

**Análisis comparativo de modelos de aprendizaje automático en la identificación de las  
Fases en la Embriogénesis Somática del Arándano (*Vaccinium Corymbosum*)**

Yilma Estefanía Sora Albornoz

Raúl Santiago Valencia Cortés

Asesor

Julio Eduardo Mejía Manzano

Universidad Nacional Abierta y a Distancia UNAD  
Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI  
Especialización en Ciencia de Bases de Datos y Analítica

2025

---

Nombre Director de Trabajo de Grado

---

Jurado

---

Jurado

## Dedicatoria

Dedico este trabajo de investigación a mi madre, Doris Cortés, por su amor infinito y por enseñarme que con dedicación y perseverancia se pueden alcanzar todas las metas. Gracias por ser mi primera maestra y por creer en mí incluso cuando yo dudaba.

A mi padre, Raúl Valencia, por ser mi ejemplo de fortaleza y determinación. Por mostrarme el valor del trabajo bien hecho y por impulsarme siempre a dar lo mejor de mí en cada proyecto que emprendo.

A mi hermano, Jeison Valencia, por su apoyo incondicional, por las conversaciones que enriquecieron mis ideas y por estar presente en cada paso de este camino académico.

A mi compañera de investigación, Estefanía Sora, por su constante esfuerzo y gran actitud en cada uno de los aspectos de este proyecto. Ha sido un privilegio recorrer este camino académico junto a una profesional tan talentosa y entusiasta.

*Raúl Santiago Valencia Cortés.*

A mis padres, Pablo Sora y Marcela Albornoz, por ser una constante fuente de inspiración a través de su pensamiento crítico y vocación investigativa. Gracias por guiarme, motivarme y compartir conmigo su experiencia, lo cual fue fundamental para desarrollar el gusto por la investigación y culminar con éxito este proceso.

A mi hermano Sebastián Sora, por su comprensión incondicional y por ser un ejemplo constante que me impulsa a seguir adelante.

A Raúl Santiago, por ser un compañero excepcional en el desarrollo de esta monografía.

Agradezco profundamente su compromiso, dedicación y el esfuerzo compartido que hicieron de este trabajo una experiencia enriquecedora.

*Yilma Estefanía Sora Albornoz.*

## **Agradecimientos**

A Dios, por ser luz, guía e inspiración constante a lo largo de este camino académico y personal.

Al tutor Julio Eduardo Mejía Manzano, director de este proyecto de grado, por su dedicación, orientación y valiosos aportes durante cada etapa del proceso.

A los docentes de la Universidad Nacional Abierta y a Distancia – UNAD, por brindar conocimientos, herramientas y acompañamiento que enriquecieron nuestra formación durante la especialización.

Extendemos nuestro más sincero agradecimiento a todas las personas que, con su apoyo y compromiso, hicieron posible la realización de este trabajo de investigación. Y a todas aquellas personas que, de una u otra manera, nos brindaron su apoyo y aliento. A quienes no mencionamos directamente, no por olvido del corazón sino de la razón, les guardamos un profundo agradecimiento.

## Resumen

La presente monografía realiza un análisis comparativo de algunos modelos de aprendizaje automático aplicados a la identificación y clasificación de las fases de embriogénesis somática en el cultivo de arándano (*Vaccinium Corymbosum*). Mediante una revisión sistemática siguiendo la metodología PRISMA, se identificaron y analizaron investigaciones recientes sobre aplicaciones de inteligencia artificial en la caracterización morfológica de estructuras vegetales, con énfasis en los procesos embriogénicos. Los resultados evidencian que las Redes Neuronales Convolucionales (CNN) y las Máquinas de Soporte Vectorial (SVM) son los modelos más frecuentemente implementados en este campo, destacando particularmente la combinación CNN-SVM con una precisión de 99.91% en la detección de enfermedades en plantas. Para la embriogénesis somática específicamente, el modelo de Regresión de Soporte Vectorial (SVR) alcanzó la mayor precisión (96.6%), demostrando su eficacia para la caracterización morfológica de estructuras embriogénicas. La precisión media general de los modelos analizados para embriogénesis somática fue de 92.23%, evidenciando el alto potencial del aprendizaje automático como herramienta para optimizar los procesos de propagación clonal del arándano, reducir la subjetividad en la identificación de fases embriogénicas, minimizar la manipulación del material vegetal y disminuir los riesgos de contaminación. Esta investigación proporciona una base metodológica para futuras implementaciones de sistemas automatizados de caracterización morfológica que pueden contribuir significativamente a la eficiencia y rentabilidad del cultivo comercial del arándano en Colombia.

**Palabras claves:** embriogénesis somática, aprendizaje automático, arándano, agricultura de precisión.

## Abstract

This monograph presents a comparative analysis of various machine learning models applied to the identification and classification of somatic embryogenesis phases in blueberry (*Vaccinium corymbosum*) cultivation. Through a systematic review following the PRISMA methodology, recent research on artificial intelligence applications in the morphological characterization of plant structures was identified and analyzed, with emphasis on embryogenic processes. The results show that Convolutional Neural Networks (CNN) and Support Vector Machines (SVM) are the most frequently implemented models in this field, particularly highlighting the CNN-SVM combination with an accuracy of 99.91% in plant disease detection. Specifically for somatic embryogenesis, the Support Vector Regression (SVR) model achieved the highest accuracy (96.6%), demonstrating its effectiveness for morphological characterization of embryogenic structures. The overall average accuracy of the analyzed models for somatic embryogenesis was 92.23%, evidencing the high potential of machine learning as a tool to optimize clonal propagation processes of blueberry, reduce subjectivity in the identification of embryogenic phases, minimize plant material manipulation, and decrease contamination risks. This research provides a methodological basis for future implementations of automated morphological characterization systems that can significantly contribute to the efficiency and profitability of commercial blueberry cultivation in Colombia.

