecir “hojas sanas”). Verdaderos Negativos (TN) = 3 Casos en los que el modelo predice correctamente una clase negativa (Modelo coinciden en predecir “hojas sanas”).

Tabla 15


Métricas de desempeño del modelo de reconocimiento visual.

Métrica	Valor
Sensibilidad del modelo	89.74%
Especificidad del modelo	100%
Precisión positiva del modelo	100%
Exactitud del modelo	90.48%

Interpretación: En la tabla 15 se muestra que el modelo tiene un rendimiento sólido con una sensibilidad del 89.74%, lo que indica que es capaz de identificar correctamente la mayoría de los casos positivos. Su especificidad del 100% y precisión positiva del 100% significan que clasifica perfectamente todos los casos negativos y que cada predicción positiva es correcta. La exactitud del 90.48% refleja su precisión general en la clasificación de todos los casos. Estos valores sugieren que el modelo es confiable tanto en la detección de positivos como en la exclusión de falsos positivos.

Figura 9

Rendimiento del modelo de reconocimiento visual - Curva ROC.



Interpretación: En la figura 9 se muestra que el modelo de reconociendo visual para identificar enfermedades del cultivo de café tiene curva ROC con un AUC de 0.71. Esto sugiere que, en el conjunto de datos de entrenamiento, el modelo ha aprendido características distintivas de antracnosis, ojos de gallo, roya amarilla, y hojas sanas generando un modelo con un Buen desempeño.

Tabla 16

Efectividad del modelo para identificar enfermedades del cultivo de café.

Indicador	Antracnosis	Ojo de gallo	Roya amarilla	Hoja Sana	General
efectividad del modelo	90.91%	85.71%	92.86%	100%	90.48%

Interpretación: En la tabla 16 se muestra que el modelo tiene una alta efectividad en la clasificación de las distintas categorías, con un rendimiento perfecto en la identificación de hoja sana (100%), sobresaliente para roya amarilla (92.86%) y antracnosis (90.91%) y bueno para ojo de gallo (85.71%). La efectividad general del modelo es del 90.48%, lo que indica un desempeño confiable en la identificación de enfermedades y hojas sanas.

Tabla 17

Tiempo promedio (tiempo en segundos) para identificar enfermedades del cultivo de café.

Indicador	Antracnosis	Ojo de gallo	Roya amarilla	Hoja Sana	General
Tiempo promedio en la identificación	2.53	2.41	1.06	1.20	2.89

Interpretación: En la tabla 17 se muestra que el tiempo promedio en la identificación varía entre las categorías, siendo más rápido para roya Amarilla (1.06 segundos) y hoja sana (1.20 segundos), mientras que antracnosis y Ojo de Gallo tienen tiempos promedio de 2.53 y

2.41 segundos, respectivamente. El tiempo promedio general es de 2.89 segundos, lo que sugiere que, aunque algunas categorías son rápidas de identificar, otras requieren más tiempo, posiblemente debido a la complejidad o las características visuales particulares de esas enfermedades.

4.1.2. Prueba de hipótesis

Tabla 18

Consolidado del indicador efectividad del modelo y tipo promedio en la identificación.

ID Muestra	Nivel de efectividad pre test	Nivel de efectividad Post test	Tiempo promedio en la identificación pre test	Tiempo promedio en la identificación post test
1	27.27	90.91	90.40	2.53
2	27.27	90.91	90.40	2.53
3	27.27	90.91	90.40	2.53
4	27.27	90.91	90.40	2.53
5	27.27	90.91	90.40	2.53
6	27.27	90.91	90.40	2.53
7	27.27	90.91	90.40	2.53
8	27.27	90.91	90.40	2.53
9	27.27	90.91	90.40	2.53
10	27.27	90.91	90.40	2.53
11	27.27	90.91	90.40	2.53
12	78.57	85.71	90.36	1.06
13	78.57	85.71	90.36	1.06
14	78.57	85.71	90.36	1.06
15	78.57	85.71	90.36	1.06
16	78.57	85.71	90.36	1.06
17	78.57	85.71	90.36	1.06
18	78.57	85.71	90.36	1.06
19	78.57	85.71	90.36	1.06
20	78.57	85.71	90.36	1.06
21	78.57	85.71	90.36	1.06
22	78.57	85.71	90.36	1.06
23	78.57	85.71	90.36	1.06
24	78.57	85.71	90.36	1.06
25	78.57	85.71	90.36	1.06

26	92.86	92.86	90.36	1.20
27	92.86	92.86	90.36	1.20
28	92.86	92.86	90.36	1.20
29	92.86	92.86	90.36	1.20
30	92.86	92.86	90.36	1.20
31	92.86	92.86	90.36	1.20
32	92.86	92.86	90.36	1.20
33	100.00	100.00	90.20	1.20
34	100.00	100.00	90.20	1.20
35	100.00	100.00	90.20	1.20
36	92.86	92.86	90.36	1.20
37	92.86	92.86	90.36	1.20
38	92.86	92.86	90.36	1.20
39	92.86	92.86	90.36	1.20
40	92.86	92.86	90.36	1.20
41	92.86	92.86	90.36	1.20
42	92.86	92.86	90.36	1.20

Tabla 19

Indicadores del pre test y post test.

	Tiempo Promedio general (Segundos)	Nivel de Efectividad General (Porcentajes)
Pre Test	90.36	71.4%
Post Test	2.89	90.48%

Ho: Los datos tiene una distribución normal.

Ha: Los datos no tiene una distribución normal.

Tabla 20

Pruebas de normalidad de los indicadores efectividad del modelo y tipo promedio en la identificación en pre y post test.

	Shapiro-Wilk		
	Estadístico	gl	Sig.
Nivel de efectividad pre test	,730	42	<.001
Nivel de efectividad Post test	,823	42	<.001
Tiempo promedio en la identificación pre test	,545	42	<.001
Tiempo promedio en la identificación post test	,619	42	<.001

Interpretación: En la tabla 20 se observa la prueba de normalidad en donde se obtuvo una significancia de 0.001 el cual es son menores a 0.05, por lo tanto, se rechaza la hipótesis nula (H_0) y se acepta la hipótesis alterna, es decir, los datos no tienen una distribución normal, por lo cual se aplicó estadística no paramétrica. Por lo tanto, se empleó la prueba de Wilcoxon para realizar la evaluación estadística correspondiente.

HE0: La validación del modelo de reconocimiento visual no confirma su efectividad para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.

HE1: La validación del modelo de reconocimiento visual confirma su efectividad para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.

Donde:

$$IE_a > IE_d$$

IE_a = Indicador de efectividad al identificar una enfermedad en el cultivo de café sin el modelo de reconocimiento visual.

IE_d = Indicador de efectividad al identificar una enfermedad en el cultivo de café con el modelo de reconocimiento visual.

Tabla 21

Test de Wilcoxon – Nivel de efectividad para identificar enfermedades en el cultivo de café.

		N	Rango promedio	Suma de rangos
Nivel de efectividad Post test - Nivel de efectividad pre test	Rangos negativos	0 ^a	,00	,00
	Rangos positivos	25 ^b	13,00	325,00
	Empates	17 ^c		
	Total	42		

a. Nivel de efectividad Post test < Nivel de efectividad pre test

b. Nivel de efectividad Post test > Nivel de efectividad pre test

c. Nivel de efectividad Post test = Nivel de efectividad pre test

Interpretación: En la tabla 21 se muestra un rango negativo 0 lo cual indica que no hubo casos donde el nivel de efectividad en el post-test fuera menor que en el pre-test. Por otro lado, en el rango positivo hubo 25 casos donde el nivel de efectividad en el post-test fue mayor que en el pre-test con un rango promedio de 13.00 y una suma de 325.00. Por último 17 tuvieron el mismo nivel de efectividad en el pre-test y el post-test, lo cual sugiere que para estos casos no hubo cambio en su efectividad tras la intervención o cambio. Dado que hay un número significativo de rangos positivos y ningún rango negativo, estos resultados sugieren que **hubo una mejora en la efectividad en el post-test** en comparación con el pre-test para una gran parte de los casos.

Tabla 22

Prueba de rangos – Nivel de efectividad para identificar enfermedades en el cultivo de café.

	Nivel de efectividad Post test - Nivel de efectividad pre test
Z	-4,512 ^b
Sig. asin. (bilateral)	<.001

a. Prueba de rangos con signo de Wilcoxon

b. Se basa en rangos negativos.

Interpretación: En la tabla 22 se observa el valor de **Z = -4.512** y el valor de significancia asintótica es **< 0.001**, lo cual es menor al nivel de significancia típico de 0.05. Esto indica que la diferencia observada en los rangos positivos es **estadísticamente significativa**. Por lo tanto, se rechaza la hipótesis nula, y se acepta la hipótesis específica de la investigación, es decir, se confirma la efectividad del modelo de reconocimiento visual para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.

HE0: El modelo de reconocimiento visual no mejora significativamente el tiempo promedio en la identificación de enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura en 2024.

HE2: El modelo de reconocimiento visual mejora significativamente el tiempo promedio en la identificación de enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura en 2024.

Donde:

$$ITP_a > ITP_d$$

ITP_a = Indicador de tiempo promedio para identificar una enfermedad en el cultivo de café sin el modelo de reconocimiento visual.

ITP_d = Indicador de tiempo promedio para identificar una enfermedad en el cultivo de café con el modelo de reconocimiento visual.

Tabla 23

Test de Wilcoxon – Tiempo promedio para identificar enfermedades en el cultivo de café.

		N	Rango promedio	Suma de rangos
Tiempo promedio en la identificación post test - Rangos negativos		42 ^a	21,50	903,00
Tiempo promedio en la identificación pre test	Rangos positivos	0 ^b	,00	,00
	Empates	0 ^c		
	Total	42		

a. Tiempo promedio en la identificación post test < Tiempo promedio en la identificación pre test

b. Tiempo promedio en la identificación post test > Tiempo promedio en la identificación pre test

c. Tiempo promedio en la identificación post test = Tiempo promedio en la identificación pre test

Interpretación: En la tabla 23 se muestra un rango negativo 42 con un rango promedio de **21.50** y una suma de **903.00**. Esto indica que, en todos los casos, el tiempo promedio en la identificación de enfermedades fue menor en el post-test que en el pre-test. Por otro lado, en el rango positivo y empate se obtuvo **0** lo que significa que no hubo casos en los que el tiempo promedio en el post-test fuera mayor o igual que en el pre-test. Estos resultados indican que el **tiempo promedio para identificar enfermedades en el cultivo de café disminuyó**

significativamente después de la intervención. Esto sugiere que la intervención fue altamente efectiva en mejorar la rapidez para identificar enfermedades.

Tabla 24

Prueba de rangos – Tiempo promedio para identificar enfermedades en el cultivo de café.

	Tiempo promedio en la identificación post test - Tiempo promedio en la identificación pre test
Z	-5,709 ^b
Sig. asin. (bilateral)	<.001

a. Prueba de rangos con signo de Wilcoxon

b. Se basa en rangos positivos.

Interpretación: En la tabla 24 se observa el valor de $Z = -5.709$ y el valor de significancia asintótica es < 0.001 , lo cual es menor al nivel de significancia típico de 0.05. Esto indica que la diferencia en el tiempo promedio de identificación entre el pre-test y el post-test es **estadísticamente significativa**. Por lo tanto, se rechaza la hipótesis nula, y se acepta la hipótesis específica de la investigación, es decir, se confirma que el modelo reconocimiento visual mejora significativamente el tiempo promedio en la identificación de enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura en 2024.

4.1.3. Discusión de resultados

En la presente investigación según la evidencia, la base teórica y los antecedentes nacionales e internacionales la hipótesis del objetivo general ha sido aceptada.

Los resultados muestran una mejora en la efectividad en la identificación de enfermedades del cultivo de café pasando de 71,4% a 90.48%, lo que equivale a un incremento del 19.08% empleado el modelo de reconocimiento visual.

Así mismo, la investigación de (Cusme y Loor, 2019), guarda relación con este estudio, ya que demuestra la efectividad del modelo para identificar y clasificar enfermedades presentes en las hojas de café. Del mismo modo las investigaciones de (Masgo y Vergaray,2023) y (Flores y Mejía, 2023) corrobora los resultados obtenidos.

De igual manera en los resultados se mostró una mejora significativa en el tiempo promedio para identificar enfermedades del cultivo de café pasando de 90.36 segundos a 2.89 segundos lo que equivale a un decremento de 96.8% empleado el modelo de reconocimiento visual.

También, la investigación de (Burgos, 2023), guarda relación con este estudio, ya que demuestra que el modelo mediante la disminución del tiempo promedio en identificar enfermedades afecta de forma positiva.

En resumen, estos resultados demuestran que el uso de un modelo de reconocimiento visual es estadísticamente eficiente para la identificación de enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.

CAPÍTULO V: CONCLUSIONES Y RECOMENDACIONES

5.1 Conclusiones

Primera: Se demostró que el modelo de reconocimiento visual es estadísticamente eficiente para identificar enfermedades del cultivo de café. En este sentido, se ha observado mejoras en la efectividad y el tiempo promedio para identificar enfermedades. Con esto se evidencia que mediante el modelo de reconocimiento visual se consiguió optimizar el proceso de identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.

Segunda: Se demostró que el modelo de reconocimiento visual es efectivo para identificar enfermedades del cultivo de café. En este sentido, se comprobó que mediante el modelo de reconocimiento visual se logró un incremento del 19.08%. Con esto se valida y confirma la efectividad del modelo para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.

Tercera: Se demostró que el modelo de reconocimiento visual mejora significativamente el tiempo promedio en la identificación de enfermedades del cultivo de café. En este sentido, se observó que mediante el modelo de reconocimiento visual se logró una reducción del 96.8% lo que equivale a un tiempo promedio de 2.89 segundos. Con esto se evidencia una mejoría significativa del tiempo promedio en la identificación de enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura en 2024.

5.2 Recomendaciones

Primera: Se sugiere ampliar la base de datos utilizada para el entrenamiento del modelo incluyendo imágenes adicionales de enfermedades comunes y atípicas del cultivo de café en la región de Tacalpo. Esto permitirá mejorar la precisión y la capacidad del modelo para reconocer una mayor variedad de enfermedades.

Segunda: Se sugiere implementar talleres prácticos para que los agricultores de la comunidad aprendan a utilizar la herramienta basada en el modelo de reconocimiento visual. Esto asegurará una adopción efectiva de la tecnología y aumentará su impacto en la productividad agrícola de la región.

Tercera: Se sugiere enriquecer la aplicación móvil, permitiendo a los agricultores acceder fácilmente a funcionalidades como recomendaciones automáticas de tratamiento para las enfermedades detectadas. Además, se recomienda implementar un sistema de almacenamiento eficiente que registre las consultas realizadas por cada usuario en una base de datos robusta y bien estructurada. Este sistema debe garantizar la seguridad, integridad y trazabilidad de la información, facilitando el análisis de datos históricos y la generación de reportes personalizados. Esto contribuirá a una gestión integral, sostenible y basada en datos para los cultivos de café.

