



**Sistema automatizado de clasificación del estado fenológico de
rosas mediante visión artificial En la producción de cultivos
florícolas**

Brayan Steven Cadavid Rueda

Universidad Ean

Facultad Ingeniería

Ingeniería de Sistemas

Bogotá , Colombia

12/Junio/2026

**Sistema automatizado de clasificación del estado fenológico de rosas mediante visión
artificial En la producción de cultivos florícolas**

BARAYAN STEVEN CADAVID RUEDA

Trabajo de grado presentado como requisito para optar al título de:

Ingeniería de Sistemas – Ingeniería de Producción

Director (a):

ING SISTEMAS : **ALEXANDER GARCIA PEREZ**

ING PRODUCCION: **JOHANNA KARINA SOLANO MEZA**

Universidad Ean

Facultad Ingeniería

Ingeniería de Sistemas

Bogotá , Colombia

14/abril/2026

Resumen

La producción de rosas constituye una actividad de alta relevancia dentro del sector florícola, donde el seguimiento adecuado del estado fenológico influye en la organización de las actividades productivas y en la programación de la cosecha. Actualmente, la inspección del crecimiento de las flores se realiza mediante evaluación visual manual por parte del personal operativo, lo cual puede generar variabilidad en los criterios de clasificación y diferencias en los tiempos de inspección entre un evaluador y otro.

El presente proyecto propone desarrollar un sistema de clasificación automatizada del estado fenológico de rosas mediante técnicas de visión artificial. De manera preliminar, el sistema estará conformado por tres componentes principales: (1) un módulo de adquisición y organización de imágenes digitales; (2) un modelo de aprendizaje automático basado en transferencia de aprendizaje encargado de clasificar las imágenes según las categorías fenológicas definidas; y (3) un módulo de almacenamiento y gestión de datos que registrará los resultados en una base de datos organizada jerárquicamente por bloques y líneas de producción simuladas. El procesamiento se realizará por lotes cada seis horas, permitiendo obtener cuatro mediciones diarias dentro de un escenario experimental controlado.

Adicionalmente, el proyecto incluye el modelamiento del proceso manual de inspección, entendido como la descripción estructurada del procedimiento actual, incluyendo la secuencia de actividades realizadas por el operario, los tiempos estimados de evaluación por lote y los criterios visuales empleados para determinar el estado fenológico de la rosa. Esta caracterización permitirá realizar una comparación metodológica entre el procedimiento tradicional y el sistema propuesto.

El alcance del proyecto se limita al diseño, desarrollo y validación del sistema en un entorno simulado, así como a la integración tecnológica para el procesamiento y almacenamiento de información, sin contemplar su implementación directa en un cultivo comercial en esta etapa.

Abstract

Rose production is very important for the flower industry. The identification of the phenological stages is important to plan the harvest and organize the production. Actually, this process is done by workers using manual observation, which can generate differences because each person can evaluate in a different way and also the inspection time is not always the same.

This project propose an automated system to classify roses using computer vision techniques. The system have three main parts: a module to take and organize images, a machine learning model for classify the images, and a module to store the data in a structured way.

The system process images every six hours, allowing a more constant monitoring of the crop in a controlled environment. Also, BPMN diagrams was used to represent the manual process and compare it with the automated system, in order to identify differences in efficiency and consistency.

The results show that the system can reduce human errors and improve the frequency of monitoring. In addition, it help to generate organized information that can support decision making in production planning. However, the system was only tested in a simulated environment, so in real conditions the results can be different.

Introducción

La inspección del estado de crecimiento de las rosas en cultivos florícolas es un proceso que tradicionalmente se realiza de forma manual mediante observación visual por parte del personal operativo, práctica ampliamente documentada en sistemas de producción hortícola convencionales (Food and Agriculture Organization of the United Nations, 2017). Este procedimiento depende en gran medida de la experiencia del evaluador, lo que genera variabilidad en la clasificación del estado fenológico de las flores y dificulta la estandarización del proceso, situación que ha sido señalada en estudios relacionados con la gestión operativa en floricultura (International Society for Horticultural Science, 2019).

Adicionalmente, la inspección manual requiere recorridos físicos por las áreas de cultivo, lo que implica tiempos operativos considerables, limitando la frecuencia del monitoreo y reduciendo la disponibilidad de información actualizada para la toma de decisiones productivas. Esta situación puede generar retrasos en la programación de corte, pérdida de oportunidad de cosecha en punto óptimo y dificultades para planificar la logística de producción.

Por otra parte, aunque existen tecnologías basadas en inteligencia artificial capaces de analizar imágenes y reconocer patrones visuales, su aplicación integrada a sistemas de monitoreo productivo en cultivos florícolas aún es limitada, especialmente en esquemas que permitan organizar la información de forma estructurada por unidades espaciales del cultivo.

En este contexto, surge la necesidad de desarrollar herramientas tecnológicas que permitan automatizar el proceso de clasificación del estado fenológico de las rosas, reducir la subjetividad en la evaluación y generar información sistematizada que apoye la planeación productiva y la toma de decisiones operativas en los cultivos

Pregunta de Investigación

¿Un sistema automatizado de visión artificial puede clasificar el estado fenológico de rosas y generar información útil para optimizar la inspección y la planeación de la cosecha?

Hipótesis

La implementación de un sistema automatizado de clasificación fenológica mediante técnicas de visión artificial reducirá la variabilidad en la inspección manual, incrementará la eficiencia del monitoreo y generará información estructurada que permitirá optimizar la toma de decisiones en la planeación productiva del cultivo de rosas en el proyecto Las Rozas.

Objetivo General

Desarrollar un sistema de clasificación automatizada del estado fenológico de rosas mediante técnicas de visión artificial, integrado a una arquitectura tecnológica de procesamiento y análisis de datos.

Objetivos Específicos

Ingeniería de Sistemas

1. Desarrollar un modelo de clasificación de imágenes utilizando técnicas de visión artificial y aprendizaje automático que permita identificar el estado fenológico de rosas a partir de un conjunto de datos estructurado.
2. Diseñar una arquitectura tecnológica en entorno simulado que integre el modelo de clasificación desarrollado con un sistema de almacenamiento estructurado y flujos de automatización mediante herramientas como n8n, definiendo los componentes, el flujo de datos y los mecanismos de procesamiento por lotes cada seis horas para el registro sistematizado y la visualización de resultados.

Ingeniería de Producción

3. Modelar el proceso actual de inspección del estado fenológico en cultivos de rosas, mediante diagramación BPMN, identificando tiempos de operación, variabilidad en la evaluación y oportunidades de mejora, con el fin de optimizar la eficiencia del proceso, reducir costos

operativos y facilitar la integración del proceso en el sistema productivo.

4. Evaluar el impacto del sistema automatizado en la planeación productiva, definiendo y midiendo indicadores clave, como la reducción del tiempo de inspección, la estandarización del proceso y el apoyo a la programación de corte, asegurando que estos indicadores permitan una mejora continua y un alineamiento con las estrategias de optimización del desempeño productivo.

Justificación

La implementación de tecnologías de visión artificial aplicadas al monitoreo de cultivos representa una oportunidad para mejorar la eficiencia operativa en la industria florícola, permitiendo automatizar procesos que tradicionalmente dependen de evaluación humana.

Desde el enfoque de Ingeniería de Sistemas, el desarrollo de modelos de clasificación de imágenes y su integración con arquitecturas de procesamiento de datos permite construir sistemas capaces de transformar información visual en datos estructurados para la toma de decisiones.

Desde la perspectiva de Ingeniería de Producción, el proyecto contempla el modelamiento del proceso actual de inspección del estado fenológico mediante análisis de tiempos y caracterización de la variabilidad en la evaluación. Esto permitirá establecer una línea base operativa del proceso y definir cómo la incorporación del sistema de clasificación impacta la estandarización, frecuencia de medición y organización espacial de la información dentro del cultivo, aportando insumos para la planificación de la cosecha.

El proyecto permite integrar el análisis tecnológico con el análisis del proceso productivo, generando una solución que no solo clasifica imágenes, sino que aporta información útil para la gestión operativa del cultivo

MARO TEORICO

1. Agricultura de precisión y digitalización agrícola

La agricultura moderna enfrenta actualmente diversos desafíos relacionados con el incremento de la productividad agrícola y, al mismo tiempo, con la necesidad de optimizar los recursos naturales y reducir el impacto asociado a los sistemas de producción. En este contexto surge el concepto de agricultura de precisión, el cual se define como una estrategia de gestión que utiliza tecnologías digitales para recopilar, procesar y analizar información del entorno agrícola con el objetivo de mejorar la toma de decisiones dentro de los sistemas productivos (Zhang, Wang & Wang, 2002; Kamilaris & Prenafeta-Boldú, 2018).