**Keywords:** somatic embryogenesis, machine learning, blueberry, precision agriculture.

## Tabla de Contenido

Introducción .....	11
Planteamiento del Problema .....	12
Justificación .....	14
Objetivos .....	16
Objetivo General.....	16
Objetivos Específicos .....	16
Marco Conceptual.....	17
Marco Teórico.....	22
Metodología .....	25
Resultados .....	29
Conclusiones .....	40
Apéndices.....	50

**Lista de Tablas**

<b>Tabla 1</b> <i>Resumen de Estudios Aplicados</i> .....	36
---	----

## Lista de Figuras

<b>Figura 1</b> <i>Estructura de la Ecuación Booleana</i> .....	26
<b>Figura 2</b> <i>Diagrama de Flujo PRISMA para la Selección de Artículos</i> .....	28
<b>Figura 3</b> <i>Nube de Palabras Modelos y Algoritmos de Aprendizaje</i> .....	30
<b>Figura 4</b> <i>Comparación de Precisión de Modelos de Aprendizaje Automático en la Clasificación de Enfermedades en Plantas</i> .....	34
<b>Figura 5</b> <i>Comparación de la Precisión de Modelos de Aprendizaje Automático en la Identificación de Fases de Embriogénesis Somática</i> .....	35

## Lista de Apéndices

<b>Apéndice A</b> <i>Modelos para la Identificación Morfológica en Embriogénesis Somática y su</i>	
<i>Precisión</i> .....	50
<b>Apéndice B</b> <i>Modelos para la Identificación Morfológica de Enfermedades de Plantas y su</i>	
<i>Precisión</i> .....	52

## Introducción

La creciente demanda global de arándano (*Vaccinium corymbosum*), impulsada por sus propiedades nutraceuticas y su potencial comercial, ha intensificado la necesidad de mejorar los métodos de propagación vegetal, especialmente en contextos de agricultura de precisión. La embriogénesis somática se ha consolidado como una técnica clave para la producción clonal masiva de plantas, sin embargo, su eficiencia aún se ve limitada por la subjetividad y complejidad del proceso de identificación morfológico en las fases embrionarias: globular, corazón y torpedo.

La clasificación manual de estas estructuras incrementa los riesgos de contaminación y retrasa los procesos productivos, frente a este panorama, el aprendizaje automático y la visión por computadora emergen como soluciones innovadoras que permiten automatizar la caracterización morfológica con alta precisión y consistencia. Esta monografía tiene como propósito analizar comparativamente algunos modelos de inteligencia artificial enfocados en la clasificación de las fases de la embriogénesis somática en arándano, con el fin de contribuir a la optimización de los protocolos de propagación in vitro. Para ello, se llevó a cabo una revisión sistemática de literatura bajo la metodología PRISMA, identificando y analizando los resultados obtenidos por los modelos como redes neuronales convolucionales (CNN), máquinas de soporte vectorial (SVM) y regresión por vectores de soporte (SVR), entre otros. El análisis se centró en la precisión, aplicabilidad y limitaciones de cada modelo, generando evidencia científica que puede ser utilizada en el diseño de sistemas automatizados en laboratorios agrícolas y biotecnológicos, en sintonía con los principios de la agricultura de precisión y la transformación digital del sector agropecuario.

## Planteamiento del Problema

La embriogénesis somática constituye una técnica biotecnológica para la propagación clonal del arándano, sin embargo, enfrenta desafíos que limitan su eficiencia y aplicación comercial. Una de las principales complicaciones radica en la complejidad para identificar y clasificar las distintas fases embriogénicas mediante observación directa, ya que estas involucran estructuras microscópicas en constante transformación morfológica. Esta dificultad se intensifica cuando en una única muestra coexisten simultáneamente embriones en diferentes estados de desarrollo, así como lo menciona Dodeman (globular, corazón y torpedo), incrementando sustancialmente la posibilidad de error humano (Dodeman et al., 1997).

Los métodos tradicionales de identificación dependen de la experiencia del observador, introduciendo un componente subjetivo que compromete la reproducibilidad y precisión del proceso. Además, el análisis manual de grandes cantidades de muestras resulta inviable en términos operativos, especialmente en contextos de producción industrial. Un problema adicional crítico es la contaminación del cultivo, debido a la manipulación constante durante la revisión manual de los embriones aumentando significativamente el riesgo de contaminación microbiológica.

Leifert, Waites y Ritchie señalan que una esterilización inadecuada del explante permite la generación de hongos, levaduras y bacterias en el medio de cultivo, representando una de las mayores limitantes del proceso (Leifert et al., 1991). Como advierten María Sánchez y José Salaverría: *"Es indispensable evitar la contaminación con microorganismos para lograr éxito en el establecimiento, incubación y manipulación del tejido in vitro, ya que éstos pueden destruir los explantes, retrasar su desarrollo al competir con ellos o generar modificaciones en el medio que afectan negativamente su sobrevivencia y desarrollo"* (Salaverría & Sánchez Cuevas, 2004).