REFERENCIAS

- Aramendiz, C., Escorcía, D., Romero, J., Torres, K., Triana, C., y Moreno, S. (2020). Sistema basado en reconocimiento de objetos para el apoyo a personas con discapacidad visual. *Investigación y Desarrollo en TIC*, 11(2), 75-82.
<https://revistas.unisimon.edu.co/index.php/identific>
- Arnold Cathalifaud, M., & Osorio, F. (1998). Introducción a los Conceptos Básicos de la Teoría General de Sistemas. *Cinta de Moebio*, (3).
<https://www.redalyc.org/articulo.oa?id=10100306>.
- Atencio Flórez, J., & Cueto Mórelo, R. (2024). *Sistema de visión artificial para la detección y control de plagas y enfermedades en los cultivos de sandía en el departamento de Córdoba* [Tesis de Titulación, Universidad de Córdoba].
<https://repositorio.unicordoba.edu.co/handle/ucordoba/8393>
- Baquadano Córdoba, L., & Palacios Periche, M. (2022). *Detección de plaga cogollero (Spodoptera frugiperda) mediante un sistema de reconocimiento de imagen en cultivo de maíz, Tambogrande-Piura 2021* [Tesis de Titulación, Universidad Cesar Vallejo].
<https://hdl.handle.net/20.500.12692/87699>
- Benito Sullca, J. (2009). *Manejo Integrado del Cultivo de Café*. Instituto Nacional De Innovación Agraria.
https://repositorio.inia.gob.pe/bitstream/20.500.12955/176/1/Cultivo_cafe_2009.pdf
- Bernal Torres, C. (2016). *Metodología de la investigación Administración, economía, humanidades y ciencias sociales*. Pearson.

https://www.academia.edu/53015080/LIBRO_BASE_Metodologia_de_la_investigacion_4ta_Edicion_Cesar_A_Bernal

Burgos Muñiz, Y. (2024). *Diseño e implementación de un prototipo para detectar plagas en los cultivos de arroz utilizando una Raspberry Pi y OpenCV*. [Tesis de Titulación, Universidad Politécnica Salesiana]. <http://dspace.ups.edu.ec/handle/123456789/27717>

Burgos Vargas, D. (2023). *Detección y clasificación de plaga pulguilla en el cultivo de aguaymanto mediante redes neuronales* [Tesis de Titulación, Universidad Señor de Sipán]. <https://hdl.handle.net/20.500.12802/12030>

Castillo Barquero, R. (2020). *¿Qué es un azure y para qué sirve?* San Marcos. <https://repositorio.usam.ac.cr/xmlui/bitstream/handle/11506/2119/LEC%20ING%20SIST%200063%202020.pdf?sequence=1&isAllowed=y>

Chávez Cañarí, D. (2023). *Sistema experto para mejorar el proceso de diagnóstico de enfermedades respiratorias en una empresa de servicios de salud, Lima 2023*. [Tesis de Titulación, Universidad Norbert Wiener]. <https://hdl.handle.net/20.500.13053/10333>

Conde Clemente, P. Alonso, J & Trivino, G. (2014). Extensión del concepto de Percepción Computacional utilizando Z-numbers. *xvii congreso español sobre tecnologías y lógica fuzzy*. 387-392. https://www.researchgate.net/publication/272495932_Extension_del_concepto_de_Percepcion_Computacional_utilizando_Z-numbers

Correa Alfaro, L. (2011). Reconocimiento Visual por Referencia, componente de la percepción en la Experiencia de Usuario. *UTEM*, (64), 1-15. <https://dialnet.unirioja.es/servlet/articulo?codigo=3714657>

- Cusme Zambrano, K., & Loor Pinargote, A. (2019). *Aplicación móvil de detección y clasificación de “la roya” en hojas de café robusta mediante aprendizaje automático* [Tesis de bachiller, Escuela Superior Politécnica Agropecuaria De Manabí Manuel Félix López] <http://repositorio.espam.edu.ec/handle/42000/1104>
- Presidente de la república y el consejo de ministros (2008). *Decreto Legislativo 1059*. Diario Oficial El peruano.
<https://www.senasa.gob.pe/senasa/descargasarchivos/jer/GESTION/DL%201059.pdf>
- Del Castillo Flores, J., & Chávez Huamán, J. (2023). *Sistema de detección de plagas en la hoja de uva en el departamento de La Libertad (Perú) usando algoritmo de redes neuronales convolucionales profundas* [Tesis de titulación, Universidad Peruana de Ciencias Aplicadas]. <http://hdl.handle.net/10757/673646>
- Earls, J. (2013). *Introducción a la teoría de sistemas complejos*. Universidad Católica del Perú.
https://books.google.es/books?hl=es&lr=&id=z6HNDwAAQBAJ&oi=fnd&pg=PT11&dq=+Teor%C3%ADa+de+Sistemas+&ots=Hp-ftm3Axx&sig=hasd5-1imYSIBFG2dz_0cFDWFPo#v=onepage&q=Teor%C3%ADa%20de%20Sistemas&f=false
- El Maghraby, A. (2021). Improving Custom Vision cognitive services model. *Journal of the ACS Advances in Computer Science*, 12(1), 36-63. de
https://asc.journals.ekb.eg/article_240134.html
- Organización de las Naciones Unidas para la Alimentación y la Agricultura. (29 de 03 de 2022). *La FAO acoge con satisfacción la decisión de conmemorar cada año el Día Internacional de la Sanidad Vegetal el 12 de mayo*.

<https://www.fao.org/newsroom/detail/fao-welcomes-decision-to-mark-international-day-of-plant-health/es>

Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2024).

Repercusiones de los desastres en la agricultura y la seguridad alimentaria 2023: Evitar y reducir las pérdidas mediante la inversión en la resiliencia. FAO.

<https://doi.org/10.4060/cc7900es>

Otzen, T., y Manterola, C. (2017). Técnicas de Muestreo sobre una Población a Estudio.

International Journal of Morphology, 35(1), 227-232. <http://dx.doi.org/10.4067/S0717-95022017000100037>

Ferrer Martínez, C. (2021). *Sistema de monitorización y detección de plagas en cultivos aplicando algoritmos de Deep Learning* [Tesis de Maestría, Universidad Oberta de Catalunya]. <http://hdl.handle.net/10609/132028>

Flores Colorado, O., Cervantes Canales, J., García-Lamont, F., & Ruiz Castilla, J. (2023).

Identificación de las principales enfermedades de la planta del café (*Coffea arabica*) a través de visión artificial. *Revista Científica Multidisciplinaria de Prospectiva*, 30(3), 1-22. <https://doi.org/10.30878/ces.v30n3a8>

Flores Mendoza, J., y Mejía Carhuajulca, G. (2023). *Aplicación Móvil usando redes neuronales convolucionales para la detección de enfermedades en las plantas de café en el distrito de Chirinos, Provincia de San Ignacio, Departamento de Cajamarca* [Tesis de Titulación, Universidad Nacional Pedro Ruiz Gallo].

<https://hdl.handle.net/20.500.12893/11478>

- Flórez López, R., & Fernández Fernández, J. (2008). *Las Redes Neuronales Artificiales. Fundamentos teóricos y aplicaciones prácticas*. Netbiblo
<https://books.google.es/books?id=X0uLwi1Ap4QC&lpg=PA11&ots=gPJClqrs3f&dq=la%20teor%C3%ADa%20de%20redes%20neuronales&lr&hl=es&pg=PA4#v=onepage&q=la%20teor%C3%ADa%20de%20redes%20neuronales&f=false>
- García Martínez, J. (2024). *Reconocimiento visual de aves con Deep Learning*. [Tesis de Titulación, Universidad de Alicante].
https://rua.ua.es/dspace/bitstream/10045/145620/1/Reconocimiento_visual_de_aves_con_Deep_Learning_Garcia_Martinez_Juan.pdf
- González, F. (2015). Modelos de aprendizaje computacional en reumatología. *Revista Colombiana de Reumatología*, 22(2), 77-78. <https://doi.org/10.1016/j.rcreu.2015.06.001>
- Hernández Sampieri, R., Fernández Collado, C., y Baptista Lucio, M. (2014). *Metodología de la investigación*. McGRAW-HILL. <https://www.esup.edu.pe/wp-content/uploads/2020/12/2.%20Hernandez,%20Fernandez%20y%20Baptista-Methodolog%C3%ADa%20Investigacion%20Cientifica%206ta%20ed.pdf>
- Incio Flores, F. A., Capuñay Sanchez, D. L. ., Estela Urbina, R. O. ., Valles Coral, M. Ángel ., Vergara Medrano, S. E. ., & Elera Gonzales, D. G. . (2021). Inteligencia artificial en educación: una revisión de la literatura en revistas científicas internacionales. *Apuntes Universitarios*, 12(1), 353–372. <https://doi.org/10.17162/au.v12i1.974>
- Instituto Nacional de Estadística e Informática. (2024). *Perú: Evolución de la Pobreza Monetaria, 2014-2023*. INEI.

<https://cdn.www.gob.pe/uploads/document/file/6578175/5558423-peru-evolucion-de-la-pobreza-monetaria-2014-2023.pdf?v=1720047420>

Junta Nacional de café. (20 de julio de 2024). *Perú requiere revertir preocupante decrecimiento de la producción de café*. <https://juntadelcafe.org.pe/peru-requiere-revertir-preocupante-decrecimiento-de-la-produccion-de-cafe/>

Leyva Mir, G. (2018). PRINCIPALES ENFERMEDADES DEL CAFÉ (*Coffea arabica*). *Agro Productividad*, 3(2). <https://revista-agroproductividad.org/index.php/agroproductividad/article/view/590>

López Feldman, A. (2015). *Cambio climático y actividades agropecuarias en América Latina*. CEPAL. <https://hdl.handle.net/11362/39824>

Manrique Rojas, E. (2020). Machine Learning: análisis de lenguajes de programación y herramientas para desarrollo. *RISTI*, 4(28), 586-599. <https://www.proquest.com/openview/c7e24c997199215aa26a39107dd2fe98/1?pq-origsite=gscholar&cbl=1006393>

Marr, D. (2010). *Vision: A Computational Investigation into the Human Representation and Processing of Visual Information*. <https://doi.org/10.7551/mitpress/9780262514620.001.0001>

Martínez Romero, E., & Esparza Olguín, L. (2021). Teorías de Sistemas Complejos: marco epistémico para abordar la complejidad socioambiental. *Intersticios Sociales*, (21), 373-398. https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2007-49642021000100373

- Martínez, H., Ramírez, E., y Sotomayor Echenique, O. (2021). *Digitalización y cambio tecnológico en las mipymes agrícolas y agroindustriales en América Latina*. CEPAL.
<https://hdl.handle.net/11362/46965>
- Masgo Ventura, H. K., y Vergaray Jauregui, C. M. (2023). *Sistema experto basado en reconocimiento de imágenes y reglas para el diagnóstico de plagas cafeteras*. [Tesis de Titulación, Universidad Nacional Toribio Rodríguez De Mendoza De Amazonas].
<https://hdl.handle.net/20.500.14077/3790>
- Matich, D. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Universidad Tecnológica Nacional.
https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monograiias/matich-redesneuronales.pdf
- Microsoft. (s.f.). *Algoritmos de aprendizaje automático*. <https://azure.microsoft.com/es-es/resources/cloud-computing-dictionary/what-are-machine-learning-algorithms#:~:text=Los%20algoritmos%20de%20aprendizaje%20autom%C3%A1tico%20son%20fragmentos%20de%20c%C3%B3digo%20que,para%20lograr%20un%20determinado%20objeti>
- Ministerio de Desarrollo Agrario y Riego. (s.f.). *Situación actual del café en el país*.
<https://www.midagri.gob.pe/portal/485-feria-scaa/10775-el-cafe-peruano>
- Moniz, A., Gordon, M., Bergum, I., Chang, M., y Grant, G. (2021). *Introducing cognitive services. Beginning Azure Cognitive Services: Data-Driven Decision Making Through Artificial Intelligence*. https://doi.org/10.1007/978-1-4842-7176-6_1

- Morales Castro, W., y Guzmán Cabrera, R. (2020). Tuberculosis: Diagnostico mediante procesamiento de imágenes, *Computación y Sistemas*. 24(2), 875–882.
<https://doi.org/10.13053/cys-24-2-3284>
- Moschner, V. (2021). *Modelo predictivo para la detección temprana de alumnos en riesgo de abandono de la carrera de profesorado en ciencias de la educación, Facultad de Humanidades de la UNNE*. [Tesis de Maestría, Universidad Nacional del Nordeste].
<http://repositorio.unne.edu.ar/handle/123456789/37789>
- Navarro Cid, J. (2001). *Las organizaciones como sistemas abiertos alejados del equilibrio*. [Tesis de Doctorado, Universidad de Barcelona]
<https://diposit.ub.edu/dspace/handle/2445/42732>
- Sinno Jialin, P. (2014). Transfer Learning. *Nanyang Technological University*,
[https://www.cse.cuhk.edu.hk/~sinnopan/publications/\[BookChapter14\]Transfer%20Learning.pdf](https://www.cse.cuhk.edu.hk/~sinnopan/publications/[BookChapter14]Transfer%20Learning.pdf)
- Ramírez Quintana, J., & Chacón Murguía, M. (2011). Redes neuronales artificiales para el procesamiento. *Revista De Ingeniería Eléctrica, Electrónica y Computación*. 9(1), 7-16.
https://www.itson.mx/publicaciones/rieeyc/Documents/v9/art2vf_redes_neuronales_artificiales_para_el_procesamiento_de_imagenes-una_revision_de_la_ultima_decada.pdf
- Real academia española. (s.f.). Modelo. En *Diccionario de la lengua española*. Recuperado el 19 de septiembre de 2019, de <https://dle.rae.es/modelo?m=form>
- Real academia española. (s.f.). Enfermedad. En *Diccionario de la lengua española*. Recuperado el 19 de septiembre de 2019, de <https://dle.rae.es/enfermedad?m=form>

- Redolfi, J. (2018). *Aplicación en agricultura de precisión de esquemas actuales de reconocimiento visual*. [Tesis de Doctorado, Universidad Nacional de Córdoba]
https://www.researchgate.net/profile/Javier-Redolfi/publication/336899385_Aplicacion_en_agricultura_de_precision_de_esquemas_actuales_de_reconocimiento_visual/links/5db99f2592851c818018c120/Aplicacion-en-agricultura-de-precision-de-esquemas-actuales-de-re
- Rodríguez Rodríguez, J., & Reguant Álvarez, M. (2020). Calcular la fiabilidad de un cuestionario o escala mediante el SPSS: el coeficiente alfa de Cronbach. *REIRE Revista d'Innovació i Recerca en Educació*, 13(2), 1-13.
<https://doi.org/10.1344/reire2020.13.230048>
- Rueda Chacón, J. (2006). *Aplicación de la metodología RUP para el desarrollo rápido de aplicaciones basado en el estándar J2EE* [Tesis de titulación, Universidad San Carlos de Guatemala]. http://biblioteca.usac.edu.gt/tesis/08/08_0308_CS.pdf
- Rumbaugh, J., Jacobson, I., & Booch, G. (2000). *El lenguaje Unificado de Modelado Manual de Referencia*. Addison Wesley
https://www.academia.edu/30999453/El_lenguaje_Unificado_de_Modelado_Manual_de_Referencia_Rumbaugh_Jacobson_Booch_
- Sánchez Flores, F. A. (2019). Epistemic Fundamentals of Qualitative and Quantitative Research: Consensus and Dissensus. *Revista Digital De Investigación En Docencia Universitaria*, 13(1), 101–122. <https://doi.org/10.19083/ridu.2019.644>
- Servicio Nacional de Sanidad Agraria. (18 de mayo de 2018). *Piura: MINAGRI atiende a pequeños caficultores mediante Escuelas de Campo*.

<https://www.senasa.gob.pe/senasacontigo/piura-minagri-atiende-pequenos-caficultores-mediante-escuelas-de-campo/>

Solutions, M. (2018). *Machine Learning, una pieza clave en la transformación de los modelos de negocio*. Management Solutions

<https://www.managementsolutions.com/sites/default/files/publicaciones/esp/machine-learning.pdf>

Tablas González, I., Guerrero Rodríguez, J. de D., Aceves Ruiz, E., Álvarez Calderón, N. M., Loyo, E. L., & Olvera Hernández, J. I. (2021). El cultivo de café en Ojo de Agua de Cuauhtémoc, Malinaltepec, Guerrero. *Revista Mexicana De Ciencias Agrícolas*, 12(6), 1031–1042. <https://doi.org/10.29312/remexca.v12i6.2736>

Valenzuela Cámara, S. (2022). *Detección y Clasificación de Enfermedades en el Tomate Mediante Deep Learning y Computer Vision* [Tesis de Maestría, Universidad Nacional de La Plata]. <https://sedici.unlp.edu.ar/handle/10915/139770>

Verdeguer Gómez, J. (2020). *Redes neuronales para la clasificación y segmentación de imágenes médicas* [Tesis de Maestría, Universidad politécnica de Valencia]. <http://hdl.handle.net/10251/158739>

Vilchez Guizado, J., & Ramón Ortiz, J. (2024). Influencia del pensamiento computacional y visual en el aprendizaje de la matemática en estudiantes universitarios. *Información tecnológica*, 35(4), 13-24. <https://dx.doi.org/10.4067/s0718-07642024000400013>

Zamora Gutiérrez, M. (2021). *Teoría general de sistemas*. San Marcos <https://repositorio.usam.ac.cr/xmlui/handle/11506/2564>

ANEXOS

Anexo 1: Matriz de consistencia

Título: Modelo de reconocimiento visual para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.				
PROBLEMA	OBJETIVOS	HIPÓTESIS	VARIABLES E INDICADORES	DISEÑO METODOLÓGICO
<p>Problema General:</p> <p>¿De qué manera el modelo de reconocimiento visual permite identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024?</p> <p>Problemas Específicos:</p> <p>PE1: ¿Cómo validar la efectividad del modelo de reconocimiento visual de enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024?</p> <p>PE2: ¿En qué medida el modelo de reconocimiento visual mejora el tiempo promedio en la identificación de enfermedades del cultivo de café en la comunidad</p>	<p>Objetivo General:</p> <p>Determinar como el modelo de reconocimiento visual permite identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024</p> <p>Objetivos Específicos:</p> <p>OE1: Validar la efectividad del modelo de reconocimiento visual de enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.</p> <p>OE2: Determinar en qué medida el modelo de reconocimiento visual mejora el tiempo promedio en la identificación de enfermedades del cultivo de café en la comunidad</p>	<p>Hipótesis General:</p> <p>El modelo de reconocimiento visual es estadísticamente eficiente para la identificación de enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024</p> <p>Hipótesis Específicas:</p> <p>HE1: La validación del modelo de reconocimiento visual confirma su efectividad para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.</p> <p>HE2: El modelo de reconocimiento visual mejora significativamente el tiempo promedio en la identificación de enfermedades del cultivo</p>	<p>Variable Independiente:</p> <p>Modelo de reconocimiento visual.</p> <p>Variable Dependiente:</p> <p>Enfermedades del cultivo de café</p> <p>Dimensiones:</p> <ul style="list-style-type: none"> - Métricas de desempeño del modelo. - Roya amarilla, Ojo de gallo, La Antracnosis. <p>Indicadores:</p> <p>-Sensibilidad, Especificidad, Precisión Exactitud, y Rendimiento del modelo.</p> <p>-Efectividad del modelo, Tiempo promedio en la identificación.</p>	<p>Tipo de Investigación:</p> <p>Investigación de tipo aplicada.</p> <p>Enfoque de la investigación:</p> <p>Investigación de enfoque cuantitativo.</p> <p>Método y diseño de la investigación:</p> <p>Diseño experimental, con un método hipotético – deductivo.</p> <p>Población y Muestra:</p> <p>Población 2000 plantas de café con una muestra de 42 plantas de café de los agricultores de la comunidad de Tacalpo 2024.</p> <p>Unidad de análisis:</p> <p>Una planta de café de los agricultores de la comunidad de Tacalpo 2024.</p>

de Tacalpo, Ayabaca,
Piura 2024?

de Tacalpo, Ayabaca,
Piura 2024.

de café en la comunidad
de Tacalpo, Ayabaca,
Piura en 2024.