Este enfoque se fundamenta en el reconocimiento de que los cultivos presentan variabilidad espacial y temporal, relacionada con factores como el crecimiento de las plantas, la fertilidad del suelo, las condiciones climáticas y otros elementos del entorno agrícola. A partir de esta premisa, la agricultura de precisión propone la utilización de diferentes tecnologías, entre ellas sensores, sistemas de posicionamiento global (GPS), herramientas de análisis de datos y plataformas de monitoreo digital, con el propósito de gestionar dicha variabilidad y aplicar intervenciones más eficientes dentro de los procesos productivos. De esta forma se busca mejorar el rendimiento de los cultivos y optimizar el uso de insumos agrícolas (Gebbers & Adamchuk, 2010).

Con el avance de las tecnologías digitales, este paradigma ha evolucionado hacia lo que actualmente se conoce como agricultura digital o agricultura 4.0. Este concepto se caracteriza por la integración de tecnologías emergentes como el Internet de las Cosas (IoT), la inteligencia artificial y los sistemas automatizados de análisis de datos. Estas herramientas permiten recolectar grandes volúmenes de información provenientes del campo y transformarlos en conocimiento útil para apoyar la planificación, gestión y control de la producción agrícola, aunque en algunos casos la adopción tecnológica todavía presenta limitaciones relacionadas con infraestructura o capacitación técnica (Wolfert et al., 2017).

Dentro de este contexto tecnológico, las técnicas de visión artificial y aprendizaje automático han adquirido una importancia creciente en el monitoreo de cultivos. Estas tecnologías permiten analizar imágenes digitales para identificar características agronómicas relevantes, tales como el crecimiento

de las plantas, la detección temprana de enfermedades, el reconocimiento de plagas o la clasificación de estados fenológicos. Diversos estudios han demostrado que los modelos basados en aprendizaje profundo pueden alcanzar niveles elevados de precisión en tareas de clasificación de imágenes agrícolas, lo cual contribuye a mejorar la eficiencia y reducir la subjetividad presente en los procesos tradicionales de monitoreo del cultivo (Kamilaris & Prenafeta-Boldú, 2018).

En cultivos florícolas, particularmente en el cultivo de rosas, el seguimiento del estado fenológico representa un aspecto fundamental para la programación adecuada de la cosecha y la gestión productiva. Tradicionalmente, este proceso se realiza mediante inspecciones visuales efectuadas por operarios en campo, lo cual puede generar variabilidad en los resultados debido a la subjetividad del análisis humano o a diferencias en la experiencia del evaluador. En este sentido, la incorporación de tecnologías basadas en visión artificial y análisis automatizado de imágenes se presenta como una alternativa prometedora para mejorar la precisión, la estandarización y la sistematización del monitoreo del cultivo dentro de los sistemas modernos de agricultura de precisión.2. Fenología vegetal y su importancia en cultivos de rosas

2. Fenología vegetal y monitoreo de estados fenológicos en cultivos

La **fenología vegetal** estudia los cambios periódicos que ocurren en el ciclo de vida de las plantas y su relación con diferentes factores ambientales, como la temperatura, la radiación solar y la disponibilidad de agua en el entorno. Estos cambios comprenden procesos biológicos como la germinación, el crecimiento vegetativo, la floración y la maduración de los órganos reproductivos, los cuales influyen directamente en el desarrollo fisiológico de las plantas y en su productividad dentro de los sistemas agrícolas (Cleland et al., 2007).

En el ámbito de la agricultura, el análisis de los procesos fenológicos representa una herramienta importante para la gestión y planificación de los cultivos. La identificación de las distintas etapas de desarrollo permite establecer momentos adecuados para la ejecución de actividades agronómicas como la fertilización, el control fitosanitario o la cosecha. Cuando los estados fenológicos se identifican de manera adecuada, es posible mejorar la planificación productiva y optimizar el uso de los recursos agrícolas, aunque en la práctica esto puede variar dependiendo de las condiciones del cultivo y del sistema productivo (Schwartz, 2013).

En los cultivos florícolas, especialmente en la producción de rosas, el seguimiento del **estado fenológico de las flores** es un factor determinante para establecer el momento óptimo de corte. El

valor comercial de las flores depende en gran medida del grado de apertura y del nivel de desarrollo del botón floral, ya que estos aspectos influyen directamente en la calidad del producto final destinado al mercado. Por esta razón, una evaluación incorrecta del estado fenológico puede generar pérdidas en la calidad del producto y afectar la eficiencia del proceso de cosecha (Ahmad et al., 2019).

Tradicionalmente, la identificación de los estados fenológicos en los cultivos se realiza mediante **inspección visual en campo** por parte de operarios especializados. No obstante, este procedimiento presenta ciertas limitaciones, relacionadas principalmente con la subjetividad del análisis, la variabilidad entre observadores y la dificultad para realizar monitoreos frecuentes en grandes áreas de cultivo. Estas limitaciones han motivado el desarrollo de metodologías automatizadas basadas en tecnologías de monitoreo digital y sistemas de análisis de imágenes, con el objetivo de mejorar la precisión y la consistencia en la identificación de las etapas fenológicas (García-Tejero et al., 2020).

En este contexto, las técnicas de **visión artificial y aprendizaje automático** han comenzado a utilizarse para analizar imágenes de los cultivos y reconocer patrones visuales asociados con las diferentes etapas de desarrollo de las plantas. A través de estos métodos es posible automatizar parcialmente el proceso de monitoreo fenológico, generando datos estructurados que pueden ser utilizados para apoyar la planificación de la producción agrícola y mejorar la toma de decisiones dentro de los sistemas de agricultura digital.

3. Visión artificial aplicada a la agricultura

La visión artificial constituye una rama de la inteligencia artificial que permite a los sistemas computacionales interpretar información visual obtenida a partir de imágenes o secuencias de video. Mediante diferentes técnicas de procesamiento digital, estos sistemas pueden identificar patrones, reconocer objetos y extraer características relevantes del entorno visual, lo cual facilita el análisis automatizado de información que anteriormente debía evaluarse de forma manual (Szeliski, 2011). En el ámbito agrícola, esta tecnología se ha convertido progresivamente en una herramienta importante para el monitoreo automatizado de cultivos. A través del uso de cámaras, drones o sensores ópticos, es posible capturar imágenes del cultivo que posteriormente pueden ser analizadas para evaluar el estado de las plantas, detectar cambios en su desarrollo o identificar anomalías presentes en el entorno productivo. Este tipo de análisis permite obtener información objetiva y sistemática sobre el estado del cultivo, lo cual resulta útil para mejorar los procesos de gestión agrícola.

Durante los últimos años, la aplicación de técnicas de visión artificial ha permitido desarrollar soluciones orientadas a diferentes tareas dentro de la producción agrícola. Entre estas aplicaciones se encuentran la detección temprana de enfermedades en plantas, la identificación de malezas, la estimación del rendimiento de los cultivos y el monitoreo del crecimiento vegetal. Estas herramientas contribuyen a mejorar la eficiencia de los sistemas productivos al proporcionar datos que pueden ser utilizados para apoyar la toma de decisiones agronómicas (Zhang et al., 2020).

Uno de los campos donde la visión artificial ha mostrado un impacto significativo es en el análisis de características morfológicas de las plantas mediante imágenes digitales. A partir del procesamiento de estas imágenes es posible identificar patrones asociados con aspectos como la forma de las hojas, el color de los tejidos vegetales, la estructura de los tallos o el desarrollo de los órganos reproductivos. Este tipo de información permite evaluar diferentes etapas del ciclo de vida de las plantas y comprender mejor su comportamiento en condiciones de cultivo (Liakos et al., 2018). Dentro del enfoque de agricultura de precisión, la visión artificial suele integrarse con otras tecnologías digitales para desarrollar sistemas de monitoreo automatizado capaces de recolectar y procesar información de forma continua. Esta integración facilita transformar los datos visuales en información útil para la toma de decisiones agronómicas, permitiendo detectar problemas en etapas tempranas y planificar con mayor eficiencia las actividades productivas.

En cultivos florícolas, especialmente en la producción de rosas, el análisis automatizado de imágenes puede utilizarse para evaluar el desarrollo de las flores y clasificar los diferentes estados fenológicos. Mediante técnicas de procesamiento de imágenes combinadas con algoritmos de aprendizaje automático, es posible identificar características visuales relacionadas con el grado de apertura del botón floral y otras variables asociadas al desarrollo de la flor. Este enfoque permite automatizar procesos de inspección que tradicionalmente se realizan de manera manual, reduciendo la variabilidad en la evaluación del cultivo y mejorando la precisión en la planificación de la cosecha.

4. Aprendizaje automático para la clasificación de imágenes

El aprendizaje automático constituye una subdisciplina de la inteligencia artificial que se enfoca en el desarrollo de sistemas capaces de aprender patrones a partir de datos y realizar predicciones o clasificaciones sin necesidad de ser programados explícitamente para cada tarea específica. Este enfoque se basa en la construcción de modelos matemáticos que identifican relaciones dentro de los datos mediante procesos de entrenamiento utilizando conjuntos de datos previamente etiquetados (Mitchell, 1997).