Allan Mata Quirós refuerza esta problemática afirmando que "*Debido a altos índices de contaminación de los medios de cultivo y a que el procedimiento de desinfección utilizado probablemente no fue suficiente para lograr eliminar los contaminantes presentes en los explantes bajo estas condiciones ambientales, los niveles de asepsia en las condiciones in vitro no permitieron mayores tasas de éxito de la técnica.*" (Quirós, 2013). Esta contaminación no solo representa un obstáculo técnico, sino que puede comprometer completamente la viabilidad del proceso, reduciendo las tasas de éxito.

La ausencia de métodos automatizados y objetivos para la identificación de las fases embriogénicas constituye una barrera tecnológica que limita la optimización de los protocolos de producción, afectando negativamente la eficiencia y rentabilidad del cultivo comercial del arándano. Ante esta problemática, surge la necesidad de implementar tecnologías de visión artificial y aprendizaje automático que permitan desarrollar sistemas capaces de identificar y clasificar con alta precisión las diferentes fases embriogénicas, reduciendo la subjetividad, minimizando la manipulación del material vegetal, disminuyendo los riesgos de contaminación y contribuyendo a la estandarización de los protocolos de embriogénesis somática para el cultivo del arándano (*Vaccinium Corymbosum*).

## Justificación

De acuerdo con las cifras mencionadas por el ICA en el 2023 "*Colombia cuenta con un área total sembrada de arándanos de, aproximadamente, 550 hectáreas. De igual manera, el número de productores de esta fruta es de un poco más de 200, de los cuales, cerca del 90% son pequeños productores*" (ICA, 2023), es decir que el mercado global del arándano está experimentando un crecimiento exponencial. Esta tendencia ha intensificado la necesidad de optimizar los métodos de propagación para satisfacer la demanda comercial. La embriogénesis somática representa una de las técnicas más prometedoras para la propagación clonal masiva, pero sus limitaciones técnicas actuales frenan su aplicación industrial. Adicionalmente, el avance acelerado de las tecnologías de inteligencia artificial y visión por computadora ha creado una coyuntura tecnológica favorable para su aplicación en la agricultura de precisión. Tal y como se observa, en el estudio realizado por Beleño, en donde se concluyó que "*es posible la utilización de técnicas de visión artificial para el control de calidad de los frutos de café, tendiendo como principal ventaja el ser un método no invasivo y que mantiene al mínimo el contacto con el producto tratado.*"(Beleño Saenz, 2016).

A partir de esta exploración, se busca identificar aquellos modelos de aprendizaje automático que permitan aumentar significativamente la precisión en la identificación de fases embriogénicas, con el fin de facilitar la toma de decisiones en tiempo real durante el proceso de cultivo, proporcionando criterios objetivos y consistentes para la clasificación de las fases embriogénicas, reduciendo la variabilidad asociada al factor humano. Paralelamente, esta investigación generará conocimiento científico transferible sobre la aplicación de algoritmos específicos para la identificación de estructuras biológicas en desarrollo, estableciendo precedentes metodológicos que podrán adaptarse a otros cultivos de importancia económica para

Colombia, como aguacate, cacao y diversas especies frutales que también requieren optimización en sus protocolos de propagación in vitro.

En el contexto de la agricultura de precisión y la transformación digital del sector agropecuario promovida por políticas nacionales, esta investigación representa una contribución directa a la modernización de los procesos productivos, alineándose con los objetivos de desarrollo sostenible y competitividad del sector agrícola colombiano en mercados internacionales.

## Objetivos

### Objetivo General

Analizar modelos de aprendizaje automático aplicables a la identificación de fases de embriogénesis somática en arándano (*Vaccinium Corymbosum*), con el propósito de contribuir a la optimización de los procesos de caracterización morfológica.

### Objetivos Específicos

Identificar los modelos de aprendizaje automático que han sido aplicados para la clasificación de estructuras morfológicas, especialmente aquellas relacionadas con procesos de embriogénesis somática.

Comparar el desempeño de dichos modelos en función de la precisión, considerando aplicaciones similares a la identificación de fases embriogénicas.

Evaluar las ventajas y limitaciones de los modelos seleccionados, con relación a su aplicabilidad al contexto específico de la embriogénesis somática del arándano.

## Marco Conceptual

El presente marco conceptual aborda la aplicación del machine learning y el deep learning en el procesamiento y clasificación de imágenes para la caracterización morfológica y el estudio de la embriogénesis somática del arándano (*Vaccinium Corymbosum L.*).

Machine Learning o aprendizaje automático: Según Bobadilla, el machine learning es la ciencia que permite a las computadoras aprender de los datos mediante algoritmos generales que identifican patrones, eliminando la necesidad de programar soluciones específicas para cada situación (Bobadilla, 2021). Esta visión resalta una transformación en la forma de abordar problemas complejos, ya que los sistemas se vuelven más adaptativos y capaces de extraer conocimiento directamente de la información disponible. En contraste, en la página oficial de IBM se menciona que, aunque el machine learning imita el proceso de aprendizaje humano y mejora su precisión con el tiempo, en su forma tradicional depende en gran medida de la intervención humana para definir las características relevantes en datos estructurado (IBM, 2022), lo que evidencia la importancia del conocimiento experto en el proceso. Por su parte, en la página oficial de AWS señala que el machine learning se basa en el desarrollo de algoritmos y modelos estadísticos para analizar grandes volúmenes de datos históricos, facilitando la identificación de patrones que impulsan la toma de decisiones y el crecimiento empresarial (Amazon Web Services, 2022). En conjunto, estas perspectivas evidencian que el machine learning no solo es una herramienta tecnológica, sino un paradigma transformador que optimiza la resolución de problemas complejos a través de la automatización y la inferencia basada en datos.