**Técnicas de recolección
de datos:**

Encuesta y observación.

**Instrumento de
recolección de datos:**

Cuestionario y ficha de
observación

**Método de análisis de
datos:**

SPSS v30 y Excel

Anexo 2: Instrumentos

Figura 10

Cuestionario aplicado a los especialistas y agricultores

24/10/24, 1:05 p.m. Clasificación Enfermedades cultivo de café


Clasificación Enfermedades cultivo de café

Este cuestionario permite identificar y clasificar enfermedades en los cultivos de café en la comunidad de Tacalpo, Ayabaca, Piura.


* Indica que la pregunta es obligatoria

Tipos de enfermedades del cultivo de café


Antracnosis
(*Colletotrichum gloeosporioides*)



Ojo de gallo
(*Mycena citricolora*)



Roya amarilla
(*Hemileia vastatrix*)




- Nombres completos *
- Profesión *
- Grado Académico *

<https://docs.google.com/forms/d/1jBgcRICITFZNVUjzNqROi6CynLOJ/AAIAoX23-E/edit>

24/10/24, 1:05 p.m. Clasificación Enfermedades cultivo de café

4. 1. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

Ojo de gallo

Roya amarilla

Antracnosis

Hoja sana

<https://docs.google.com/forms/d/1jBgcRICITFZNVUjzNqROi6CynLOJ/AAIAoX23-E/edit>

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

5. 2. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

6. 3. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

<https://docs.google.com/forms/d/1jB9xcRICITFZNWJczNxQROI6jCynLOjVAAtAoX23-E/edit>

3/35

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

7. 4. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

8. 5. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

<https://docs.google.com/forms/d/1jB9xcRICITFZNWJczNxQROI6jCynLOjVAAtAoX23-E/edit>

4/35

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

9. 6. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

10. 7. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

11. 8. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

12. 9. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

13. 10. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

14. 11. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

15. 12. ¿Qué tipo de enfermedad es? *

*Marca solo un óvalo.*

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

16. 13. ¿Qué tipo de enfermedad es? *

*Marca solo un óvalo.*

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

17. 14. ¿Qué tipo de enfermedad es? *

*Marca solo un óvalo.*

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

18. 15. ¿Qué tipo de enfermedad es? *

*Marca solo un óvalo.*

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

19. 16. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

20. 17. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

21. 18. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

22. 19. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

23. 20. ¿Qué tipo de enfermedad es? *

*Marca solo un óvalo.*

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

24. 21. ¿Qué tipo de enfermedad es? *

*Marca solo un óvalo.*

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

25. 22. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

26. 23. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

27. 24. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

<https://docs.google.com/forms/d/1jB9xcRICITFZnWJczNxQROi6jCynLOJVAAtAoX23-E/edit>

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

28. 25. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

29. 26. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

21/35

<https://docs.google.com/forms/d/1jB9xcRICITFZnWJczNxQROi6jCynLOJVAAtAoX23-E/edit>

22/35

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

30. 27. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

31. 28. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

32. 29. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

33. 30. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

34. 31. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

35. 32. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

36. 33. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

37. 34. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

38. 35. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

39. 36. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

40. 37. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

41. 38. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

42. 39. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

43. 40. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

44. 41. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

24/10/24, 1:05 p.m.

Clasificación Enfermedades cultivo de café

45. 42. ¿Qué tipo de enfermedad es? *



Marca solo un óvalo.

- Ojo de gallo
- Roya amarilla
- Antracnosis
- Hoja sana

Este contenido no ha sido creado ni aprobado por Google.

Google Formularios

Figura 11*Respuestas del cuestionario aplicado a los agricultores*

pregunta	Imagen	Respuesta agricultor	Duracion (Segundos)
1. ¿Qué tipo de enfermedad es?	antracnosis1.jpg	Antracnosis	122.60
2. ¿Qué tipo de enfermedad es?	antracnosis13.jpg	Ojo de gallo	122.60
3. ¿Qué tipo de enfermedad es?	antracnosis15.jpg	Antracnosis	122.60
4. ¿Qué tipo de enfermedad es?	antracnosis16.jpg	Ojo de gallo	122.60
5. ¿Qué tipo de enfermedad es?	antracnosis17.jpg	Hoja sana	60.00
6. ¿Qué tipo de enfermedad es?	antracnosis4.jpg	Hoja sana	60.00
7. ¿Qué tipo de enfermedad es?	antracnosis5.jpg	Hoja sana	60.00
8. ¿Qué tipo de enfermedad es?	antracnosis6.jpg	Hoja sana	60.00
9. ¿Qué tipo de enfermedad es?	antracnosis7.jpg	Antracnosis	88.00
10. ¿Qué tipo de enfermedad es?	antracnosis8.jpg	Roya amarilla	88.00
11. ¿Qué tipo de enfermedad es?	antracnosis9.jpg	Ojo de gallo	88.00
12. ¿Qué tipo de enfermedad es?	ojoDeGallo11.jpg	Roya amarilla	122.60
13. ¿Qué tipo de enfermedad es?	ojoDeGallo20.jpg	Roya amarilla	122.60
14. ¿Qué tipo de enfermedad es?	ojoDeGallo13.jpg	Ojo de gallo	122.60
15. ¿Qué tipo de enfermedad es?	ojoDeGallo14.jpg	Ojo de gallo	122.60
16. ¿Qué tipo de enfermedad es?	ojoDeGallo15.jpg	Ojo de gallo	122.60
17. ¿Qué tipo de enfermedad es?	ojoDeGallo16.jpg	Ojo de gallo	60.00
18. ¿Qué tipo de enfermedad es?	ojoDeGallo21.jpg	Ojo de gallo	60.00
19. ¿Qué tipo de enfermedad es?	ojoDeGallo17.jpg	Ojo de gallo	60.00
20. ¿Qué tipo de enfermedad es?	ojoDeGallo19.jpg	Ojo de gallo	60.00
21. ¿Qué tipo de enfermedad es?	ojoDeGallo2.jpg	Ojo de gallo	60.00
22. ¿Qué tipo de enfermedad es?	ojoDeGallo18.jpg	Ojo de gallo	88.00
23. ¿Qué tipo de enfermedad es?	ojoDeGallo6.jpg	Ojo de gallo	88.00
24. ¿Qué tipo de enfermedad es?	ojoDeGallo7.jpg	Ojo de gallo	88.00
25. ¿Qué tipo de enfermedad es?	ojoDeGallo8.jpg	Ojo de gallo	88.00
26. ¿Qué tipo de enfermedad es?	roya1.jpg	Roya amarilla	122.60
27. ¿Qué tipo de enfermedad es?	roya10.jpg	Roya amarilla	122.60
28. ¿Qué tipo de enfermedad es?	roya11.png	Roya amarilla	122.60
29. ¿Qué tipo de enfermedad es?	roya12.jpg	Roya amarilla	122.60
30. ¿Qué tipo de enfermedad es?	roya13.jpg	Roya amarilla	122.60
31. ¿Qué tipo de enfermedad es?	roya14.jpg	Roya amarilla	60.00
32. ¿Qué tipo de enfermedad es?	roya15.jpg	Ojo de gallo	60.00
33. ¿Qué tipo de enfermedad es?	sanas1.png	Hojas sana	122.60
34. ¿Qué tipo de enfermedad es?	sanas2.jpeg	Hoja sana	60.00
35. ¿Qué tipo de enfermedad es?	sanas3.jpeg	Hoja sana	88.00
36. ¿Qué tipo de enfermedad es?	roya2.jpg	Roya amarilla	60.00
37. ¿Qué tipo de enfermedad es?	roya3.jpg	Roya amarilla	60.00
38. ¿Qué tipo de enfermedad es?	roya5.jpeg	Roya amarilla	60.00
39. ¿Qué tipo de enfermedad es?	roya6.jpeg	Roya amarilla	88.00
40. ¿Qué tipo de enfermedad es?	roya7.jpeg	Roya amarilla	88.00
41. ¿Qué tipo de enfermedad es?	roya8.jpg	Roya amarilla	88.00
42. ¿Qué tipo de enfermedad es?	roya9.png	Roya amarilla	88.00

Figura 12

Respuestas del cuestionario aplicado a los especialistas

Marca temporal		21/10/2024 11:08	21/10/2024 11:06
Nombres completos		Eusebio More Chapilliquen	Darwin Raúl Abad Portocarrero
Profesión		Ingeniería Agrónoma	Técnico agropecuario
Grado Académico		Ingeniero Agrónomo	Superior
pregunta	Imagen	Respuesta especialista1	Respuesta especialista2
1. ¿Qué tipo de enfermedad es?	antracnosis1.jpg	Antracnosis	Antracnosis
2. ¿Qué tipo de enfermedad es?	antracnosis13.jpg	Antracnosis	Antracnosis
3. ¿Qué tipo de enfermedad es?	antracnosis15.jpg	Antracnosis	Antracnosis
4. ¿Qué tipo de enfermedad es?	antracnosis16.jpg	Antracnosis	Antracnosis
5. ¿Qué tipo de enfermedad es?	antracnosis17.jpg	Antracnosis	Antracnosis
6. ¿Qué tipo de enfermedad es?	antracnosis4.jpg	Antracnosis	Antracnosis
7. ¿Qué tipo de enfermedad es?	antracnosis5.jpg	Antracnosis	Antracnosis
8. ¿Qué tipo de enfermedad es?	antracnosis6.jpg	Antracnosis	Antracnosis
9. ¿Qué tipo de enfermedad es?	antracnosis7.jpg	Antracnosis	Antracnosis
10. ¿Qué tipo de enfermedad es?	antracnosis8.jpg	Antracnosis	Antracnosis
11. ¿Qué tipo de enfermedad es?	antracnosis9.jpg	Antracnosis	Antracnosis
12. ¿Qué tipo de enfermedad es?	ojoDeGallo11.jpg	Ojo de gallo	Ojo de gallo
13. ¿Qué tipo de enfermedad es?	ojoDeGallo20.jpg	Ojo de gallo	Ojo de gallo
14. ¿Qué tipo de enfermedad es?	ojoDeGallo13.jpg	Ojo de gallo	Ojo de gallo
15. ¿Qué tipo de enfermedad es?	ojoDeGallo14.jpg	Ojo de gallo	Ojo de gallo
16. ¿Qué tipo de enfermedad es?	ojoDeGallo15.jpg	Ojo de gallo	Ojo de gallo
17. ¿Qué tipo de enfermedad es?	ojoDeGallo16.jpg	Ojo de gallo	Ojo de gallo
18. ¿Qué tipo de enfermedad es?	ojoDeGallo21.jpg	Ojo de gallo	Ojo de gallo
19. ¿Qué tipo de enfermedad es?	ojoDeGallo17.jpg	Ojo de gallo	Ojo de gallo
20. ¿Qué tipo de enfermedad es?	ojoDeGallo19.jpg	Ojo de gallo	Ojo de gallo
21. ¿Qué tipo de enfermedad es?	ojoDeGallo2.jpg	Ojo de gallo	Ojo de gallo
22. ¿Qué tipo de enfermedad es?	ojoDeGallo18.jpg	Ojo de gallo	Ojo de gallo
23. ¿Qué tipo de enfermedad es?	ojoDeGallo6.jpg	Ojo de gallo	Ojo de gallo
24. ¿Qué tipo de enfermedad es?	ojoDeGallo7.jpg	Ojo de gallo	Ojo de gallo
25. ¿Qué tipo de enfermedad es?	ojoDeGallo8.jpg	Ojo de gallo	Ojo de gallo
26. ¿Qué tipo de enfermedad es?	roya1.jpg	Roya amarilla	Roya amarilla
27. ¿Qué tipo de enfermedad es?	roya10.jpg	Roya amarilla	Roya amarilla
28. ¿Qué tipo de enfermedad es?	roya11.png	Roya amarilla	Roya amarilla
29. ¿Qué tipo de enfermedad es?	roya12.jpg	Roya amarilla	Roya amarilla
30. ¿Qué tipo de enfermedad es?	roya13.jpg	Roya amarilla	Roya amarilla
31. ¿Qué tipo de enfermedad es?	roya14.jpg	Roya amarilla	Roya amarilla
32. ¿Qué tipo de enfermedad es?	roya15.jpg	Roya amarilla	Roya amarilla
33. ¿Qué tipo de enfermedad es?	sanas1.png	sana	sana
34. ¿Qué tipo de enfermedad es?	sanas2.jpeg	sana	sana
35. ¿Qué tipo de enfermedad es?	sanas3.jpeg	sana	sana
36. ¿Qué tipo de enfermedad es?	roya2.jpg	Roya amarilla	Roya amarilla
37. ¿Qué tipo de enfermedad es?	roya3.jpg	Roya amarilla	Roya amarilla
38. ¿Qué tipo de enfermedad es?	roya5.jpeg	Roya amarilla	Roya amarilla
39. ¿Qué tipo de enfermedad es?	roya6.jpeg	Roya amarilla	Roya amarilla
40. ¿Qué tipo de enfermedad es?	roya7.jpeg	Roya amarilla	Roya amarilla
41. ¿Qué tipo de enfermedad es?	roya8.jpg	Roya amarilla	Roya amarilla
42. ¿Qué tipo de enfermedad es?	roya9.png	Roya amarilla	Roya amarilla

Figura 13*Ficha de observación del Pre Test*

Pre Test		Ficha de Observacion n°01	
Muestra	Respuesta agricultor	Tiempo Respuesta Agricultor (Segundos)	Respuesta Especialista
1	Antracnosis	122.60	Antracnosis
2	Ojo de gallo	122.60	Antracnosis
3	Antracnosis	122.60	Antracnosis
4	Ojo de gallo	122.60	Antracnosis
5	Hoja sana	60.00	Antracnosis
6	Hoja sana	60.00	Antracnosis
7	Hoja sana	60.00	Antracnosis
8	Hoja sana	60.00	Antracnosis
9	Antracnosis	88.00	Antracnosis
10	Roya	88.00	Antracnosis
11	Ojo de gallo	88.00	Antracnosis
12	Roya	122.60	Ojo de gallo
13	Roya	122.60	Ojo de gallo
14	Ojo de gallo	122.60	Ojo de gallo
15	Ojo de gallo	122.60	Ojo de gallo
16	Ojo de gallo	122.60	Ojo de gallo
17	Ojo de gallo	60.00	Ojo de gallo
18	Ojo de gallo	60.00	Ojo de gallo
19	Ojo de gallo	60.00	Ojo de gallo
20	Ojo de gallo	60.00	Ojo de gallo
21	Ojo de gallo	60.00	Ojo de gallo
22	Ojo de gallo	88.00	Ojo de gallo
23	Ojo de gallo	88.00	Ojo de gallo
24	Ojo de gallo	88.00	Ojo de gallo
25	Ojo de gallo	88.00	Ojo de gallo
26	Roya	122.60	Roya amarilla
27	Roya	122.60	Roya amarilla
28	Roya	122.60	Roya amarilla
29	Roya	122.60	Roya amarilla
30	Roya	122.60	Roya amarilla
31	Roya	60.00	Roya amarilla
32	Ojo de gallo	60.00	Roya amarilla
33	Hojas sana	122.60	sana
34	Hoja sana	60.00	sana
35	Hoja sana	88.00	sana
36	Roya	60.00	Roya amarilla
37	Roya	60.00	Roya amarilla
38	Roya	60.00	Roya amarilla
39	Roya	88.00	Roya amarilla
40	Roya	88.00	Roya amarilla
41	Roya	88.00	Roya amarilla
42	Roya	88.00	Roya amarilla

