

Maestría en

Inteligencia Artificial Aplicada

Trabajo previo a la obtención de título de Magister en Inteligencia Artificial Aplicada

AUTOR/ES:

Erick Stuart Almeida Chávez

Jonathan Santiago Almeida Salas

Steven Andres Guamán Figueroa

Carlos Eduardo Vaca Cano

Bryan Steven Vinueza Bustamante

TUTOR/ES:

Karla Mora

Alejandro Cortés

TEMA

**Modelo de Visión por Computadora (CV) para la detección
temprana de Botrytis Cinérea en cultivos de rosas en la Sierra
Ecuatoriana**

Certificación de autoría

Nosotros, Erick Stuart Almeida Chávez, Jonathan Santiago Almeida Salas, Steven Andrés Guamán Figueroa, Carlos Eduardo Vaca Cano y Bryan Steven Vinueza Bustamante, declaramos bajo juramento que el trabajo aquí descrito es de nuestra autoría; que no ha sido presentado anteriormente para ningún grado o calificación profesional y que se ha consultado la bibliografía detallada.

Cedemos nuestros derechos de propiedad intelectual a la Universidad Internacional del Ecuador (UIDE), para que sea publicado y divulgado en internet, según lo establecido en la Ley de Propiedad Intelectual, su reglamento y demás disposiciones legales.



Erick Stuart Almeida Chavez



Firma

Erick Stuart Almeida Chávez

Firma

Jonathan Santiago Almeida Salas

Firma

Steven Andrés Guamán Figueroa



Firmado electrónicamente por:
CARLOS EDUARDO VACA
CANO

Validar únicamente con FirmaSC

Firma

Carlos Eduardo Vaca Cano



Bryan Steven Vinueza Bustamante



Firma

Bryan Steven Vinueza Bustamante

Autorización de Derechos de Propiedad Intelectual

Nosotros, (Erick Stuart Almeida Chávez, Jonathan Santiago Almeida Salas, Steven Andrés Guamán Figueroa, Carlos Eduardo Vaca Cano y Bryan Steven Vinueza Bustamante, en calidad de autores del trabajo de investigación titulado Modelo de Visión por Computadora (CV) para la detección temprana de Botrytis Cinérea en cultivos de rosas en la Sierra Ecuatoriana, autorizamos a la Universidad Internacional del Ecuador (UIDE) para hacer uso de todos los contenidos que nos pertenecen o de parte de los que contiene esta obra, con fines estrictamente académicos o de investigación. Los derechos que como autores nos corresponden, lo establecido en los artículos 5, 6, 8, 19 y demás pertinentes de la Ley de Propiedad Intelectual y su Reglamento en Ecuador.

D. M. Quito, 28 de diciembre de 2025



Erick Stuart Almeida Chavez
Time Stamping Security Data

Firma
Erick Stuart Almeida Chávez

Firma
Jonathan Santiago Almeida Salas

Firma
Steven Andrés Guamán Figueroa



Firmado electrónicamente por:
CARLOS EDUARDO VACA
CANO
Validar únicamente con FirmaBC

Firma
Carlos Eduardo Vaca Cano




Bryan Steven Vinueza Bustamante
Time Stamping Security Data


Firma
Bryan Steven Vinueza Bustamante

Aprobación de dirección y coordinación del programa

Nosotros, **Alejandro Cortés Director EIG** y **Karla Mora Coordinadora UIDE**, declaramos que: **(Erick Stuart Almeida Chávez, Jonathan Santiago Almeida Salas, Steven Andrés Guamán Figueroa, Carlos Eduardo Vaca Cano y Bryan Steven Vinueza Bustamante)** son los autores exclusivos de la presente investigación y que ésta es original, auténtica y personal de ellos.



Alejandro Cortes
Directora de la
Maestría en Inteligencia Artificial Aplicada



Karla Mora
Coordinadora de la
Maestría en Inteligencia Artificial Aplicada

DEDICATORIA

Este trabajo está dedicado a mis padres, Marcos y Gloria, quienes con su ejemplo constante de esfuerzo y dedicación me inspiran a seguir capacitándome y superándome día tras día.

A mis hermanos, Marco y Karen, por su apoyo incondicional en cada uno de mis proyectos personales y profesionales, y por impulsarme a adentrarme en nuevos desafíos.

A mis abuelos, Luis y Leonor, que desde el cielo guían cada uno de mis pasos, y a mis abuelos José y Lágrima, que aun en la distancia siempre me brindan su cariño y afecto.

Bryan Steven Vinueza Bustamante

Dedico este logro a mis padres, Susy y Carlos, por ser mi base, mi ejemplo de esfuerzo y constancia, y por creer en mí incluso en los momentos en que yo mismo dudé. Gracias por su amor incondicional, su apoyo infinito y por enseñarme que la disciplina y la pasión abren cualquier camino. A mi abuelita Mercedes, por su sabiduría, su cariño y sus palabras siempre oportunas, que me han acompañado a lo largo de este camino como una fuente constante de inspiración y fortaleza.

Y a mi novia Hely, por su paciencia, su comprensión y su amor, por acompañarme en cada desvelo, motivarme a seguir adelante y recordarme siempre por qué vale la pena perseguir mis sueños.

Carlos Eduardo Vaca Cano

Dedico este trabajo a mis padres, Guadalupe y Gilber, por darme esa base inquebrantable de quien soy ahora.

A mi madre, por ser mi más grande ejemplo de fortaleza. Gracias por enseñarme el valor del orden en mi vida; tu forma de ser ha sido una brújula en mi camino. A mi padre, por heredarme su razonamiento lógico, por demostrarme que, aunque el camino sea duro, rendirse nunca es una opción y por enseñarme a ver el lado bueno de las cosas. Ustedes son mi alegría y mi mayor bendición.

A mi hermano Alexis, quien siempre ha cuidado de mí, que ha sido un guía en mi vida. Eres un ejemplo de hombre para mí, y eres mi referente de que el esfuerzo, el trabajo duro y la resiliencia siempre traen su recompensa. Y a Jenny, gracias por tu cariño y por ser la compañera ideal de mi hermano, haciendo de esta familia más alegre y fuerte.

A mi novia Nicole, el amor de mi vida. Gracias por tu sabiduría, inteligencia y creatividad, por enseñarme algo nuevo cada día, por darme claridad cuando más lo necesito, por motivarme a no detenerme ante nada y por hacerme reír con tus ocurrencias.

Steven Andrés Guamán Figueroa

Quiero dedicar este trabajo y por consiguiente el logro que representa a la memoria de mi padre Santiago, quien hoy me está cuidando desde el cielo. A pesar de su partida prematura, sus bendiciones han sido mi mayor protección a lo largo de este camino. Como siempre se lo dije en vida, le estaré eternamente agradecido por mostrarme cómo comportarme a la altura de un profesional y enseñarme a afrontar cada reto que se me presente, con valentía y por, sobre todo, a ser un hombre de bien.

Gracias, papá, por inculcarme que en la vida hay que seguir adelante con paso firme, ser responsable y entregar el máximo esfuerzo en cada una de nuestras obligaciones. Este nuevo logro en mi vida académica es un tributo a su memoria y a la formación que me brindaste, pilares fundamentales para ser hoy el profesional que soy.

Jonathan Santiago Almeida Salas

A Bella y Pochita,

mis fieles compañeras durante incontables horas de trabajo, estudio y desarrollo de proyectos. Tal vez no entienden de tesis, pero siempre supieron cuándo necesitaba un ronroneo de aliento o simplemente su presencia a mi lado.

Gracias por acompañarme en cada capítulo, cada proyecto y cada noche de estudio; por sus siestas sobre mis libros y por recordarme, con su amor incondicional, que siempre hay tiempo para una pausa y un poco de cariño.

Este logro también es suyo, mis pequeñas.

Erick Stuart Almeida Chávez

AGRADECIMIENTOS

Agradezco profundamente a mis padres, Marcos y Gloria, y a mis hermanos, Marco y Karen, quienes siempre me brindan su apoyo incondicional.

A mis compañeros de maestría, Erick Almeida, Jonathan Almeida, Steven Guamán y Eduardo Vaca, ya que sin su colaboración y apoyo no habría sido posible el desarrollo de este trabajo.

Asimismo, expreso mi gratitud a todos los docentes de EIG y UIDE por las enseñanzas impartidas en clase y por las valiosas experiencias compartidas a lo largo de este proceso académico.

Bryan Steven Vinueza Bustamante

Expreso mi más sincero agradecimiento a mis compañeros de maestría Erick Almeida, Jonathan Almeida, Steven Guamán y Steven Vinueza por el apoyo constante, el trabajo en equipo y el intercambio de conocimientos a lo largo de este proceso académico. Su compañerismo, compromiso y disposición para colaborar hicieron de este camino una experiencia de aprendizaje enriquecedora tanto a nivel profesional como personal.

Asimismo, extiendo mi agradecimiento a los docentes de EIG y de la UIDE, por su guía, dedicación y valiosas enseñanzas, las cuales han sido fundamentales para el desarrollo de mis competencias y para la culminación exitosa de esta maestría en Inteligencia Artificial Aplicada.

A todos ustedes, gracias por contribuir de manera significativa a este logro académico.

Carlos Eduardo Vaca Cano

Agradezco a mis padres, Guadalupe y Gilber, y a mi hermano Alexis, porque este logro no hubiese sido posible sin su apoyo incondicional y su guía en cada momento de mi vida.

A mi novia Nicole, quien me impulsó a tomar este desafío. Gracias por recomendarme esta maestría, por nunca dejar de ver mi potencial y apoyarme con paciencia y amor durante todo el proceso.

A la Universidad Internacional del Ecuador (UIDE) por la formación brindada.

Y a mis compañeros de equipo: Jonathan Almeida, Steven Vinuesa, Erick Almeida y Eduardo Vaca, por el tiempo y trabajo dedicado para culminar este proyecto.

Steven Andrés Guamán Figueroa

Palabras me van a faltar para agradecer a todos quienes me apoyaron, que estuvieron presentes a lo largo de esta maestría.

Principalmente, a mi madre Sylvia, y a mi hermano Daniel, pilares esenciales durante toda esta trayectoria. Ustedes saben que mi gratitud es infinita, no solo por el apoyo emocional incondicional que me han brindado, sino por la generosidad con la que sacrificaron su propio tiempo y ajustaron sus actividades para que yo pudiera cumplir con mis jornadas académicas y cumplir con este gran sueño. Gracias por ser ese motor que, con palabras de aliento y motivación, me impulsaron a no rendirme y a seguir adelante en los momentos de mayor fatiga, motivándome siempre a alcanzar mi máximo potencial. Este título no lo considero solo como un logro individual, sino que es el resultado del esfuerzo coordinado y el amor de una familia que siempre camina unida.

Adicionalmente, quiero expresar mi gratitud a los docentes que formaron parte durante este camino. Gracias por su mentoría y por inspirarme a innovar e investigar como poder aplicar estas nuevas tecnologías con un sentido más crítico y profesional.

Por último, pero no por ello menos importante quiero agradecer a Steven Guamán, Steven Vinuesa, Erick Almeida y Eduardo Vaca, mis compañeros de equipo. Gracias por el apoyo, el compromiso y la disposición para colaborar constantemente en cada etapa de este proyecto.

Jonathan Santiago Almeida Salas

Quiero expresar mi más profundo agradecimiento a quienes hicieron posible este trabajo.

En primer lugar, a mis padres, Lola y Papachi, por su apoyo incondicional en cada etapa de este camino. Su confianza, paciencia y constante aliento fueron fundamentales para llegar hasta aquí.

A mi prometida, Vanessa, por sus cuidados y atenciones justo cuando más los necesitaba. Tu comprensión, apoyo y paciencia durante este proceso significaron más de lo que las palabras pueden expresar.

A mis dos gatas, Bella y Pochita, fieles compañeras en las largas noches de estudio, cuya presencia silenciosa hizo más llevaderas las horas de trabajo.

A todos ustedes, gracias por ser parte de este logro.

Erick Stuart Almeida Chávez

RESUMEN

Los métodos tradicionales de revisión florícola basados en la inspección visual humana presentan diferentes limitaciones debido a la subjetividad del observador. Factores como la fatiga visual, falta de experiencia, la dificultad de detectar los síntomas de la infección y diferenciarlos correctamente de otras posibles infecciones, son clave para una detección temprana y correcta de una posible presencia de Botrytis Cinérea en cultivos de rosas. El presente trabajo de titulación aborda esta problemática, describiendo el desarrollo y la implementación de un sistema basado en un modelo de visión por computadora de alta precisión fundamentado en algoritmos de aprendizaje profundo. Para ello, metodológicamente se optó por un enfoque fundamentado en redes neuronales convolucionales (CNN), centrándose en la última versión YOLOv8. Adicionalmente, se construyó un conjunto de datos especializado que contiene variaciones de iluminación y enfoque propias de los entornos reales de florícolas en el Ecuador. De esta manera, el modelo fue sometido a procesos de entrenamiento, normalización y Data Augmentation a través de la plataforma Roboflow, logrando una detección fiel de posibles infecciones y discriminación con otros factores como lo son daños climáticos o manuales. El análisis de resultados demuestra que la automatización del diagnóstico no solo reduce drásticamente los tiempos de detección, sino que el modelo alcanzó métricas de desempeño sobresalientes, con una precisión media promedio (mAP) que valida su capacidad de generalización en condiciones reales de campo. El sistema propuesto se integra en una interfaz web reactiva desarrollada con React y Bulma, facilitando así un diagnóstico instantáneo y bilingüe para el usuario final.

Palabras Claves: Visión por Computadora, Botrytis Cinerea, Inteligencia Artificial, YOLOv8, Aprendizaje Profundo, Roboflow, Precisión media Promedio (mAP).

ABSTRACT

Traditional floricultural inspection methods based on human visual assessment present several limitations due to observer subjectivity. Factors such as visual fatigue, lack of experience, and the difficulty of detecting infection symptoms and correctly distinguishing them from other possible diseases are critical challenges for the early and accurate detection of *Botrytis cinerea* in rose crops. This undergraduate thesis addresses this problem by describing the development and implementation of a high-precision computer vision–based system grounded in deep learning algorithms.

Methodologically, an approach based on convolutional neural networks (CNNs) was adopted, focusing on the latest version of YOLOv8. In addition, a specialized dataset was constructed, incorporating variations in lighting and focus representative of real floriculture environments in Ecuador. Consequently, the model underwent training, normalization, and data augmentation processes using the Roboflow platform, achieving reliable detection of potential infections and effective discrimination from other factors such as climatic or manual damage.

The results analysis demonstrates that diagnostic automation not only significantly reduces detection times but also enables the model to achieve outstanding performance metrics. In particular, the obtained mean Average Precision (mAP) validates the model's ability to generalize under real field conditions. The proposed system is integrated into a reactive web interface developed using React and Bulma, thereby facilitating instant, bilingual diagnosis for the end user.

Keywords: Computer Vision, *Botrytis Cinerea*, Artificial Intelligence, YOLOv8, Deep Learning, Roboflow, Mean Average Precision (mAP).