Deep learning: Según Sandra, "*es una rama del machine learning que permite a las máquinas aprender y mejorar de forma autónoma, adaptándose a situaciones nuevas y*

*trabajando de manera eficaz con grandes volúmenes de datos"*(Uribe et al., 2011), característica que le otorga un valor significativo en aplicaciones específicas, pues como señala Wanjari, *"Los algoritmos de Aprendizaje Profundo son valorados en el reconocimiento de imágenes porque automatizan los pasos de extracción de características y aprendizaje propios del campo"* (Wanjari & Verma, 2025), funcionamiento que se debe fundamentalmente a su arquitectura interna, ya que según Gozde Karatas, *"Los algoritmos de aprendizaje profundo realizan sus operaciones utilizando múltiples capas consecutivas. Las capas están interconectadas y cada capa recibe la salida de la capa anterior como entrada. Es una gran ventaja utilizar algoritmos eficientes para extraer características jerárquicas"* (Karatas et al., 2018), lo que explica su capacidad para procesar información compleja de manera gradual y efectiva.

Procesamiento de imágenes: Es un campo tecnológico que, según Carlo Ramírez y Wilmar Ramírez, se fundamenta en la extracción de información de las imágenes y el aprendizaje a partir de ellas, transformando datos visuales en conocimiento utilizable (Ramírez Gil & Ramírez Gil, 2023). Como señala Yanying Zhang, este campo abarca una serie de procesos específicos que incluyen la clasificación de imágenes, compresión, mejora, codificación y extracción de características, todos ellos orientados a garantizar que la imagen sea suficientemente clara para una identificación eficaz de la información contenida(Zhang & Zheng, 2022) . Estos procesos constituyen un flujo de trabajo sistemático que permite manipular y analizar imágenes digitales con el objetivo de mejorar su calidad, facilitar su interpretación y extraer datos significativos que pueden ser aprovechados en diversas aplicaciones científicas, médicas, industriales y cotidianas.

Clasificación de imágenes: En el ámbito de la clasificación de imágenes, se reconoce que este proceso permite identificar y etiquetar el contenido visual presente en una imagen de forma

automatizada. De igual modo, Robalo, Aguilar y Manzano sostienen que estas técnicas no solo mejoran la información visual, sino que también automatizan la detección de objetos o áreas de interés, incrementando así la eficiencia del análisis (Cabrera et al., 2024). Complementariamente, González, Alegre y Fidalgo definen la clasificación de imágenes como el proceso de determinar de manera automática los contenidos de una imagen, asignando una o varias etiquetas a partir de un conjunto fijo de categorías (González-Castro et al., n.d.). En conjunto, estos enfoques resaltan la importancia de la automatización en la interpretación de datos visuales, lo que resulta esencial para aplicaciones en inteligencia artificial, análisis de grandes volúmenes de información y otras áreas tecnológicas, permitiendo que los sistemas sean más precisos y rápidos en la toma de decisiones basadas en imágenes.

**Embriogénesis somática:** Es un proceso biológico complejo mediante el cual células somáticas son reprogramadas para adquirir capacidad embriogénica, permitiéndoles desarrollarse en estructuras capaces de regenerar una planta completa (Méndez-Hernández et al., 2019). Este fenómeno constituye un proceso de múltiples etapas, que según Davidson, comienza con la inducción del tejido embriogénico, seguido por la proliferación y formación de embriones somáticos tempranos, procesos que requieren la presencia de reguladores de crecimiento vegetal específicos como auxinas y citoquininas (Davidson et al., 2024). Mohsen Hesami profundiza esta definición al categorizar la embriogénesis somática en diferentes eventos característicos como la diferenciación celular, la activación de la división celular, la desdiferenciación de células y la reprogramación de su metabolismo, eventos que en conjunto permiten la transformación de células ordinarias en células con potencial regenerativo completo (Hesami et al., 2020).

**Caracterización morfológica:** Es un proceso científico que, según Hernández-Villareal, consiste en la determinación de un conjunto de caracteres mediante el uso de descriptores

definidos que permiten diferenciar taxonómicamente a las plantas. Este proceso no es meramente descriptivo, sino que cumple funciones esenciales en el campo de la botánica y la agronomía, ya que se utiliza para estudiar la variabilidad genética, identificar especies vegetales y conservar recursos genéticos valiosos (Hernández Villareal, 2013). Complementando esta definición, Paula García destaca la aplicación práctica de estos estudios al afirmar que "*permiten valorar el material genético, con la finalidad de seleccionar y ser utilizados en programas de fitomejoramiento y conservación*" (García-Godos et al., 2022). De esta manera, la caracterización morfológica se posiciona como un procedimiento fundamental para el mejoramiento y preservación de la diversidad vegetal.

Arándanos (*Vaccinium Corymbosum*): es un arbusto perenne cuyo crecimiento se adapta principalmente a climas fríos del hemisferio norte, aunque también existen variedades en regiones tropicales. Sus frutos, caracterizados por una tonalidad azulada o rojiza, son ricos en compuestos bioactivos como antocianos y minerales, lo que les confiere un alto valor nutricional y medicinal (Hine-Gómez & Abdelnour-Esquivel, n.d.). Su importancia económica radica en la creciente demanda de alimentos con propiedades antioxidantes y en su potencial en la industria farmacéutica y alimentaria.

Desde una perspectiva botánica, el arándano pertenece a la familia de las frambuesas y su crecimiento se da en arbustos de tamaño reducido, entre 30 y 50 centímetros de altura (ADEX, 2009). Esta característica lo convierte en una planta de fácil cultivo en distintos sistemas agrícolas, favoreciendo su expansión comercial. Además, su riqueza en antioxidantes ha generado interés en investigaciones sobre sus beneficios en la prevención de enfermedades relacionadas con el estrés oxidativo, lo que refuerza su posicionamiento como un superalimento en la dieta humana.