Figura 14*Ficha de observación del Post Test*

Post Test		Ficha de Observacion nº02		
Muestra	Respuesta Modelo	Probabilidad Respuesta Modelo	Tiempo Respuesta Modelo (Segundos)	Respuesta Especialista
1	Antracnosis	0.99	1.83	Antracnosis
2	Antracnosis	1.00	7.39	Antracnosis
3	Ojo de gallo	0.88	7.78	Antracnosis
4	Antracnosis	1.00	5.09	Antracnosis
5	Antracnosis	0.97	3.65	Antracnosis
6	Antracnosis	0.98	3.21	Antracnosis
7	Antracnosis	0.99	7.08	Antracnosis
8	Antracnosis	0.97	3.80	Antracnosis
9	Antracnosis	0.91	5.92	Antracnosis
10	Antracnosis	0.98	3.46	Antracnosis
11	Antracnosis	0.99	3.32	Antracnosis
12	Roya amarilla	0.85	2.12	Ojo de gallo
13	Ojo de gallo	0.76	2.67	Ojo de gallo
14	Ojo de gallo	1.00	2.90	Ojo de gallo
15	Ojo de gallo	0.98	2.44	Ojo de gallo
16	Roya amarilla	1.00	0.77	Ojo de gallo
17	Ojo de gallo	0.98	4.34	Ojo de gallo
18	Ojo de gallo	1.00	4.33	Ojo de gallo
19	Ojo de gallo	1.00	2.92	Ojo de gallo
20	Ojo de gallo	0.99	3.56	Ojo de gallo
21	Ojo de gallo	1.00	5.56	Ojo de gallo
22	Ojo de gallo	0.99	3.03	Ojo de gallo
23	Ojo de gallo	1.00	5.59	Ojo de gallo
24	Ojo de gallo	1.00	5.43	Ojo de gallo
25	Ojo de gallo	1.00	2.17	Ojo de gallo
26	Roya amarilla	1.00	1.28	Roya amarilla
27	Roya amarilla	0.99	1.14	Roya amarilla
28	Roya amarilla	0.98	2.08	Roya amarilla
29	Roya amarilla	0.99	0.92	Roya amarilla
30	Roya amarilla	1.00	0.93	Roya amarilla
31	Roya amarilla	0.99	1.04	Roya amarilla
32	Antracnosis	0.99	2.29	Roya amarilla
33	Negative	1.00	2.49	sana
34	Negative	1.00	0.73	sana
35	Negative	1.00	0.66	sana
36	Roya amarilla	1.00	2.20	Roya amarilla
37	Roya amarilla	1.00	1.25	Roya amarilla
38	Roya amarilla	1.00	0.69	Roya amarilla
39	Roya amarilla	1.00	0.66	Roya amarilla
40	Roya amarilla	1.00	0.62	Roya amarilla
41	Roya amarilla	1.00	1.09	Roya amarilla
42	Roya amarilla	0.98	0.84	Roya amarilla

Figura 15*Ficha de observación del Retest*

Retest			Ficha de Observacion n°03	
Muestra	Respuesta Modelo	Probabilidad Respuesta Modelo	Tiempo Respuesta Modelo (Segundos)	Respuesta Especialista
1	Antracnosis	0.99	0.83	Antracnosis
2	Antracnosis	1.00	3.53	Antracnosis
3	Ojo de gallo	0.88	2.72	Antracnosis
4	Antracnosis	1.00	3.23	Antracnosis
5	Antracnosis	0.97	2.15	Antracnosis
6	Antracnosis	0.98	2.02	Antracnosis
7	Antracnosis	0.99	2.64	Antracnosis
8	Antracnosis	0.97	1.90	Antracnosis
9	Antracnosis	0.91	3.33	Antracnosis
10	Antracnosis	0.98	3.16	Antracnosis
11	Antracnosis	0.99	2.31	Antracnosis
12	Roya amarilla	0.85	1.88	Ojo de gallo
13	Ojo de gallo	0.76	2.56	Ojo de gallo
14	Ojo de gallo	1.00	2.70	Ojo de gallo
15	Ojo de gallo	0.98	2.36	Ojo de gallo
16	Roya amarilla	1.00	0.92	Ojo de gallo
17	Ojo de gallo	0.98	2.55	Ojo de gallo
18	Ojo de gallo	1.00	2.85	Ojo de gallo
19	Ojo de gallo	1.00	2.54	Ojo de gallo
20	Ojo de gallo	0.99	1.74	Ojo de gallo
21	Ojo de gallo	1.00	2.46	Ojo de gallo
22	Ojo de gallo	0.99	1.91	Ojo de gallo
23	Ojo de gallo	1.00	3.31	Ojo de gallo
24	Ojo de gallo	1.00	4.27	Ojo de gallo
25	Ojo de gallo	1.00	1.71	Ojo de gallo
26	Roya amarilla	1.00	1.30	Roya amarilla
27	Roya amarilla	0.99	1.09	Roya amarilla
28	Roya amarilla	0.98	1.62	Roya amarilla
29	Roya amarilla	0.99	0.94	Roya amarilla
30	Roya amarilla	1.00	0.89	Roya amarilla
31	Roya amarilla	0.99	0.98	Roya amarilla
32	Antracnosis	0.99	1.91	Roya amarilla
33	Negative	1.00	2.07	sana
34	Negative	1.00	0.77	sana
35	Negative	1.00	0.76	sana
36	Roya amarilla	1.00	1.29	Roya amarilla
37	Roya amarilla	1.00	0.95	Roya amarilla
38	Roya amarilla	1.00	0.67	Roya amarilla
39	Roya amarilla	1.00	0.65	Roya amarilla
40	Roya amarilla	1.00	0.66	Roya amarilla
41	Roya amarilla	1.00	1.07	Roya amarilla
42	Roya amarilla	0.98	0.85	Roya amarilla

Anexo 3: Validez del instrumento

Documentos para validar los instrumentos de medición a través de juicio de expertos

CARTA DE PRESENTACIÓN

Magíster/Doctor: Cordova Forero Julio Alfredo Martin

Presente

Asunto: VALIDACIÓN DE INSTRUMENTOS A TRAVÉS DE JUICIO DE EXPERTO.

Es muy grato comunicarme con usted para expresarle mi saludo y, asimismo, hacer de su conocimiento que siendo estudiante del programa de titulación requiero validar los instrumentos a fin de recoger la información necesaria para desarrollar mi investigación, con la cual optaré el grado de Ingeniero de Sistemas.

El título nombre de mi proyecto de investigación es “Modelo de reconocimiento visual para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024” y, debido a que es imprescindible contar con la aprobación de docentes especializados para aplicar los instrumentos en mención, he considerado conveniente recurrir a usted, ante su connotada experiencia en temas de ingeniería.

El expediente de validación que le hago llegar contiene:

- Carta de presentación.
- Definiciones conceptuales de las variables y dimensiones.
- Matriz de operacionalización de las variables.
- Certificado de validez de contenido de los instrumentos.

Expresándole los sentimientos de respeto y consideración, me despido de usted, no sin antes agradecer por la atención que dispense a la presente.

Atentamente,



Nombre: Denilson Jaramillo Castillo

DNI: 76131029

Documentos para validar los instrumentos de medición a través de juicio de expertos**CARTA DE PRESENTACIÓN**

Magíster/Doctor: Dr Joel Martin Visurraga Agüero

Presente

Asunto: VALIDACIÓN DE INSTRUMENTOS A TRAVÉS DE JUICIO DE EXPERTO.

Es muy grato comunicarme con usted para expresarle mi saludo y, asimismo, hacer de su conocimiento que siendo estudiante del programa de titulación requiero validar los instrumentos a fin de recoger la información necesaria para desarrollar mi investigación, con la cual optaré el grado de Ingeniero de Sistemas.

El título nombre de mi proyecto de investigación es “Modelo de reconocimiento visual para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024” y, debido a que es imprescindible contar con la aprobación de docentes especializados para aplicar los instrumentos en mención, he considerado conveniente recurrir a usted, ante su connotada experiencia en temas de ingeniería.

El expediente de validación que le hago llegar contiene:

- Carta de presentación.
- Definiciones conceptuales de las variables y dimensiones.
- Matriz de operacionalización de las variables.
- Certificado de validez de contenido de los instrumentos.

Expresándole los sentimientos de respeto y consideración, me despido de usted, no sin antes agradecer por la atención que dispense a la presente.

Atentamente,



Nombre: Denilson Jaramillo Castillo

DNI: 76131029

Documentos para validar los instrumentos de medición a través de juicio de expertos**CARTA DE PRESENTACIÓN**

Magíster/Doctor: CALERO HUAMAN CHARLEN MAXIMO

Presente

Asunto: VALIDACIÓN DE INSTRUMENTOS A TRAVÉS DE JUICIO DE EXPERTO.

Es muy grato comunicarme con usted para expresarle mi saludo y, asimismo, hacer de su conocimiento que siendo estudiante del programa de titulación requiero validar los instrumentos a fin de recoger la información necesaria para desarrollar mi investigación, con la cual optaré el grado de Ingeniero de Sistemas.

El título nombre de mi proyecto de investigación es “Modelo de reconocimiento visual para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024” y, debido a que es imprescindible contar con la aprobación de docentes especializados para aplicar los instrumentos en mención, he considerado conveniente recurrir a usted, ante su connotada experiencia en temas de ingeniería.

El expediente de validación que le hago llegar contiene:

- Carta de presentación.
- Definiciones conceptuales de las variables y dimensiones.
- Matriz de operacionalización de las variables.
- Certificado de validez de contenido de los instrumentos.

Expresándole los sentimientos de respeto y consideración, me despido de usted, no sin antes agradecer por la atención que dispense a la presente.

Atentamente,



Nombre: Denilson Jaramillo Castillo

DNI: 76131029

Definición conceptual de las variables y dimensiones**Variable 1:** Modelo de reconocimiento visual

Implementación de un modelo entrenado con imágenes de café afectado por distintas enfermedades, capaz de detectar y clasificar automáticamente las enfermedades a partir de fotos de las hojas.

Dimensiones de la variable:

Métricas de desempeño del modelo:

Rendimiento del modelo de reconocimiento visual al identificar enfermedades del café, medido por la precisión, velocidad, y capacidad de identificar múltiples enfermedades.

Variable 2: Enfermedades del cultivo de café

Presencia de síntomas visibles en las plantas de café que indican infecciones por hongos, bacterias, virus u otros agentes patógenos. Estas enfermedades pueden ser detectadas visualmente o mediante el uso de tecnologías de reconocimiento visual.

Dimensiones de la variable:

Roya amarilla: Presencia de manchas amarillas en las hojas del cafeto, causada por *Hemileia vastatrix*. Se evalúa la extensión de la infección en las hojas y el número de plantas afectadas.

Ojo de gallo: Presencia de manchas circulares de color marrón claro y bordes más oscuros en las hojas de café.

Antracnosis: Presencia de manchas necróticas en las hojas, frutos o ramas del cafeto. Se mide la severidad de las manchas y la extensión de la infección en las distintas partes de la planta.

Matriz de operacionalización de la variable

Variable 1: Modelo de reconocimiento visual

Dimensiones	Definición conceptual	Definición operacional	Indicador	Escala de medición	Escala valorativa
Métricas de desempeño del modelo.	Sistema automatizado basado en tecnologías de visión por computadora que permite adquirir, procesar, analizar y entender imágenes digitales. (Redolfi, 2018)	Implementación de un modelo entrenado con imágenes de café afectado por enfermedades, capaz de detectar y clasificar automáticamente las enfermedades a partir de fotos de las hojas.	- Sensibilidad. - Especificidad. - Precisión. - Exactitud. - Rendimiento del modelo.	Nominal	Escala de Likert

Variable 2: Enfermedades del cultivo de café

Dimensiones	Definición conceptual	Definición operacional	Indicador	Escala de medición	Escala valorativa
- Roya amarilla - Ojo de gallo - Antracnosis.	Conjunto de patologías que se presentan en diferentes etapas del desarrollo de la planta las cuales afectan la producción del cultivo de café, causando deterioro en las hojas, tallos, frutos y raíces, (Tablas, et al. 2021).	Presencia de síntomas visibles en las plantas de café que indican infecciones por hongos, bacterias, virus u otros agentes patógenos. Estas enfermedades pueden ser detectadas visualmente o mediante el uso de tecnologías de reconocimiento visual.	- Efectividad del modelo - Tiempo promedio en la identificación.	Razón	Porcentaje y razón

Modelo de reconocimiento visual para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024

N.º	DIMENSIONES / ítems	Pertinencia ¹	Relevancia ²	Claridad ³	Sugerencias			
Variable 1: Modelo de reconocimiento visual								
DIMENSIÓN 1: Métricas de desempeño del modelo.		Sí	No	Si	No	Si	No	
1	Sensibilidad	$\frac{TP}{TP + FN}$	x		x		x	
2	Especificidad	$\frac{TN}{TN + FP}$	x		x		x	
3	Precisión	$\frac{TP}{TP + FP}$	x		x		x	
4	Exactitud	$\frac{TP + TN}{TP + TN + FP + FN}$	x		x		x	
5	Rendimiento del modelo	Área Bajo la Curva (AUC)	x		x		x	
Variable 2: Enfermedades del cultivo de café								
DIMENSIÓN 1: Roya amarilla, Ojo de gallo, Antracnosis.		Sí	No	Si	No	Si	No	
1	Efectividad del modelo	$\frac{TCC}{TM} \times 100$	x		x		x	
2	Tiempo promedio en la identificación.	$\frac{\sum TI}{TM}$	x		x		x	

TP: Verdaderos Positivo.

FN: Falsos Negativos.

TN: Verdaderos Negativos.

FP: Falsos Positivos.

TCC: Número total de coincidencias correctas.

TM: Número total de muestras.

$\sum TI$: Suma de los tiempos en la identificación.

¹**Pertinencia:** el ítem corresponde al concepto teórico formulado.

²**Relevancia:** el ítem es apropiado para representar al componente o dimensión específica del constructo.

³**Claridad:** se entiende sin dificultad alguna el enunciado del ítem, es conciso, exacto y directo.

Nota. Suficiencia: se dice suficiencia cuando los ítems planteados son suficientes para medir la dimensión.

Observaciones (precisar si hay suficiencia):

Opinión de aplicabilidad:

Aplicable [x]

Aplicable después de corregir []

No aplicable []

Apellidos y nombres del juez validador: Dr./Mg. Cordova Forero Julio Alfredo

DNI: 09924829

Especialidad del validador: Ingeniero en Estadística e Informática

08 de noviembre del 2024



Cordova Forero Julio Alfredo

**Modelo de reconocimiento visual para identificar enfermedades del cultivo de café
en la comunidad de Tacalpo, Ayabaca, Piura 2024**

N.º	DIMENSIONES / ítems	Pertinencia ¹	Relevancia ²	Claridad ³	Sugerencias			
Variable 1: Modelo de reconocimiento visual								
DIMENSIÓN 1: Métricas de desempeño del modelo.		Sí	No	Sí	No	Sí	No	
1	Sensibilidad	$\frac{TP}{TP + FN}$	X		X		X	
2	Especificidad	$\frac{TN}{TN + FP}$	X		X		X	
3	Precisión	$\frac{TP}{TP + FP}$	X		X		X	
4	Exactitud	$\frac{TP + TN}{TP + TN + FP + FN}$	X		X		X	
5	Rendimiento del modelo	Área Bajo la Curva (AUC)	X		X		X	
Variable 2: Enfermedades del cultivo de café								
DIMENSIÓN 1: Roya amarilla, Ojo de gallo, Antracnosis.		Sí	No	Sí	No	Sí	No	
1	Efectividad del modelo	$\frac{TCC}{TM} \times 100$	X		X		X	
2	Tiempo promedio en la identificación.	$\frac{\sum TI}{TM}$	X		X		X	

TP: Verdaderos Positivo.

FN: Falsos Negativos.

TN: Verdaderos Negativos.

FP: Falsos Positivos.

TCC: Número total de coincidencias correctas.

TM: Número total de muestras.

$\sum TI$: suma de los tiempos en la identificación.

¹**Pertinencia:** el ítem corresponde al concepto teórico formulado.

²**Relevancia:** el ítem es apropiado para representar al componente o dimensión específica del constructo.

³**Claridad:** se entiende sin dificultad alguna el enunciado del ítem, es conciso, exacto y directo.

Nota. Suficiencia: se dice suficiencia cuando los ítems planteados son suficientes para medir la dimensión.

Observaciones (precisar si hay suficiencia): Suficiente

Opinión de aplicabilidad:

Aplicable [X] Aplicable después de corregir [] No aplicable []

Apellidos y nombres del juez validador: Dr Joel Martin Visurraga Agüero

DNI: 10192315

Especialidad del validador: Ingeniería de Sistemas e Informática

11 de noviembre del 2024



Dr. Ing. Joel Martin Visurraga Agüero

Modelo de reconocimiento visual para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024

N.º	DIMENSIONES / ítems	Pertinencia ¹	Relevancia ²	Claridad ³	Sugerencias			
Variable 1: Modelo de reconocimiento visual								
DIMENSIÓN 1: Métricas de desempeño del modelo.		Sí	No	Si	No	Si	No	
1	Sensibilidad	$\frac{TP}{TP + FN}$	X		X		X	
2	Especificidad	$\frac{TN}{TN + FP}$	X		X		X	
3	Precisión	$\frac{TP}{TP + FP}$	X		X		X	
4	Exactitud	$\frac{TP + TN}{TP + TN + FP + FN}$	X		X		X	
5	Rendimiento del modelo	Área Bajo la Curva (AUC)	X		X		X	
Variable 2: Enfermedades del cultivo de café								
DIMENSIÓN 1: Roya amarilla, Ojo de gallo, Antracnosis.		Sí	No	Si	No	Si	No	
1	Efectividad del modelo	$\frac{TCC}{TM} \times 100$	X		X		X	
2	Tiempo promedio en la identificación.	$\frac{\sum TI}{TM}$	X		X		X	

TP: Verdaderos Positivo.