TABLA DE CONTENIDOS (Índice)

Capítulo 1:	1
1. Introducción	1
1.1. Definición del proyecto	1
1.2. Justificación e importancia del trabajo de investigación	2
1.3. Alcance	6
Dataset.....	6
Modelo de detección	6
Prototipo.....	7
Exclusiones.....	7
1.4. Objetivos.....	8
1.4.1. Objetivo general	8
1.4.2. Objetivo específico	8
Capítulo 2:	10
2. Revisión de Literatura	10
2.1. Estado del Arte.....	10
2.1.1. Panorama fitosanitario del sector florícola en Ecuador.....	10
2.1.2. Importancia de la Rosicultura en Ecuador.....	10
2.1.3. Principales patologías en el cultivo de rosas	10
2.1.4. Impacto de Botrytis cinérea en producción	11
2.1.5. Costos en el tratamiento de la Botrytis.....	13
2.1.6. Estadísticas de pérdidas en Ecuador.....	13
2.1.7. La dificultad de detectar la enfermedad a tiempo: por qué se necesita inteligencia artificial	14
2.1.8. Epidemiología: Condiciones ambientales predisponentes	15
2.1.9. El triángulo de la enfermedad en rosas.....	15
2.1.10. Variables climáticas críticas.....	16
2.1.11. Factores de Manejo en Invernadero.....	17
2.1.12. Caracterización Visual y Sintomatología de Botrytis cinérea	17
2.1.13. Diagnóstico Diferencial: Distinguiendo Botrytis de Otros Daños	20
2.1.14. La IA y la Visión por computadora en el Ecuador.....	21
2.1.15. Aplicación de la IA en el entorno agrícola.	23

2.1.16.	Arquitectura de Sistemas de Agricultura de Precisión	26
2.1.17.	Análisis de Modelos de Deep Learning.....	27
2.2.	Marco Teórico.....	30
2.2.1.	Sistemas Backend en Aplicaciones de Inteligencia Artificial	30
2.2.2.	Python como Lenguaje Dominante en Inteligencia Artificial	32
2.2.3.	Deep Learning y Redes Neuronales Convolucionales	32
2.2.4.	Aplicación del Deep Learning en la Agricultura de Precisión	33
2.2.5.	Clasificación de Imágenes vs. Detección de Objetos.....	34
2.2.6.	Modelos YOLO y Detección en Tiempo Real	35
2.2.7.	Preparación, Anotación y Calidad de los Datos	36
2.2.8.	Aumentación de Datos como Estrategia de Generalización.....	37
2.2.9.	Entrenamiento de Redes Neuronales y Uso de GPU	38
2.2.10.	FastAPI como Infraestructura de Inferencia	39
Capítulo 3:		39
3.	Desarrollo.....	39
3.1.	Arquitectura general del sistema	39
3.2.	Desarrollo del modelo de inteligencia artificial	40
3.2.1.	Selección del Modelo: YOLOv8	40
3.2.2.	Preparación y etiquetado de datos (Roboflow).....	41
3.2.3.	Estrategias de aumentación de datos	41
3.2.4.	Entrenamiento del Modelo	48
3.3.	Implementación del Backend	49
3.3.1.	Framework FastAPI.....	49
3.3.2.	Diseño del Endpoint de análisis.....	49
3.3.3.	Estructura de la Respuesta.....	50
3.3.4.	Flujo de procesamiento de petición	50
3.4.	Desarrollo del Frontend.....	53
3.4.1.	Framework de Estilo (Bulma)	53
3.4.2.	Diseño UI/UX.....	53
3.4.3.	Flujo de Usuario en la Detección	54
3.5.	Internacionalización y Accesibilidad.....	54
3.6.	Consideraciones Finales	55
CAPITULO 4:		56
4.	ANÁLISIS DE RESULTADOS	56

4.1.	Pruebas de Concepto	56
	Medición de Rendimiento y Latencia	58
4.2.	Análisis de Resultados	62
	Discriminación de Rosas por deterioro no relacionado con la infección	62
	Verdaderos positivos en rosas infectadas	65
	Generalización de Rosas Sanas sin infección	69
CAPITULO 5:		73
5.	CONCLUSIONES Y RECOMENDACIONES	73
5.1.	Conclusiones.....	73
5.2.	Recomendaciones	74
APÉNDICE		85
	Anexo A	85
	Anexo B	85
	Anexo C	85

LISTA DE TABLAS (Índice de tablas)

Tabla 1 Principales enfermedades en rosas..... 12

Tabla 2 Diferencias entre Botrytis y otros daños 20

Tabla 3 Aplicaciones de la IA en la producción Florícola Global y Local 25

Tabla 4 Arquitectura de Deep Learning en tareas Agrícolas y Florícolas 29

Tabla 5 Parámetros de aumentación de datos aplicados 43

Tabla 6 Parámetros para generación de imágenes con botritis 44

Tabla 7 Parámetros para generación de imágenes sanas, sin ningun tipo de lesión 45

Tabla 8 Parámetros para generación de imágenes sanas, pero con ligeras lesiones mecánicas..... 47

Tabla 9 Resumen pruebas de concepto 57

Tabla 10. Resumen de tiempos de casos de prueba 60

LISTA DE FIGURAS (Índice de figuras)

Fig. 1	Oídio o Mildiú Polvoroso	3
Fig. 2	Mildeo Velloso	4
Fig. 3	Modelos de IA - Sistemas Backend	31
Fig. 4	API REST - Mecanismo de Comunicación.....	32
Fig. 5	Deep Learning en la Agricultura.....	33
Fig. 6	Clasificación vs Detección de Objetos.....	35
Fig. 7	Yolo v8	36
Fig. 8	Calidad de datos	37
Fig. 9	Etiquetado de datos	38
Fig. 10	Estructura de respuesta de detección de botritis	50
Fig. 11	Diagrama de procesamiento de peticiones	52
Fig. 12	Inicio de cronómetro en backend.....	58
Fig. 13	Fin del cronómetro para backend.....	58
Fig. 14	Inicio del cronómetro para Frontend.....	59
Fig. 15	Finalización del cronómetro para Frontend	59
Fig. 16	Ejecución del sistema con cronómetro.....	60
Fig. 17	Rosa enferma sin Botrytis – Escenario 1	63
Fig. 18	Rosa enferma sin Botrytis – Escenario 2	64
Fig. 19	Rosa con Botrytis - Escenario 1	66
Fig. 20	Rosa con Botrytis - Escenario 2.....	67
Fig. 21	Rosa con Botrytis - Escenario 3.....	68
Fig. 22	Rosa Sana - Escenario 1	69
Fig. 23	Rosa Sana - Escenario 2.....	70
Fig. 24	Rosa Sana - Escenario 3	71

LISTA DE CÓDIGO FUENTE (Índice de figuras)

Código Fuente 1	Respuesta del servidor para la para el escenario de la Fig. 17	64
Código Fuente 2	Respuesta del servidor para la para el escenario de la Fig. 18	65
Código Fuente 3	Respuesta del servidor para la para el escenario de la Fig. 19	66
Código Fuente 4	Respuesta del servidor para la para el escenario de la Fig. 20	67
Código Fuente 5	Respuesta del servidor para la para el escenario de la Fig. 21	68
Código Fuente 6	Respuesta del servidor para la para el escenario de la Fig. 22	70
Código Fuente 7	Respuesta del servidor para la para el escenario de la Fig. 23	71
Código Fuente 8	Respuesta del servidor para la para el escenario de la Fig. 24	72

Capítulo 1:

1. Introducción

1.1. Definición del proyecto

El presente proyecto se centra en el diseño, entrenamiento y despliegue de un modelo de visión por computadora fundamentado en técnicas de aprendizaje profundo, orientado a la detección temprana de botritis (*Botrytis cinérea*) en cultivos de rosas de exportación en la región de la Sierra Ecuatoriana. El desarrollo contempla todas las etapas fundamentales para un sistema de inteligencia artificial aplicado al ámbito agrícola, abarcando desde la obtención y preprocesamiento de imágenes hasta la creación y estructuración de un conjunto de datos equilibrado, el diseño y entrenamiento de un modelo de redes neuronales convolucionales, y la integración de la solución en una aplicación práctica accesible para productores y técnicos del sector.

La propuesta contempla la captura sistematizada de imágenes en condiciones de campo, ejerciendo control sobre variables como iluminación y distancia focal, con el propósito de alimentar el sistema con información visual relevante tanto de especímenes sanos como de aquellos afectados por botritis en distintas etapas de desarrollo de la enfermedad. Se establecerán protocolos rigurosos de muestreo y organización de datos orientados a garantizar que el conjunto de datos resulte robusto y representativo de los escenarios reales presentes en unidades productivas florícolas.

Durante la fase de modelado, se experimentará con varias arquitecturas de aprendizaje profundo, tanto para el proceso de clasificación como detección de objetos. Durante este proceso se probó las diferentes versiones de la Familia YOLO (You Only Look Once) y se analizó ResNet y EfficientNet, aplicando técnicas de aprendizaje por transferencia para

optimizar el aprovechamiento de recursos computacionales y mejorar la precisión del modelo ante la disponibilidad limitada de datos locales. El desempeño del modelo seleccionado será evaluado mediante métricas convencionales que incluyen exactitud, sensibilidad, puntuación F1 y matriz de confusión, procediéndose al ajuste de hiperparámetros con el objetivo de maximizar la capacidad de detección acertada de la enfermedad.

El sistema resultante será encapsulado en una interfaz intuitiva mediante una plataforma web y el modelo IA utilizando microservicios, que permita la identificación inmediata de posibles casos de Botritis a partir de fotografías de rosas de la región de Cayambe, facilitando así la toma de decisiones oportunas y fundamentadas. Adicionalmente, se analizarán los requerimientos asociados a la escalabilidad y viabilidad de implementación en contextos productivos reales, considerando la infraestructura disponible, los costos operativos y el potencial impacto en la gestión fitosanitaria.

De esta manera, el proyecto aspira a consolidar una herramienta tecnológica innovadora, alineada con los principios de la agricultura de precisión, que represente un aporte significativo al sector florícola ecuatoriano y sea susceptible de adaptación a diferentes patologías en cultivos de alto valor comercial.

1.2. Justificación e importancia del trabajo de investigación

En los últimos años, la Botrytis ha sido uno de los principales desafíos fitosanitarios para cultivos de rosas en Ecuador, teniendo un impacto diferencial con respecto a otras enfermedades debido a su naturaleza como superpatógeno, ya que esta amenaza se encuentra presente desde el cultivo hasta el momento de llegada al consumidor final, por lo cual se lo considera un factor de riesgo, a diferencia de otros patógenos como el Peronospora sparsa (Redagráfica, 2022). Entre algunas de las enfermedades más comunes que afectan a las rosas de la región interandina se encuentra el Oidio o Mildiu Polvoroso generado por el hongo

Sphaerotheca pannosa, la característica fundamental de este hongo es que no requiere de una película de agua para empezar con la infección y una de sus características es su capacidad de germinar en humedades relativas que oscilan entre 40% a 70% (Agro link, 2025; *Oídio en rosales – Encuentra la mejor manera de curarlo*, 2024).

Fig. 1

Oídio o Mildiú Polvoroso



Nota. La imagen muestra la presencia de oídio, una enfermedad fúngica caracterizada por un crecimiento blanquecino pulverulento sobre la superficie de la hoja. Imagen tomada de *Powdery mildew on rose leaf*, por Oregon State University, 9 de junio de 2025, *Solve Pest Problems*.

Otra de las enfermedades presentes es el Mildeo Velloso ocasionado por el hongo *Peronospora Sparsa*, este se manifiesta con manchas irregulares de una tonalidad púrpura a marrón en las hojas (*Control de Mildiu Velloso en Cultivo de Rosa | Intagri S.C.*, 2019), esta enfermedad por lo general infecta hojas, tallos sépalos, por lo general es una enfermedad de

finca, ya que su detección es sencilla en actividades de monitoreo o cosecha (*Conoce y controla el Mildeo Velloso* | ADAMA Colombia, 2022).

Fig. 2

Mildeo Velloso



Nota. Adaptado de *Mildeo velloso*, por B. Romero, 2021, Metroflor Colombia.

Una de las enfermedades también presente es la mancha negra, ocasionada por el *Diplocarpon rosae*, su característica es lesiones circulares de color negro con bordes irregulares, este hongo genera defoliación prematura y se lo asocia debido a la existencia de alta humedad y presencia de agua en las hojas por tiempos prolongados (Agro Link, 2025a; Asociación Uruguaya de la Rosa, 2020).

Aun cuando todas las enfermedades que se detallaron afectan la producción de las rosas ecuatorianas, la Botrytis es la patología más crítica de la rosa ecuatoriana, esto debido a que su comportamiento biológico hace que pueda evadir controles, sea altamente virulento en su transportación y comercialización final (Agro Link, 2025a; *La botrytis en rosa*, n.d.).

Las pérdidas económicas y de producción debidos a este hongo son considerables y

afectan tanto a la calidad como al volumen exportable. Estudios recientes muestran que la Botrytis puede llegar a generar pérdidas hasta de un 30% de la producción anual en condiciones graves (*La botrytis en rosa*, 2025), lo cual representa cerca de 150 millones de dólares anuales debido al rechazo de flores en destino y a la reducción de la vida útil del producto durante la cadena de exportación (Jiménez Pazmiño & Silva Moya, 2025).

Para poder combatir a la Botrytis, los productores se ven obligados a invertir constantemente en fungicidas, aumentando los costos de producción hasta en un 30% en algunos casos, lo que puede disminuir su rentabilidad (Jiménez Pazmiño & Silva Moya, 2025). Adicionalmente, la Botrytis no solo afecta al volumen exportable ni costos extras para combatirla, sino también a la reputación de la flor ecuatoriana como producto premium, ya que reduce la calidad visual y la vida útil en florero, siendo esto un aspecto clave para los mercados internacionales (Agro Link, 2025b).

El diseño y la implementación de un modelo de visión por computador ayudaría a impulsar la modernización del sector agrícola, acercándolo a tendencias globales de digitalización y agricultura de precisión. Solamente en el año 2024, el sector florícola ecuatoriano exportó más de 1000 millones de dólares en flores, pero la reincidencia de Botrytis sigue siendo el principal motivo de créditos de calidad y rechazos comerciales en el exterior (*Tendencias del comercio global en 2025*, 2025).

Con el uso de un modelo de visión por computador, facilitaría a una detección temprana y precisa de la Botrytis, lo que reduce la diseminación y disminuyendo drásticamente las pérdidas económicas (Tigrero Bacilio, 2024)

Adicionalmente, el modelo ayudaría a optimizar el uso de fungicidas al identificar solo aquellas áreas realmente afectadas, promoviendo un manejo más sostenible y económico de los insumos agrícolas.

A pesar de los beneficios que el modelo de visión por computador presenta, hay que tener en cuenta que es fundamental que su adopción sea acompañada de estrategias de capacitación, inversión y adaptación tecnológica (Tigrero Bacilio, 2024).

1.3. Alcance

Frente a las pérdidas significativas que han alcanzado hasta 150 millones de dólares anuales causadas por la Botrytis Cinérea en la floricultura ecuatoriana (Jiménez Pazmiño & Sliva Mora, 2025), este proyecto se centra en el diseño, entrenamiento y despliegue de un prototipo de un modelo de visión por computadora para la detección temprana del hongo Botrytis Cinerea en rosas, aportando así a la modernización y sostenibilidad del área florícola en el Ecuador.

Dataset

La base del proyecto será la creación de un dataset de imágenes digitales, enfocado en las variedades de rosas de alta exportación del Ecuador. Este repositorio se organizará en dos categorías para el entrenamiento: “Sanas” y “Afectadas”, donde se priorizará la captura de síntomas visuales de Botrytis en sus etapas iniciales. Para asegurar un modelo robusto, las imágenes seguirán una estandarización de ángulo, distancia e iluminación base, y se permitirá la variabilidad natural presente en un entorno florícola real como los cambios de luz solar y clima. Adicionalmente, se aplicarán técnicas de aumento de datos (como rotaciones y cambios de brillo) para enriquecer el dataset y mejorar la generalización del modelo.

Modelo de detección

Se desarrollará un modelo de clasificación basado en Deep Learning, utilizando una arquitectura de Red Neuronal Convolucional (CNN) la cual es la base estándar en el análisis de imágenes. El resultado final será un clasificador con la capacidad de procesar una imagen

de una flor y responder con un diagnóstico predictivo, identificándola como “Sana” o “Afectada”.

Prototipo

El entregable final del proyecto será un prototipo, desarrollado bajo una arquitectura de microservicios desacoplada. Este enfoque permite la independencia del backend y frontend, lo cual facilita la escalabilidad del proyecto, el mantenimiento y la portabilidad del sistema.

- Backend: Se implementará como un microservicio desarrollado en Python (utilizando Flask o FastAPI). La responsabilidad de este microservicio será encapsular el modelo de IA y exponer un endpoint que gestione el procesamiento de las imágenes.
- Frontend: Se desarrollará una Single Page Application (SPA) en React para exponer al usuario una experiencia dinámica. Esta interfaz consumirá el microservicio de forma asíncrona, permitiendo así que el usuario cargue las imágenes y vea los resultados sin la necesidad de volver a cargar la página o el navegador.

Exclusiones

Para asegurar la viabilidad de los objetivos del proyecto, se definen las siguientes exclusiones, que, aunque son relevantes, se consideran etapas futuras o incluso futuros proyectos independientes.

- Análisis de video en tiempo real: El alcance se limita únicamente al análisis de imágenes estáticas cargadas por el usuario. La implementación de un modelo

capaz de procesar video en tiempo real (drones, cámaras fijas o gafas de realidad virtual/aumentada) no forman parte de este proyecto.

- **Detección multienfermedad:** El modelo será entrenado exclusivamente para identificar Botrytis Cinerea. El diagnóstico de otras plagas o enfermedades están fuera del alcance actual.
- **Cuantificación de la severidad:** El sistema proporcionará una clasificación binaria (“Sana” o “Afectada”) y un nivel de confiabilidad para el diagnóstico. No se desarrollará la funcionalidad para identificar el medir el nivel de avance de la infección en la flor.
- **Desarrollo de Hardware:** El proyecto utilizará solamente equipos comerciales y estándar para la captura de imágenes, como celulares y cámaras simples. El diseño, la construcción o la personalización de hardware como cámaras, drones, sensores, y sistemas de iluminación no están considerados.

1.4. Objetivos

1.4.1. Objetivo general

Desarrollar una herramienta de modelo de visión por computadora de alto rendimiento para la detección temprana del hongo Botrytis Cinérea en cultivos de rosas, con el fin de proporcionar al sector florícola ecuatoriano una herramienta eficiente, precisa y accesible que facilite la toma de decisiones agronómicas oportunas, impulsando así la modernización, productividad y sostenibilidad del área florícola en Ecuador.