Agricultura de precisión: García subraya cómo la agricultura de precisión se apoya en un conjunto de tecnologías digitales, como imágenes satelitales, sensores en campo, servicios meteorológicos, transmisión remota de datos y el uso de smartphones, que permiten una gestión más tecnificada de la actividad agrícola (García Molina, n.d.). Estas herramientas posibilitan a técnicos y productores recopilar y analizar grandes volúmenes de información en tiempo real, lo que mejora la toma de decisiones y optimiza la gestión de las parcelas desde tres dimensiones clave: agronómica, al beneficiar directamente a los cultivos; medioambiental, al reducir el impacto negativo de las prácticas agrícolas; y económica, al incrementar la eficiencia productiva. Además, el autor destaca que el verdadero potencial de esta tecnología se alcanza al integrarla con modelos agronómicos capaces de abordar necesidades específicas del cultivo, como el riego y la nutrición, lo que permite diseñar planes de manejo más precisos y sostenibles.

Vega & Ruiz definen la agricultura de precisión como un conjunto de tecnologías aplicadas al ámbito agrario, cuya característica común es la utilización de las tecnologías de la información y la comunicación (TIC) para optimizar tanto la toma de decisiones como su ejecución en el campo (Agüera Vega & Gil Ribes, n.d.). Estas herramientas permiten analizar datos con mayor exactitud, facilitando intervenciones más eficientes y puntuales en los procesos productivos. De este modo, la agricultura de precisión no solo implica el uso de tecnología avanzada, sino también una transformación en la forma en que se gestionan los recursos y se responde a las necesidades del cultivo, promoviendo una producción más inteligente y controlada.

## Marco Teórico

El avance de las técnicas biotecnológicas ha permitido el desarrollo de métodos de propagación in vitro cada vez más eficientes, entre ellos, la embriogénesis somática se destaca como una estrategia para la reproducción de especies vegetales de interés agrícola, como el arándano (*Vaccinium Corymbosum*). No obstante, la identificación precisa de las distintas fases embrionarias continúa representando un desafío técnico, debido a la subjetividad del análisis visual y la variabilidad morfológica de las estructuras en desarrollo. En este contexto, el uso de tecnologías emergentes como el procesamiento de imágenes y el aprendizaje automático se presenta como una alternativa prometedora para automatizar y optimizar la clasificación de embriones. El presente marco teórico expone los fundamentos conceptuales y antecedentes investigativos que sustentan la aplicación de modelos de aprendizaje automático en la identificación de fases de embriogénesis somática en el que se enmarca esta problemática.

La embriogénesis somática (ES) es un proceso biotecnológico mediante el cual células somáticas, no reproductivas, se transforman en embriones con una estructura y función similares a los embriones cigóticos. Este fenómeno permite la regeneración de plantas genéticamente idénticas a la planta madre, y ha sido ampliamente estudiado por su relevancia en la propagación de especies vegetales (Sánchez Jhong et al., 2019). La ES constituye una herramienta fundamental en la agricultura de precisión, tanto para la conservación de recursos genéticos como para la producción masiva de material vegetal libre de patógenos y con alto valor comercial. En este sentido, las investigaciones biotecnológicas en micropropagación reconocen su utilidad para garantizar uniformidad genética y altos rendimientos productivos, aspectos clave en programas de fitomejoramiento y producción comercial a gran escala (Llvisaca et al., 2020).

En este contexto, el cultivo in vitro se ha consolidado como una técnica clave dentro de la agricultura de precisión, al permitir la propagación controlada y masiva de plantas con características deseadas, facilitando su integración en sistemas agrícolas más eficientes y tecnológicamente asistidos. Su principal objetivo es la micropropagación de plantas a través de la producción de clones con características idénticas a la planta donante, en condiciones controladas e independientes de factores climáticos o estacionales (Mazurek et al., 2024). Esta técnica se ha consolidado como una alternativa eficiente frente a métodos tradicionales como la propagación por esquejes, los cuales requieren mayor tiempo y presentan una tasa de éxito limitada (Ghosh et al., 2018). En el caso de especies como el arándano, la micropropagación permite obtener plantas durante todo el año mediante la proliferación de yemas axilares o por embriogénesis somática, optimizando así la producción agrícola.

Uno de los beneficios más significativos del cultivo in vitro es su capacidad para eliminar patógenos, conservar germoplasma y facilitar el rescate de especies amenazadas. Estos avances han impactado positivamente en la sostenibilidad, la seguridad alimentaria y el fitomejoramiento, permitiendo la generación de plantas más resistentes a plagas, enfermedades y condiciones ambientales adversas ((Delgado-Paredes et al., 2021);(Sayali Bharat et al., 2020)). No obstante, el éxito de estos procedimientos depende en gran medida del control estricto de las condiciones de esterilidad, ya que el medio de cultivo es susceptible a la contaminación microbiana. Por esta razón, se emplean desinfectantes químicos en bajas concentraciones y, en algunos casos, antibióticos, aunque estos últimos pueden afectar negativamente la organogénesis (Norouzi et al., 2022).