FN: Falsos Negativos.

TN: Verdaderos Negativos.

FP: Falsos Positivos.

TCC: Número total de coincidencias correctas.

TM: Número total de muestras.

$\sum TI$: suma de los tiempos en la identificación.

¹**Pertinencia:** el ítem corresponde al concepto teórico formulado.

²**Relevancia:** el ítem es apropiado para representar al componente o dimensión específica del constructo.

³**Claridad:** se entiende sin dificultad alguna el enunciado del ítem, es conciso, exacto y directo.

Nota. Suficiencia: se dice suficiencia cuando los ítems planteados son suficientes para medir la dimensión.

Observaciones (precisar si hay suficiencia):

Opinión de aplicabilidad:

Aplicable [x]

Aplicable después de corregir []

No aplicable []

Apellidos y nombres del juez validador: CALERO HUAMAN CHARLEN MAXIMO

DNI: 43679394

Especialidad del validador: MAESTRO INGENIERIA DE SISTEMAS

21 de noviembre del 2024

CHARLEN MAXIMO CALERO HUAMAN

Anexo 4: Confiabilidad del instrumento**Tabla 25***Confiabilidad del instrumento según el coeficiente alfa de Cronbach*

Estadísticas de fiabilidad	
Alfa de Cronbach	N de elementos
0.979	5

Valor obtenido (0.979): Este coeficiente indica una muy alta fiabilidad entre los ítems analizados. Un Alfa de Cronbach superior a 0.9 es considerado excelente, lo que sugiere que los 5 elementos incluidos en el análisis están midiendo de manera consistente el mismo constructo.

Anexo 5: Aprobación del Comité de Ética



COMITÉ INSTITUCIONAL DE ÉTICA E INTEGRIDAD CIENTÍFICA

CONSTANCIA DE APROBACIÓN

Lima, 30 de Diciembre de 2024

Investigador(a)
DENILSON JARAMILLO CASTILLO
Exp. N°:1147-2024

De mi consideración:

Es grato expresarle mi cordial saludo y a la vez informarle que el Comité Institucional de Ética e Integridad Científica de la Universidad Privada Norbert Wiener (CIEIC-UPNW) **evaluó** y **APROBÓ** los siguientes documentos:

- Protocolo titulado: “**Modelo de reconocimiento visual para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024..**” **Versión 01** con fecha **21/12/2024**.
- Formulario de Consentimiento Informado Versión **01** con fecha **21/12/2024**.

El cual tiene como investigador principal al Sr(a) Denilson Jaramillo Castillo.

La APROBACIÓN comprende el cumplimiento de las buenas prácticas éticas, el balance riesgo/beneficio, la calificación del equipo de investigación y la confidencialidad de los datos, entre otros.

El investigador deberá considerar los siguientes puntos detallados a continuación:

1. **La vigencia** de la aprobación es de **dos años** (24 meses) a partir de la emisión de este documento.
2. **El Informe de Avances** se presentará cada 6 meses, y el informe final una vez concluido el estudio.
3. **Toda enmienda o adenda** se deberá presentar al CIEIC-UPNW y no podrá implementarse sin la debida aprobación.
4. Si aplica, **la Renovación** de aprobación del proyecto de investigación deberá iniciarse treinta (30) días antes de la fecha de vencimiento, con su respectivo informe de avance.

Es cuanto informo a usted para su conocimiento y fines pertinentes.

Atentamente,

Raúl Antonio Rojas Ortega
Presidente

Comité Institucional de Ética e Integridad Científica
UPNW



Anexo 6: Formato de consentimiento informado

"Año del Bicentenario, de la consolidación de nuestra Independencia, y de la conmemoración de las heroicas batallas de Junín y Ayacucho"

CONSENTIMIENTO

El que suscribe Octavio Jaramillo Mija.

Consta que:

El Sr. Jaramillo Castillo Denilson con DNI 76131029, se encuentra desarrollando su tesis en mis terrenos, titulada modelo de reconocimiento visual para identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024, según los requerimientos especificados, para ayudar a que este proceso se optimice.

El modelo de reconocimiento visual facilitará la identificación temprana de enfermedades en los cultivos de café, mejorando el manejo agrícola y la productividad.

Se emite esta constancia para los fines que el alumno crea conveniente.

Ayabaca, 08 de noviembre del 2024.



Octavio Jaramillo Mija

DNI 03126800

Anexo 7: Informe del asesor de turnitin

NOMBRE DEL TRABAJO

Proyecto Tesis Jaramillo Denilson final (2).docx

AUTOR

Denilson Jaramillo

RECuento DE PALABRAS

17990 Words

RECuento DE CARACTERES

103171 Characters

RECuento DE PÁGINAS

155 Pages

TAMAÑO DEL ARCHIVO

22.8MB

FECHA DE ENTREGA

Jan 27, 2025 6:52 PM GMT-5

FECHA DEL INFORME

Jan 27, 2025 6:54 PM GMT-5

● 16% de similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para cada base de datos.

- 13% Base de datos de Internet
- Base de datos de Crossref
- 13% Base de datos de trabajos entregados
- 3% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

● Excluir del Reporte de Similitud

- Material bibliográfico
- Material citado
- Material citado
- Material citado
- Coincidencia baja (menos de 10 palabras)

1. PLANEACIÓN DEL PROYECTO

Objetivo general:

Desarrollar un modelo de reconocimiento visual que permita identificar enfermedades del cultivo de café en la comunidad de Tacalpo, Ayabaca, Piura 2024.

Objetivos específicos:

Recopilar y organizar imágenes representativas de plagas y enfermedades comunes en cultivos de café.

Diseñar y entrenar un modelo de reconocimiento visual utilizando Custom Vision de Azure AI para clasificar e identificar las enfermedades.

Validar la precisión y efectividad del modelo mediante pruebas con datos reales provenientes de la comunidad.

Implementar el modelo en un sistema accesible para agricultores de la región.

Alcance

Recopilación de datos: Se obtendrán imágenes de cultivos afectados en la región, asegurando su correcta rotulación.

Desarrollo del modelo: Se emplearán técnicas avanzadas de visión por computadora en Azure para construir el modelo.

Pruebas y validación: Se evaluará la efectividad del modelo mediante métricas como precisión, sensibilidad y especificidad.

Implementación y capacitación: Se diseñará una interfaz para agricultores y se realizarán capacitaciones básicas en el uso del sistema.

Asimismo, se revisó investigaciones y tecnologías relacionadas con el uso de visión por computadora para la detección de enfermedades en cultivos, con un énfasis particular en cultivos de café.

Presupuesto

Tabla 26


Presupuesto del proyecto

Tipo de cambio	S/3.78				
PROPUESTA	Cantidad	Tiempo	C/U S/	Total S/	Total \$
IMPLEMENTACIÓN					
RR. HH.					
Jefe de proyecto	1	3	S/3,000.00	S/9,000.00	\$2,384.11
Diseñador	1	3	S/2,000.00	S/6,000.00	\$1,589.40
Programador	1	3	S/2,000.00	S/6,000.00	\$1,589.40
Analista de datos	1	3	S/2,000.00	S/6,000.00	\$1,589.40
EQUIPO TECNOLÓGICO					
Computadora	4		S/2,000.00	S/8,000.00	\$2,119.21
LICENCIAS					
Custom vision Service	1	3	S/47.94	S/143.83	\$38.10
Android Studio	1	3	0	S/0.00	\$0.00
Microsoft office 2019	4	1	210	S/840.00	\$222.52
StarUML	1	3	0	S/0.00	\$0.00
Balsamiq	1	3	S/33.98	S/101.93	\$27.00
SPSS	1	3	S/261.61	S/784.82	\$207.90
SERVICIOS BASICOS					
Internet	1	3	120	S/360.00	\$95.36
Energía Eléctrica	1	3	50	S/150.00	\$39.74
Agua	1	3	30	S/90.00	\$23.84
Útiles	1	3	20	S/60.00	\$15.89
Alquiler de Oficina	1	3	500	S/1,500.00	\$397.35
CAPACITACIÓN					
Capacitación	1	1	2000	S/2,000.00	\$529.80
TOTAL				S/41,030.58	\$10,869.03

Cronograma de actividades

Figura 16

Diagrama de actividades del proyecto



2. RECOLECCIÓN DE DATOS

Con el consentimiento informado de los agricultores locales para acceder a los cultivos se realizó capturas de imágenes en diferentes condiciones de luz natural para evitar sesgos en el entrenamiento del modelo. Además, de limpiar las hojas antes de la toma para eliminar partículas que puedan confundir al modelo. Asimismo, se tomó fotografías a hojas sanas y afectadas para garantizar que el modelo diferencie entre estados saludables y enfermos. Todo ello se realizó en distintas zonas de la comunidad de Tacalpo para reflejar la diversidad geográfica y ambiental.

3. PREPROCESAMIENTO DE DATOS

Con las imágenes tomadas se procedió a limpiar, ajustar, organizar y etiquetar cada una para posteriormente organizarlas por carpetas y renombrarlas de manera uniforme para facilitar su identificación y trazabilidad. Al final se tuvo 100 fotografías tal como se muestra en la siguiente tabla:

Tabla 27

Imágenes tomadas para el entrenamiento del modelo

Etiquetado	Cantidad
Hojas sanas	25
Hojas con antracnosis	25
Hojas con ojo de gallo	25
Hojas con roya amarilla	25

4. DESARROLLO DEL MODELO

4.1 Crear proyecto Custom Vision de Azure AI

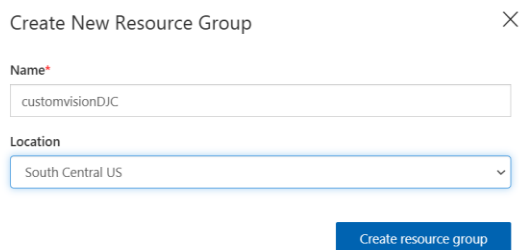
Requisitos previos

Cuenta de Azure: Acceso a un suscriptor activo en Azure. <https://azure.microsoft.com/es-es/>

Grupo de Recurso de Custom Vision: Configura un grupo de recurso de Custom Vision en el portal de Azure.

Figura 17

Interfaz para crear un nuevo grupo de recursos en Custom Vision Azure



Create New Resource Group

Name*

customvisionDJC

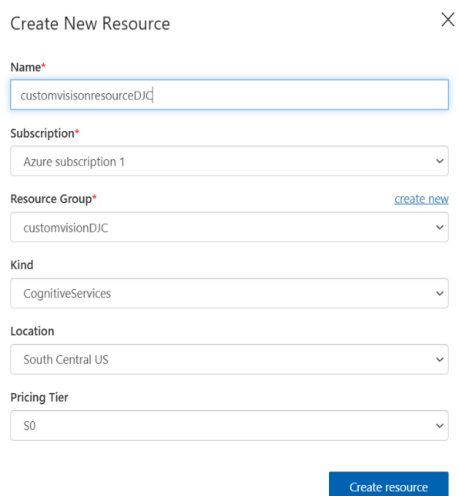
Location

South Central US

Create resource group

Figura 18

Interfaz para crear un nuevo recurso en Custom Vision Azure



Create New Resource

Name*

customvisionresourceDJC

Subscription*

Azure subscription 1

Resource Group* [create new](#)

customvisionDJC

Kind

CognitiveServices

Location

South Central US

Pricing Tier

S0

Create resource

Configuración del proyecto

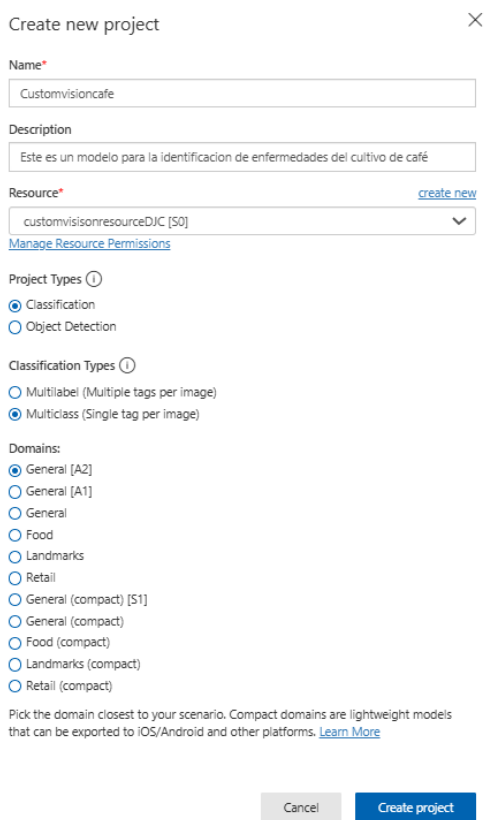
Acceder a la plataforma de Custom Vision con las credenciales de la cuenta de Azure.

<https://www.customvision.ai/>

Crear un nuevo proyecto y completa los campos requeridos:

Figura 19

Interfaz para crear un nuevo proyecto en Custom Vision Azure



Create new project

Name*

Customvisioncafe

Description

Este es un modelo para la identificación de enfermedades del cultivo de café

Resource* [create new](#)

customvisionresourceDJC [S0] [Manage Resource Permissions](#)

Project Types ⓘ

Classification

Object Detection

Classification Types ⓘ

Multilabel (Multiple tags per image)

Multiclass (Single tag per image)

Domains:

General [A2]

General [A1]

General

Food

Landmarks

Retail

General (compact) [S1]

General (compact)

Food (compact)

Landmarks (compact)

Retail (compact)

Pick the domain closest to your scenario. Compact domains are lightweight models that can be exported to iOS/Android and other platforms. [Learn More](#)

Cancel Create project

Nombre del proyecto: Custom Vision Café.

Descripción: Este es un modelo para la identificación de enfermedades del cultivo de café.

Recurso: Selecciona el recurso configurado previamente.

Tipo de proyecto: Multiclass (para identificar categorías como sano, antracnosis, ojo de gallo, roya amarilla).

Dominio: General puesto que no hay un dominio relacionado con agricultura.

Algoritmo utilizado en Custom Vision: Azure Custom Vision utiliza algoritmos de clasificación basados en aprendizaje profundo (deep learning), específicamente redes neuronales convolucionales (CNNs, por sus siglas en inglés), que están optimizadas para tareas de visión por computadora. Aunque Azure no proporciona detalles exactos sobre la arquitectura específica de los modelos, se sabe que sus algoritmos están ajustados para diferentes dominios y tipos de proyectos.

Tipo de proyecto utilizado: Clasificación Multiclase (Multiclass Classification) este tipo de proyecto permite asignar cada imagen a una única categoría. Ideal para casos donde cada imagen pertenece a una sola etiqueta (por ejemplo, Sano, antracnosis, ojo de gallo, roya amarilla).

Dominio de Clasificación utilizado: Cuando se configura un proyecto en Azure Custom Vision, puedes seleccionar el dominio, que optimiza el modelo para escenarios específicos. En este caso se seleccionó general el cual está optimizado para máxima precisión en tareas de clasificación general.

Proceso de personalización: En el entrenamiento del modelo en Custom Vision, los algoritmos utilizan transferencia de aprendizaje (transfer learning) luego el modelo se ajusta al conjunto de datos específico, acelerando el entrenamiento y mejorando la precisión con menos datos. Asimismo, Custom Vision ajusta los hiperparámetros y pesos del modelo

automáticamente durante el entrenamiento, dependiendo del dominio seleccionado y el dataset proporcionado.

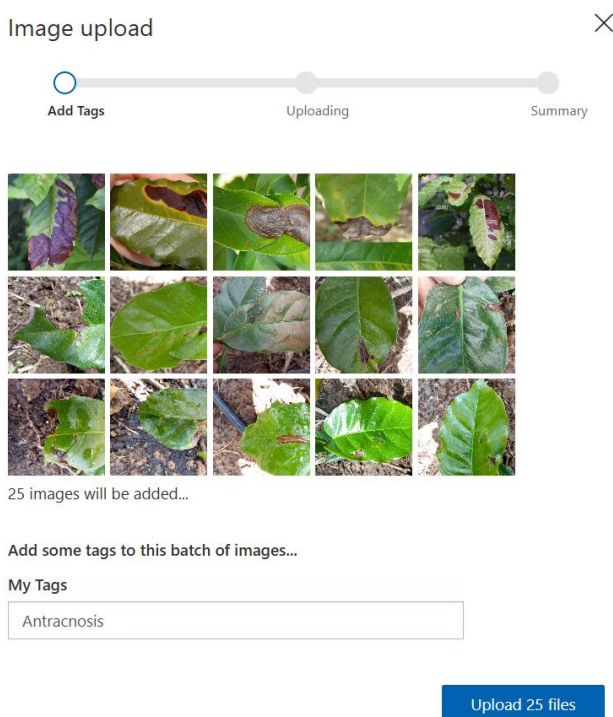
Ventaja clave: Los usuarios no necesitan conocimientos avanzados en aprendizaje profundo, ya que Azure gestiona automáticamente la selección de modelos y el ajuste de parámetros.