1.4.2. Objetivo específico

- Establecer la arquitectura de la red neuronal de visión por computadora más idónea para el procesamiento de un dataset integral y diversificado de imágenes de tejido de rosas (sano y enfermo por Botrytis Cinérea) el cual sea capaz de ejecutar la

detección temprana de dicha patología.

- Entrenar el modelo de IA hasta que sus resultados demuestren una confiabilidad estadística con un rango de aceptación alto en las métricas clave de clasificación de Botrytis Cinérea.
- Desplegar el modelo de clasificación aplicando la plataforma de Roboflow para la detección temprana de Botrytis Cinérea a partir del dataset seleccionado.

Capítulo 2:

2. Revisión de Literatura

2.1. Estado del Arte

2.1.1. Panorama fitosanitario del sector florícola en Ecuador

Ecuador es un referente mundial en la producción y exportación de rosas. Sin embargo, los productores se enfrentan a una batalla constante: las enfermedades derivadas de la humedad y las variaciones climáticas. Estas enfermedades comprometen directamente tanto a la calidad final de la flor como el volumen de la cosecha. Ante este escenario, se vuelve indispensable integrar herramientas tecnológicas capaces de detectar estas amenazas a tiempo, actuando antes de que el daño sea irreversible (Manvert, 2025).

2.1.2. Importancia de la Rosicultura en Ecuador

Ecuador es reconocido mundialmente en el mercado de flores. Las rosas son, por mucho, el producto estrella y ocupan cerca del 72% de toda el área destinada a cultivos florales en el país.

La mayoría de la producción ocurre en invernaderos ubicados en la Sierra andina. Las provincias de Pichincha y Cotopaxi son las más importantes. Dentro de Pichincha, el Cantón Pedro Moncayo destaca porque ahí está el 31.9% de las hectáreas cultivadas de toda la provincia. Cotopaxi también es relevante, especialmente en zonas como Yambo donde se han realizado varios ensayos (Trioxy, 2025).

Para dimensionar la relevancia económica de las rosas ecuatorianas, basta mencionar que Colombia y Ecuador juntos proveen aproximadamente el 70% de las rosas que se exportan a Estados Unidos y Europa (Manvert, 2025).

2.1.3. Principales patologías en el cultivo de rosas

Los cultivos de rosas en Ecuador enfrentan varias enfermedades fúngicas. Junto con Botrytis cinérea, estas enfermedades afectan tanto el rendimiento como la calidad de la producción.

Las enfermedades más comunes son:

Roya: Esta enfermedad fúngica es causada por *Uromyces caryophyllinus* en el clavel, pero también ataca a las rosas (Enfermedades de las plantas - Prevención, control y daños, 2025). Se identifica por pústulas uredospóricas naranjas que aparecen en el envés de las hojas.

Mildiu Velloso (*Peronospora sparsa*): Presenta manchas marrones o purpuras irregulares principalmente en hojas, peciolo y tallos. (Caiza, 2013) menciona que las condiciones climáticas ideales son una humedad relativa superior al 50% y temperaturas entre 25°C y 30°C.

Oídio (Mildiu Polvoso): El agente causal es *Sphaerotheca pannosa* var. *rosae*. Los síntomas son manchas blancas y pulverulentas que cubren los tejidos jóvenes: brotes, hojas, botones florales y la base de las espinas. Estas manchas pueden deformar las hojas. (Matute, 2019) menciona que las temperaturas entre 15°C y 27°C y una alta humedad son las condiciones ideales para que el hongo se desarrolle.

2.1.4. Impacto de Botrytis cinérea en producción

El "moho gris" que causa Botrytis cinérea es probablemente el peor problema fitosanitario que enfrentan los floricultores (Manvert, 2025). Las pérdidas económicas se pueden evidenciar desde que la flor está en el campo hasta que llega al mercado de exportación.

En la Tabla 1 se comparan las principales enfermedades que atacan a las rosas y cómo impactan la producción. Como se puede ver, Botrytis es una de las que más daño causa, tanto al cultivo como al producto final.

Tabla 1*Principales enfermedades en rosas*

Enfermedad	Impacto Económico	Perdidas Reportadas	Validación de afectación
Botrytis	Pérdida de Valor (Rechazo en Destino). El costo incluye producción + empaque + flete aéreo.	40% de pérdida producción si no se controla (Campués, 2023). Reclamos de hasta 84.29% (Ha et al., 2021).	Crítica. Destruye el producto terminado. Genera notas de crédito y pérdida de clientes internacionales (Ha et al., 2021).
Mildiu Velloso	Pérdida de Volumen (Productividad). Planta defoliada no produce tallos.	Alta en temporada de lluvias. Puede causar pérdida total de follaje, requiriendo meses para recuperar la planta (Anonymous, 2021).	Alta. Afecta la capacidad productiva de la fábrica biológica (la planta), pero el daño es visible antes de exportar.
Oídio	Pérdida de Calidad (Descarte en Finca). Tallo nacional o compost.	Incidencias del 33% al 75% en testigos sin control (Aponte, 2015). Común en veranos o transición.	Media/Alta. Tallo afectado se descarta en clasificación. No suele viajar al cliente, evitando el costo logístico del rechazo.
Roya	Pérdida de Vigor. Menor calidad de tallo.	Umbral de acción bajo (3-5% de hojas)	Moderada. Generalmente controlable con monitoreo. Menos explosiva que Botrytis

(Agrolink, 2025b).	o Mildiu en invernaderos
Incidencia focalizada.	modernos.

Nota. La tabla presenta las principales enfermedades que afectan a las rosas, describiendo su impacto económico, las pérdidas reportadas y la valoración del nivel de afectación en la producción. Las referencias de cada dato se encuentran indicadas dentro del contenido de la tabla.

2.1.5. Costos en el tratamiento de la Botrytis

Resistencia y costos operacionales: El uso repetido de fungicidas químicos ha llevado a que Botrytis cinérea desarrolle resistencia (Caiza, 2013). Esto ha complicado enormemente el control y ha disparado los costos. Como menciona (Manvert, 2025), los productores ahora tienen que rotar entre fungicidas más específicos (y más caros) porque los productos convencionales han perdido efectividad. El control se volvió un problema crónico.

Pérdidas en campo y rechazos en postcosecha: Las pérdidas no ocurren solo en el campo. Sí, hay una reducción en el rendimiento directo, pero el verdadero golpe económico viene después (Manvert, 2025). Las pecas que deja la enfermedad en los pétalos externos arruinan la calidad de la flor. Esto hace que una gran parte se rechace en la clasificación (Metroflor Colombia, 2017). Peor aún, algunas infecciones no se ven de inmediato (quedan latentes) y aparecen durante el transporte o en el almacenamiento, lo que compromete la vida en florero. Además, las infecciones latentes pueden aparecer durante el transporte o almacenamiento, afectando la vida en florero y la calidad de exportación.

2.1.6. Estadísticas de pérdidas en Ecuador

Los datos de fincas ecuatorianas muestran que del total de flor de desecho o nacional que se retira diariamente, en promedio el 16% de esa pérdida se debe a esta enfermedad.

Ese 16% constante de pérdida evidencia un problema: los programas tradicionales de control químico reactivo simplemente no están dando resultados. Cuando la infección se vuelve severa, los estudios muestran pérdidas que alcanzan el 30% de la producción anual (Manvert, 2025).

2.1.7. La dificultad de detectar la enfermedad a tiempo: por qué se necesita inteligencia artificial

La detección temprana de Botrytis es crítica porque la infección avanza muy rápido. Hay casos donde plantas aparentemente sanas ya tienen la enfermedad.

Síntomas iniciales difíciles de ver: (GardenTech, 2017) menciona que las primeras señales son manchas pardas irregulares en pétalos o manchas oscuras en capullos. Estos síntomas son problemáticos porque se parecen mucho al daño mecánico o a infecciones por otros hongos.

Limitaciones de la detección humana: El moho grisáceo (que son las conidias del hongo) es el síntoma más obvio. Pero para cuando se ve a simple vista, ya es tarde. En ese punto el hongo está liberando millones de esporas al ambiente del invernadero y el daño ya está hecho (DryGair, 2019).

Por qué usar IA: Como la detección humana de los síntomas iniciales es difícil y el diagnóstico tradicional llega tarde (cuando ya hay esporulación), el diagnóstico temprano real debe enfocarse en identificar las manchas pardas iniciales o detectar las condiciones ambientales que favorecen la enfermedad. Los sensores de alta precisión y las herramientas de diagnóstico digital permiten monitorear parámetros fisiológicos y climáticos para

anticiparse a los síntomas visibles e identificar zonas de riesgo antes de que haya esporulación masiva (Beccatelli, 2025). Esto justifica desarrollar un modelo de inteligencia artificial que pueda identificar patrones sutiles o condiciones ambientales que favorecen la enfermedad, cosas que son difíciles de detectar con inspección visual periódica.

Botrytis cinerea es un patógeno oportunista que entra frecuentemente por heridas causadas por actividades normales como la poda o cosecha. Además, completa su ciclo de infección en solo 3 a 4 días, lo que deja una ventana muy corta para actuar efectivamente. Esta rapidez supera la capacidad del monitoreo humano convencional.

2.1.8. Epidemiología: Condiciones ambientales predisponentes

Un modelo de IA para detectar Botrytis cinérea necesita operar en el contexto real donde se desarrolla esta enfermedad. El moho gris no aparece de forma aleatoria, su epidemiología responde al Triángulo de la Enfermedad, un concepto que relaciona tres factores críticos. Aquí es donde los datos meteorológicos, especialmente humedad y temperatura, se convierten en herramientas predictivas tan importantes como la detección visual misma.

2.1.9. El triángulo de la enfermedad en rosas

Para que el moho gris se desarrolle necesita que coincidan tres elementos: una planta susceptible, un patógeno virulento y condiciones ambientales favorables. Interrumpir cualquiera de estos componentes detiene el ciclo de la enfermedad (Metroflor Colombia, 2017).

El Huésped (Rosa): Los rosales son altamente vulnerables a esta enfermedad, especialmente cuando presentan tejidos dañados o envejecidos. Las infecciones ingresan típicamente a través de heridas en tallos, hojas, pétalos y brotes jóvenes. Un exceso de nitrógeno genera tejidos más succulentos y propensos a la infección (Gauthier et al., 2021).

El Patógeno (*Botrytis cinérea*): Este hongo necrotrófico se alimenta destruyendo las células del hospedero. Su manejo es complicado por su capacidad de adaptación y porque el uso intensivo de fungicidas ha generado cepas altamente resistentes. La severidad de los brotes depende del control de la fuente de inóculo (esporas) en el ambiente (Agrolink, 2025a).

El Ambiente (Microclima del Invernadero): Este es el factor más determinante. Las infecciones prosperan con temperaturas frescas o moderadas y humedad relativa alta (Trioxy, 2025). En la floricultura de altura, las fluctuaciones térmicas provocan condensación, generando el agua libre que las esporas necesitan para germinar.

2.1.10. Variables climáticas críticas

Las condiciones climáticas definen las "ventanas de riesgo" para la infección, haciéndolas indispensables para cualquier modelo predictivo.

Humedad Relativa: El papel del agua libre sobre los pétalos. Contrario a lo que podría pensarse, el factor crítico no es simplemente tener una humedad relativa elevada, sino la presencia de agua libre “rocío o gutación” sobre la superficie de los tejidos vegetales.

Sin agua libre, las esporas simplemente no germinan. (Latorre & Rioja, 2002) menciona que hay diversos estudios in vitro han demostrado que incluso con humedades relativas muy altas (86% o 98%), si no hay agua libre sobre la superficie, no ocurre la germinación. Aunque se ha reportado que la germinación requiere humedades del 93% o superiores, lo que realmente importa es que esa humedad alta propicie la condensación microscópica sobre los tejidos (Trioxy, 2025). Esta película de agua imperceptible es la que activa el proceso de germinación e infección.

La infección se consolida cuando los tejidos susceptibles permanecen mojados por períodos prolongados; entre 6 y 12 horas según diferentes estudios (Manvert, 2025). Por eso, la estrategia preventiva más efectiva se centra en reducir la duración del mojado foliar.

Temperatura: Rangos óptimos para el desarrollo del hongo. Botrytis cinérea prospera en climas templados. Su crecimiento y esporulación son más intensos entre 15°C y 25°C, alcanzando el punto ideal para germinar cerca de los 20°C. Sin embargo, las esporas tienen capacidad de germinar en un rango más amplio, desde 5°C hasta 30°C.

Lo que realmente favorece al tizón es el patrón térmico típico de invernaderos: días templados o nublados que alternan con noches frías. Estas oscilaciones generan condensación sobre los tejidos vegetales, creando el ambiente perfecto para la infección. Por suerte, cuando la temperatura sube más allá de los 30°C, las infecciones cesan (Gauthier et al., 2021).

2.1.11. Factores de Manejo en Invernadero

Las prácticas agronómicas pueden generar sin querer microclimas ideales para el hongo, a veces con el mismo impacto que los fungicidas mismos (Gauthier et al., 2021).

Ventilación y Densidad de Siembra. Cuando hay muchas plantas juntas y poco movimiento de aire, la humedad queda atrapada en el dosel vegetal. Esto crea exactamente el microclima húmedo que Botrytis necesita para prosperar.

Ventilar bien es clave para bajar la humedad. La estrategia "Calentar y Ventilar" funciona mejor, sobre todo de noche o en días nublados: se sube un poco la temperatura mientras entra aire fresco, reduciendo la humedad y evaporando el agua de las superficies. Lo ideal es hacerlo dos o tres veces por hora durante la noche y al amanecer (Pundt, 2022).

2.1.12. Caracterización Visual y Sintomatología de Botrytis cinérea

Esta sección describe cómo se manifiesta la enfermedad visualmente, información crucial para entrenar y etiquetar correctamente los modelos de detección por IA.

Fisiología de la Infección. Botrytis cinérea es un hongo necro trófico que mata las células del huésped para alimentarse de ellas. Penetra el tejido de la rosa mediante dos mecanismos:

Penetración Oportunista (Pasiva). El hongo aprovecha heridas y aperturas naturales como micro fisuras o daños físicos por insectos, granizo, poda o cosecha. Las rosas son especialmente vulnerables porque liberan azúcares y aminoácidos que estimulan la germinación de las esporas (Metroflor Colombia, 2017).

Penetración Activa (Enzimática). Puede colonizar tejido vivo sin necesidad de una herida previa. Libera enzimas (pectinasas y celulasas) que degradan la cutícula y pared celular, matando las células. La primera señal visual detectable es la necrosis focal causada por esta acción enzimática (Agrolink, 2025a).

Sintomatología inicial (Fase Latente y Temprana). Un modelo de IA debe enfocarse en detectar síntomas tempranos, ya que cuando aparece el moho gris visible, la infección está avanzada y dispersando esporas masivamente.

Como menciona (Gauthier et al., 2021), los primeros síntomas en rosas suelen ser sutiles. En pétalos aparecen como lesiones pequeñas, circulares y focales, a veces llamadas "pecas" o puntos descoloridos.

Morfología. Puntea duras de 1 a 3 mm aproximadamente

Localización. Principalmente en pétalos externos de capullos y rosas maduras

En otros tejidos. Las hojas muestran manchas pardas irregulares. En tallos aparecen zonas blandas o hundidas

Cambios de coloración según el tipo de rosa. Adicionalmente, (Gauthier et al., 2021) informa que los cambios cromáticos varían con el color natural del pétalo:

Rosas blancas. Inician con la aparición de puntos o “pecas” de color rojo brillante o fucsia, y en etapas más avanzadas estas se tornan de color marrón claro, expandiéndose hasta pudrir el pétalo por completo.

Rosas tonos claros (Crema, Amarillo pálido, Rosado suave). Inician como manchas circulares de color marrón claro o canela, en etapas avanzadas el tejido se vuelve acuoso y aparece el crecimiento de micelio gris.

Rosas rojas o bicolors. El ataque degrada los pigmentos (antocianinas), creando manchas pálidas, grisáceas o blanquecinas que contrastan claramente con el fondo rojo, esta decoloración focal es la señal clave.

Efecto halo. Alrededor de la puntea dura central puede verse un anillo sutil de tejido clorótico o empapado de agua. Este halo indica la difusión temprana de toxinas fúngicas antes de la colonización completa (Novobac, 2025).

Evolución de los Síntomas (Fase Avanzada). En esta etapa hay daño estructural severo y la planta se convierte en fuente masiva de inóculo.

Pudrición blanda y colapso: (Gauthier et al., 2021) menciona que las lesiones iniciales se fusionan, el tejido se desorganiza y aparece una pudrición blanda y acuosa de color gris o marrón claro. Los botones florales y flores enteras colapsan completamente.

Crecimiento del micelio (el "moho gris"): El signo definitivo es un moho vellosito grisáceo con textura aterciopelada o algodonosa. Este "polvo gris" está formado por filamentos fúngicos (micelios) y grupos de esporas. Cuando este moho es visible, la infección está avanzada y liberando esporas al ambiente (GardenTech, 2017).