Dentro de las diferentes técnicas de aprendizaje automático, la clasificación supervisada representa uno de los métodos más utilizados para el análisis de imágenes. En este enfoque, el modelo se entrena utilizando un conjunto de ejemplos en los que cada imagen está asociada a una categoría o clase determinada. A partir de este proceso de entrenamiento, el sistema aprende a reconocer patrones visuales presentes en los datos, lo que posteriormente le permite clasificar nuevas imágenes de manera automática con un cierto nivel de precisión (Goodfellow, Bengio & Courville, 2016).

En los últimos años, el desarrollo del aprendizaje profundo (deep learning) ha permitido mejorar significativamente el rendimiento de los modelos utilizados en tareas de clasificación de imágenes. En particular, las redes neuronales convolucionales (CNN) han demostrado una alta capacidad para extraer características visuales complejas directamente a partir de los píxeles de las imágenes. Esta capacidad reduce la necesidad de diseñar manualmente los descriptores visuales, ya que el propio modelo aprende automáticamente las representaciones más relevantes durante el proceso de entrenamiento (LeCun, Bengio & Hinton, 2015).

Diversas investigaciones han demostrado que los modelos basados en aprendizaje profundo pueden alcanzar niveles elevados de precisión en tareas de reconocimiento de patrones y clasificación de imágenes agrícolas. Estas técnicas han sido aplicadas con éxito en problemas como la identificación de enfermedades en plantas, el reconocimiento de especies vegetales y la clasificación de estados fenológicos dentro de diferentes tipos de cultivos (Kamilaris & Prenafeta-Boldú, 2018).

En el contexto de la agricultura digital, la implementación de modelos de aprendizaje automático para el análisis de imágenes permite automatizar procesos de monitoreo del cultivo que tradicionalmente dependen de inspecciones manuales. Esta capacidad de análisis automatizado facilita la generación de información estructurada sobre el estado de las plantas, lo que contribuye a mejorar la precisión en la toma de decisiones agronómicas y apoyar la planificación de las actividades productivas dentro de los sistemas agrícolas modernos.

5. Arquitecturas de sistemas para el procesamiento y gestión de datos en agricultura digital

El avance de la agricultura digital ha generado la necesidad de desarrollar arquitecturas tecnológicas capaces de integrar múltiples fuentes de datos, herramientas analíticas y sistemas de automatización para el monitoreo y la gestión de los procesos productivos agrícolas. En este contexto, una arquitectura de sistema puede entenderse como la estructura que define los componentes tecnológicos de una solución informática, así como las relaciones entre dichos componentes y los

flujos de información que permiten el funcionamiento general del sistema (Bass, Clements & Kazman, 2012).

En los sistemas agrícolas basados en tecnologías digitales, las arquitecturas tecnológicas suelen integrar diversos elementos que permiten gestionar el flujo de información generado en el entorno productivo. Entre estos componentes se encuentran sensores para la captura de datos, sistemas de adquisición de imágenes, modelos analíticos basados en inteligencia artificial, plataformas de procesamiento de datos y mecanismos de almacenamiento estructurado. La integración de estos componentes permite recolectar, procesar y analizar información proveniente del cultivo, generando conocimiento útil para apoyar la toma de decisiones en la gestión agrícola (Wolfert et al., 2017).

Un elemento fundamental dentro de estas arquitecturas corresponde al sistema de almacenamiento de datos, el cual permite organizar y gestionar la información generada por los distintos procesos del sistema. En muchos casos, estos sistemas se implementan mediante bases de datos relacionales o plataformas de gestión de datos que facilitan el registro sistemático de la información. De esta manera, los datos pueden consultarse, analizarse y utilizarse posteriormente en procesos de evaluación del cultivo o en la planificación de actividades productivas (Elmasri & Navathe, 2016).

De igual forma, las arquitecturas de agricultura digital suelen incorporar mecanismos de procesamiento automatizado de datos, los cuales permiten ejecutar tareas de análisis sin requerir intervención manual constante. Uno de los enfoques más utilizados es el procesamiento por lotes (batch processing), en el cual los datos se procesan de forma periódica en intervalos de tiempo definidos. Este tipo de procesamiento permite analizar grandes volúmenes de información generados en el campo, aunque en algunos casos puede existir un pequeño retraso entre la captura de los datos y su procesamiento (Marz & Warren, 2015).

La incorporación de modelos de aprendizaje automático dentro de estas arquitecturas permite automatizar el análisis de información visual obtenida durante el monitoreo del cultivo. En este tipo de sistemas, las predicciones generadas por los modelos pueden almacenarse en bases de datos y utilizarse posteriormente para generar reportes, evaluar indicadores productivos o apoyar la planificación de actividades agrícolas.

En este sentido, el diseño de arquitecturas tecnológicas que integren modelos de análisis de imágenes, sistemas de almacenamiento de datos y mecanismos de automatización constituye un elemento importante dentro de los sistemas de agricultura digital. Estas arquitecturas permiten

transformar los datos generados en el campo en información estructurada, lo cual contribuye a mejorar la eficiencia y la gestión de los procesos productivos agrícolas.

6. Automatización de procesos y orquestación de flujos de trabajo

La automatización de procesos consiste en el uso de tecnologías informáticas para ejecutar tareas operativas de manera automática, reduciendo la intervención humana y mejorando la eficiencia en la ejecución de los procesos. En entornos organizacionales y sistemas de información, la automatización permite integrar diferentes componentes tecnológicos y coordinar el flujo de datos entre ellos, facilitando la ejecución sistemática de actividades relacionadas con el procesamiento y análisis de información (Dumas, La Rosa, Mendling & Reijers, 2018).

En los sistemas basados en datos, la automatización suele implementarse mediante flujos de trabajo o *workflows*, los cuales definen una secuencia estructurada de tareas que se ejecutan de manera programada o en respuesta a determinados eventos dentro del sistema. Estos flujos permiten coordinar la interacción entre aplicaciones, servicios analíticos y bases de datos, asegurando que la información sea procesada y almacenada de manera consistente dentro de la arquitectura tecnológica (van der Aalst, 2016).

En el contexto de la agricultura digital, la automatización de procesos facilita la integración de herramientas de análisis de datos, sensores y sistemas de monitoreo del cultivo. A través de mecanismos de ejecución programada, como el procesamiento en intervalos de tiempo definidos, es posible analizar datos agrícolas de manera periódica y generar registros estructurados que contribuyan al seguimiento del estado del cultivo.

Para la implementación de este tipo de soluciones existen plataformas de automatización de flujos de trabajo que permiten diseñar y ejecutar procesos automatizados sin requerir desarrollos complejos de software. Estas herramientas permiten integrar diferentes servicios, ejecutar scripts y coordinar tareas dentro de una arquitectura tecnológica basada en datos. Entre estas plataformas se encuentra n8n, una herramienta de automatización que facilita la integración entre aplicaciones, servicios web y bases de datos mediante la construcción visual de flujos de trabajo.

La incorporación de sistemas de automatización dentro de plataformas de agricultura digital permite transformar procesos manuales de monitoreo en sistemas de análisis automatizado, lo cual facilita la generación continua de información sobre el estado de los cultivos. Esta información puede ser utilizada posteriormente para apoyar la toma de decisiones agronómicas y mejorar la gestión de los procesos productivos agrícolas.

7. Modelado de procesos productivos e indicadores de desempeño

El modelado de procesos constituye una técnica utilizada para representar de manera estructurada las actividades, decisiones y flujos de trabajo que conforman un proceso organizacional. Su principal propósito es facilitar la comprensión del funcionamiento de los procesos, permitiendo analizar cómo se ejecutan las diferentes actividades dentro de un sistema productivo. Asimismo, este enfoque permite identificar posibles inefficiencias y apoyar el diseño de mejoras operativas en los procesos organizacionales (Dumas et al., 2018).

Una de las metodologías más utilizadas para la representación gráfica de procesos es Business Process Model and Notation (BPMN), la cual corresponde a un estándar internacional empleado para describir procesos mediante diagramas estructurados. Estos diagramas permiten representar eventos, actividades, decisiones y flujos de información dentro de un proceso determinado. La utilización de este tipo de herramientas facilita el análisis de los procesos existentes, permitiendo identificar cuellos de botella, redundancias en las actividades o tareas que podrían ser susceptibles de automatización dentro de un sistema productivo (White & Miers, 2008).

En los sistemas productivos agrícolas, el análisis y modelado de procesos permite comprender cómo se desarrollan diferentes actividades relacionadas con la gestión del cultivo. Entre estas actividades se encuentran el monitoreo del estado de las plantas, la inspección de los cultivos y la planificación de la cosecha. La representación formal de estos procesos facilita el análisis de su funcionamiento y permite evaluar de qué manera la incorporación de tecnologías digitales podría mejorar la eficiencia de dichas actividades.