A pesar de los avances tecnológicos, la identificación de embriones somáticos sigue representando un desafío, ya que tradicionalmente se ha basado en la observación visual por

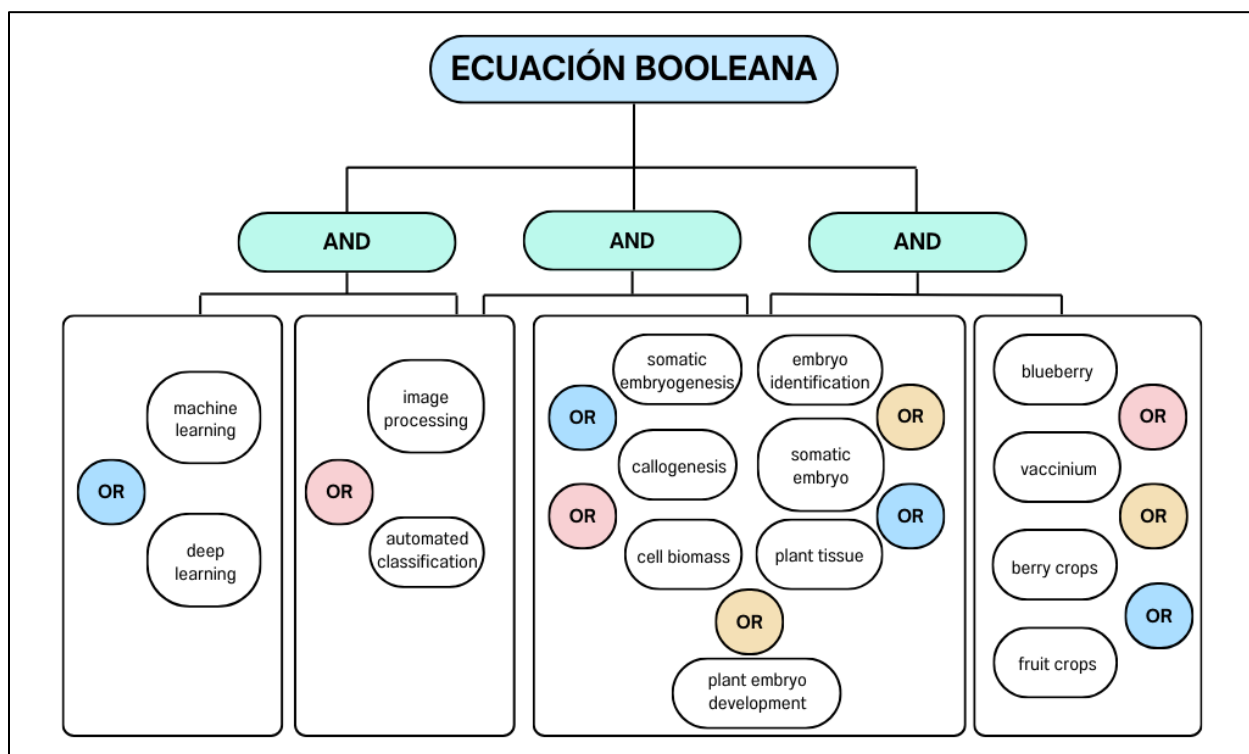
parte de operadores expertos. Esta práctica introduce un alto grado de subjetividad y un riesgo elevado de contaminación por manipulación constante (Mata et al., n.d.). Por ello, en los últimos años ha cobrado relevancia la aplicación de modelos de aprendizaje automático y visión por computadora, los cuales permiten una clasificación automática y precisa de los embriones en sus diferentes estadios morfológicos. Herramientas como las redes neuronales artificiales (RNA), el análisis discriminante lineal (LDA), y los árboles de decisión han mostrado resultados prometedores en especies como el café (Científico et al., 2017) y el Agave tequilana (Rodríguez-Garay et al., 2009), permitiendo optimizar los protocolos de selección morfológica y reducir el error humano.

Asimismo, la integración de sensores digitales y sistemas automatizados con capacidad de clasificación en tiempo real abre la posibilidad de estandarizar procesos en laboratorios con alta carga de trabajo, alineándose con los objetivos de una agricultura de precisión. Estos avances permiten aumentar la trazabilidad, la eficiencia y la calidad del material vegetal producido, lo cual resulta esencial para la competitividad del sector agrícola y la conservación de la biodiversidad vegetal.

## Metodología

Se realizó una revisión bibliográfica siguiendo los lineamientos de la metodología PRISMA (Page et al., 2021), con el objetivo de identificar y sintetizar la literatura científica relevante sobre los modelos de aprendizaje automático aplicables a la identificación de fases de embriogénesis somática en arándano, con el propósito de contribuir a la optimización de los procesos de caracterización morfológica.

Para garantizar la relevancia de los resultados, se elaboró una estrategia de búsqueda implementando la metodología PRISMA. Esta estrategia incorporó diversos términos relacionados con cada concepto principal del estudio. La búsqueda se realizó en múltiples bases de datos académicas, priorizando Scopus, Google Académico y Springer Nature Link, para maximizar la cobertura de la literatura científica disponible a nivel global. La ecuación booleana utilizada (Figura 1) incorporó términos específicos como "blueberry", "Vaccinium", "somatic embryogenesis" "machine learning", "deep learning", "image processing" y "callogenesis", entre otros. Estos términos fueron combinados mediante operadores booleanos (AND, OR) para optimizar tanto la especificidad como la sensibilidad de la búsqueda. El período de análisis se restringió a publicaciones realizadas entre enero de 2020 y marzo de 2025, abarcando cinco años de estudios, para asegurar la inclusión de las técnicas más actualizadas y relevantes en el campo.

**Figura 1***Estructura de la Ecuación Booleana*

*Nota.* Estructura aplicada para búsqueda sistemática de literatura científica.