2.1.13. Diagnóstico Diferencial: Distinguiendo Botrytis de Otros Daños

Diferenciar correctamente es vital para evitar falsos positivos en modelos de IA, no todo daño visible es Botrytis, como se resumen en la **Tabla 2**.

Tabla 2

Diferencias entre Botrytis y otros daños

Característica	Botrytis cinérea	Daño Mecánico	Quemadura Solar	Fitotoxicidad
Forma	Puntea duras circulares (inicial); pudrición amorfa (avanzado)	Lineal, raspada o desgarro	Mancha amplia e irregular	Patrones geométricos, bordes definidos
Textura	Húmeda, blanda, acuosa	Seca, nítida	Seca, apergaminada	Seca o clorótica con bordes marcados
Progresión	Crece radialmente; ciclo completo en 3-4 días	Estática, no se propaga	Estática, solo deshidratación	Estática, no crece
Signo definitivo	Moho gris ceniza SIEMPRE presente en fase avanzada	Sin micelio	Sin micelio (excepto colonización secundaria)	Sin micelio

Nota. La tabla presenta una comparación diagnóstica entre *Botrytis cinérea* y otros tipos de daños en plantas, considerando características visuales, textura, progresión de la lesión y signos distintivos. Su

finalidad es facilitar la diferenciación fitosanitaria en campo entre enfermedades fúngicas, daños mecánicos, quemaduras solares y fitotoxicidad.

La textura es el diferenciador principal. La pudrición blanda y húmeda indica Botrytis, mientras que daños mecánicos o solares producen tejidos secos o apergaminados. La presencia de moho gris ceniza confirma definitivamente la infección.

2.1.14. La IA y la Visión por computadora en el Ecuador.

La adopción cada vez más presente de tecnologías como la Inteligencia Artificial, en especial medida a la Visión por Computador y el Aprendizaje Profundo, están permitiendo una transición de la agricultura convencional hacia una de precisión. El monitoreo en tiempo real de cultivos y la toma de decisiones de manera automática son herramientas cruciales para que agricultura en el Ecuador pueda mantener la competitividad y la calidad de la exportación (Chandra, 2025).

La visión por computadora es clave para automatizar en el contexto de que permite visualizar y analizar el entorno agrícola, para ello los modelos de Deep Learning que son entrenados con un gran volumen de imágenes diagnostican con precisión sectores que anteriormente dependiente exclusivamente de la revisión humana. Un claro ejemplo es que en la floricultura ornamental detecta con una precisión mayor al 90% las patologías como mildiu polvoriento, Botrytis, diferencias nutricionales que facilitan la intervención temprana y reducen las pérdidas de las cosechas (Chandra, 2025)

Desafíos de la Visión por Computador. La visión por computadora no solo se considera el análisis de imágenes estáticas, sino también el despliegue plataformas que permitan el monitoreo y la toma de acciones. Estas plataformas pueden ser dispositivos actuales como Vehículos aéreos no tripulados o robots terrestres que facilitan la recolección de información y junto con los algoritmos de Redes Neuronales Convolucionales (CNN)

permiten tener un rendimiento de clasificación alto incluso ante variación de condiciones como la intensidad de luz, color y condiciones geométricas de cultivos (*Robots Using Machine Vision Algorithms in Agriculture*, n.d.).

Aunque la navegación aérea de drones está tomando más terreno, la navegación terrestre en estos escenarios sigue manteniendo un grado de complejidad superior debido a diferentes obstáculos, desnivel del suelo y variaciones presentes en los terrenos agrícolas. Bajo estas consideraciones adicionalmente se busca generar algoritmos de procesamiento de imágenes más robustos que dotando de una ruta de navegación más confiable (Moreano et al., 2020).

Procesamiento y preparación de imágenes para el Deep Learning. La preparación y la calidad de los datos de entrada es tan importante como la arquitectura implementada en el modelo de Deep Learning. En la optimización del entrenamiento de las CNN y generar el modelo en las condiciones de campo variable que impone la floricultura, es requerido seguir una secuencia de estrategias para el preprocesamiento (Ashurov et al., 2025).

Entre las estrategias se encuentra el redimensionamiento de todas las imágenes, garantizando un tamaño de entrada consistente con la arquitectura de la CNN, la división para entrenamiento y validación, junto con la normalización de los valores dados de píxeles a un rango de valores uniforme. Esta uniformidad evita que aparezcan desequilibrios que podrían afectar la estabilidad del sistema CNN (Ashurov et al., 2025). El preprocesamiento deficiente puede afectar la capacidad del modelo en generalizar, siendo inestable en condiciones reales (Heck & Schouten, 2023)

2.1.15. Aplicación de la IA en el entorno agrícola.

La aplicación de modelos de IA está en una etapa de madurez avanzada a nivel global, en las que se emplea soluciones de alta precisión que involucra la sanidad del cultivo como el control de la calidad posterior a la cosecha.

Madurez tecnológica global en la Floricultura. A nivel global, la IA ha optimizado significativamente la gestión de la producción. En el estado de sanidad vegetal, los modelos de Deep Learning demuestran una precisiones de detección de enfermedades superiores al 90% en flores ornamentales, lo cual permite implementar estrategias de manejo proactivo y reducir drásticamente las pérdidas de cultivo (Chandra, 2025).

En el control de calidad postcosecha, el proceso de clasificación de la flor de corte basado en el estado de madurez ha sido revolucionado por el *Deep Learning* (Sun et al., 2021). Una contribución técnica crucial es la integración de la información de profundidad que es un método de clasificación propuesto que utiliza la fusión de imágenes RGB tradicionales y la información de profundidad, creando una entrada RGBD de cuatro dimensiones (4D) para la red neuronal convolucional (Sun et al., 2021). Esta información geométrica es esencial para determinar con precisión el estado de madurez del botón floral.

La comparación de diversas arquitecturas CNN (VGG16, ResNet18, MobileNetV2 e InceptionV3) demuestran que la adición de datos de profundidad mejora consistentemente la precisión de todos los modelos (Sun et al., 2021). Este fenómeno establece que las características geométricas, como el volumen o grosor del botón floral (una característica distintiva de la rosa ecuatoriana) (García-Cabezas et al., 2022), son determinantes clave de la calidad. El modelo que alcanzó la máxima precisión fue la red InceptionV3 ajustada, la cual, utilizando la entrada RGBD, logró una precisión de clasificación de 98.44%, lo que subraya

la importancia de los sensores 3D en la infraestructura de clasificación de alta precisión (Sun et al., 2021).

Floricultura ecuatoriana, contexto y limitaciones. El sector florícola es uno de los motores económicos para Ecuador, es el 1% al Producto Interno Bruto (PIB) nacional y el 11% en torno al PIB agrícola. En el cierre del 2024 los ingresos por exportación superaron los \$747 millones, abarcando cerca del 4% de las exportaciones no petroleras del país (mruiz, 2025b). El punto diferencial de Ecuador en el mercado internacional se basa en la calidad intrínseca de sus rosas, caracterizadas por el grosor del botón, la robustez del tallo y una durabilidad prolongada, que puede alcanzar hasta 20 días después de la cosecha (García-Cabezas et al., 2022). Estos atributos hacen que el 70% de la producción se dirija a mercados de alta exigencia como Rusia, Estados Unidos y la Unión Europea (mruiz, 2025b).

Proyectos de Investigación y Desarrollo en Ecuador. Ecuador ha comenzado a establecer soluciones locales de Inteligencia Artificial y Visión por Computador enfocadas al entorno florícola. Uno de ellos es el Grupo de Investigación en Telecomunicaciones y Temática (GITEL) de la Universidad Politécnica Salesiana (UPS) que lidera el proyecto SISMO-ROSAS, centrado en optimizar el ciclo productivo de las rosas. Ejecutado en Cuenca y Déleg en conjunto con la florícola FLORLAGO, incluyen el desarrollo de un sistema automatizado de conteo de rosas basado en procesamiento de imágenes (Jachero & David, 2023; mruiz, 2025b). Este algoritmo de conteo emplea técnicas de binarización y filtrado de imágenes para la determinación precisa del inventario (Jachero & David, 2023). Además, permite la medición multivariable para monitorear el estado nutricional y climático del suelo y ambiente, y explora la aplicación de inteligencia artificial generativa (mruiz, 2025b).

Otro enfoque de investigación local es el liderado por GRICAM y DASTIC de la UPS, se centrado en la sostenibilidad. La adopción de la agricultura de precisión habilitada

por Visión por Computador está proyectada para reducir el uso de plaguicidas peligrosos entre un 30% y un 50% en las fincas intervenidas (mruiz, 2025a). Esta transición no solo ofrece beneficios ambientales y de salud, sino que también tiene una causalidad económica directa debido a que la reducción de costos en insumos, que pueden representar hasta el 40% del gasto total en la floricultura familiar, proporciona un Retorno de Inversión (ROI) tangible y acelerado para la adopción de VC (mruiz, 2025a).

En la Tabla 3, se muestra algunas aplicaciones desarrolladas aplicando la IA tanto en la producción florícola en el Ecuador y en el entorno Internacional.

Tabla 3
Aplicaciones de la IA en la producción Florícola Global y Local

Aplicación	Tarea Específica	Tecnología	Precisión	Beneficio	Estudio
		Principal	Típica	Estratégico	
Detección de Enfermedades	Identificación de	Deep Learning	>90%	Intervención	(Chandra, 2025)
	Mildiu, Botrytis, Deficiencias	(CNN)		temprana, reducción de pérdidas.	
Control de Calidad	Clasificación de	CNN con	Hasta	Estandarización	(Sun et al., 2021)
	Madurez del Botón Floral	Fusión RGBD (4D)	98.44%	de calidad de exportación y diferenciación.	
Monitoreo e Inventario	Conteo Automatizado de Rosas	Procesamiento de Imágenes/Machine Learning	Prototipo funcional	Optimización de tiempo y recursos,	(Jachero & David, 2023;

planificación	mruiz,
logística.	2025a)

Nota. La tabla resume aplicaciones de la inteligencia artificial en la producción florícola a nivel global y local, indicando tareas específicas, tecnologías empleadas, niveles de precisión reportados y beneficios estratégicos en los procesos productivos. Las referencias de cada estudio se encuentran señaladas en la última columna.

2.1.16. Arquitectura de Sistemas de Agricultura de Precisión

Para la implementación de la IA se requiere una arquitectura de sistema robusta y adaptable. La Agricultura de Precisión es un término agronómico basado en la variabilidad en campo que se estructura en ciertas etapas clave: recolección de datos, procesamiento y toma de decisiones (Vivas et al., 2016).

Infraestructura Digital y Manejo de Datos. Los sistemas de Agricultura de Precisión incorporan un conjunto de sensores instalados en las zonas de cultivo para monitorizar variables ambientales y del suelo, que permite alimentar modelos de riego y fertilización. La arquitectura requiere soluciones de almacenamiento que contemplen la variabilidad espacio temporal de los componentes (zonas, cultivos, sectores de irrigación). Por ejemplo, el almacenamiento en bases de datos NoSQL como MongoDB para gestionar la naturaleza cambiante y heterogénea de estos datos, los cuales son complementados con información de otras fuentes, como servicios meteorológicos o análisis de suelo (*Arquitectura Software Basada En Tecnologías Smart Para Agricultura de Precisión*, n.d.).

Control de Calidad (QC) y Contextualización. Un proceso esencial para la toma de decisiones en PA es el control de calidad de los datos recolectados. Para garantizar la precisión, es necesario que este control de calidad utilice la información de contexto del

sistema de adquisición de datos y del medio ambiente. Este enfoque permite que el sistema "comprenda" las situaciones de su entorno, mejorando la calidad de los datos para que las decisiones subsiguientes sean robustas (Vivas et al., 2016).

2.1.17. Análisis de Modelos de Deep Learning

La selección de la arquitectura de Deep Learning es crucial y depende del propósito, este ya sea priorizar la precisión del diagnóstico o la velocidad para la automatización en tiempo real.

Arquitecturas Clásicas de Clasificación. Las Redes Neuronales Convolucionales (CNN) tradicionales como ResNet y VGG han sido fundamentales en procesos de clasificación de imágenes (Acenjo et al., 2023). En el entorno agrícola, la elección entre estas arquitecturas implica una compensación directa entre la máxima precisión y la eficiencia computacional.

Un estudio comparativo en el diagnóstico de enfermedades foliares en cultivos de maíz reveló esta disyuntiva (Ruiz et al., 2024):

- La red ResNet-50 demostró una capacidad superior de clasificación, alcanzando una precisión del 95% (Ruiz et al., 2024).
- La red MobileNet-v2 logró una precisión favorable del 90% en la clasificación correcta de enfermedades (Ruiz et al., 2024).

Aunque ResNet-50 tiene una precisión máxima, MobileNet-v2 destaca por brindar un menor consumo computacional (Ruiz et al., 2024). Esto es de vital importancia en la floricultura, donde los sistemas rápidos son necesarios para manejar el alto volumen y la rotación de la producción. Por lo tanto, mientras que ResNet podría ser la opción predilecta para la toma de decisiones críticas y menos urgentes, arquitecturas más ligeras o

especializadas en tiempo real (como MobileNet o YOLO) son preferibles para procesos de producción que requieren velocidad de inferencia, como la cosecha o el conteo automatizado.

Modelos de Detección de Objetos en Tiempo Real. Para las tareas que requieren no solo clasificar, sino también localizar objetos específicos (detección de cabezas florales, botones, defectos) en un flujo continuo, los modelos de Detección de Objetos en Tiempo Real son indispensables. La familia YOLO “You Only Look Once” tiene la capacidad para detectar objetos rápidamente con alta precisión y un mínimo de errores de fondo (*Explicación de la detección de objetos YOLO*, 2024).

En la floricultura, la evolución de esta familia es clave. Estudios recientes en Ecuador demuestran que, al experimentar con YOLOv5, YOLOv7 y YOLOv8, la versión YOLOv8 fue seleccionada consistentemente por su rendimiento superior en precisión y velocidad sobre sus predecesores. YOLOv8 ofrece la ventaja arquitectónica de implementar capacidades de *tracking* nativas, facilitando el seguimiento de objetos, lo cual es esencial para el conteo de inventario y la gestión dinámica de la cosecha (Amaguaya, 2024).

Métricas de Rendimiento Clave. Para evaluar el rendimiento de los modelos de detección de objetos como YOLO, las métricas no deben solo cumplir un simple *Accuracy* (precisión de clasificación). La métrica de mAP (mean Average Precision) es la métrica fundamental para evaluar la detección de objetos, ya que cuantifica la capacidad del modelo no solo para clasificar correctamente el objeto, sino también para localizarlo espacialmente dentro de la imagen (*mAP, «precisión promedio media», métrica clave en la IA*, 2024).

El uso del mAP permite una comparación detallada entre diferentes algoritmos identificando qué algoritmos ofrecen el mejor rendimiento en tareas complejas, permitiendo la optimización de los modelos para obtener la máxima eficiencia operativa. Puede adaptarse incluso adaptarse para ponderar de manera diferente los requisitos específicos de una

aplicación, demostrando su adaptabilidad en la agricultura de precisión (*mAP*, «*precisión promedio media*», *métrica clave en la IA*, 2024).

En la **Tabla 4** se presenta un resumen de la comparativa de arquitecturas de *Deep Learning* en tareas agrícolas y florícolas, destacando las ventajas operacionales según la aplicación:

Tabla 4
Arquitectura de Deep Learning en tareas Agrícolas y Florícolas

Modelo/Arquitectura	Tipo de Tarea	Métrica Clave y Rendimiento Reportado	Consideración Operacional	Contexto de Uso (Floricultura/Agro)	Estudio
ResNet-50	Clasificación	95% Precisión (Diagnosis foliar)	Alto Costo Computacional, Máxima Exactitud	Diagnosis de Enfermedades ¹²	(Ruiz et al., 2024)
MobileNet-v2	Clasificación (Ligera)	90% Precisión (Diagnosis foliar)	Bajo Desgaste Computacional, Velocidad	Aplicaciones Edge/Móviles ¹²	(Ruiz et al., 2024)
YOLOv5	Detección de Objetos, Localización 3D	Detección 2D efectiva	Adecuado para Robótica y Conteo en Tiempo Real	Cosecha Robótica, Conteo en Ecuador ¹⁷	(Taddei Dalla Torre et al., 2024)
YOLOv8	Detección de Objetos, Tracking	Superior a v5 y v7 en precisión y velocidad	Implementación de Seguimiento (Tracking) nativo	Detección de Calidad de Rosas ¹⁵	(Amaguaya, 2024)

SAM (Zero-Shot)	Segmentación, Estimación de Pose	Prometedor en Localización 3D	Alto rendimiento sin reentrenamiento específico	Robótica de Cosecha (Eslabón de Segmentación) ¹⁷	(Taddei Dalla Torre et al., 2024)
------------------------	--	--	--	---	---

Nota. La tabla presenta una comparación de arquitecturas de *deep learning* utilizadas en tareas agrícolas y florícolas, considerando tipo de tarea, métricas de rendimiento, requerimientos computacionales, contexto de uso y estudios de referencia. Su propósito es identificar modelos adecuados según la aplicación, nivel de precisión y condiciones operativas. Las fuentes de información se indican en la última columna.