4.2 Entrenamiento inicial del modelo

Subir las imágenes recolectadas que han sido pre procesadas y organizadas al proyecto de Custom vision para luego asignarles su respectiva etiqueta.

Figura 20

Interfaz para subir las imágenes de entrenamiento al proyecto creado en Custom Vision Azure




Una vez etiquetadas las imágenes, se selecciona Train para comenzar el entrenamiento del modelo.

Modo rápido (Quick Training): Para obtener resultados iniciales rápidamente.

Modo avanzado (Advanced Training): Para modelos más precisos con datasets grandes.

Figura 21

Interfaz para entrenar el modelo en Custom Vision Azure



En este caso se cargó al proyecto 100 imágenes divididas entre hojas sanas, con antracnosis, ojo de gallo y roya amarilla el algoritmo se entrena con esos datos y calcula su propia precisión probándose a sí mismo con esas mismas imágenes.

4.3 Revisar métricas de desempeño

Precisión: Qué tan bien el modelo evita falsos positivos.

Recall: Qué tan bien el modelo detecta las verdaderas categorías.

AP: Balance entre precisión y recall.

Figura 22

Métricas de desempeño del modelo después del entrenamiento en Custom Vision Azure

Iteration 5

Finished training on **23/10/2024, 9:43:14 a.m.** using **General [A2]** domain
 Iteration id: **a735f143-a0fe-4fa5-9ab8-3d17e7767d5a**
 Classification type: **Multiclass (Single tag per image)**
 Published as: **Iteration5**




Figura 23

Rendimiento del modelo por etiqueta en Custom Vision Azure

Performance Per Tag

Tag	Precision	Recall	A.P.	Image count
Roya amarilla	100.0%	100.0%	100.0%	25
Ojo de gallo	100.0%	100.0%	100.0%	25
Negative	100.0%	100.0%	100.0%	25
Antracnosis	100.0%	100.0%	100.0%	25


5. IMPLEMENTACIÓN EN ENTORNO DE PRUEBAS

5.1 Implementación en un entorno de pruebas

En el entorno de pruebas “Quick Test” en Azure Custom Vision permite evaluar de manera rápida y sencilla el rendimiento del modelo entrenado utilizando imágenes nuevas antes de implementarlo en producción tal como se muestra en la siguiente imagen.

Figura 24

Interfaz para hacer las pruebas con nuevos datos desde Custom Vision Azure



5.2 Interpretación de resultados

El modelo analiza la imagen y devuelve:

Etiqueta predicha: La categoría más probable (ej. ojo de gallo).

Probabilidad: Un porcentaje que indica la confianza del modelo en su predicción (ej. 99.9%).

Correcto: Si la etiqueta coincide con la realidad y la probabilidad es alta (>80%), el modelo muestra buen desempeño.

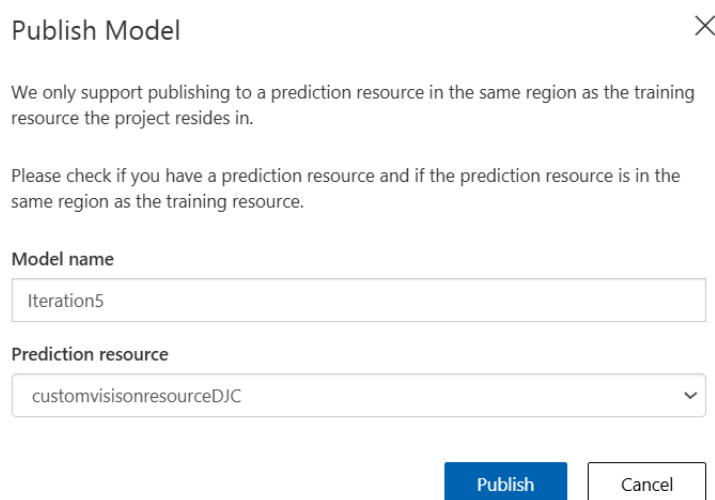
Incorrecto o dudoso: Si la etiqueta es errónea o la probabilidad es baja (<50%), esto indica áreas de mejora en el modelo o el dataset.

6. PUBLICAR MODELO

La publicación del modelo entrenado en Azure Custom Vision permite que esté disponible para su uso mediante una API. Esto es fundamental para posteriormente integrarlo en una aplicación que puedan ser utilizadas por los agricultores o usuarios finales.

Figura 25

Interfaz para publicar el modelo desde Custom Vision Azure



Publish Model ×

We only support publishing to a prediction resource in the same region as the training resource the project resides in.

Please check if you have a prediction resource and if the prediction resource is in the same region as the training resource.

Model name

Prediction resource

7. ANÁLISIS Y DISEÑO DEL SISTEMA

7.1 Modelado Del Negocio

Figura 26

Diagrama de entidades del negocio.

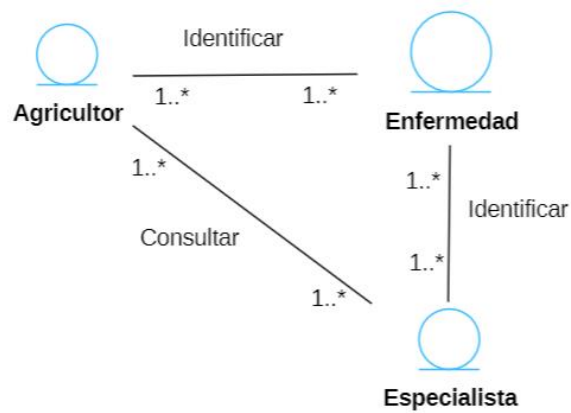


Figura 27

Diagrama de actividades del negocio.

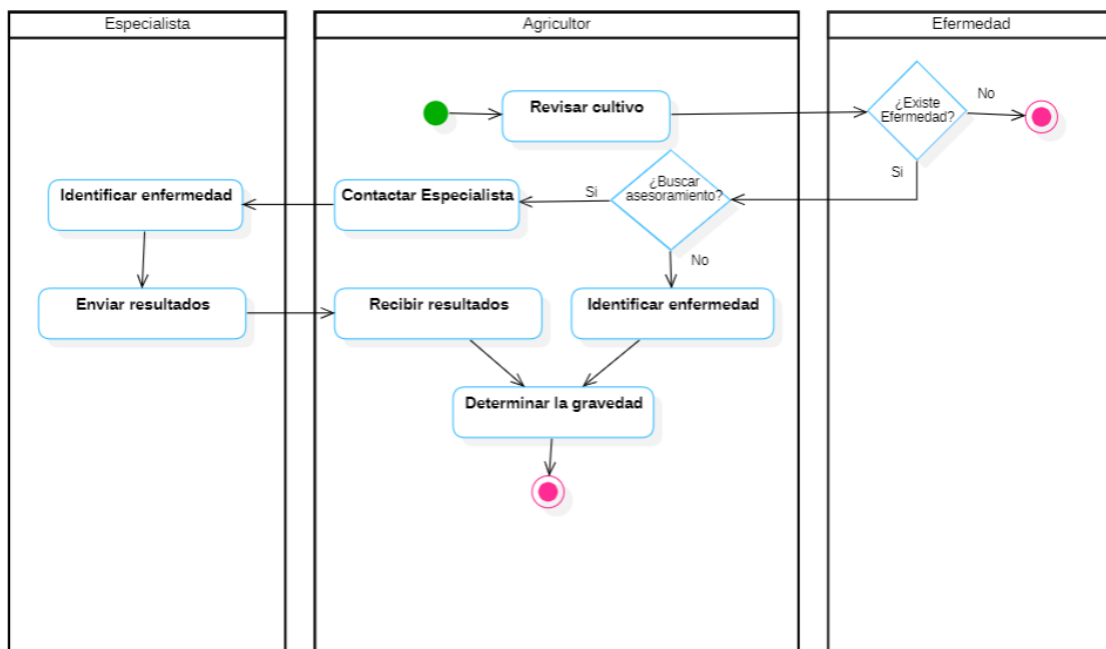


Figura 28

Diagrama de secuencia del negocio.

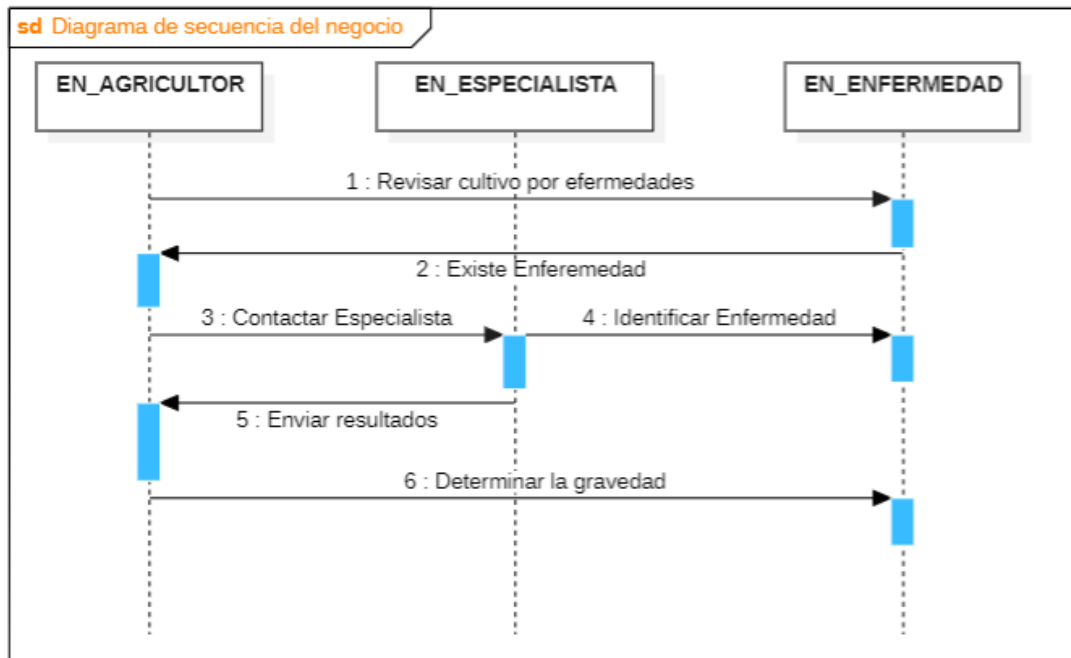
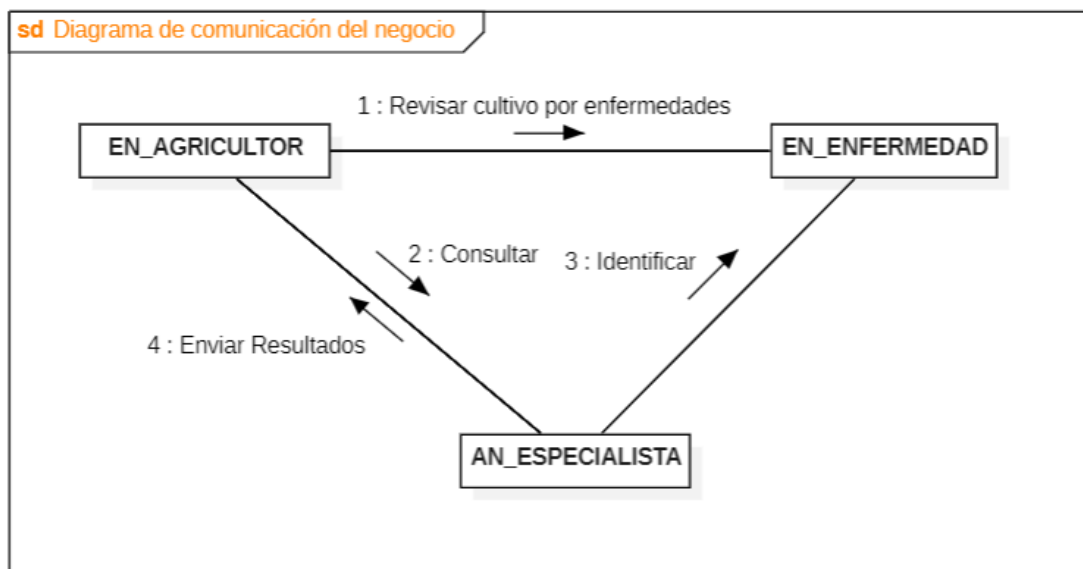


Figura 29

Diagrama de comunicación del negocio.



7.2

Requerimientos

Tabla 28

Requerimientos funcionales.

Proceso de Negocio	Actividad del Negocio	Responsable del Negocio	Requerimiento	Caso de Uso	Actores		
Identificar Enfermedad.	Revisar cultivo por enfermedades.	Agricultor	R01	Tomar imagen de la hoja de café	C01	Tomar Imagen	Agricultor
	Contactar especialista.	Agricultor	R02	Procesar imagen de la hoja de café	C02	Consultar modelo	Agricultor
	Identificar enfermedad.	Especialista					
	Enviar resultados.	Especialista	R03	Mostar Resultados	C03	Mostrar Predicción	Agricultor
	Determinar la gravedad.	Agricultor					

Tabla 29


Requerimientos no funcionales.

Requerimientos no Funcionales	Descripción
Navegabilidad	Los agricultores utilizan las funcionalidades de la aplicación de forma rápida y sencilla. Permitiendo la ejecución de actividades correspondientes de una manera sencilla, amigable, eficiente y rápida.
Seguridad	El sistema solicita solo la información estrictamente necesaria para cumplir con su propósito. No se almacena datos sensibles.

Usabilidad	El sistema cuenta con menús y ventanas interactivas además de ser agradables y de fácil entendimiento.
Rapidez	El sistema permitirá al agricultor una facilidad al desarrollar sus actividades rutinarias e identificar enfermedades de café.
Eficiencia	El sistema reducirá los errores y el tiempo de respuesta.

Figura 30

Diagrama general de casos de uso del sistema.



Especificaciones de casos de uso del sistema

Especificación de Caso de Uso: Tomar Imagen

Breve Descripción: El caso de uso tomar imagen permite al usuario habilitar la cámara de su teléfono para tomar una imagen.

Actor: Agricultor.

Flujo Básico:

1. El caso de uso comienza cuando el usuario ingresa a la interfaz principal con un único botón que dice analizar.
2. El usuario presiona el botón “ANALIZAR”.
3. El sistema valida y solicita permiso para habilitar la cámara del teléfono.
4. El sistema muestra la interfaz de la cámara.
5. El usuario toma una fotografía de la hoja de café a analizar.
6. El Usuario confirma la fotografía tomada.

Flujo Alternativo:

Permiso denegado para habilitar la cámara

En el paso 3 del flujo básico, si el usuario denegó los permisos para habilitar la cámara del teléfono el sistema mostrara el MSG “No se pudo abrir la cámara”. El sistema no permitirá continuar con el proceso hasta que se habilite el permiso.

Precondiciones: Dispositivo móvil con cámara operativa.

Postcondiciones: Fotográfica de la hoja de café tomada.


Puntos de Extensión: No aplica

Requerimientos Especiales: No aplica

Prototipo

Figura 31

Prototipo para el caso de uso tomar imagen



Especificación de Caso de Uso: Consultar modelo

Breve Descripción: El caso de uso consultar modelo permite al usuario enviar la fotografía tomada de la hoja de café al modelo de reconocimiento visual para su análisis.

Actor: Agricultor

Flujo Básico:

1. El caso de uso comienza cuando el usuario confirma la fotografía tomada.
2. El sistema se conecta al modelo de reconocimiento visual mediante la API.
3. El modelo procesa la imagen.
4. El modelo predice y brinda los resultados con el porcentaje por cada etiqueta.

Flujo Alternativo:

Sistema no se conecta con la API.

En el paso 2 del flujo básico, si ocurre un error al conectarse con el API del modelo de reconocimiento visual el sistema mostrará el MSG “Error en la solicitud” y finalizará la consulta.

Precondiciones: Fotografía tomada desde el teléfono.

Postcondiciones: Modelo genera predicción.


Puntos de Extensión: No aplica

Requerimientos Especiales: No aplica

Prototipo

Figura 32

Prototipo para el caso de uso consultar modelo



Especificación de Caso de Uso: Mostrar Predicción

Breve Descripción: El caso de uso mostrar predicción permite al usuario visualizar el resultado de la predicción de modelo de reconocimiento visual al procesar la fotografía tomada de la hoja de café.

Actor: Agricultor.

Flujo Básico:

1. El caso de uso comienza cuando el modelo brinda los resultados de la predicción.

2. El sistema recibe los resultados del API.
3. El sistema muestra la interfaz mostrar predicción.
4. El sistema muestra en una gráfica la etiqueta con el mayor porcentaje y a su vez completa los campos y muestra todos los resultados (las etiquetas con sus respectivos porcentajes).

Flujo Alternativo: No aplica

Precondiciones: Resultados de la predicción del modelo de reconocimiento visual.

Postcondiciones: No aplica.