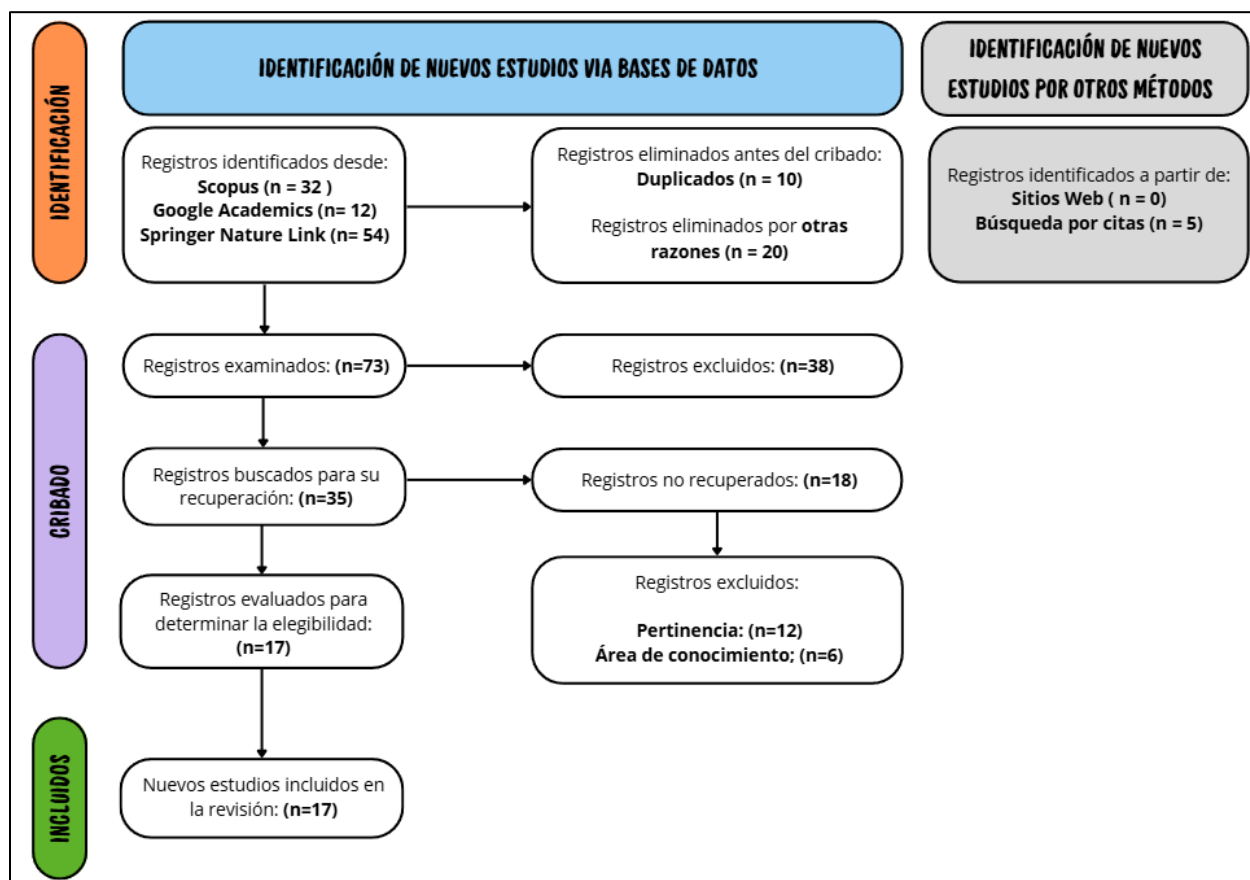
Los criterios de inclusión contemplaron artículos originales publicados en revistas científicas con proceso de revisión por pares, estudios que abordaran específicamente el uso de modelos de aprendizaje automático para el análisis de la morfología vegetal, investigaciones que implementaran técnicas de procesamiento avanzado de datos o imágenes, y trabajos que evaluaran la aplicación de inteligencia artificial o aprendizaje automático, con especial énfasis en aquellos relacionados con modelos aplicados a la embriogénesis somática. Se consideraron únicamente publicaciones disponibles en idiomas inglés o español con textos completos accesibles para su análisis integral.

Por otra parte, los criterios de exclusión abarcaron estudios que no abordaran el análisis de la morfología vegetal, investigaciones enfocadas exclusivamente en aspectos botánicos sin componente tecnológico, artículos de opinión, cartas al editor o literatura gris, publicaciones sin metodología claramente definida, y estudios duplicados o con resultados preliminares de investigaciones ya incluidas en la revisión. Estos criterios permitieron filtrar de manera efectiva la literatura disponible para concentrar el análisis en los estudios más relevantes para los objetivos planteados.

El proceso de selección siguió cuatro fases secuenciales bien diferenciadas. En la fase de identificación, la búsqueda inicial en las bases de datos generó un conjunto de registros potencialmente relevantes eliminándose los documentos duplicados. Durante el cribado inicial, se revisaron títulos y resúmenes aplicando los criterios de inclusión y exclusión previamente establecidos. En la evaluación de elegibilidad, se analizaron los textos completos de los artículos preseleccionados para verificar su cumplimiento con todos los criterios establecidos. Finalmente, en la fase de inclusión, se seleccionaron los artículos que cumplieron íntegramente con la mayoría de los requisitos. El proceso completo de selección fue documentado mediante un diagrama de flujo PRISMA (Figura 2), que refleja de manera transparente el número de estudios considerados en cada fase y los motivos de exclusión.