2.2. Marco Teórico

2.2.1. Sistemas Backend en Aplicaciones de Inteligencia Artificial

En las arquitecturas actuales de software, el backend representa la capa encargada del procesamiento central para la gestión de datos y la ejecución de la lógica de la aplicación, la cual, combinada con inteligencia artificial, la capa adquiere un rol aún más crítico, ya que es responsable de la carga, ejecución y optimización de modelos de aprendizaje automático y profundo (Amershi et al., 2019).

En sistemas de visión por computador, el backend actúa como intermediario entre la captura de imágenes y la generación de inferencias automatizadas. Su función principal consiste en recibir datos visuales, aplicar procesos de preprocesamiento, ejecutar modelos entrenados y devolver resultados estructurados que puedan ser interpretados por aplicaciones predefinidas (Goodfellow et al., 2016).

Fig. 3***Modelos de IA - Sistemas Backend***

Nota. Ilustración conceptual de modelos de inteligencia artificial integrados con sistemas *backend*. Elaboración propia con apoyo de herramientas de inteligencia artificial (IA).

2.2.1.1. APIs REST como Mecanismo de Comunicación. Las APIs REST (Representational State Transfer) constituye uno de los estilos arquitectónicos más utilizados para la comunicación entre sistemas distribuidos, donde REST se basa en principios como la comunicación sin estado (stateless), la separación cliente-servidor y el uso de identificadores uniformes de recursos (Fielding, 2000).

En aplicaciones de inteligencia artificial, las APIs REST permiten desacoplar el modelo de inferencia del cliente que lo consume, facilitando la escalabilidad, el mantenimiento y la reutilización del sistema, mediante el uso del formato JSON como medio de intercambio de datos proporciona ligereza, legibilidad y compatibilidad con múltiples plataformas, incluyendo aplicaciones web y móviles (Bray, 2014).

Fig. 4*API REST - Mecanismo de Comunicación*

Nota. Ilustración conceptual del funcionamiento de una API REST, mostrando el intercambio de solicitudes GET y POST y el uso de formato JSON para la comunicación entre cliente y servidor. Elaboración propia asistida por herramientas de inteligencia artificial.

2.2.2. Python como Lenguaje Dominante en Inteligencia Artificial

Python se ha consolidado como el lenguaje predominante en el desarrollo de sistemas de inteligencia artificial debido a su simplicidad sintáctica, su comunidad activa y su extenso ecosistema de librerías especializadas, el facilitando el desarrollo de aplicaciones en menor tiempo y optimizando recursos (Van Rossum & Drake, 1995).

Los Frameworks como PyTorch, TensorFlow y Ultralytics han permitido reducir significativamente la complejidad de implementar modelos de Deep Learning, facilitando tanto el entrenamiento como la inferencia. Además, Python se integra fácilmente con frameworks backend modernos como FastAPI (Van Rossum & Drake, 1995).

2.2.3. Deep Learning y Redes Neuronales Convolucionales

El Deep Learning es una subdisciplina del aprendizaje automático basada en redes neuronales profundas capaces de aprender representaciones jerárquicas de los datos. En el caso del análisis de imágenes, las redes neuronales convolucionales (CNN) han demostrado un desempeño superior frente a técnicas tradicionales (LeCun et al., 2015).

Las CNN utilizan capas convolucionales que permiten detectar patrones locales como bordes, texturas y formas, los cuales se combinan progresivamente para identificar estructuras complejas. Esta capacidad resulta fundamental para el análisis de imágenes agrícolas, donde las enfermedades presentan variaciones visuales sutiles y no homogéneas en las rosas (Mohanty et al., 2016a).

Fig. 5

Deep Learning en la Agricultura



Nota. Ilustración conceptual del uso de redes neuronales convolucionales (*convolutional neural networks, CNN*) aplicadas al análisis agrícola mediante *deep learning*. Elaboración propia asistida por herramientas de inteligencia artificial.

2.2.4. Aplicación del Deep Learning en la Agricultura de Precisión

La agricultura de precisión busca día a día optimizar el uso de recursos mediante la toma de decisiones basada en datos. En este contexto, el Deep Learning ha permitido


automatizar tareas como la detección de plagas, enfermedades y estrés vegetal a partir de imágenes capturadas en campo (Mohanty et al., 2016b).

En particular, las enfermedades fúngicas representan un desafío significativo debido a su rápida propagación y a la dificultad de detección en etapas tempranas. La Botrytis cinerea, conocida como moho gris, es un hongo que afecta cultivos ornamentales como las rosas, generando pérdidas económicas considerables si no se detecta a tiempo para combatir la plaga (Williamson, 2007).

2.2.5. Clasificación de Imágenes vs. Detección de Objetos

En visión por computador, la clasificación de imágenes consiste en asignar una única etiqueta a toda la imagen. Aunque este enfoque ha sido ampliamente utilizado, presenta limitaciones cuando el objeto de interés ocupa solo una pequeña región de la imagen (Krizhevsky et al., 2012).

Por el contrario, la detección de objetos permite identificar múltiples instancias dentro de una imagen y localizar su posición mediante cajas delimitadoras. Este enfoque resulta especialmente adecuado para la detección de enfermedades vegetales localizadas, como manchas fúngicas, ya que proporciona información espacial relevante para la toma de decisiones agronómicas (Redmon et al., 2016).

Fig. 6*Clasificación vs Detección de Objetos*

Nota. Ilustración conceptual que compara los enfoques de clasificación de imágenes y detección de objetos en visión por computador, destacando la diferencia entre asignar una categoría global y localizar múltiples objetos dentro de una escena. Elaboración propia asistida por herramientas de inteligencia artificial.

2.2.6. Modelos YOLO y Detección en Tiempo Real

YOLO (You Only Look Once) es una familia de modelos de detección de objetos caracterizada por realizar la detección en una sola pasada por la red neuronal. Esta arquitectura unificada permite alcanzar velocidades de inferencia en tiempo real, lo que resulta fundamental para aplicaciones interactivas (Redmon et al., 2016).


2.2.6.1. Evolución Arquitectónica hacia YOLOv8. YOLOv8 introduce mejoras significativas respecto a versiones anteriores, incluyendo detección anchor-free, en la cual se optimiza las funciones de pérdida y una arquitectura más eficiente. Estas innovaciones permiten mejorar la precisión sin sacrificar la velocidad de detección, posicionando a

YOLOv8 como una solución de estado del arte (*Explore Ultralytics YOLOv8 - Ultralytics YOLO Docs*, 2023).

2.2.6.2. Justificación del Uso de YOLOv8 Medium. La elección de la variante YOLOv8 Medium responde a la necesidad de equilibrar capacidad de aprendizaje y eficiencia computacional. La detección de Botrytis cinerea requiere identificar texturas complejas y manchas de pequeño tamaño en las rosas, lo que demanda una red con suficiente profundidad para capturar estas características sin incurrir en sobreajuste o latencias excesivas (*Explore Ultralytics YOLOv8 - Ultralytics YOLO Docs*, 2023).

Fig. 7

Yolo v8



Nota. Ilustración conceptual del modelo YOLOv8 para detección de objetos en tiempo real.

Elaboración propia asistida por herramientas de inteligencia artificial.

2.2.7. Preparación, Anotación y Calidad de los Datos


El rendimiento de un modelo de Deep Learning está directamente relacionado con la calidad del conjunto de datos utilizado para su entrenamiento. Los datos mal detectados o poco representativos pueden introducir sesgos y degradar significativamente la capacidad de generalización del modelo (Shorten & Khoshgoftaar, 2019).

La anotación mediante cajas delimitadoras define explícitamente las regiones relevantes, permitiendo al modelo aprender la correspondencia entre patrones visuales y

clases objetivo, donde las herramientas especializadas como Roboflow facilitan este proceso, asegurando la consistencia de la información y reduciendo los errores humanos (Brad Dwyer, 2021).

Fig. 8

Calidad de datos



Nota. Ilustración conceptual sobre la calidad de datos en visión por computador, mostrando diferencias en resolución y claridad de imágenes. Elaboración propia asistida por herramientas de inteligencia artificial.

Roboflow es una plataforma orientada a la gestión integral de datasets para tareas de visión por computador, que facilita la anotación de imágenes, el control de versiones de los conjuntos de datos y la aplicación de técnicas de preprocesamiento y aumento de datos (data augmentation) de forma estructurada (Brad Dwyer, 2021).

2.2.8. Aumentación de Datos como Estrategia de Generalización

La aumentación de datos consiste en aplicar transformaciones artificiales a las imágenes originales para generar nuevas muestras de entrenamiento. Estas técnicas permiten simular variaciones del mundo real y reducir el sobreajuste del modelo para mejorar su eficacia (Wang & Perez, 2017).

Las transformaciones como escala de grises, ajustes de brillo, saturación, exposición y transformaciones geométricas, obligan al modelo a aprender características invariantes como texturas y formas, en lugar de depender solo de condiciones específicas de las capturas (Heaton, 2018; Shorten & Khoshgoftaar, 2019).

En el contexto de Botrytis cinerea, la eliminación parcial de la información cromática resulta especialmente relevante, ya que el hongo presenta una textura característica independientemente del color de la rosa (Arnal Barbedo, 2019).

2.2.9. Entrenamiento de Redes Neuronales y Uso de GPU

El entrenamiento de modelos profundos implica operaciones matemáticas intensivas, principalmente con la utilización de multiplicaciones de matrices, es por ello que las Unidades de Procesamiento Gráfico (GPU) están optimizadas para este tipo de operaciones paralelas, reduciendo significativamente los tiempos de entrenamiento y optimización de los recursos (Sanders & Kandrot, 2010).

Fig. 9

Etiquetado de datos



Nota. Ilustración conceptual del proceso de etiquetado de datos en visión por computador para el entrenamiento de modelos de detección de objetos. Elaboración propia asistida por herramientas de inteligencia artificial.

El uso de plataformas en la nube como Google Colab democratiza el acceso a recursos computacionales avanzados, permitiendo entrenar modelos complejos sin necesidad de una infraestructura local, especializada para este tipo de aplicaciones (Bisong, 2019).

2.2.10. FastAPI como Infraestructura de Inferencia

FastAPI es un framework moderno para la creación de APIs en Python, diseñado para alto rendimiento y validación automática de datos. Su compatibilidad con ASGI permite manejar múltiples solicitudes concurrentes, lo que resulta esencial para servicios de inferencia en tiempo real (Ramírez, 2020).

La estrategia de cargar el modelo en memoria durante el arranque del servidor reduce la latencia y mejora la experiencia del usuario, siendo una práctica recomendada en sistemas productivos de inteligencia artificial en tiempo (Amershi et al., 2019).

Capítulo 3:

3. Desarrollo

3.1.Arquitectura general del sistema

El sistema funciona con una arquitectura cliente-servidor bastante estándar. Cuando un usuario abre la aplicación en su navegador, puede subir una foto de una rosa que será enviada al servidor backend a través de una petición POST. Una vez que el servidor recibe la imagen, la pasa por el modelo de inteligencia artificial entrenado y regresa la respuesta en

JSON. Esta respuesta básicamente dice si encontró o no Botrytis en la flor, qué tan seguro está el modelo de ese resultado, y exactamente en qué parte de la imagen detectó el problema.

Esta separación tiene sus ventajas. El trabajo pesado de correr el modelo de deep learning necesita bastante poder de cómputo, algo que no todos los dispositivos tienen. Al dejar esa parte en el servidor, el celular o computadora del usuario solo tiene que encargarse de mostrar la interfaz y mandar las fotos. Otro beneficio importante es que, si después se entrena una versión mejorada del modelo, solo hay que actualizarla en el servidor sin tocar para nada la aplicación que usa el cliente.

3.2.Desarrollo del modelo de inteligencia artificial

3.2.1. Selección del Modelo: YOLOv8

Escoger el modelo adecuado fue probablemente la decisión más crítica de todo el proyecto. Al principio se consideraron opciones como ResNet o EfficientNet, que son arquitecturas bastante populares cuando se trata de clasificar imágenes. Pero después de revisar cómo se comporta realmente la Botrytis en las rosas, quedó claro que lo mejor era usar YOLOv8 Medium de Ultralytics.

El asunto es que la Botrytis no infecta la flor de manera uniforme. Lo que sucede es que en las primeras etapas aparecen manchas pequeñas en partes específicas de los pétalos. Un clasificador tradicional simplemente indica "sí hay Botrytis" o "no hay Botrytis" en la imagen completa, pero si la mancha es reducida y el resto de la rosa se ve sana, puede que ni siquiera la detecte. YOLO funciona de manera diferente: no solo identifica si hay presencia de la enfermedad, sino que marca exactamente dónde está, delimitando con cajas las zonas infectadas. Esto hace la diferencia cuando se busca detectar la enfermedad en etapas tempranas, antes de que se disemine por toda la flor.

Además, YOLO tiene otra ventaja importante: es muy rápido. Analiza la imagen completa en una sola pasada, mientras que otros detectores más antiguos necesitan hacer el trabajo en dos etapas. Esto significa que la aplicación web puede dar respuestas casi instantáneas, en cuestión de milisegundos. También deja abierta la posibilidad de desarrollar después una versión móvil que funcione en tiempo real directamente en el invernadero.

Se eligió específicamente la variante Medium (yolov8m.pt) porque las lesiones que deja la Botrytis son bastante sutiles y varían dependiendo del color de la rosa. Se necesitaba una red con suficiente capacidad para captar esos detalles finos sin confundirlos con daños mecánicos o con manchas de otros hongos que también afectan las rosas.

3.2.2. Preparación y etiquetado de datos (Roboflow)

Para gestionar el dataset se decidió trabajar con Roboflow. Esta plataforma facilita el etiquetado visual de las imágenes, permitiendo marcar con cajas delimitadoras las áreas infectadas y asignarles la clasificación correspondiente: healthy_rose para rosas sanas o botrytis_rose para las infectadas. Una de las principales ventajas de usar Roboflow es que asegura que las coordenadas de estas cajas queden registradas con precisión y en el formato exacto que requiere YOLOv8, evitando así los errores típicos que suelen ocurrir cuando se hace la conversión de forma manual (Ultralytics, 2023).

Otra característica útil de la herramienta son sus validaciones automáticas. Antes de arrancar con el entrenamiento, el sistema revisa que no haya problemas como cajas superpuestas entre sí o etiquetas que no coincidan, lo que termina ahorrando bastante tiempo que de otra forma se perdería corrigiendo errores durante la depuración del modelo.

3.2.3. Estrategias de aumentación de datos

El desafío más grande fue la limitación en la cantidad de fotos de rosas enfermas disponibles. Conseguir ese volumen de imágenes en invernaderos reales habría tomado

meses. Para solucionar esto se aplicaron técnicas de aumentación de datos en Roboflow, que básicamente crean variaciones de las fotos originales, y adicionalmente a esto, se creó 3 scripts para generar imágenes de rosas con signos de botritis Anexo B, imágenes de rosas sanas sin ningún tipo de lesiones Anexo A e imágenes de rosas con danos mecánicos Anexo C las cuales se les puede considerar rosa sana dependiendo el nivel de daño que muestren.

Las transformaciones utilizadas en Roboflow tienen toda una justificación técnica:

Escala de grises (15% de las imágenes). Las rosas vienen en muchos colores, pero la Botrytis se manifiesta diferente según el cultivar. Al eliminar el color en algunas fotos se obliga al modelo a enfocarse en texturas y formas, no solo en colores. Así el modelo puede detectar el hongo incluso en variedades que no vio durante el entrenamiento.

Saturación (-25% a +25%). Los dispositivos móviles procesan los colores de manera diferente. Algunos exageran los rojos, otros los dejan pálidos. Con esta variación el modelo aprende a reconocer la enfermedad sin importar cómo sature los colores el dispositivo del usuario.

Exposición (-15% a +15%). En el invernadero la luz cambia constantemente. Puede haber sombras fuertes o sol directo. Esta técnica simula esas condiciones para que el modelo no confunda una sombra con una mancha real.

Rotaciones y volteos. Permiten que la detección funcione, aunque el usuario tome la foto inclinada o desde cualquier ángulo.

Brillo variable. Maneja las diferencias entre días nublados versus soleados.

Con estas técnicas se convirtieron unas 40 imágenes originales en más de 120 variaciones, triplicando efectivamente el dataset sin necesidad de captura adicional en campo, los parámetros para la aumentación de datos se indica en **Tabla 5**.