Puntos de Extensión: No aplica

Requerimientos Especiales: No aplica

Prototipo

Figura 33

Prototipo para el caso de uso mostrar predicción



7.3 Análisis y diseño

Figura 34

Boundaries del sistema




Figura 35

Controles del sistema

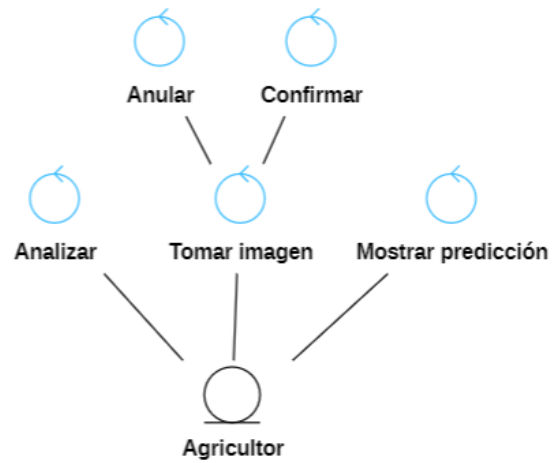


Figura 36

Entidades del sistema




Figura 37

Diagrama de actividades del caso de uso tomar imagen

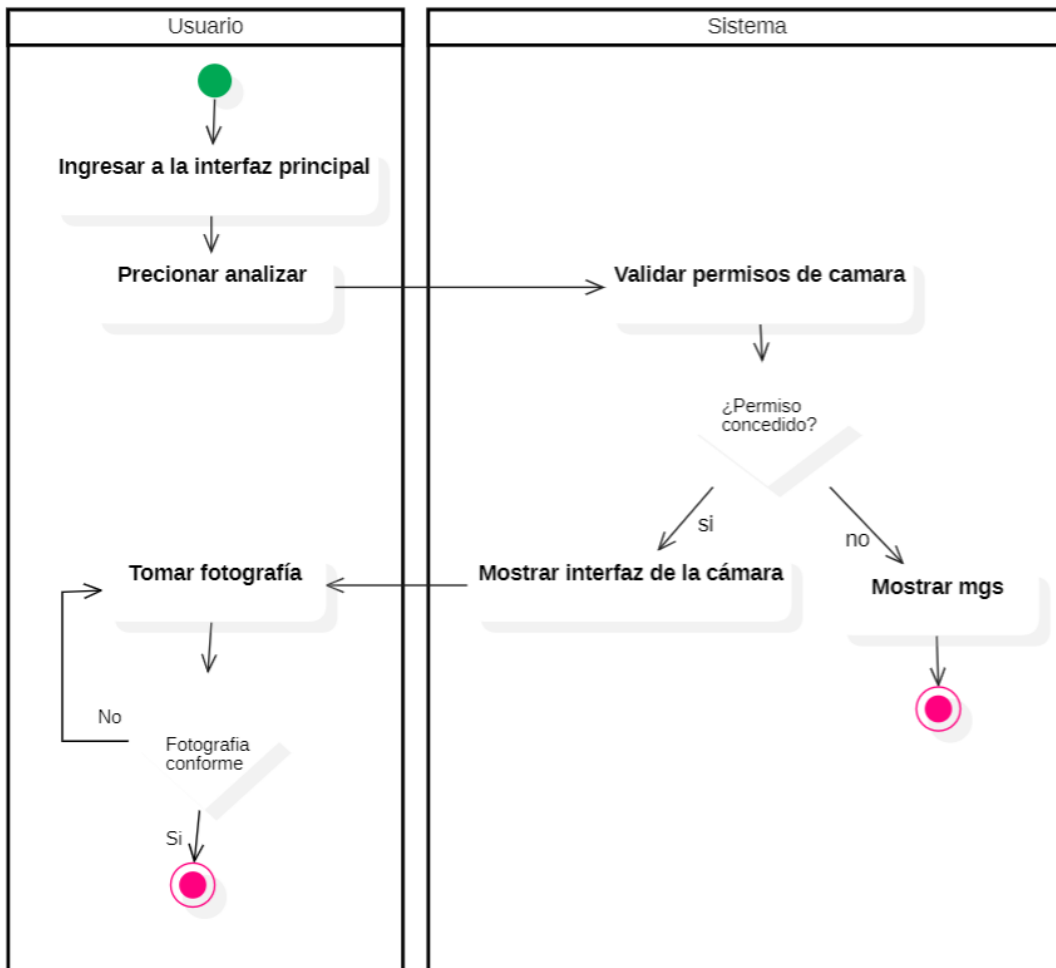


Figura 38

Diagrama de actividades del caso de uso consultar modelo.

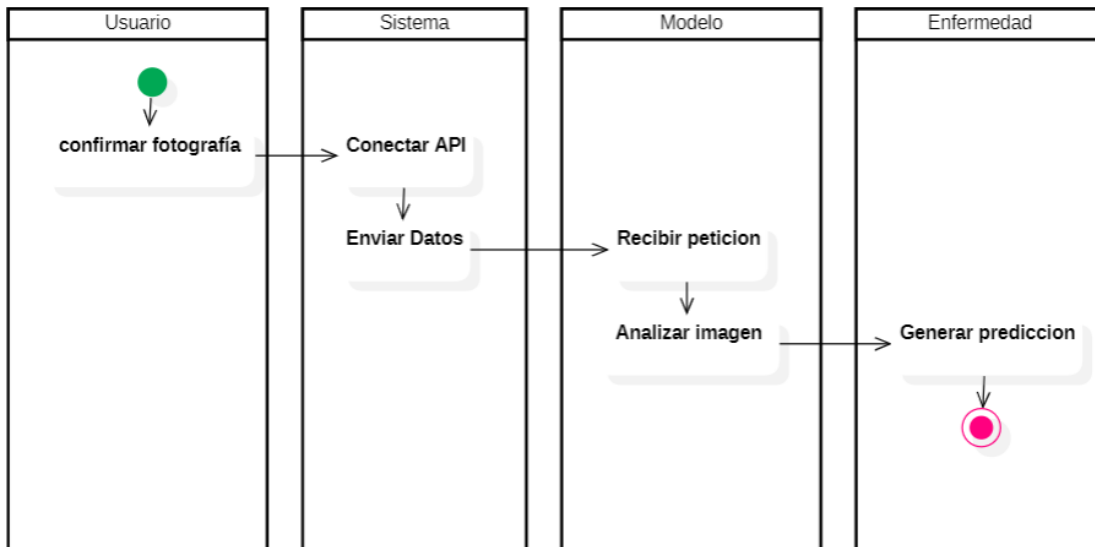
**Figura 39**

Diagrama de actividades del caso de uso mostrar predicción.




Figura 40

Diagrama de secuencia del caso de uso tomar imagen.

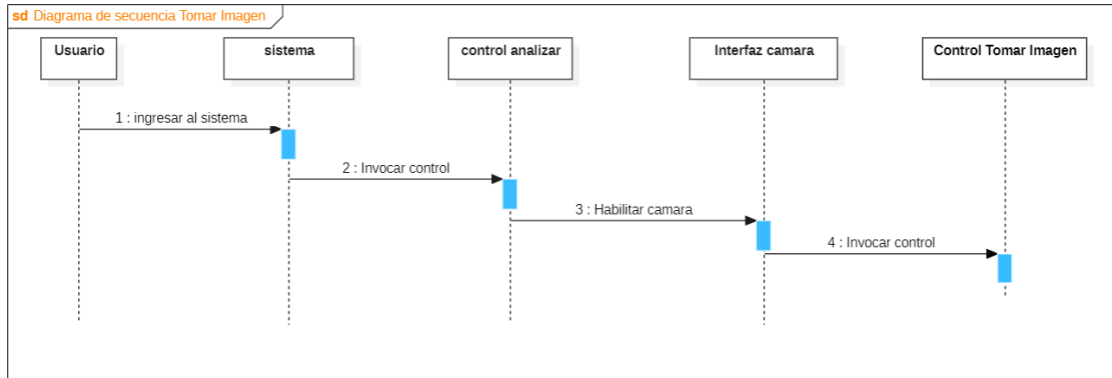
**Figura 41**

Diagrama de secuencia del caso de uso consultar modelo.

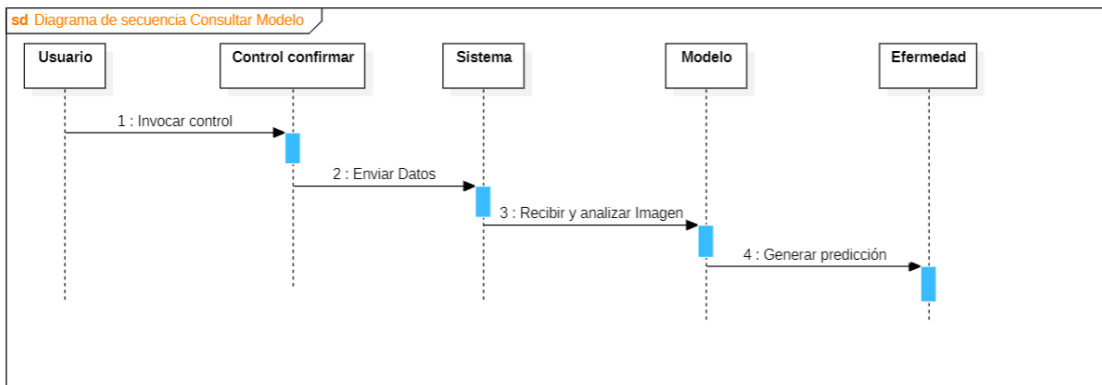
**Figura 42**

Diagrama de secuencia del caso de uso mostrar predicción.




Figura 43

Diagrama de comunicación del caso de uso tomar imagen.

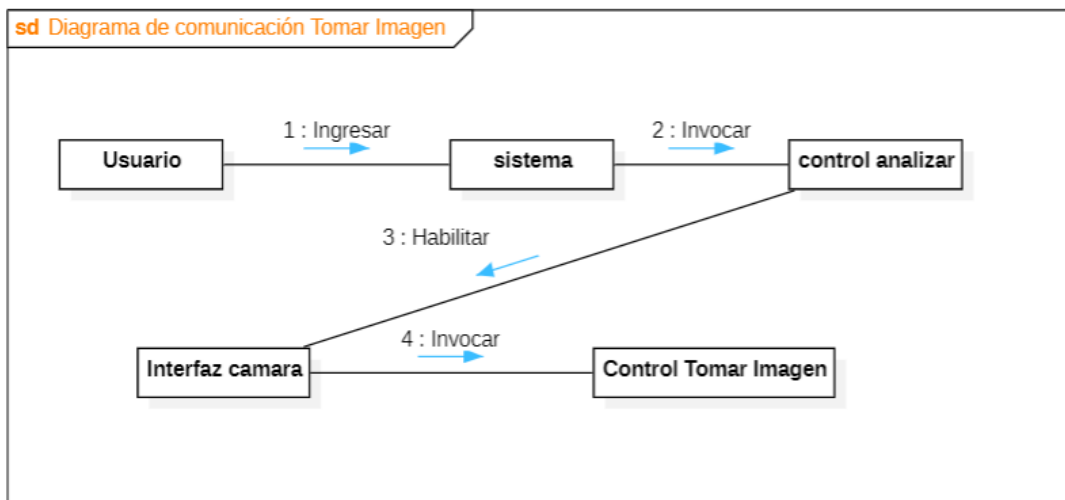
**Figura 44**

Diagrama de comunicación del caso de uso consultar modelo.

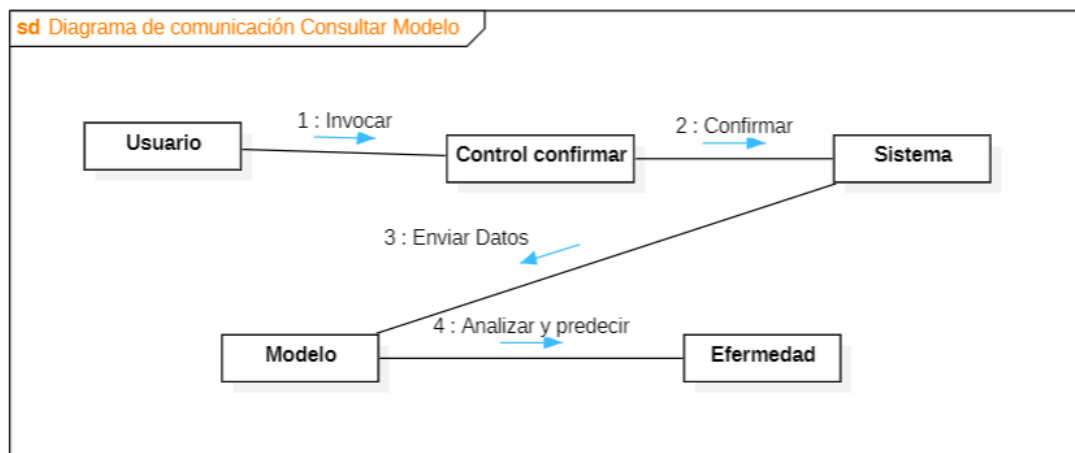


Figura 45

Diagrama de comunicación del caso de uso mostrar predicción.

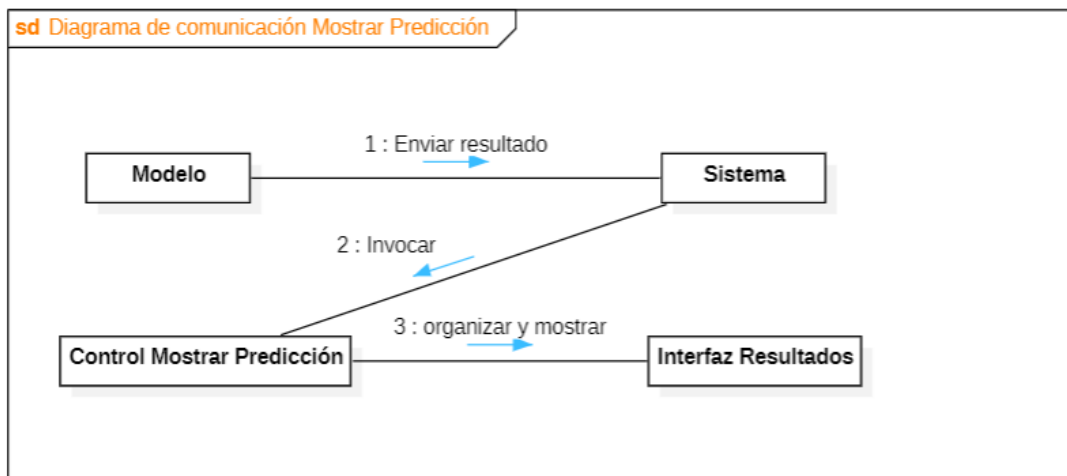
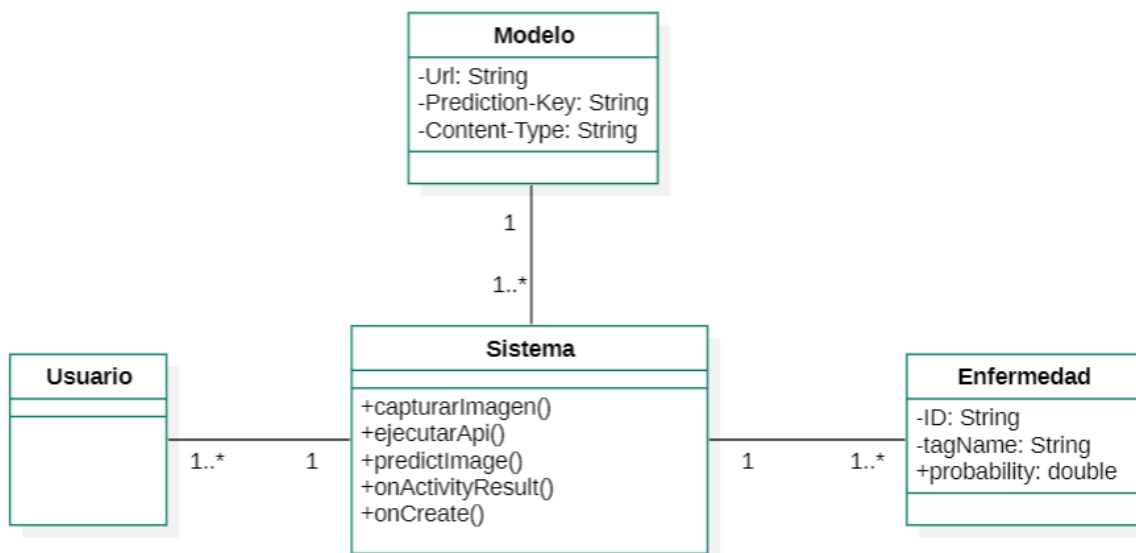


Figura 46

Diagrama de clase del sistema



8. IMPLEMENTACIÓN DEL SISTEMA

Figura 47

Código fuente de la interfaz de bienvenida

```

SplashScreenActivity.java x </> activity_splash_screen.xml
1 package com.example.appvisioncafe;
2
3 > import ...
22
23
24 </> public class SplashScreenActivity extends AppCompatActivity {
25
26     @Override
27     protected void onCreate(Bundle savedInstanceState) {
28         super.onCreate(savedInstanceState);
29         setContentView(R.layout.activity_splash_screen);
30         TimerTask tarea = new TimerTask() {
31             @Override
32             public void run() {
33                 Intent intent = new Intent( packageContext: SplashScreenActivity.this, MainActivity.class);
34                 startActivity(intent);
35                 finish();
36             }
37         };
38         Timer tiempo = new Timer();
39         tiempo.schedule(tarea, delay: 5000);
40
41     }