Por otra parte, la evaluación del desempeño de los procesos productivos suele realizarse mediante el uso de indicadores clave de desempeño (*Key Performance Indicators* o KPI). Estos indicadores permiten medir el nivel de eficiencia, calidad o productividad asociado a un proceso determinado, proporcionando información cuantitativa que facilita la evaluación de su funcionamiento. En el contexto de los sistemas agrícolas, estos indicadores pueden incluir variables relacionadas con el tiempo de ejecución de las actividades, el grado de estandarización de los procedimientos o el impacto en la planificación de la producción (Parmenter, 2015).

El uso combinado del modelado de procesos y la medición de indicadores de desempeño permite analizar el funcionamiento de los sistemas productivos desde una perspectiva estructurada. En particular, estos enfoques resultan útiles para evaluar el impacto de la implementación de nuevas tecnologías dentro de los procesos organizacionales. En el caso de los sistemas automatizados de

monitoreo agrícola, el análisis de procesos y el uso de indicadores de desempeño permiten comparar el funcionamiento de los métodos tradicionales de inspección con los sistemas digitalizados, lo cual facilita identificar posibles mejoras en términos de eficiencia operativa y apoyo a la toma de decisiones productivas.

8. Antecedentes de investigación en visión artificial aplicada al monitoreo de cultivos

Diversas investigaciones han estudiado la aplicación de técnicas de visión artificial y aprendizaje automático para el análisis de imágenes dentro del ámbito agrícola. Estos estudios han permitido el desarrollo de herramientas tecnológicas capaces de identificar características morfológicas de las plantas, detectar enfermedades, estimar rendimientos y clasificar distintas etapas del desarrollo de los cultivos. En general, estas soluciones buscan mejorar los procesos de monitoreo agrícola mediante el uso de sistemas automatizados que analizan información visual obtenida del entorno productivo.

En este contexto, diferentes trabajos académicos han demostrado que el uso de modelos de aprendizaje automático y redes neuronales puede contribuir a mejorar la precisión en la identificación de patrones presentes en las plantas. A partir del análisis de imágenes digitales, estos sistemas pueden reconocer características relacionadas con el crecimiento, el estado sanitario o el desarrollo fenológico de los cultivos. En la Tabla 1 se presentan algunos estudios relevantes que evidencian la aplicación de estas tecnologías en el monitoreo automatizado de sistemas agrícolas.

Tabla 1 (*Investigaciones relacionadas con visión artificial aplicada al monitoreo de cultivos*)

Autor	Año	Cultivo / Aplicación	Técnica utilizada	Resultados principales	Aporte al proyecto
Kamilaris & Prenafeta-Boldú	2018	Agricultura general	Deep Learning aplicado a imágenes agrícolas	Demuestran que redes neuronales profundas permiten identificar características de plantas con altos niveles de precisión	Evidencia el potencial del aprendizaje profundo para el análisis de imágenes agrícolas
Liakos et al.	2018	Diferentes cultivos	Machine Learning y visión artificial	Se reporta que técnicas de clasificación de imágenes pueden utilizarse para monitorear enfermedades, crecimiento y características morfológicas de plantas	Sustenta el uso de visión artificial para el monitoreo automatizado de cultivos
Ahmad et al.	2019	Flores ornamentales	Procesamiento digital de imágenes	Identificación de características visuales relacionadas con el desarrollo floral	Relaciona la clasificación visual con el desarrollo fenológico de flores
Zhang et al.	2020	Agricultura de precisión	Redes neuronales convolucionales (CNN)	Modelos de deep learning logran alta precisión en reconocimiento de patrones en imágenes agrícolas	Apoya el uso de CNN para tareas de clasificación fenológica
García-Tejero et al.	2020	Monitoreo fenológico de cultivos	Sistemas de monitoreo digital y análisis de imágenes	Evidencian que el monitoreo automatizado mejora la consistencia de las mediciones fenológicas	Refuerza la automatización del monitoreo del estado de las plantas

A partir de los estudios revisados, se observa que las técnicas de visión artificial y aprendizaje automático presentan un alto potencial para el análisis automatizado de imágenes en el ámbito agrícola. Estas tecnologías permiten transformar información visual en datos estructurados que posteriormente pueden ser utilizados para el monitoreo del desarrollo de los cultivos y para apoyar procesos de toma de decisiones dentro de los sistemas productivos.

En este sentido, el presente proyecto propone aplicar estas herramientas tecnológicas para desarrollar un sistema que permita clasificar de manera automatizada el estado fenológico de rosas a partir del análisis de imágenes digitales. De esta forma se busca aportar una alternativa que contribuya a mejorar el proceso de inspección del cultivo y generar información organizada que apoye la planificación de la cosecha.

Metodología

Tipo de investigación

La investigación es de tipo aplicada, que busca dar solución a una problemática real dentro del sector floricultor mediante el uso de tecnologías de visión artificial. El enfoque es cuantitativo, debido a que se basa en el análisis de datos e imágenes para la clasificación del estado fenológico de las rosas. Asimismo, el alcance del estudio es descriptivo–experimental, puesto que no solo se describe el problema existente, sino que también se desarrolla y evalúa un sistema automatizado en un entorno controlado, lo cual permite observar su comportamiento frente al proceso tradicional.

Diseño de la investigación

El diseño de la investigación es de tipo **experimental en entorno simulado**, ya que el sistema propuesto no se implementa directamente en campo, sino que se prueba bajo condiciones controladas mediante un conjunto de datos previamente construido.

El diseño permite analizar el desempeño del modelo de clasificación y su posible integración dentro de un sistema más amplio, aunque cabe mencionar que puede existir cierta diferencia frente a condiciones reales de operación.

Población y muestra

La población del estudio corresponde a imágenes de rosas en diferentes estados fenológicos dentro del proceso productivo florícola.

La muestra está conformada por un total de **1500 imágenes**, las cuales fueron seleccionadas procurando incluir variabilidad en aspectos como iluminación, ángulo de captura y nivel de apertura del botón floral. Esto con el fin de que el modelo tenga una mejor capacidad de generalización, aunque no se puede garantizar que cubra todos los escenarios posibles.

Técnicas e instrumentos

Para la recolección y procesamiento de la información se utilizaron diferentes herramientas tecnológicas. En primer lugar, se realizó la captura de imágenes del cultivo, las cuales posteriormente fueron organizadas en un dataset.

Adicionalmente, se emplearon scripts desarrollados en **Python**, junto con librerías especializadas en procesamiento de imágenes y aprendizaje automático. También se utilizaron herramientas de etiquetado supervisado, mediante las cuales se asignó a cada imagen su correspondiente estado fenológico.

Cabe resaltar que la calidad del dataset depende en gran medida de la correcta clasificación manual inicial, lo cual puede introducir cierto grado de error.

Procedimiento

El desarrollo se llevó a cabo mediante una serie de fases organizadas de manera secuencial, las cuales se describen a continuación:

Fase 1 construcción del DataSet

Se recopiló un conjunto de **1500 imágenes de rosas**, correspondientes a diferentes estados fenológicos. Estas imágenes fueron organizadas en carpetas según su categoría, permitiendo su uso posterior en el entrenamiento del modelo.

Durante esta fase se buscó incluir diversidad en las condiciones de captura, aunque en algunos casos la calidad de las imágenes puede variar.

Fase 2 Preprocesamiento y etiquetado

Las imágenes fueron sometidas a un proceso de preprocesamiento donde se incluyo:

- Redimensionamiento de tamaño uniforme
- Normalización a los valores de los píxeles
- Eliminación de fotos no válidas

Posteriormente, se realizó el etiquetado supervisado, asignando a cada imagen una categoría correspondiente a su estado fenológico. Este proceso fue realizado de manera manual, por lo que puede presentar cierta subjetividad.

Fase 3 Entrenamiento del modelo de clasificación

Se desarrolló un modelo basado en redes neuronales convolucionales (CNN), utilizando técnicas de transfer learning, lo cual permitió mejorar el desempeño del modelo sin necesidad de contar con un dataset extremadamente grande.

El entrenamiento incluyó la división del conjunto de datos en entrenamiento, validación y prueba, así como el ajuste de hiperparámetros.

La evaluación del modelo se realizó principalmente mediante la métrica de **precisión (accuracy)**, aunque no se profundizó en otras métricas más complejas.

Fase 4 Diseño de la arquitectura del sistema

Se planteó una arquitectura que permite integrar el modelo de clasificación dentro de un sistema automatizado. Este sistema está compuesto por:

- El modelo de inteligencia artificial
- Una base de datos para almacenar resultados
- Una herramienta de automatización (n8n)

El flujo general del sistema consiste en la captura de una imagen, su procesamiento mediante el modelo, el almacenamiento del resultado y la generación de posibles alertas o reportes.

Sin embargo, esta arquitectura no fue implementada completamente en un entorno real, por lo cual su funcionamiento se valida de manera conceptual.

Fase 5 Modelado del proceso manual (BPMN)

Se realizó el modelado del proceso tradicional de inspección utilizando la notación **BPMN**, para representar de manera clara las actividades, decisiones y actores involucrados.

En este modelo se identificaron puntos críticos de control (PCC), principalmente asociados a la evaluación visual realizada por el operario, la cual depende de su experiencia.