Tabla 5*Parámetros de aumentación de datos aplicados*

Técnica	Parámetros	Justificación
Escala de Grises	15% de imágenes	Aprendizaje de texturas independiente del color
Saturación	-25% a +25%	Compensar diferencias entre dispositivos
Exposición	-15% a +15%	Adaptación a luz variable en invernadero
Rotación	90° horaria/antihoraria	Detección desde cualquier ángulo
Volteo	ACTi Vado	Invarianza a orientación de imagen
Horizontal		
Brillo	Variación sutil	Robustez ante cambios de luz natural
Desenfoque	Hasta 2.5px	Simulación de diferentes calidades de cámara
Ruido	Hasta 0.1% pixels	Simulación de compresión de imagen

Nota. La tabla describe técnicas de aumento de datos (*data augmentation*) aplicadas al conjunto de imágenes, especificando los parámetros utilizados y la justificación de cada transformación para mejorar la robustez del modelo ante variaciones de iluminación, orientación, calidad de imagen y condiciones de captura. Elaboración propia.

Por otro lado, las consideraciones técnicas usadas para generar fotografías de rosas con botritis, rosas sanas y rosas con danos mecánicos son indicadas en Tabla 6 ,Tabla 6, Tabla 8 respectivamente:

Tabla 6

Parámetros para generación de imágenes con botritis

Parámetro	Especificación	Justificación
Modelo	imagen-3.0-generate-002	Versión avanzada de Vertex AI con seguimiento detallado de instrucciones
Relación de aspecto	1:1	Estandarización para procesamiento del modelo de detección
Variedades	6 cultivares: Vendela, Explorer, St. Patrick, Movie Star, Peach, Rosa	Diversidad cromática representativa de cultivos ecuatorianos
Etapas de floración	4 etapas (0-100% apertura)	Refleja ciclo de infecciones latentes durante desarrollo floral
Ángulos de cámara	3 perspectivas (frontal, 30°, cenital)	Simula variabilidad de captura por usuarios en campo
Características de síntomas	Lesiones circulares < 0.3mm, 3-7 marcas/flor, superficie seca y mate	Infección temprana pre-esporulación, cuando intervención es efectiva
Textura especificada	Pigmentación plana, NO brillante, NO húmeda	Evita confusión del modelo con gotas de agua o artefactos

Prompt negativo	Agua, gotas, brillo, elementos 3D, estambres (etapas tempranas)	Previene artefactos no representativos de Botrytis real
Iluminación	Macro 8K, difusión suave tipo invernadero	Claridad para detectar lesiones milimétricas.
Control de tasa	60 seg. cada 2 imágenes	Cumplimiento de límites API Vertex AI

Nota. La tabla presenta los parámetros utilizados para la generación controlada de imágenes sintéticas destinadas al entrenamiento del modelo de detección, incluyendo configuraciones del modelo, condiciones visuales y características sintomáticas simuladas.

Tabla 7

Parámetros para generación de imágenes sanas, sin ningún tipo de lesión

Parámetro	Especificación	Justificación
Modelo	imagen-3.0-generate-002	Consistencia con categoría Botrytis
Relación de aspecto	1:1	Coherencia entre todas las categorías
Variedades	12 cultivares (incluye Vendela, Explorer, Freedom, Lemon Yellow, Hot Pink, Lavender, Coral, etc.)	Mayor diversidad cromática para robustez ante variedades no vistas

Etapas de floración	6 etapas (0-100% con mayor granularidad)	Representación completa del ciclo comercial
Ángulos de cámara	25+ perspectivas (frontales, angulados, cenitales, perfiles, con/sin tallo 0-10cm)	Máxima variabilidad para robustez ante condiciones reales
Estado del espécimen	Condición prístina: CERO daños, manchas o imperfecciones	Establece estándar de clase negativa con contraste claro
Fondos	5 tipos rotados (campo, invernadero, cultivo controlado, espacio floral, neutro)	Diversidad de contextos de captura
Prompt negativo	Cualquier daño, Botrytis, moho, lesiones, decoloración, marchitamiento	Garantiza ausencia total de síntomas
Énfasis en perfección	Múltiples capas enfatizando "PERFECTO", "INMACULADO", "CALIDAD MUSEO"	Asegura especímenes ideales sin defectos malinterpretables
Control de tasa	60 seg. cada 2 imágenes	Cumplimiento de límites API Vertex AI

Nota. La tabla resume los parámetros definidos para la generación controlada de imágenes sintéticas correspondientes a la clase negativa, estableciendo condiciones de espécimen prístino, diversidad de cultivares, variabilidad de captura y restricciones de generación para garantizar muestras libres de síntomas y adecuadas para el entrenamiento del modelo de detección.

Tabla 8*Parámetros para generación de imágenes sanas, pero con ligeras lesiones mecánicas*

Parámetro	Especificación	Justificación
Modelo	imagen-3.0-generate-002	Consistencia entre categorías
Relación de aspecto	1:1	Formato estándar
Variedades	6 cultivares (iguales a Botrytis)	Comparación directa con clase positiva
Etapas de floración	4 etapas (iguales a Botrytis)	Consistencia con clase positiva
Ángulos de cámara	7 perspectivas intermedias	Variabilidad media entre Botrytis (3) y sanas (25+)
Tipos de daño	3 categorías abióticas:	Entrenamiento para reducir falsos positivos
1. Thrips	Estrías plateado-blanquecinas lineales, patrón de rayaduras paralelas	Daño lineal (NO circular) distinguible de Botrytis
2. Química	Manchas con bordes afilados y geométricos de residuos	Bordes definidos (NO halos difusos) vs. infección fúngica
3. Mecánica	Un área de magulladura/desgarro con patrón direccional	Daño direccional único (NO múltiple, NO circular)
Cantidad de daño	1-2 marcas máximo, < 5% superficie, 95%+ pétalos perfectos	Daño mínimo realista que podría confundirse con Botrytis temprana

Textura	Completamente seca, sin brillo ni humedad	Consistencia con daños abióticos reales
Prompt negativo	Botrytis, moho, manchas circulares, halos difusos, 3+ marcas, daño extenso	Asegura daño claramente abiótico y mínimo
Control de tasa	60 seg. cada 2 imágenes	Cumplimiento de límites API Vertex AI

Nota. La tabla presenta los parámetros definidos para la generación de imágenes sintéticas con daños abióticos, describiendo tipos de daño, nivel de afectación, condiciones visuales y restricciones de generación, con el fin de entrenar al modelo para diferenciar lesiones no fúngicas y reducir falsos positivos en la detección de Botrytis.

3.2.4. Entrenamiento del Modelo

Se diseñó un flujo de trabajo híbrido para el entrenamiento. La mayor parte se realizó en Google Colab con GPU Tesla T4, ya que entrenar YOLOv8 Medium localmente habría consumido varias horas. Con la GPU de Colab el tiempo se redujo a minutos. Se creó un notebook (Botrytis_training.ipynb) que descarga el dataset, instala las dependencias necesarias y ejecuta 100 épocas de entrenamiento de forma automática.

Adicionalmente, se desarrollaron scripts locales en Python (train_yolo.py) para no depender completamente de servicios en la nube. Este script detecta automáticamente cómo está organizado el dataset, genera el archivo data.yaml con las rutas correctas, y puede dividir los datos en entrenamiento y validación si es necesario.

Al final del proceso, ya sea en Colab o localmente, se obtiene el archivo `best.pt` que contiene todos los pesos de la red neuronal entrenada. Este archivo representa el "conocimiento" adquirido por el sistema para detectar Botrytis

3.3.Implementación del Backend

3.3.1. *Framework FastAPI*

Para el servidor se seleccionó FastAPI, un framework de Python reconocido por su alto rendimiento. Está construido sobre ASGI, alcanzando velocidades comparables a frameworks en lenguajes compilados como Go (*FastAPI*, 2025). Esta característica es crucial cuando se necesita procesar múltiples peticiones simultáneas sin degradación del rendimiento.

Adicionalmente, FastAPI incluye validación automática de datos con Pydantic. Los tipos de datos se validan automáticamente y cuando llega información incorrecta se generan errores claros, sin necesidad de escribir código de validación manual.

3.3.2. *Diseño del Endpoint de análisis*

El servidor expone un endpoint POST `/analyze` implementado en el archivo `main.py`. El aspecto crítico del diseño es que el modelo YOLO se carga en memoria una sola vez cuando arranca el servidor, no en cada petición individual. Cargar el modelo desde disco consume varios segundos, y si esto ocurriera en cada petición, el usuario experimentaría tiempos de espera inaceptables. Al cargarlo una vez y mantenerlo en RAM, las peticiones subsecuentes acceden inmediatamente al modelo y responden en milisegundos.

El flujo de procesamiento es directo: llega la imagen, se procesa con el modelo aplicando un umbral de confianza del 40% para filtrar detecciones débiles, y los resultados

(tensores numéricos) se transforman en un JSON legible con las coordenadas de las cajas, la clase detectada y el porcentaje de confianza.

3.3.3. Estructura de la Respuesta

El JSON de respuesta incluye el estado general (detectado o no detectado), el nivel de confianza global, y un array con todas las detecciones encontradas. Cada detección incluye sus coordenadas espaciales y clasificación correspondiente. Esta estructura permite que el frontend muestre alertas apropiadas, visualice las áreas infectadas, o sugiera acciones según el diagnóstico recibido, la estructura de esta respuesta se muestra en Fig. 10.

Fig. 10


Estructura de respuesta de detección de botritis

```
{
  "status": "string ('infected' | 'uninfected')",
  "message": "string ('ALERT: Botrytis detected in the rose.' |
    'No signs of Botrytis detected in the rose.')",
  "total_detections": "integer (número de lesiones detectadas)",
  "detections": [
    {
      "box": "array [x1, y1, x2, y2]
        (coordenadas del bounding box)",
      "label": "string ('botrytis_rose' | 'uninfected_rose')",
      "confidence": "float (0.0 - 1.0,
        nivel de confianza de la detección)",
      "is_infected": "boolean (true | false)"
    }
  ]
}
```

3.3.4. Flujo de procesamiento de petición

El procesamiento de imágenes se ejecuta mediante un endpoint POST /analyze que, valida el archivo recibido, lo transforma a formato RGB y ejecuta la inferencia con YOLOv8. El sistema descarta automáticamente detecciones con menos del 40% de confianza y aplica

una lógica de prioridad de riesgo: basta encontrar una sola rosa infectada para activar la alerta de Botrytis. La Fig. 11 detalla este flujo de validación y respuesta.

Fig. 11*Diagrama de procesamiento de peticiones*

3.4.Desarrollo del Frontend

3.4.1. Framework de Estilo (Bulma)

Para los estilos se utilizó Bulma, una librería "pure CSS" que no incluye JavaScript propio. Esta característica elimina potenciales conflictos con bibliotecas modernas como React o Vue, que eran opciones consideradas durante la planificación inicial (*Bulma*, 2025). Bulma es liviano y se integra fácilmente en cualquier proyecto de desarrollo moderno.

El framework también proporciona amplia libertad para personalizar componentes. A diferencia de Bootstrap que tiene estilos muy definidos y difíciles de modificar, Bulma utiliza clases utilitarias que dan control total sobre la apariencia sin necesidad de sobrescribir constantemente los estilos predefinidos.

3.4.2. Diseño UI/UX

La aplicación tiene un diseño responsive, esto la hace accesible mediante web o móviles. Esto es importante porque los usuarios potenciales incluyen técnicos agrícolas trabajando desde oficinas y agricultores accediendo directamente con móviles en el invernadero.

El sistema se estructura en tres pantallas principales:

Página de Inicio: Presenta información general del proyecto con el título "Detección Inteligente de Botrytis" y describe las principales ventajas: monitoreo preciso mediante IA, plataforma robusta de aprendizaje automático, y base de conocimiento sobre prevención y tratamientos efectivos para Botrytis Cinerea.

Página de Información: Utiliza pestañas interactivas para mostrar detalles organizados en cuatro categorías: la enfermedad, la solución propuesta, el rigor científico del modelo, y los beneficios del sistema. También incluye un enlace al repositorio en GitHub para usuarios que requieran examinar el código fuente.

Pantalla de Detección: Es la vista funcional principal donde se realiza el análisis. Contiene un área de carga de imágenes, botones de control para analizar o limpiar la selección, e instrucciones claras sobre el uso correcto de la funcionalidad.

3.4.3. *Flujo de Usuario en la Detección*

Cada estado del flujo fue diseñado pensando en la claridad y facilidad de uso:

Estado Inicial. Al acceder a la pantalla aparece un cuadro con bordes punteados indicando el área para subir la imagen. El botón "Analizar imagen" permanece deshabilitado (visualmente en gris) hasta que se cargue un archivo válido.

Carga de Imagen. Al seleccionar una foto se muestra una vista previa inmediata y el botón de análisis se habilita, cambiando su apariencia para indicar que está listo para interactuar.

Procesamiento. Al hacer clic en "Analizar imagen" aparece un spinner animado con el texto "Analizando imagen..." mientras se procesa la petición. Los botones se bloquean temporalmente para prevenir múltiples envíos accidentales.

Resultados Positivos. Si se detecta Botrytis, se despliega un mensaje de alerta con fondo rojizo mostrando "Botrytis Detectada", una barra de confiabilidad con el porcentaje (por ejemplo, 74%), y la recomendación de aplicar fungicida y aislar el espécimen afectado.

Resultados Negativos. Si no hay detección, aparece un mensaje con fondo verdoso indicando "Rosa Sana", con confianza cercana a 0% en Botrytis, y la sugerencia de continuar con el monitoreo regular del cultivo.

Manejo de Errores. En caso de problemas de comunicación o procesamiento, se muestra un mensaje de error claro (como "Failed to fetch") que permite al usuario comprender que ocurrió un fallo y puede intentar nuevamente.

3.5. Internacionalización y Accesibilidad

Para hacer el sistema accesible a más usuarios se agregó soporte para dos idiomas: español e inglés. La implementación usa archivos separados para cada idioma (Messages_es.js y Messages_en.js) donde cada texto tiene una llave y su traducción correspondiente. Cuando un usuario selecciona un idioma, la aplicación simplemente carga el archivo nuevo y todos los textos en la interfaz se actualizan de inmediato.

El selector de idioma se ve diferente según dónde el usuario ejecute el programa. Si se encuentra en la versión de escritorio, hay espacio suficiente en la barra superior donde se muestra un menú desplegable, en el cual, al hacer clic en el nombre del proyecto aparecen las opciones disponibles de idiomas. Por otra parte, en celulares no hay espacio disponible en la parte superior, por lo cual el selector de idioma se muestra en la parte inferior del menú desplegable.

Esta característica amplía bastante el alcance del sistema. Ahora puede usarlo tanto gente de países hispanohablantes como de regiones donde se habla inglés, que son justamente los dos grupos principales en la industria de las rosas a nivel global.

3.6.Consideraciones Finales

El desarrollo del sistema integró componentes de inteligencia artificial de vanguardia con principios sólidos de ingeniería de software. La arquitectura modular adoptada facilita el mantenimiento futuro y permite actualizar el modelo de detección sin modificar otros componentes del sistema.

Las tecnologías que se eligieron (YOLOv8 para la detección, FastAPI para el backend y Bulma para el frontend) no fueron decisiones aleatorias. Cada una responde a necesidades específicas del proyecto, buscando un balance entre que el sistema funcione rápido y que sea fácil de usar. Al final se logró un sistema que, aunque tiene componentes técnicos complejos por dentro, resulta bastante intuitivo para quien lo usa, algo clave si se quiere que realmente se adopte en invernaderos comerciales.

CAPITULO 4:

4. ANÁLISIS DE RESULTADOS

4.1. Pruebas de Concepto

El objetivo de las presentes pruebas de concepto fue para validar la transición entre el método actual (inspección manual) a un sistema impulsado mediante la visión por computadora y redes convolucionales (CNN). Para ello, se tomó como punto inicial las condiciones reales de florícolas ecuatorianas, donde características como la iluminación y calidad de la imagen pueden variar. El “cerebro” del proyecto, como se mencionó en secciones anteriores, consistió en someter al modelo (Roboflow) con un conjunto de 2561 imágenes, entre las que se encontraban imágenes de rosas sanas, enfermas con Botrytis Cinérea, maltratadas por el clima y por la manipulación humana. De esta manera, se planteó la verificación de si la CNN podía discriminar, con un porcentaje de precisión alto, los principales síntomas de la enfermedad (como lo es las micromanchas acuosas) de las anomalías no patógenas, como lo son los daños mecánicos o de clima.

Durante la fase de pruebas, se implementó el prototipo funcionando como modelo especialista con una precisión (mAP) en fases de cosechas, en lo que la flor se encontraba en su punto de madurez más alto. En estas pruebas se pudo comprobar que el porcentaje de éxito en la detección de Botrytis correctamente fue de alrededor de un 90%. Adicionalmente, este análisis empleando nuestro prototipo optimiza el tiempo de diagnóstico de manera drástica. Una detección minuciosa y detallada por cada tallo de rosa puede demorar entre 15 y 30 segundos (además de tener en cuenta que estos tiempos pueden variar dependiendo de la experiencia de la persona que está realizando la revisión), nuestro sistema muestra un análisis técnico en menos de 1 segundo en el proceso de análisis de IA. Esta pronta respuesta se

puede traducir en eficiencia, la cual permitirá una toma de decisiones pronta, facilitando así la segregación de especímenes infectados, evitando así, que el hongo se propague al resto del lote.