```

Figura 48

Método para capturar la imagen desde la cámara del teléfono.

```

// Método para capturar la imagen desde la cámara
public void capturarImagen(View view) { 1 usage
    Intent takePictureIntent = new Intent(MediaStore.ACTION_IMAGE_CAPTURE);
    if (takePictureIntent.resolveActivity(getPackageManager()) != null) {
        startActivityForResult(takePictureIntent, REQUEST_IMAGE_CAPTURE);
    } else {
        Toast.makeText( context: this, text: "No se pudo abrir la cámara", Toast.LENGTH_SHORT).show();
    }
}

```

Figura 49*Método onActivityResult*

```
@Override
protected void onActivityResult(int requestCode, int resultCode, @Nullable Intent data) {
    super.onActivityResult(requestCode, resultCode, data);
    if (requestCode == REQUEST_IMAGE_CAPTURE && resultCode == RESULT_OK && data != null) {
        Bundle extras = data.getExtras();
        imageBitmap = (Bitmap) extras.get("data");
        Toast.makeText(context: MainActivity.this, text: "Procesando imagen...", Toast.LENGTH_LONG).show();

        ejecutarApi(); // Llama a la API después de capturar la imagen
    }
}
```

Figura 50*Método para ejecutar el API del modelo*

```
// Método para ejecutar la API después de capturar la imagen
public void ejecutarApi() { 1 usage
    if (imageBitmap != null) {
        predictImage();
    } else {
        Toast.makeText(context: this, text: "Primero captura una imagen", Toast.LENGTH_SHORT).show();
    }
}
```

Figura 51

Método para enviar la imagen al modelo y generar la predicción

```
// Método para enviar la imagen a la API
public void predictImage() {
    OkHttpClient client = new OkHttpClient();

    // Convertir la imagen a un arreglo de bytes
    ByteArrayOutputStream byteArrayOutputStream = new ByteArrayOutputStream();
    imageBitmap.compress(Bitmap.CompressFormat.JPEG, 100, byteArrayOutputStream);
    byte[] imageBytes = byteArrayOutputStream.toByteArray();

    // Crear el cuerpo de la solicitud con los datos binarios
    RequestBody body = RequestBody.create(imageBytes, MediaType.parse("application/octet-stream"));

    // Construir la solicitud HTTP
    Request request = new Request.Builder()
        .url(PREDICTION_URL)
        .addHeader("Prediction-Key", PREDICTION_KEY)
        .addHeader("Content-Type", "application/octet-stream")
        .post(body)
        .build();

    // Ejecutar la solicitud en un nuevo hilo
    client.newCall(request).enqueue(new Callback() {
        @Override
        public void onFailure(Call call, IOException e) {
            e.printStackTrace();
            runOnUiThread() -> Toast.makeText(context, MainActivity.this, "Error en la solicitud: " + e.getMessage(), Toast.LENGTH_SHORT).show();
        }

        @Override
        public void onResponse(Call call, Response response) throws IOException {
            if (response.isSuccessful()) {
                final String responseData = response.body().string();

                // Mostrar el resultado
                runOnUiThread() -> {
                    try {
                        JSONObject jsonResponse = new JSONObject(responseData);
                        JSONArray predictions = jsonResponse.getJSONArray("predictions");

                        StringBuilder result = new StringBuilder();
                        // Recorrer cada predicción y almacenarla en el ArrayList
                        for (int i = 0; i < predictions.length(); i++) {
                            JSONObject prediction = predictions.getJSONObject(i);
                            double probability = prediction.getDouble("probability");
                            String tagName = prediction.getString("tagName");

                            result.append("Etiqueta: ").append(tagName)
                                .append(" - Probabilidad: ")
                                .append(probability)
                                .append("\n");
                        }

                        Bundle enviarResultado = new Bundle();
                        enviarResultado.putString("ResultadoAPI", result.toString());
                        Intent intent = new Intent(context, MainActivity.this, MainActivity_Response.class);
                        intent.putExtras(enviarResultado);
                        startActivity(intent);
                    } catch (Exception e) {
                        e.printStackTrace();
                        Toast.makeText(context, MainActivity.this, "Error al procesar la respuesta JSON", Toast.LENGTH_SHORT).show();
                    }
                });
            } else {
                runOnUiThread() -> Toast.makeText(context, MainActivity.this, "Respuesta fallida: " + response.code(), Toast.LENGTH_SHORT).show();
            }
        }
    });
}
}
```

Figura 52

Código fuente de la interfaz mostrar resultados

```

public class MainActivity_Response extends AppCompatActivity {

    TextView txtEtiqueta1, txtEtiqueta2, txtEtiqueta3, txtEtiqueta4; 2 usages
    TextView txtProbabi1, txtProbabi2, txtProbabi3, txtProbabi4; 2 usages

    private ProgressBar circular_pro; 2 usages
    private TextView txtResul; 3 usages

    private int progressStatus = 0; 4 usages
    private Handler handler = new Handler(); 1 usage

    @Override
    protected void onCreate(Bundle savedInstanceState) {
        super.onCreate(savedInstanceState);
        setContentView(R.layout.activity_main_response);

        txtEtiqueta1 = findViewById(R.id.txt_etiqueta1);
        txtEtiqueta2 = findViewById(R.id.txt_etiqueta2);
        txtEtiqueta3 = findViewById(R.id.txt_etiqueta3);
        txtEtiqueta4 = findViewById(R.id.txt_etiqueta4);
        txtProbabi1 = findViewById(R.id.txt_probabi1);
        txtProbabi2 = findViewById(R.id.txt_probabi2);
        txtProbabi3 = findViewById(R.id.txt_probabi3);
        txtProbabi4 = findViewById(R.id.txt_probabi4);

        circular_pro = findViewById(R.id.progressBar);
        txtResul = findViewById(R.id.txt_Resultado_porcentaje);

        Bundle mostrarResultados = getIntent().getExtras();
        String info = mostrarResultados.getString( new "ResultadoAPI");

        // Dividir la cadena por "Etiqueta:" y luego por " - Probabilidad:"
        String[] items = info.split( /regex: "Etiqueta:" );
        List<String> tagsList = new ArrayList<>();
        List<String> probabilitiesList = new ArrayList<>();

        for (String item : items) {
            if (item.trim().isEmpty()) {
                String[] parts = item.split( /regex: " - Probabilidad:" );
                String tagName = parts[0].trim();
                String probability = String.format( "%2f", Double.parseDouble(parts[1].trim()) * 100);
                tagsList.add(tagName);
                probabilitiesList.add(probability);
            }
        }

        // Verificar que hay al menos 4 elementos
        if (tagsList.size() >= 4 && probabilitiesList.size() >= 4) {
            // Mostrar los valores de etiquetas y probabilidades en los TextViews
            txtEtiqueta1.setText(tagsList.get(0) + ".");
            txtProbabi1.setText(probabilitiesList.get(0) + "%");

            txtEtiqueta2.setText(tagsList.get(1) + ".");
            txtProbabi2.setText(probabilitiesList.get(1) + "%");

            txtEtiqueta3.setText(tagsList.get(2) + ".");
            txtProbabi3.setText(probabilitiesList.get(2) + "%");

            txtEtiqueta4.setText(tagsList.get(3) + ".");
            txtProbabi4.setText(probabilitiesList.get(3) + "%");

            // Inicia el progreso automáticamente
            new Thread(new Runnable() {
                @Override
                public void run() {
                    double probMayor = Double.parseDouble(probabilitiesList.get(0));

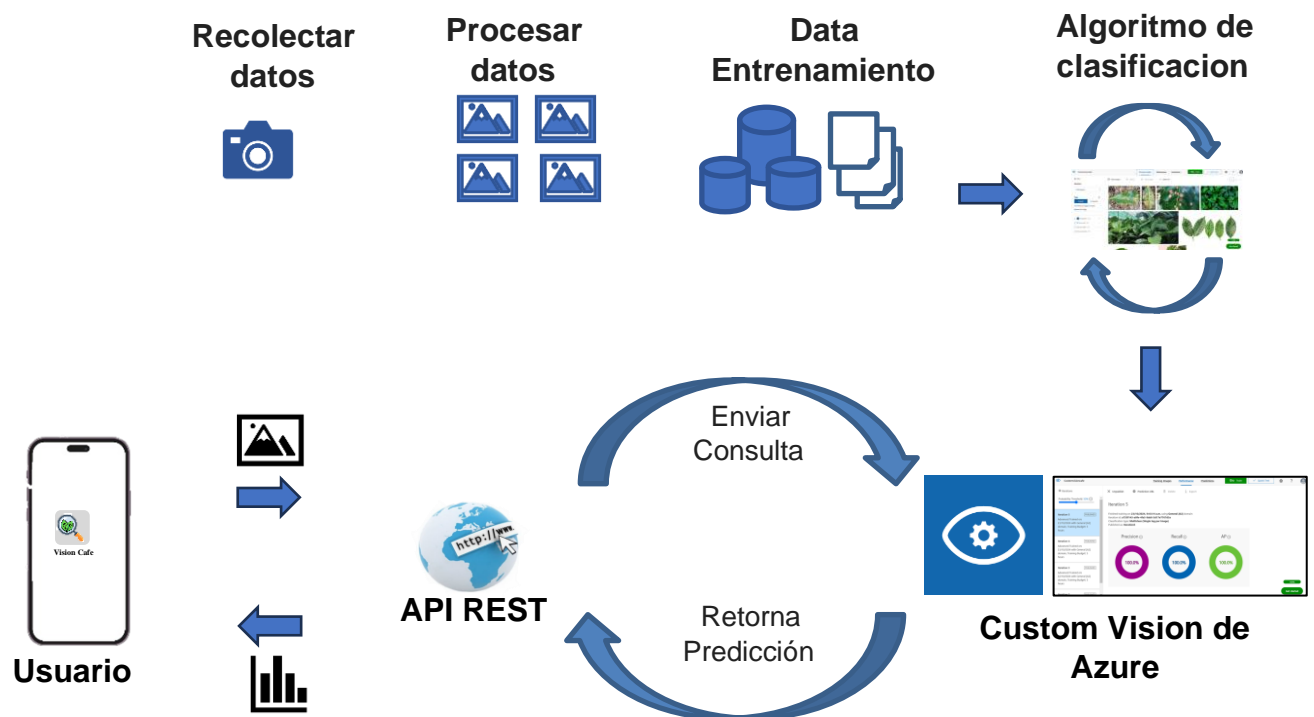
                    while (progressStatus < probMayor) {
                        progressStatus += 1;
                        handler.post(new Runnable() {
                            @Override
                            public void run() {
                                circular_pro.setProgress(progressStatus);
                                txtResul.setText(tagsList.get(0) + "\n" + progressStatus + "%");
                            }
                        });
                        try {
                            Thread.sleep( 10);
                        } catch (InterruptedException e) {
                            e.printStackTrace();
                        }
                    }
                }
            }).start();
        } else {
            // Mensaje de error: si hay menos de 4 etiquetas/probabilidades
            txtResul.setText("Datos insuficientes para mostrar.");
        }
    }
}

```

9. INTEGRACIÓN DEL MODELO Y EL SISTEMA

Figura 53

Diagrama de integración del sistema con el modelo



Interfaz de bienvenida

Es la primera pantalla que los usuarios ven al abrir la aplicación y tiene como objetivo presentar la app de forma atractiva.

Figura 54

Interfaz de bienvenida del sistema




Interfaz analizar

Permite que el usuario pueda habilitar la cámara de tu teléfono al presionar en el botón analizar.

Figura 55

Interfaz analizar del sistema




Interfaz tomar foto

Permite que el usuario tome una fotografía de la hoja de café que desee analizar.

Figura 56

Interfaz tomar foto del sistema



Interfaz Confirmar fotografía

Permite que el usuario una vez tomado la fotografía pueda confirmar o volver a tomar una nueva fotografía.

Figura 57

Interfaz Confirmar fotografía del sistema




Interfaz mostrar resultados

Permite que el usuario pueda visualizar el resultado de la predicción que hizo el modelo de la fotografía tomada.

Figura 58

Interfaz mostrar resultados



10. PRUEBAS CON LA INTEGRACIÓN

Tabla 30

Caso de pruebas tomar fotografía

Nombre de la prueba	Tomar fotografía			
Requirement Number Tested	01			
Tipo de Pruebas	Funcionalidad			
Caso de uso de prueba	-			
Número de caso de prueba	3			
Descripción de la prueba	Tomar una fotografía desde la cámara del teléfono			
Pre-Condiciones	<ul style="list-style-type: none"> ● Ingresar a la aplicación 			
Post-condiciones	<ul style="list-style-type: none"> ● Mostrar la fotografía tomada 			
Notas:				
Resultado DD/MM/YYYY (Pass/Fail/Warnin g/Incomplete)	Pass – Revisado (18/11/2024)			
	PASOS DE PRUEBA	RESULTADOS ESPERADOS	P	F
1.	Habilitar cámara del teléfono.	Cámara habilitada.	X	
2.	Solo tener habilitado la opción de foto.	Tomar solo fotos.	X	
3.	Mostrar la fotografía tomada.	Muestra la fotografía tomada.	X	

Tabla 31

Caso de pruebas mostrar resultados de la predicción

Nombre de la prueba	Mostrar resultados de la predicción			
Requirement Number Tested	02			
Tipo de Pruebas	Funcionalidad			
Caso de uso de prueba	-			
Número de caso de prueba	3			
Descripción de la prueba	Mostrar la predicción del modelo respecto a la imagen tomada.			
Pre-Condiciones	<ul style="list-style-type: none"> ● Fotografía tomada desde la cámara 			
Post-condiciones	<ul style="list-style-type: none"> ● Resultados del modelo 			
Notas:				
Resultado DD/MM/YYYY (Pass/Fail/Warning/Incomplete)	Pass – Revisado (18/11/2024)			
	PASOS DE PRUEBA	RESULTADOS ESPERADOS	P	F
1.	Confirmar fotografía.	Permite confirmar fotografía.	X	
2.	Conectarse a la API del modelo.	Se conecta a la API rest del modelo.	X	
3.	Mostrar resultado principal.	Muestra el resultado principal de la predicción del modelo.	X	
4.	Mostrar todos los resultados.	Muestra todos los resultados según el modelo.	X	

11. PLAN DE CAPACITACIÓN

Se presenta la planificación de capacitación dividida en dos partes: capacitación para el usuario y capacitación técnica. Duración: 1 hora por día durante 2 días.

Parte Usuario:

Introducción y Primeros Pasos:

- Uso de la aplicación.
- Explicación de la interfaz de usuario.
- Funcionalidades principales de la aplicación.

Instalación y Configuración:

- Cómo descargar e instalar la aplicación.
- Guía paso a paso para descargar e instalar la herramienta en dispositivos.

Diagnóstico y Resolución de Problemas:

- Resolución de problemas comunes del usuario.
- Guía para solucionar errores frecuentes en el uso de la aplicación.
- Respuestas a preguntas frecuentes (FAQ).

Casos Prácticos y Aplicaciones Reales:

- Uso de la aplicación en el contexto real.
- Realización de simulaciones para identificar enfermedades en imágenes reales.
- Aplicación práctica de las funcionalidades de la app.

Evaluación y Retroalimentación:

- Asegurar que los usuarios estén listos para utilizar la aplicación de forma independiente.
- Recopilación de retroalimentación y evaluación de la comprensión del sistema por parte de los usuarios.


Parte Técnica:

Actualizaciones y configuraciones técnicas:

- Instrucciones sobre cómo cargar imágenes al modelo.
- Revisión de los formatos de imágenes aceptados.
- Incorporar datos sobre nuevas enfermedades al modelo.
- Procedimiento para actualizar el modelo con nuevas categorías de enfermedades.
- Entrenamiento del modelo con nuevos datos.
- Evaluación de la precisión del modelo tras el entrenamiento.

Soporte técnico básico:

- Soporte técnico en caso de problemas con el sistema.
- Protocolos y métodos para detectar y solucionar problemas en el modelo.
- Procedimientos para mantener el modelo actualizado y en funcionamiento óptimo.
- Planificación de actividades futuras para mantener el modelo.

Figura 59*Diagrama de actividades plan de capacitación*

● 16% de similitud general

Principales fuentes encontradas en las siguientes bases de datos:

- 13% Base de datos de Internet
- Base de datos de Crossref
- 13% Base de datos de trabajos entregados
- 3% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

FUENTES PRINCIPALES

Las fuentes con el mayor número de coincidencias dentro de la entrega. Las fuentes superpuestas no se mostrarán.

1	repositorio.uwiener.edu.pe Internet	2%
2	uwiener on 2023-10-02 Submitted works	1%
3	repositorio.ucv.edu.pe Internet	1%
4	Submitted on 1687209244651 Submitted works	<1%
5	hdl.handle.net Internet	<1%
6	Universidad Cesar Vallejo on 2016-08-09 Submitted works	<1%
7	repositorioacademico.usmp.edu.pe Internet	<1%
8	Universidad Ricardo Palma on 2024-01-12 Submitted works	<1%