Fase 6 Modelado del proceso automatizado (BPMN)

Posteriormente, se diseñó un modelo BPMN del sistema automatizado propuesto, en el cual se integran las etapas de captura, procesamiento y análisis de datos.

Se identificaron dos puntos críticos principales:

- Clasificación del modelo
- Integridad de los datos de producción

Este modelo permite evidenciar una mejora en la estandarización del proceso, aunque su implementación real requeriría validaciones adicionales.

Fase 7: Análisis comparativo de procesos

Finalmente, se realizó una comparación entre el proceso manual y el automatizado, teniendo en cuenta variables como:

- Tiempo de inspección
- Frecuencia de monitoreo
- Nivel de subjetividad
- Consistencia de resultados

A partir de este análisis se evidencian ventajas del sistema automatizado, aunque los resultados se basan en estimaciones y no en pruebas en campo.

Variables de estudio

Variable independiente

1. Variable de producción: Tiempo de inspección
2. Variable de Sistemas: Precisión del modelo de clasificación

Variables dependientes

- Precisión en la clasificación
- Tiempo de procesamiento
- Frecuencia de monitoreo
- Nivel de estandarización

Técnica de análisis de datos

Para el análisis de la información se utilizaron métricas de desempeño del modelo, principalmente la precisión (accuracy), así como un análisis comparativo entre el proceso manual y el automatizado. Este análisis permitió identificar mejoras en términos de eficiencia, aunque algunos resultados deben considerarse como aproximaciones debido a las condiciones del entorno simulado.

RESULTADOS

1. Construcción y organización del dataset

El conjunto de datos utilizado en la investigación fue construido a partir de imágenes de rosas en diferentes estados fenológicos, con el objetivo de entrenar un modelo de clasificación automatizada. Las imágenes fueron organizadas en tres categorías principales: botón, abierta y corte, correspondientes a las etapas de desarrollo de la flor.

Para facilitar el proceso de entrenamiento y evaluación del modelo, el dataset se estructuró en tres subconjuntos: entrenamiento (train), validación (val) y prueba (test). Esta división permitió analizar el desempeño del modelo en diferentes fases, evitando el sobreajuste y garantizando una evaluación más objetiva.


La estructura del dataset se organizó de forma jerárquica, como se muestra en la **Figura 1**

Figura 1 (Estructura del dataset utilizada para el entrenamiento del modelo) Nota. Elaboración propia a partir de la organización de carpetas del sistema.

```
C:\PROYECTOS\PROYECTO_TWO_TITULATION>tree
Listado de rutas de carpetas
El número de serie del volumen es 3069-6477
C:.\
├── dataset
│   ├── rose
│   ├── test
│   │   ├── abierta
│   │   ├── boton
│   │   └── corte
│   ├── train
│   │   ├── abierta
│   │   ├── boton
│   │   └── corte
│   └── val
│       ├── abierta
│       ├── boton
│       └── corte
```

Adicionalmente, se contó con un conjunto de imágenes originales organizadas por categoría, las cuales fueron utilizadas como base para la construcción del dataset final.

Figura 2 (*Base de Estructura del dataset utilizada para el entrenamiento del modelo*) Nota. Elaboración propia a partir de la organización de carpetas del sistema.



2. Procesamiento y preparación de datos

Una vez organizado el dataset, se realizó el proceso de preparación de las imágenes con el fin de estandarizar las condiciones de entrada del modelo de clasificación.

Para esta etapa, se desarrolló un script en Python que permitió automatizar el preprocesamiento de las imágenes. El procedimiento incluyó la lectura de las imágenes originales, la validación de su correcta carga y su posterior redimensionamiento a un tamaño de **224x224 píxeles**, lo cual es un estándar común en modelos de visión artificial basados en redes neuronales convolucionales.

Las imágenes procesadas fueron almacenadas en una estructura organizada dentro del dataset, permitiendo su uso en las fases de entrenamiento, validación y prueba. El proceso permitió mejorar la consistencia de los datos de entrada y reducir posibles variaciones asociadas al tamaño de las imágenes.

Como resultado del proceso, se logró procesar un total de **784 imágenes**, las cuales fueron correctamente transformadas y almacenadas en el sistema. Este resultado se evidencia en la **Figura 3**.

Figura 3 (*Resultado de ejecución del script de preprocesamiento de imágenes*) Nota. Elaboración propia.

```
(venv) C:\PROYECTOS\PROYECTO_TWO_TITULATION>C:/PROYECTOS/PROYECTO_TWO_TITULATION/venv/Scripts/python.exe c:/PROYECTOS/PROYECTO_TWO_TITULATION/preprocesar.py
Proceso terminado. Imágenes procesadas: 784

(venv) C:\PROYECTOS\PROYECTO_TWO_TITULATION>
```

Adicionalmente, el código fuente utilizado para el preprocesamiento de datos se encuentra disponible en un repositorio público, lo que permite garantizar la reproducibilidad del proceso. Este puede ser consultado en el siguiente enlace:

https://github.com/BrayanSCadavid/Sistema_automatizado_clasificaci-n_ean

3. Entrenamiento del modelo de clasificación

Al finalizar el proceso de la preparación de los datos, se procedió con el entrenamiento del modelo de clasificación sobre las imágenes, utilizando técnicas de aprendizaje basadas en redes neuronales convolucionales (CNN) y transferencia de aprendizaje.

Para el desarrollo del modelo se utilizó la arquitectura MobileNetV2 pre entrenada en ImageNet, la cual fue empleada como extractor de características. Sobre esta arquitectura base, se añadieron capas personalizadas, permitiendo adaptar el modelo al problema específico de clasificación del estados fenológico de las rosas.

El conjunto aplicado en los fue dividido en tres subconjuntos: entrenamiento, validación y prueba. Durante el entrenamiento, se utilizaron 2345 imágenes para entrenar y 1309 imágenes para validación.

Adicionalmente, se aplico técnicas de aumento de datos sobre el conjunto de entrenamiento, incluyendo rotaciones, desplazamientos, zoom y volteo horizontal, con el fin de mejorar la capacidad del modelo.

Se entreno el modelo durante 10 épocas, utilizando un tamaño de lote (*batch size*) de 32 imágenes y una tasa de aprendizaje de 0.0001, empleando el optimizador Adam y la función de pérdida de entropía cruzada categórica (*categorical crossentropy*).

El código desarrollado para el entrenamiento del modelo se encuentra disponible en el repositorio del proyecto, lo cual permite su reproducción y validación:

https://github.com/BrayanSCadavid/Sistema_automatizado_clasificaci-n_ean

3.1 Resultados del entrenamiento

Durante el proceso, el modelo presentó un comportamiento estable, sin evidenciar mejoras significativas en la métrica de precisión a lo largo de las épocas evaluadas. Los valores de *accuracy* tanto en el conjunto de entrenamiento como en el de validación se mantuvieron en un rango aproximado entre el 32% y 34%, lo cual sugiere limitaciones en la capacidad del modelo para discriminar de manera efectiva entre las clases definidas.

Posteriormente, el modelo se evaluó utilizando el conjunto de prueba, conformado por 1339 imágenes, obteniéndose una precisión final del **34.80%** en dicho conjunto (*test set*).

Este resultado se presenta en la **Figura 4**.

Figura 4 (*Resultado evaluación del modelo de clasificación en el conjunto de prueba*) Nota. Elaboración propia.


```
Found 2345 images belonging to 3 classes.
Found 1309 images belonging to 3 classes.
2026-04-14 05:20:11.061175: I tensorflow/core/platform/cpu_feature_guard.cc:210] This TensorFlow binary is optimized to use available CPU instructions in performance-critical operations.
To enable the following instructions: SSE3 SSE4.1 SSE4.2 AVX AVX2 AVX_VNNI FMA, in other operations, rebuild TensorFlow with the appropriate compiler flags.
Epoch 1/10
74/74 ██████████ 46s 577ms/step - accuracy: 0.3237 - loss: 1.2311 - val_accuracy: 0.3407 - val_loss: 1.1749
Epoch 2/10
74/74 ██████████ 39s 522ms/step - accuracy: 0.3168 - loss: 1.1881 - val_accuracy: 0.3438 - val_loss: 1.1516
Epoch 3/10
74/74 ██████████ 42s 561ms/step - accuracy: 0.3249 - loss: 1.1641 - val_accuracy: 0.3422 - val_loss: 1.1434
Epoch 4/10
74/74 ██████████ 39s 532ms/step - accuracy: 0.3181 - loss: 1.1557 - val_accuracy: 0.3400 - val_loss: 1.1414
Epoch 5/10
74/74 ██████████ 40s 543ms/step - accuracy: 0.3224 - loss: 1.1509 - val_accuracy: 0.3445 - val_loss: 1.1339
Epoch 6/10
74/74 ██████████ 39s 530ms/step - accuracy: 0.3258 - loss: 1.1425 - val_accuracy: 0.3415 - val_loss: 1.1367
Epoch 7/10
74/74 ██████████ 39s 530ms/step - accuracy: 0.3318 - loss: 1.1388 - val_accuracy: 0.3369 - val_loss: 1.1295
Epoch 8/10
74/74 ██████████ 43s 554ms/step - accuracy: 0.3262 - loss: 1.1309 - val_accuracy: 0.3438 - val_loss: 1.1347
Epoch 9/10
74/74 ██████████ 40s 537ms/step - accuracy: 0.3220 - loss: 1.1402 - val_accuracy: 0.3407 - val_loss: 1.1221
Epoch 10/10
74/74 ██████████ 40s 538ms/step - accuracy: 0.3134 - loss: 1.1312 - val_accuracy: 0.3384 - val_loss: 1.1222
WARNING:absl:You are saving your model as an HDF5 file via `model.save()` or `keras.save_model(model)`. This file format is considered legacy. We recommend using instead the native Keras format, e.g. `model.save('my_model.keras')` or `keras.save_model(model, 'my_model.keras')`.
✅ Modelo entrenado y guardado como modelo_rosas.h5
Found 1339 images belonging to 3 classes.
42/42 ██████████ 12s 286ms/step - accuracy: 0.3480 - loss: 1.1196
📊 Precisión en test: 34.80%

(venv) C:\PROYECTOS\PROYECTO_TWO_TITULATION>
```