Tabla 9

Resumen pruebas de concepto

Parámetros de Evaluación	Inspección Manual	Sistema Diseñado	Diferencia / Impacto
Tiempo Procesamiento (Por Rosa analizada)	Entre 15-30 segundos.	Menos de 1 segundos para cada análisis.	Reducción del 80% en tiempo de análisis.
Fatiga del observador	Puede verse afectada por el cansancio del observador.	No existe fatiga (Prototipo puede funcionar 24/7).	Análisis estándar independientemente de la carga de trabajo.
Detección de síntomas	Subjetiva (Depende de la experiencia del observador).	Objetiva (Basada en el entrenamiento del modelo)	Mayor tasa de éxito y disminución de falsos positivos.
Escalabilidad	Depende enteramente de la capacidad del personal.	Alta (en futuros desarrollos se puede ampliar a más lugares o para la detección de otras enfermedades).	Optimiza costos y tiempos de preparación del personal.

Nota. La tabla compara el desempeño de la inspección manual frente al sistema automatizado propuesto para la detección de síntomas en rosas, considerando tiempo de procesamiento, fatiga del

observador, objetividad en la detección y escalabilidad operativa, así como el impacto de estas diferencias en la eficiencia y confiabilidad del proceso de evaluación.

Medición de Rendimiento y Latencia

Para la evaluación del rendimiento del sistema en un entorno real, se implementó un cronómetro para verificar correctamente el tiempo de ejecución del análisis. Para ello, se añadió una sección de código para la detección del tiempo. Para backend el código necesario esta detallado en la Fig. 12 y Fig. 13.

Fig. 12

Inicio de cronómetro en backend

```
28 @app.post("/analyze")
29 async def analyze(file: UploadFile = File(...)):
30+     start_time = time.time() # INICIO CRONÓMETRO BACKEND
31+
32     if model is None:
33         raise HTTPException(status_code=500, detail="Model not loaded on server.")
34
```

Fig. 13

Fin del cronómetro para backend

```
76
77+     end_time = time.time() # FIN CRONÓMETRO BACKEND
78+     process_time = round(end_time - start_time, 4) # Calculamos la diferencia
79+
80     return JsonResponse(content={
81         "status": status_global,
82         "message": message,
83         "total_detections": len(detections),
84+         "detections": detections,
85+         "inference_time_seconds": process_time # RESPUESTA EN EL SERVICIO
86     })
```

Finalmente, para frontend se añadió el iniciador y la muestra en consola de los tiempos de ejecución, como se puede observar en la Fig. 14 y Fig. 15.

Fig. 14*Inicio del cronómetro para Frontend*

```
5      const formData = new FormData();
6      formData.append("file", file);
7+      You, 2 weeks ago • first commit ...
8+      // INICIO CRONÓMETRO FRONTEND
9+      const startTime = performance.now();
10
```


Fig. 15*Finalización del cronómetro para Frontend*

```
22      const data = await response.json();
23+
24+      // FIN CRONÓMETRO FRONTEND
25+      const endTime = performance.now();
26+      const totalTimeMs = (endTime - startTime).toFixed(2); // Tiempo total usuario
27+
28+      console.log(`-----`);
29+      console.log(`Tiempo Total (Usuario): ${totalTimeMs} ms`);
30+      console.log(`Tiempo IA (Backend): ${data.inference_time_seconds} s`);
31+      console.log(`-----`);
32
```

Lo cual se puede observar en la Fig. 16, donde se puede apreciar los tiempos de Backend y Frontend al poner en ejecución el sistema.

Fig. 16

Ejecución del sistema con cronómetro



Se realizaron diferentes pruebas de estrés midiendo dos variables críticas el tiempo de Interferencia (variable en backend) y el tiempo total de respuesta (medido con la interacción del usuario). El tiempo de interferencia es el tiempo base que se tarda el modelo en procesar la imagen y generar una predicción; el tiempo total de respuesta es el tiempo que transcurre desde que el usuario envía la solicitud hasta que se muestra la respuesta en pantalla. Para ello, se procedió a la ejecución de 5 iteraciones consecutivas con 8 casos de pruebas, obteniendo los resultados mostrados en la Tabla 10 .

Tabla 10.

Resumen de tiempos de casos de prueba

Caso de Prueba	Promedio Tiempo de Interferencia	Promedio Tiempo total de Respuesta	Descripción de la Prueba
Caso #1	0.251 segundos	0.260 segundos	Rosa Deteriorada sin infección

Caso #2	0.291 segundos	0.360 segundos	Rosa Deteriorada sin infección
Caso #3	0.216 segundos	0.223 segundos	Rosa con Infección (Botrytis)
Caso #4	0.180 segundos	0.247 segundos	Rosa con Infección (Botrytis)
Caso #5	0.224 segundos	0.294 segundos	Rosa con Infección (Botrytis)
Caso #6	0.218 segundos	0.225 segundos	Rosa Sana
Caso #7	0.275 segundos	0.281 segundos	Rosa Sana
Caso #8	0.289 segundos	0.296 segundos	Rosa Sana
Promedio	0.243 segundos	0.273 segundos	

Nota. La tabla presenta los resultados de pruebas de desempeño del sistema de detección, mostrando los tiempos promedio de inferencia y de respuesta total para diferentes estados de la rosa (sana, deteriorada sin infección e infectada con *Botrytis*), con el fin de evaluar la eficiencia operativa del modelo en distintos escenarios.

De esta manera, se pudo comprobar que el rendimiento computacional para este sistema es altamente eficiente, ya que el tiempo de interferencia tiene una media de 0.23 segundos. Esto es un indicador fundamental, ya que indica que el modelo entrenado, el cual

está basado en la arquitectura YOLOv8 Medium, con los parámetros y la configuración actual, es capaz de procesar aproximadamente 4 FPS en el servidor de prueba. Cabe destacar que se considere que estas pruebas fueron realizadas bajo un sistema controlado. De esta manera, en caso de que se desee mover el sistema a entornos de producción nuevos, se debe tomar en cuenta que ciertas características pueden variar los resultados de la velocidad del procesamiento para cada imagen. Características como la latencia de la Red y el envío de información entre backend y frontend son clave para entender que el “tiempo total” del análisis puede verse incrementado por el tiempo de subida de la imagen al servidor y la descarga del JSON para posterior muestra en frontend.

4.2. Análisis de Resultados

Una vez teniendo el sistema entrenado con el dataset de 2561 imágenes se puede proceder al análisis de cada uno de los casos de interés. Para demostración de la efectividad del sistema se realizaron varias pruebas con diferentes imágenes inéditas para el modelo de rosas y en diferentes estados, abarcando escenarios de sanidad, infección de la enfermedad y deterioro natural no relacionado a la Botrytis, además de variar el ángulo de detección y la iluminación.


Discriminación de Rosas por deterioro no relacionado con la infección

Dado estas pruebas se pudo comprobar que uno de los mayores desafíos que enfrentamos fue el clasificar entre una planta que se encuentra enferma con Botrytis de una que este infectada de otra enfermedad o que sea una planta senescente (vieja) o incluso que haya tenido daño por manipulación humana o mecánica. De este modo, como se puede observar en la Fig. 17 y Fig. 18, se utilizó imágenes con rosas que poseían signos claros de marchitamiento, decoloración amarilla y/o necrosis, todos signos relacionados al

envejecimiento natural. Un modelo no entrenado o generalista en la clasificación de sanar-enfermas podría clasificarlas como rosas “infectadas”. En nuestra Ilustración, el modelo asignó correctamente la etiqueta de rosa sin infección (uninfected_rose), teniendo una confianza del 77%. Esto demuestra que el entrenamiento realizado fue satisfactorio, y el modelo logró detectar satisfactoriamente la textura específica que tiene la infección (micelio grisáceo/esporulación) y el etiquetado no se basó únicamente en el color o la forma que podría presentar la rosa. Por este motivo en pantalla se muestra la etiqueta de “Libre de Botrytis”, ya que se pudo comprobar que esta sin esta infección específica, pero no descarta algún otro deterioro que pueda tener la flor.

Fig. 17

Rosa enferma sin Botrytis – Escenario 1



Código Fuente 1

Respuesta del servidor para la para el escenario de la Fig. 17

```
{
  "status": "uninfected",
  "message": "No signs of Botrytis detected in the
rose.",
  "total_detections": 1,
  "detections": [
    {
      "box": [
        0,
        0,
        787,
        585
      ],
      "label": "uninfected_rose",
      "confidence": 0.77,
      "is_infected": false
    }
  ]
}
```

Fig. 18

Rosa enferma sin Botrytis – Escenario 2




Código Fuente 2

Respuesta del servidor para la para el escenario de la Fig. 18


```
{
  "status": "uninfected",
  "message": "No signs of Botrytis detected in the rose.",
  "total_detections": 1,
  "detections": [
    {
      "box": [
        316,
        59,
        521,
        270
      ],
      "label": "uninfected_rose",
      "confidence": 0.75,
      "is_infected": false
    }
  ]
}
```

Verdaderos positivos en rosas infectadas

Para los casos mostrados en la Fig. 19, Fig. 20 y Fig. 21 se pudo mostrar una alta sensibilidad para la localización de la infección. Durante el entrenamiento, se priorizó que el modelo no solo clasificara la imagen globalmente, sino que generaba una delimitación precisa (Bounding Box) alrededor de la zona afectada de la imagen. De esta manera en Ilustración de que en el bounding box se detectara alguna infección, se etiquetaría como botrytis_rose y se activaría el estado de alerta (status: infected). De esta manera, se emitiría la alerta de que se encontró la infección, independientemente del estado del resto de la flor.

Fig. 19*Rosa con Botrytis - Escenario 1***Código Fuente 3***Respuesta del servidor para la para el escenario de la Fig. 19*

```
{
  "status": "infected",
  "message": "ALERT: Botrytis detected in the rose.",
  "total_detections": 1,
  "detections": [
    {
      "box": [
        233,
        183,
        666,
        649
      ],
      "label": "botrytis_rose",
      "confidence": 0.98,
      "is_infected": true
    }
  ]
}
```


Fig. 20*Rosa con Botrytis - Escenario 2***Código Fuente 4***Respuesta del servidor para la para el escenario de la Fig. 20*

```
{
  "status": "infected",
  "message": "ALERT: Botrytis detected in the rose.",
  "total_detections": 1,
  "detections": [
    {
      "box": [
        0,
        226,
        364,
        520
      ],
      "label": "botrytis_rose",
      "confidence": 0.79,
      "is_infected": true
    }
  ]
}
```

Fig. 21*Rosa con Botrytis - Escenario 3***Código Fuente 5***Respuesta del servidor para la para el escenario de la Fig. 21*

```
{
  "status": "infected",
  "message": "ALERT: Botrytis detected in the rose.",
  "total_detections": 1,
  "detections": [
    {
      "box": [
        87,
        32,
        315,
        226
      ],
      "label": "botrytis_rose",
      "confidence": 0.98,
      "is_infected": true
    }
  ]
}
```

Generalización de Rosas Sanas sin infección

En caso de la discriminación de ejemplares que no tuvieran ni daños ni la presencia de la infección se pudo observar un nivel de certeza del 98%. Esto se puede ver de mejor manera en las Fig. 22, Fig. 23 y Fig. 24, en las cuales se pudo identificar correctamente especímenes de diferentes colores (en esta Ilustración rojas y rosadas) y teniendo condiciones diferentes entre sí, como lo son la iluminación y rotación. Esto muestra que el entrenamiento del modelo usando aumento de datos (Data Augmentation) tomando estas condiciones anteriormente mencionadas fue efectivo principalmente para evitar el sesgo que se podía generar si solo se tomaba un solo tipo de imagen como ejemplo.

Fig. 22

Rosa Sana - Escenario 1



Código Fuente 6

Respuesta del servidor para la para el escenario de la Fig. 22

```
{
  "status": "uninfected",
  "message": "No signs of Botrytis detected in the rose.",
  "total_detections": 1,
  "detections": [
    {
      "box": [
        8,
        63,
        339,
        380
      ],
      "label": "uninfected_rose",
      "confidence": 0.98,
      "is_infected": false
    }
  ]
}
```

Fig. 23

Rosa Sana - Escenario 2



Código Fuente 7

Respuesta del servidor para la para el escenario de la Fig. 23

```
{
  "status": "uninfected",
  "message": "No signs of Botrytis detected in the rose.",
  "total_detections": 1,
  "detections": [
    {
      "box": [
        8,
        42,
        971,
        874
      ],
      "label": "uninfected_rose",
      "confidence": 0.98,
      "is_infected": false
    }
  ]
}
```

Fig. 24

Rosa Sana - Escenario 3



Código Fuente 8

Respuesta del servidor para la para el escenario de la Fig. 24

```
{
  "status": "uninfected",
  "message": "No signs of Botrytis detected in the rose.",
  "total_detections": 1,
  "detections": [
    {
      "box": [
        37,
        23,
        186,
        143
      ],
      "label": "uninfected_rose",
      "confidence": 0.98,
      "is_infected": false
    }
  ]
}
```

CAPITULO 5:

5. CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones

- Debido a la escasez de un dataset de imágenes con las patologías de la Botrytis en rosas en sitios oficiales o en florícolas en el sector de Cayambe. Una de las alternativas fue la generación de datos sintéticos como una solución a esta problemática. Si la generación de imágenes respeta las características biológicas del patógeno (textura aterciopelada, coloración grisácea), una red neuronal puede transferir ese aprendizaje a escenarios reales con éxito.
- Simplificar la etiquetación en dos clases *botrytis_rose* y *uninfected_rose* ayudó a resolver el conflicto de ambigüedad de etiquetas en rosas que no presentan la patología como rosas sanas, daños mecánicos o vejez.
- Para el desarrollo de este sistema se estableció la selección de la arquitectura de YOLOv8 con su categorización en Medium, y una resolución de entrada de 512x512 píxeles, datando al sistema de un rendimiento óptimo para evitar un alto consumo computacional. Esta configuración permite diferenciar variaciones en texturas permitiendo evitar los falsos positivos en rosas marchitas sin comprometer al tiempo de ejecución del análisis.
- Los tiempos de operación de ejecución que se obtuvieron menores a 300 ms, dan la apertura a que este sistema pueda emplearse en aplicaciones de tiempo real que pueda emplearse como una herramienta de campo que facilite la detección de Botrytis.
- Independientemente del tipo de imágenes que muestren o no patologías, la detección no supone una carga computacional extra para el modelo preentrenado.

5.2. Recomendaciones

- Aunque los resultados con datos sintéticos son prometedores, se recomienda realizar una fase de *Fine-Tuning* (ajuste fino) del modelo. Esto implica re-entrenar las últimas capas de la red neuronal con un conjunto pequeño (aprox. 100-200 imágenes) de fotografías reales tomadas directamente en los invernaderos objetivo. Esto ayudará a calibrar el modelo frente a variables ambientales no controladas como polvo en la lente, contraluz solar intenso y desenfoque de movimiento.
- Dada la variabilidad observada en los encuadres, se recomienda integrar en la interfaz de usuario una guía visual (overlay o recuadro en pantalla) que instruya al agricultor sobre la distancia óptima de captura (20-30 cm). Garantizar que la flor ocupe al menos el 50% del encuadre aumentará significativamente la confianza de las predicciones en etapas tempranas de la enfermedad.
- El éxito del modelo en distinguir entre tejido sano, tejido muerto no infeccioso y tejido con Botrytis sugiere que la arquitectura tiene capacidad para aprender más clases. Se recomienda ampliar el dataset para incluir otras enfermedades prevalentes en rosas, como el *Oídio* (*Sphaerotheca pannosa*) o el *Mildeo Velloso*, transformando la herramienta en un asistente fitosanitario integral. Aunque el enfoque binario actual es exitoso para la detección específica de Botrytis, se recomienda para futuras iteraciones evolucionar hacia un sistema de clasificación multi-clase que mantenga la lógica de "No Infectado" como clase base.
- Actualmente, la dependencia de una conexión a internet para consultar la API puede ser una limitante en zonas rurales. Se recomienda exportar el modelo optimizado a formato ONNX o TFLite para ejecutar la inferencia directamente en el dispositivo móvil del usuario (Edge Computing), eliminando la latencia y permitiendo el

funcionamiento en áreas sin cobertura.