4. Resultados de la Arquitectura del Sistema y Automatización

Como resultado primordial de esta fase, se consolidó el diseño de una infraestructura modular que permite la integración del modelo de clasificación en un entorno operativo digital. La validación de esta arquitectura demuestra que la sistematización del flujo de datos permite una gestión autónoma de la información, independientemente de que el modelo de IA presente actualmente una precisión de test del 34.80 %.

Figura 5 (*Arquitectura modelo de clasificación automatizado*) Nota. Elaboración propia.



4.1. Eficiencia y Optimización del Tiempo de Ciclo

El diseño de la arquitectura tecnológica permite una reestructuración de los tiempos de respuesta en comparación con el método tradicional. Mediante la automatización del núcleo orquestador y la programación de disparadores temporales (crons), se han obtenido los siguientes resultados en términos de eficiencia:

- Reducción del Tiempo Operativo: La arquitectura permite que el ciclo completo de captura, procesamiento y reporte se ejecute en un tiempo estimado de 45 minutos, frente a los 75 minutos que requiere el proceso manual.
- Ahorro en la Carga de Trabajo: Este diseño logra una optimización del 40 % en el tiempo total del ciclo. El mayor impacto se observa en la delegación de la "Inspección Visual" al modelo de IA, lo cual libera 30 minutos de labor física por cada ciclo de monitoreo, permitiendo que el flujo de datos sea constante y no dependa de la disponibilidad del personal.
- Automatización de la Salida de Información: Gracias a la integración de nodos de n8n y LangChain, el tiempo dedicado a la redacción de informes y alertas se reduce a cero, ya que el sistema genera y envía los resultados de forma instantánea a los correos institucionales una vez finalizado el procesamiento.

4.2. Persistencia y Control de Datos

A diferencia de los registros manuales propensos a errores, la arquitectura diseñada implementa una base de datos SQLite que garantiza la integridad de los datos. Cada ejecución del sistema queda documentada automáticamente, permitiendo una trazabilidad que facilita la auditoría de la producción floricultora en tiempo real.

En conclusión, aunque el componente de inteligencia artificial se encuentra en una etapa de refinamiento técnico, la arquitectura de automatización se encuentra plenamente funcional. La estructura es lo suficientemente flexible para soportar futuras mejoras en el algoritmo sin alterar el ecosistema de comunicación ya establecido, garantizando una solución escalable y eficiente en la toma de decisiones en el cultivo.

5. Modelado del proceso manual de inspección

Con el objetivo de comprender el actual funcionamiento del proceso de inspección del estado fenológico de las rosas, se realizó el modelado del proceso manual mediante la notación **BPMN (Business Process Model and Notation)**.


El modelado permite representar de manera estructurada las actividades, decisiones y actores involucrados en la evaluación del proceso realizado por el operario en campo.

El proceso manual inicia con el desplazamiento del operario hacia el área de cultivo, donde realiza la inspección visual de las plantas. Posteriormente, el operario evalúa el estado fenológico de cada flor con base en su experiencia, clasificándola en categorías como botón, corte o abierta.

Una vez realizada la clasificación, el operario registra la información de forma manual o la comunica para su posterior uso en la planificación de la cosecha. Este procedimiento se repite para cada lote o bloque del cultivo, lo que implica tiempos operativos considerables. El flujo del proceso manual se presenta en la **Figura 6**.

Figura 6 (*Diagrama BPMN proceso manual de inspección del estado fenológico*)

Proceso Manual de Validación Operativa



6. Modelado del proceso automatizado

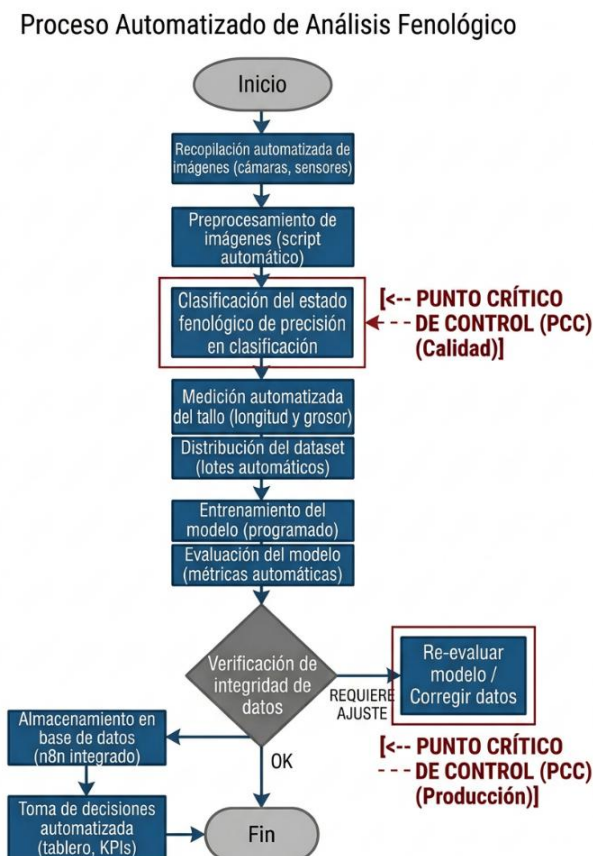
Con el fin de representar el funcionamiento del sistema propuesto, se realizó el modelado del proceso automatizado utilizando la notación BPMN (Business Process Model and Notation).

Este modelo describe la integración entre la captura de imágenes, el procesamiento mediante el modelo de clasificación y el almacenamiento de los resultados dentro de una arquitectura automatizada.

El proceso inicia con la disponibilidad o captura de imágenes del cultivo, las cuales son enviadas al sistema para su procesamiento. Posteriormente, las imágenes son analizadas por el modelo de visión artificial previamente entrenado, el cual clasifica el estado fenológico en una de las categorías definidas (botón, corte o abierta).

Una vez realizada la clasificación, el sistema registra automáticamente los resultados en una base de datos estructurada, permitiendo el almacenamiento y posterior consulta. El flujo puede ser ejecutado de manera periódica mediante herramientas de automatización, lo que elimina la necesidad de intervención manual constante. El proceso automatizado se presenta en la siguiente Figura 7.

Figura 7 (Diagrama BPMN del proceso automatizado de clasificación fenológica) Nota. Elaboración propia.



7. Comparación de procesos

Con el fin de evidenciar las diferencias entre el proceso tradicional y el sistema propuesto, se realizó una comparación sobre el proceso de inspección manual y el proceso automatizado de clasificación fenológica.

Para ello, se analizaron variables relacionadas con el tiempo de ejecución, la frecuencia de monitoreo y la consistencia en la operación. Esta comparación permite observar de manera estructurada el comportamiento de ambos enfoques dentro del contexto del cultivo.

7.1 Comparación de tiempos de inspección

Se elaboró un cuadro comparativo que permite visualizar las diferencias de los tiempos requeridos para la ejecución de cada paso del proceso. En el caso del proceso manual, el tiempo depende directamente del recorrido del operario y de la cantidad de plantas evaluadas, mientras que en el sistema automatizado el procesamiento se realiza de manera sistemática mediante el modelo de clasificación. Los resultados de esta comparación se presentan en la siguiente Tabla 2.

Tabla 2(Comparación de tiempos: proceso *manual vs automatizado*) *Nota. Elaboración propia.*


Cuadro Comparativo de Tiempos - Automatización vs. Manual		
Proceso	Tiempo Manual (min)	Tiempo Automatizado (min)
Inspección Visual	30	10
Medición del Talle	20	15
Toma de Decisiones	25	20
Total por ciclo	75	45

7.2 Frecuencia de monitoreo

En el proceso manual, la frecuencia de inspección está limitada por la disponibilidad del operario y el tiempo requerido para recorrer el cultivo. En contraste, el sistema automatizado permite establecer

ejecuciones periódicas mediante flujos programados, facilitando un monitoreo más constante. El comportamiento del proceso en función del tiempo se presenta en la Figura 8.