6. REFERENCIAS BIBLIOGRÁFICAS

- Acenjo, B. X. T., Pariona, M. A. T., & Cárdenas, E. J. E. (2023). Comparativa entre RESNET-50, VGG-16, Vision Transformer y Swin Transformer para el reconocimiento facial con oclusión de una mascarilla. *Interfases*, 17, 56–78.
- Agro link. (2025). Rosas (Rosa spp.) – Manejo Integral. *Agro Link - Ecuador*.
<https://agrolink.ec/rosas-rosa-spp-manejo-integral/>
- Agro Link. (2025a, July 7). Cómo proteger las rosas de las principales enfermedades y aumentar su rentabilidad con una estrategia profesional. *Agro Link - Ecuador*.
<https://agrolink.ec/como-proteger-las-rosas-de-las-principales-enfermedades/>
- Agro Link. (2025b, August 8). Cómo Reconocer y Manejar la Enfermedad en Rosas: Botrytis cinerea (Podredumbre Gris). *Agro Link - Ecuador*. <https://agrolink.ec/botrytis-cinerea-rosas-control-enfermedades-agrolink-ecuador/>
- Agrolink. (2025a, August 8). Cómo Reconocer y Manejar la Enfermedad en Rosas: Botrytis cinerea (Podredumbre Gris). *Agro Link - Ecuador*. <https://agrolink.ec/botrytis-cinerea-rosas-control-enfermedades-agrolink-ecuador/>
- Agrolink. (2025b, August 8). Cómo Reconocer y Manejar la Enfermedad Roya en Rosas (Phragmidium spp.). *Agro Link - Ecuador*. <https://agrolink.ec/roya-en-rosas-control-enfermedades-agrolink-ecuador/>
- Amaguaya, K. M. P. (2024). *APLICACIÓN DE MACHINE LEARNING PARA ESTIMAR LA PRODUCCIÓN DE EMPRESAS AGRÍCOLAS EXPORTADORAS Y ANÁLISIS DE PRODUCTOS EN EMPRESAS IMPORTADORAS*.
- Amershi, S., Begel, A., Bird, C., DeLine, R., Gall, H., Kamar, E., Nagappan, N., Nushi, B., & Zimmermann, T. (2019). Software engineering for machine learning: A case study. *2019 IEEE/ACM 41st International Conference on Software Engineering: Software*

Engineering in Practice (ICSE-SEIP), 291–300.

<https://ieeexplore.ieee.org/abstract/document/8804457/>

Anonymous. (2021, June 17). *Manejo Integrado de Plagas | Integrated Pest Management*.

<https://ipm.cahnr.uconn.edu/manejo-integrado-de-plagas/>

Aponte, D. (2015). *EL OIDO (Sphaerotheca pannosa) CON SU METODO DE CONTROL BIOLOGICO EN EL CULTIVO DE ROSA (Rosa sp.)* [UNIVERSIDAD TECNICA DE AMBATO]. <https://www.scribd.com/document/338942494/Control-de-Oidio-en-Rosas>

Arnal Barbedo, J. G. (2019). Plant disease identification from individual lesions and spots using deep learning. *Biosystems Engineering*, 180, 96–107.

<https://doi.org/10.1016/j.biosystemseng.2019.02.002>

Arquitectura Software Basada en Tecnologías Smart para Agricultura de Precisión. (n.d.).

ResearchGate. Retrieved December 14, 2025, from

https://www.researchgate.net/publication/306041668_Arquitectura_Software_Basada_en_Tecnologias_Smart_para_Agricultura_de_Precision

Ashurov, A. Y., Al-Gaashani, M. S. A. M., Samee, N. A., Alkanhel, R., Atteia, G., Abdallah, H. A., & Saleh Ali Muthanna, M. (2025). Enhancing plant disease detection through deep learning: A Depthwise CNN with squeeze and excitation integration and residual skip connections. *Frontiers in Plant Science*, 15.

<https://doi.org/10.3389/fpls.2024.1505857>

Asociación Uruguay de la Rosa (Director). (2020, May 29). *Enfermedades en los Rosales—Hongos* [Video recording]. <https://www.youtube.com/watch?v=JfUrRkAUfIE>

Beccatelli, M. (2025, March 30). *Moho gris (Botrytis cinerea) en viñedos y cultivos frutales: Síntomas y soluciones*. <https://plantvoice.farm/es/moho-gris-botrytis-cinerea-en-vinedos-y-cultivos-frutales/>

- Bisong, E. (2019). *Building Machine Learning and Deep Learning Models on Google Cloud Platform: A Comprehensive Guide for Beginners*. Apress. <https://doi.org/10.1007/978-1-4842-4470-8>
- Brad Dwyer. (2021). *Roboflow: Computer vision tools for developers and enterprises*. <https://roboflow.com/>
- Bray, T. (2014). *The javascript object notation (json) data interchange format*. <https://www.rfc-editor.org/rfc/rfc7159>
- Bulma: Free, open source, and modern CSS framework based on Flexbox. (2025, May 6). <https://bulma.io>
- Caiza, V. (2013). *COLECCIÓN, IDENTIFICACIÓN Y PRUEBAS DE EFICACIA IN VITRO DE (Trichoderma sp). EN EL CONTROL BIOLÓGICO DE (Botrytis cinerea) EN LA FINCA FLORÍCOLA PICASSO ROSES*. [UNIVERSIDAD POLITÉCNICA SALESIANA]. <https://dspace.ups.edu.ec/bitstream/123456789/5073/1/UPS-YT00104.pdf>
- Campués, S. (2023). *EVALUACIÓN DE Bacillus amyloliquefaciens P. EN EL CONTROL DE Botrytis cinerea P. EN Rosa sp. VARIEDAD ORANGE CRUSH, CAYAMBE* [UNIVERSIDAD TÉCNICA DEL NORTE]. <https://repositorio.utn.edu.ec/bitstream/123456789/13985/2/03%20AGP%20357%20TRABAJO%20DE%20GRADO.pdf>
- Chandra, R. (2025). *Digital and biotechnological interventions in floriculture: A comprehensive review*.
- Conoce y controla el Mildeo Velloso | ADAMA Colombia. (2022, March 23). <https://www.adama.com/colombia/es/noticias-y-actualidad/conoce-y-controla-el-mildeo-velloso-en-los-cultivos-de-rosa-y-cebolla>

Control de Mildiu Velloso en Cultivo de Rosa | Intagri S.C. (2019).

<https://www.intagri.com/articulos/fitosanidad/control-de-mildiu-velloso-en-cultivo-de-rosa>

DryGair. (2019, October 30). Prevención de la botritis: Tratamiento del moho gris sin fungicidas - DryGair. *Drygair Greenhouse Dehumidifiers*. <https://drygair.com/es/blog-es/preventing-botrytis-without-fungicides/>

Enfermedades de las plantas—Prevención, control y daños. (2025, January 16).

Enfermedades comunes de las plantas. <https://www.koppert.ec/enfermedades-de-las-plantas/>

Explicación de la detección de objetos YOLO: Guía para principiantes. (2024).

<https://www.datacamp.com/blog/yolo-object-detection-explained>

Explore Ultralytics YOLOv8—Ultralytics YOLO Docs. (2023).

<https://docs.ultralytics.com/models/yolov8/>

FastAPI. (2025, October 6). <https://fastapi.tiangolo.com/>

Fielding, R. T. (2000). *Architectural styles and the design of network-based software architectures*. University of California, Irvine.

<https://search.proquest.com/openview/fc2d064044b971dda476dfb429a2b344/1?pq-origsite=gscholar&cbl=18750&diss=y>

García-Cabezas, E. F., Ulcuango-Guajan, W. R., Moyano-Alulema, J. C., & Cayán-Martínez, J. C. (2022). Propuesta de una máquina automatizada cortadora de tallos de flores.

Ingenium et Potentia, 4(7), 108. <https://doi.org/10.35381/i.p.v4i7.1880>

GardenTech. (2017, March 4). *Identificación y control del moho gris o podredumbre de Botrytis*. GardenTech. <https://gardentech.qa.central.com/es/identify-plant-diseases/botrytis-blight>

- Gauthier, N., Boice, M., Leonberger, K., & Kaiser, C. (2021, March 11). *Enfermedades por Botrytis (PPFS-GEN-19-S) | Plant Pathology*. Department of Plant Pathology.
<https://plantpathology.mgcafe.uky.edu/enfermedades-por-botrytis-ppfs-gen-19-s>
- Ha, S. T. T., Choi, B., & In, B.-C. (2021). Nature and Regulation of Botrytis cinerea in Rosa hybrida. *Flower Research Journal*, 29, 129–137.
<https://doi.org/10.11623/frj.2021.29.3.02>
- Heaton, J. (2018). Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning: The MIT Press, 2016, 800 pp, ISBN: 0262035618. *Genetic Programming and Evolvable Machines*, 19(1–2), 305–307. <https://doi.org/10.1007/s10710-017-9314-z>
- Heck, P., & Schouten, G. (2023). *Defining Quality Requirements for a Trustworthy AI Wildflower Monitoring Platform* (No. arXiv:2303.13151). arXiv.
<https://doi.org/10.48550/arXiv.2303.13151>
- Jachero, C., & David, C. (2023). *Desarrollo de un algoritmo para el conteo de rosas basado en técnicas de procesamiento de imágenes*.
- Jiménez Pazmiño, K. C., & Silva Moya, A. (2025). *Bacterias del género BACILLUS como agentes de control biológico in vitro de los hongos fitopatógeno BOTRYTIS SP. y COLLETOTRICHUM SP* [bachelorThesis].
<http://dspace.ups.edu.ec/handle/123456789/29578>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25.
<https://proceedings.neurips.cc/paper/2012/hash/c399862d3b9d6b76c8436e924a68c45b-Abstract.html>
- La botrytis en rosa: Qué es y cómo combatirla*. (n.d.). manvert | Bioestimulantes y nutrientes avanzados para tus cultivos. Retrieved December 26, 2025, from <https://manvert.com>

- La botrytis en rosa: Qué es y cómo combatirla.* (2025, January 16). manvert | Bioestimulantes y nutrientes avanzados para tus cultivos. <https://manvert.com>
- Latorre, B., & Rioja, M. (2002). The effect of temperature and relative humidity on conidial germination of *Botrytis cinerea*. *Cien. Inv. Agr.*, 29, 67–72.
<https://doi.org/10.7764/rcia.v29i2.1318>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Manvert. (2025, January 16). *La botrytis en rosa: Qué es y cómo combatirla.* manvert | Bioestimulantes y nutrientes avanzados para tus cultivos. <https://manvert.com>
- mAP, «precisión promedio media», métrica clave en la IA. (2024, January 6).
<https://www.innovatiana.com/es/post/mean-average-precision>
- Matute, P. (2019). *CONTROL BIOLOGICO DEL MOHO GRIS (Botrytis cinerea) EN CULTIVOS DE FRESA (Fragaria vesca L.) MEDIANTE HONGOS FILAMENTOSOS ANTAGONISTAS* [UNIVERSIDAD POLITÉCNICA SALESIANA].
<https://dspace.ups.edu.ec/bitstream/123456789/18147/1/UPS-CT008620.pdf>
- Metroflor Colombia. (2017, January 29). Botrytis cinérea. *Metroflor*.
<https://www.metroflorcolombia.com/botrytis-cinerea/>
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016a). Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science*, 7.
<https://doi.org/10.3389/fpls.2016.01419>
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016b). Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science*, 7.
<https://doi.org/10.3389/fpls.2016.01419>
- Moreano, G., Cajamarca, J., & Tenicota, A. (2020). Agricultura de Precisión: Preprocesamiento y Segmentación de Imágenes para Obtención de una Ruta de

- Navegación Autónoma Terrestre. *Revista Politécnica*, 44(2), 43–50.
<https://doi.org/10.33333/rp.vol44n2.05>
- mruiz. (2025a, October 28). UPS lidera proyecto para una floricultura sostenible en Cayambe. *NOTIUPS*. <https://notiups.ups.edu.ec/ups-lidera-proyecto-para-una-floricultura-sostenible/>
- mruiz. (2025b, October 31). Proyecto SISMO-ROSAS impulsa la innovación en la floricultura. *NOTIUPS*. <https://notiups.ups.edu.ec/proyecto-sismo-rosas-impulsa-la-innovacion-en-la-floricultura/>
- Novobac. (2025, May 3). *Cómo identificar y combatir la plaga de Botrytis en tus rosas*. Novobac. <https://es.novobac.com/blog/combatar-la-botrytis-en-sus-rosas/>
- Oídio en rosales – Encuentra la mejor manera de curarlo*. (2024). Novobac. <https://es.novobac.com/blog/mildiu-polvoroso-en-rosas/>
- Pundt, L. (2022, June 7). *Tizón de Botrytis en cultivos de invernadero*. USDA NIFA CPPM. <https://ipm-cahnrm.media.uconn.edu/wp-content/uploads/sites/3216/2022/08/Tizon-de-Botrytis-en-Cultivos-de-Invernadero.pdf>
- Redagícola. (2022, October 24). Botrytis cinerea, el superpatógeno que no es bienvenido en rosas. *Redagícola*. <https://redagricola.com/botrytis-cinerea-el-superpatogeno-que-no-es-bienvenido-en-rosas/>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 779–788. https://www.cv-foundation.org/openaccess/content_cvpr_2016/html/Redmon_You_Only_Look_CVPR_2016_paper.html
- Robots using Machine Vision Algorithms in Agriculture*. (n.d.). Retrieved December 14, 2025, from <https://www.rsipvision.com/robots-using-machine-vision-agriculture/>

- Ruiz, J., Godínez, Z., Pilar, F., Mendoza, B., Rojas-Mancera, E., Jazmín, R., Trasviña-Osorio, R. J., Fernando, L., Jiménez, V., Rangel, S., Godínez, A., Becerra-Mendoza, Z., & Villanueva-Jiménez, R. (2024). Evaluación Comparativa de Redes Neuronales Convolucionales ResNet-50 y MobileNet-v2 para el Diagnóstico de Enfermedades Foliares en Cultivos de Maíz. *Musyarakah Journal of Sharia Economic (MJSE)*.
<https://doi.org/10.5281/zenodo.13943077>
- Sanders, J., & Kandrot, E. (2010). *CUDA by example: An introduction to general-purpose GPU programming*. Addison-Wesley Professional.
https://books.google.com/books?hl=es&lr=&id=49OmnOmTEtQC&oi=fnd&pg=PT17&dq=CUDA+by+example&ots=tu3g1oTiV-&sig=D_EaEptAgWWR-ILzZRO3F_MqqBA
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 60. <https://doi.org/10.1186/s40537-019-0197-0>
- Sun, X., Li, Z., Zhu, T., & Ni, C. (2021). Four-Dimension Deep Learning Method for Flower Quality Grading with Depth Information. *Electronics*, 10(19), 2353.
<https://doi.org/10.3390/electronics10192353>
- Taddei Dalla Torre, F., Melgani, F., Pertot, I., & Furlanello, C. (2024). Artificial Intelligence Vision Methods for Robotic Harvesting of Edible Flowers. *Plants*, 13(22), 3197.
<https://doi.org/10.3390/plants13223197>
- Tendencias del comercio global en 2025: La demanda de flores y cómo Ecuador puede liderar en Norteamérica – Cámara de Comercio de Quito.* (2025, January 21).
<https://ccq.ec/tendencias-del-comercio-global-en-2025-la-demanda-de-flores-y-como-ecuador-puede-liderar-en-norteamerica/>

- Tigrero Bacilio, S. F. (2024). *Implementación de un rover automatizado con tecnología de visión artificial para la clasificación de tres tipos de plantas sanas/enfermas en cultivos de ciclo corto*. <https://repositorio.upse.edu.ec/handle/46000/11942>
- Trioxy, T. (2025, July 17). Botrytis. *Trioxy*. <https://trioxy.ec/botrytis/>
- Ultralytics. (2023, November 23). *Integración de Roboflow*. <https://docs.ultralytics.com/es/integrations/roboflow/>
- Van Rossum, G., & Drake, F. L. (1995). *Python reference manual* (Vol. 111). Centrum voor Wiskunde en Informatica Amsterdam. <http://www.cs.cmu.edu/afs/cs.cmu.edu/project/gwydion-1/OldFiles/OldFiles/python/Doc/ref.ps>
- Vivas, F. Y., Corrales, J. C., & Ramírez-González, G. (2016). Aproximación a un modelo contextual para calidad de datos en agricultura de precisión. *Revista Ingenierías Universidad de Medellín*, 15(29), 99–112.
- Wang, J., & Perez, L. (2017). The effectiveness of data augmentation in image classification using deep learning. *Convolutional Neural Networks Vis. Recognit*, 11(2017), 1–8.
- Williamson. (2007). *Botrytis cinerea: The cause of grey mould disease*. <https://bsppjournals.onlinelibrary.wiley.com/doi/10.1111/j.1364-3703.2007.00417.x>

APÉNDICE

Anexo A

https://github.com/almeidaErick/RoseImageGeneration/blob/main/create_rose_photos_completely_healthy.py

Anexo B

https://github.com/almeidaErick/RoseImageGeneration/blob/main/create_rose_photos_with_botritis.py

Anexo C

https://github.com/almeidaErick/RoseImageGeneration/blob/main/create_rose_photos_with_mechanical_damages.py