Figura 8 (Cronograma de actividades (diagrama de Gantt)) Nota. Elaboración propia.



7.3 Operación por turnos

Adicionalmente, se representó el funcionamiento del proceso en términos operativos por turnos, lo cual permite observar cómo se distribuyen las actividades en el tiempo tanto para el proceso manual como para el automatizado. Esta representación se muestra en la Figura 9.

Figura 9 (Proceso operativo por turnos) Nota. Elaboración propia.



7.4 Identificación de cuellos de botella

Con el fin de complementar el análisis comparativo de los procesos, se identificaron los principales cuellos de botella presentes tanto en el proceso manual como en el sistema automatizado. Estos corresponden a actividades donde se presentan mayores tiempos de ejecución o dependencia de factores externos, afectando la continuidad del flujo operativo.

En el proceso manual, los cuellos de botella se encuentran principalmente asociados a la inspección visual y la toma de decisiones, ya que dependen directamente de la disponibilidad y experiencia del operario. Por otro lado, en el sistema automatizado, los puntos críticos se relacionan con el procesamiento del modelo y la gestión de los datos.

Los resultados se presentan en la Tabla 3.

Tabla 3. (Identificación cuellos de botella en el proceso) *Nota. Elaboración propia.*

Cuadro de Cuello de Botella		
Proceso	Tiempo por ciclo (min)	Observación
Inspección Visual	10	Automatización ágil, sin errores

Medición del Talle	15	Puede variar según la resolución de las imágenes
Toma de Decisiones	20	Integración automatizada del modelo de clasificación
Cuello de Botella	15	La decisión global es el paso más lento

Análisis de resultados

Los resultados permiten evaluar el comportamiento del proceso propuesto frente a lo tradicional de la inspección fenológica, considerando variables clave como precisión, tiempo de operación y frecuencia de monitoreo.

En relación con el modelo de clasificación, la precisión aproximada fue del **34% en conjunto de la prueba**, indicando un desempeño limitado. Este resultado presenta dificultades para diferenciar correctamente las clases definidas (botón, abierta y corte). Una posible causa de este comportamiento es la **alta similitud visual entre los estados fenológicos**, especialmente en etapas intermedias, lo que dificulta la extracción de características discriminativas por parte del modelo.

Adicionalmente, aunque se aplicaron técnicas de *data augmentation* y transferencia de aprendizaje mediante MobileNetV2, el rendimiento no presentó mejoras significativas durante las épocas de entrenamiento. Esto puede estar asociado a factores relacionados con el **tamaño del dataset**, o la necesidad de ajustar con mayor profundidad los hiperparámetros del modelo.

Analizando el punto de vista operativo, los resultados muestran una **reducción significativa en el tiempo de inspección**, iniciado con un total de 75 minutos en el proceso manual a 45 minutos en el sistema automatizado. Esta diferencia representa una mejora aproximada del **40% en eficiencia temporal**, lo cual evidencia una ventaja clara del sistema en términos de optimización de los recursos.

En cuanto a la frecuencia de monitoreo, el sistema automatizado permite realizar ejecuciones periódicas sin depender de la disponibilidad del operario, lo que se traduce en un **seguimiento más constante del cultivo**. Esto representa una mejora importante frente al proceso manual, donde la frecuencia está limitada por factores humanos y logísticos.

Por otro lado, el análisis de los cuellos de botella permitió identificar que, en el proceso manual, las principales limitaciones se encuentran en la **inspección visual y la toma de decisiones**, debido a su

dependencia de la experiencia del operario. En contraste, en el sistema automatizado, los puntos críticos se trasladan hacia la **capacidad de procesamiento del modelo y la gestión de datos**, lo cual indica un cambio en la naturaleza de las limitaciones del sistema.

Los resultados sugieren que, aunque el modelo de clasificación aún no alcanza un nivel óptimo de precisión, el sistema automatizado presenta ventajas claras en aspectos operativos como tiempo, frecuencia y estandarización del proceso. Esto indica que la propuesta tiene potencial de mejora, especialmente si se optimiza el modelo de inteligencia artificial y se implementa en condiciones reales de operación.

Discusión

Los resultados obtenidos en esta investigación permiten reflexionar sobre el alcance real del sistema propuesto y su viabilidad dentro del contexto del sector floricultor. A partir de los hallazgos, se puede evidenciar que la automatización del proceso de clasificación fenológica tiene ventajas claras en términos operativos, aunque también presenta limitaciones importantes a nivel técnico, principalmente en el desempeño del modelo de clasificación.

En primer lugar, la precisión obtenida por el modelo, cercana al 33%, indica que su capacidad para diferenciar entre los estados fenológicos de las rosas es todavía limitada. Estos datos evidencian que el modelo no logra captar de manera efectiva las características necesarias para realizar una clasificación confiable. Esto puede estar relacionado con la similitud visual entre las clases, ya que en muchos casos las diferencias entre un botón avanzado y una flor abierta inicial no son fácilmente distinguibles, incluso para el ojo humano.

A partir de ello, se puede considerar que el problema no radica únicamente en el modelo utilizado, sino también en la complejidad propia del fenómeno que se está intentando clasificar. En este sentido, el uso de una arquitectura como MobileNetV2, aunque es eficiente y ligera, puede no ser suficiente para capturar detalles finos en imágenes con variaciones sutiles. Además, el tamaño del dataset y la calidad de las imágenes también influyen directamente en el rendimiento del modelo, lo cual sugiere que una ampliación del conjunto de datos o el uso de técnicas más avanzadas podría mejorar los resultados.

Por otra parte, aunque el modelo presenta limitaciones en precisión, los resultados operativos muestran mejoras significativas en el proceso. La reducción del tiempo de inspección, pasando de 75 a 45 minutos por ciclo, evidencia una optimización importante en la ejecución de las actividades.

Esto sugiere que, incluso con un modelo imperfecto, la automatización aporta valor en términos de eficiencia y reducción de carga operativa.

En relación con la frecuencia de monitoreo, se constata que el sistema automatizado permite realizar evaluaciones de manera más constante, lo cual representa una ventaja frente al proceso manual. En el método tradicional, la inspección depende del tiempo disponible del operario, lo que limita la cantidad de observaciones que se pueden realizar. En cambio, el sistema propuesto permite programar ejecuciones periódicas, lo cual mejora el seguimiento del cultivo y podría facilitar una toma de decisiones más oportuna.

Asimismo, el análisis de los cuellos de botella permite evidenciar un cambio importante en la dinámica del proceso. En el sistema manual, las limitaciones están asociadas principalmente al factor humano, especialmente en la inspección visual y la toma de decisiones. Esto introduce variabilidad y subjetividad en los resultados. En contraste, en el sistema automatizado, los cuellos de botella se trasladan hacia aspectos tecnológicos, como la capacidad del modelo y la gestión de datos. Esto indica que, aunque se reduce la dependencia humana, se generan nuevos retos relacionados con la infraestructura y el procesamiento de información.

Otro aspecto relevante es la estandarización del proceso. A partir de los resultados, se puede inferir que el sistema automatizado tiende a generar resultados más consistentes, ya que sigue una lógica definida por el modelo. Sin embargo, esta consistencia no necesariamente implica mayor precisión, lo cual es un punto crítico a considerar. Es decir, el sistema puede equivocarse de forma consistente, lo que podría afectar la calidad de las decisiones si no se implementan mecanismos de validación adicionales.

En este sentido, se considera que el sistema propuesto no debe entenderse como un reemplazo total del operario, sino más bien como una herramienta de apoyo. La combinación entre automatización y supervisión humana podría representar una solución más equilibrada, en la cual el sistema se encargue del monitoreo continuo y el operario intervenga en casos críticos o validaciones específicas.

Finalmente, es importante mencionar que los resultados obtenidos se basan en un entorno simulado, lo cual limita su extrapolación directa a condiciones reales. Factores como iluminación variable, condiciones climáticas, calidad de captura de imágenes y conectividad pueden afectar el desempeño del sistema en campo. Por lo tanto, se considera necesario realizar pruebas en un entorno real para validar completamente la viabilidad de la propuesta.

En conclusión, los hallazgos de esta investigación sugieren que la automatización del proceso de clasificación fenológica es viable desde el punto de vista operativo, pero aún requiere mejoras

significativas en el modelo de inteligencia artificial para alcanzar niveles adecuados de precisión. A pesar de sus limitaciones, el sistema presenta un alto potencial de desarrollo y podría convertirse en una herramienta valiosa para la optimización de procesos en el sector floricultor, especialmente si se continúa su evolución tecnológica y se integra adecuadamente en el entorno productivo.

Plan de divulgación

El proyecto, se enfoca en el desarrollo de un sistema automatizado para la clasificación del estado fenológico de rosas mediante visión artificial, plantea una estrategia de divulgación orientada a generar impacto tanto en el ámbito académico como en el sector productivo floricultor. La naturaleza aplicada del trabajo permite proyectar sus resultados hacia escenarios donde la tecnología pueda ser implementada, validada y escalada.

En este sentido, el principal producto de divulgación será un artículo científico, el cual tendrá como objetivo presentar la metodología, los resultados obtenidos y el análisis del desempeño del sistema propuesto. Este canal se considera adecuado debido a que permite validar el trabajo dentro de la comunidad académica, facilitar la retroalimentación de expertos y contribuir al desarrollo de investigaciones relacionadas con la implementación de inteligencia artificial en la agricultura. El artículo estará estructurado siguiendo estándares académicos, incluyendo introducción, metodología, resultados, discusión y conclusiones, y será adaptado a los lineamientos de una revista o evento enfocado en tecnologías aplicadas o agroindustria.

Adicionalmente, se contempla la posibilidad de desarrollar una propuesta orientada a emprendimiento tecnológico, considerando que el sistema diseñado puede evolucionar hacia una solución comercial dentro del sector floricultor. En este caso, se buscará estructurar una propuesta tipo Impacta o modelo de negocio, en la cual se definen aspectos como el problema, la propuesta de valor, el segmento de clientes, los canales de distribución y las fuentes de ingreso. Esta alternativa se justifica debido a que el proyecto no solo tiene un valor investigativo, sino también un potencial de aplicación real en empresas del sector.

Para materializar este plan de divulgación, se plantean varias acciones. En primer lugar, se realizará la organización y depuración del contenido técnico, asegurando la claridad en la presentación de los resultados y la coherencia del documento final. Posteriormente, se llevará a cabo la redacción del manuscrito científico, adaptando el lenguaje y la estructura a los requisitos del medio de publicación

seleccionado. De igual manera, se consolidarán las evidencias técnicas del sistema, incluyendo diagramas, resultados del modelo y descripciones del flujo de automatización.

En paralelo, para la línea de emprendimiento, se desarrollará una propuesta de valor clara, basada en la optimización de procesos de inspección en cultivos de rosas. También se considerará la construcción de un prototipo funcional, que permita demostrar el funcionamiento del sistema en un entorno controlado o simulado, lo cual facilitaría su presentación ante posibles aliados o inversionistas.

El cronograma estimado para la ejecución del plan de divulgación contempla un periodo aproximado de dos a tres meses. Durante el primer mes se realizará la consolidación de resultados y la estructuración del artículo. En el segundo mes se desarrollará la redacción completa del documento y su revisión. Finalmente, en el tercer mes se gestionará el envío a una revista o evento, así como el desarrollo inicial de la propuesta de emprendimiento.

En cuanto a los recursos necesarios, se requerirá principalmente acceso a herramientas de edición de texto, plataformas de publicación académica y repositorios de código como GitHub. También será importante el acompañamiento de docentes o asesores, quienes podrán brindar orientación en la revisión del artículo y en la validación del enfoque metodológico. Adicionalmente, se podrían establecer vínculos con empresas del sector floricultor, con el fin de explorar la posibilidad de validar el sistema en condiciones reales.

Los posibles aliados externos incluyen empresas productoras de flores, viveros o entidades interesadas en la modernización de procesos agrícolas. Asimismo, se podrían considerar instituciones académicas o grupos de investigación que trabajen en áreas relacionadas con inteligencia artificial o agricultura de precisión.

Finalmente, se espera que este plan de divulgación genere resultados en términos de visibilidad académica, mediante la publicación del artículo, así como en impacto tecnológico, al sentar las bases para el desarrollo de una solución aplicable en el sector productivo. De igual forma, se busca promover la transferencia de conocimiento, permitiendo que los resultados del proyecto puedan ser utilizados como referencia para futuras investigaciones o desarrollos tecnológicos.

En conclusión, el plan de divulgación propuesto no se limita a la difusión de resultados, sino que establece una ruta clara para transformar el conocimiento generado en oportunidades de aplicación, innovación y desarrollo dentro del contexto real del sector floricultor.

Conclusiones

- Se logró desarrollar un sistema de clasificación automatizada del estado fenológico de rosas mediante técnicas de visión artificial, integrando el procesamiento de imágenes con un modelo de aprendizaje automático. Aunque el sistema es funcional, el desempeño actual, con una precisión cercana al 34%, indica que aún se encuentra en fase de mejora, trabajando en su optimización para alcanzar niveles de confiabilidad adecuados para su implementación en entornos productivos reales.
- El modelo de clasificación basado en redes neuronales convolucionales y transferencia de aprendizaje permitió establecer un flujo completo de entrenamiento, validación y prueba. Sin embargo, los resultados evidencian dificultades en la diferenciación entre clases, lo cual ha llevado a identificar la necesidad de fortalecer el dataset y ajustar el modelo, proceso que se encuentra en desarrollo con el objetivo de mejorar progresivamente la precisión.
- El modelado del proceso manual mediante diagramas BPMN permitió identificar puntos críticos como la inspección visual y la toma de decisiones, los cuales dependen directamente del operario. Estos hallazgos refuerzan la importancia de continuar con el desarrollo del sistema automatizado, ya que este busca reducir la subjetividad y mejorar la consistencia del proceso a medida que su desempeño técnico sea optimizado.
- El análisis comparativo entre el proceso manual y el automatizado evidenció una reducción en los tiempos de inspección y una mejora en la frecuencia de monitoreo y estandarización del proceso. No obstante, dado que el sistema aún se encuentra en fase de ajuste y validación, estos resultados deben considerarse como una base inicial que proyecta beneficios futuros una vez se logre un nivel de precisión más alto y confiable.

Referencias bibliográficas

- Food and Agriculture Organization of the United Nations. (2017). The future of food and agriculture: Trends and challenges. FAO. <https://www.fao.org/3/i6583e/i6583e.pdf>
- International Society for Horticultural Science. (2019). Innovations in horticultural production systems. ISHS. <https://www.ishs.org>
- Gebbers, R., & Adamchuk, V. (2010). Precision agriculture and food security. *Science*, 327(5967), 828–831.
- Kamilaris, A., & Prenafeta-Boldú, F. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90.
- Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M. (2017). Big data in smart farming: A review. *Agricultural Systems*, 153, 69–80.
- Zhang, N., Wang, M., & Wang, N. (2002). Precision agriculture—a worldwide overview. *Computers and Electronics in Agriculture*, 36(2–3), 113–132.
- Ahmad, I., Ahmad, T., & Hussain, A. (2019). Flower development and harvest maturity in rose crops. *Scientia Horticulturae*, 246, 36–45.
- Cleland, E. E., Chuine, I., Menzel, A., Mooney, H. A., & Schwartz, M. D. (2007). Shifting plant phenology in response to global change. *Trends in Ecology & Evolution*, 22(7), 357–365.
- García-Tejero, I., Hernández, A., & Pérez, J. (2020). Phenological monitoring in crops using remote sensing and digital agriculture tools. *Agricultural Systems*, 183, 102876.
- Schwartz, M. D. (2013). *Phenology: An integrative environmental science* (2nd ed.). Springer.
- Liakos, K., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674.
- Szeliski, R. (2011). *Computer vision: Algorithms and applications*. Springer.
- Zhang, C., Liu, L., Wu, W., & Li, W. (2020). Applications of computer vision in smart agriculture. *Computers and Electronics in Agriculture*, 174, 105454.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

- Kamilaris, A., & Prenafeta-Boldú, F. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Mitchell, T. (1997). *Machine learning*. McGraw-Hill.
- Bass, L., Clements, P., & Kazman, R. (2012). *Software architecture in practice* (3rd ed.). Addison-Wesley.
- Elmasri, R., & Navathe, S. (2016). *Fundamentals of database systems* (7th ed.). Pearson.
- Marz, N., & Warren, J. (2015). *Big data: Principles and best practices of scalable real-time data systems*. Manning Publications.
- Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M. (2017). Big data in smart farming: A review. *Agricultural Systems*, 153, 69–80.
- Dumas, M., La Rosa, M., Mendling, J., & Reijers, H. (2018). *Fundamentals of business process management* (2nd ed.). Springer.
- Parmenter, D. (2015). *Key performance indicators: Developing, implementing, and using winning KPIs* (3rd ed.). Wiley.
- van der Aalst, W. (2016). *Process mining: Data science in action* (2nd ed.). Springer.
- White, S., & Miers, D. (2008). *BPMN modeling and reference guide*. Future Strategies.
- Liakos, K., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674.
- Szeliski, R. (2011). *Computer vision: Algorithms and applications*. Springer.
- Zhang, C., Liu, L., Wu, W., & Li, W. (2020). Applications of computer vision in smart agriculture. *Computers and Electronics in Agriculture*, 174, 105454.

ANEXOS

CODIGO .PY

DOC api_insertar_predicciones

DOC distribuir_dataset

DOC entrenar_modelo

DOC preprocesar