Figura 2

Diagrama de Flujo PRISMA para la Selección de Artículos



Como resultado del proceso de selección en cuatro fases descrito anteriormente, y tras la aplicación sistemática de los criterios de inclusión y exclusión en las etapas de identificación, cribado, evaluación de elegibilidad e inclusión final, se conformó un corpus definitivo de 17 artículos. Estos documentos, que superaron satisfactoriamente todos los filtros metodológicos establecidos, constituyeron la base documental para la presente monografía.

## Resultados

En la presente sección se exponen los hallazgos obtenidos a partir de la revisión sistemática de documentos científicos enfocados en el análisis y procesamiento de características morfológicas de las plantas, con especial énfasis en las fases de la embriogénesis somática. Se procedió a listar los modelos y algoritmos de aprendizaje implementados en los artículos seleccionados, identificando aquellos con mayor frecuencia de aplicación en este campo específico. La clasificación se realizó mediante un análisis de las publicaciones, examinando las metodologías empleadas en relación con el objetivo central de esta monografía.


El propósito fundamental de este análisis fue establecer un panorama general de los modelos y algoritmos predominantes en el estudio morfológico vegetal. Esta sistematización permite, en etapas posteriores, realizar comparaciones entre la precisión reportada de los diversos modelos y la frecuencia con que estos han sido implementados en la literatura científica. Los resultados aquí presentados constituyen la base para identificar tendencias metodológicas y evaluar la eficacia de las distintas aproximaciones en el análisis morfológico vegetal.

Para visualizar de forma clara los modelos y algoritmos de aprendizaje más frecuentemente mencionados en los documentos analizados, se utilizó una **nube de palabras** (Figura 3). Esta herramienta gráfica permite identificar de manera inmediata las tendencias predominantes dentro de un corpus textual, destacando los términos más recurrentes mediante variaciones en el tamaño y el color. En el contexto de esta revisión sistemática, la nube de palabras facilita la identificación de los enfoques metodológicos más comunes en el análisis morfológico de plantas, especialmente en las fases de embriogénesis somática. Además, su carácter visual apoya la interpretación cualitativa de los datos, sirviendo como complemento al análisis cuantitativo realizado en secciones posteriores. Esta representación gráfica no solo

refuerza los hallazgos del estudio, sino que también permite detectar patrones emergentes y posibles líneas de investigación futuras.

### Figura 3

*Nube de Palabras Modelos y Algoritmos de Aprendizaje*



De esta manera, se puede identificar en la Figura 3 cómo el modelo de redes neuronales convolucionales (CNN) es uno de los modelos con mayor frecuencia en el análisis y procesamiento de las imágenes, esto puede deberse a que este modelo “*basa el aprendizaje de conceptos complejos, mediante la descomposición de los mismos en elementos más simples, donde el entrenamiento viene dado por establecer gradualmente un grupo de filtros de convolución, los cuales son determinados en función a la 44 Arquitecturas de Red Neuroconvolucional para Aplicaciones de Robótica Asistencial base de datos de entrenamiento y la estructura general de la red*” (Jiménez et al., n.d.). Es decir que, tienen capacidad para

descomponer conceptos complejos en componentes más simples mediante filtros de convolución. Esta característica permite que las CNN aprendan de manera progresiva, ajustando automáticamente dichos filtros en función de los datos de entrenamiento y la arquitectura de la red. Este enfoque jerárquico de aprendizaje resulta especialmente efectivo en tareas visuales, ya que facilita la detección de patrones básicos que luego se combinan para identificar elementos más complejos.

Así mismo, se observa que las máquinas de soporte vectorial (SVM) son otro de los modelos que más se resaltan en la nube de palabras, ya que se enfoca en *“solucionar problemas de clasificación y regresión relacionados a la predicción de series de tiempo y clasificación de imágenes, mostrando tener muy buenos resultados en comparación a otras metodologías tradicionales”* (Castañeda, 2021). Esto resalta la versatilidad y robustez del modelo, ya que puede abordar tanto problemas de clasificación como de regresión, mostrando un rendimiento superior frente a métodos tradicionales.

De igual manera, se pueden destacar modelos como YOLO (You Only Look Once), ya que se puede encontrar en distintas versiones, obteniendo una variedad significativa de precisión entre cada una de las versiones, este modelo se caracteriza por que *“permite la detección simultánea de objetos y su clasificación mediante convoluciones y capas de anclaje”* (León León et al., 2024). Esto sugiere que estos modelos tienen una evolución continua para adaptarse a diferentes necesidades de precisión y velocidad.

Por otro lado, se destaca el uso de algoritmos de aprendizaje, como lo son " K-Nearest Neighbors (KNN)", "Random Forest", "Decision Tree", "Naive Bayes", y " Support Vector Regression (SVR)" que indican una aplicación más amplia de métodos clásicos de aprendizaje automático.

Los artículos seleccionados para este estudio pueden dividirse en dos categorías principales: aquellos relacionados con la **embriogénesis somática** y los enfocados **en la detección de enfermedades en plantas**. Esta clasificación surge debido a las similitudes metodológicas en los estudios morfológicos utilizados como base para los modelos de aprendizaje automático aplicados en ambos campos.

Es importante destacar que, durante el proceso de revisión bibliográfica, se evidenció la escasa literatura disponible sobre la aplicación específica de modelos de inteligencia artificial en el análisis morfológico de las fases de embriogénesis somática, particularmente en el cultivo de arándanos. Esta limitación en la producción científica a nivel mundial motivó la implementación de una estrategia metodológica complementaria: la inclusión de estudios enfocados en la detección de enfermedades en plantas, específicamente aquellos que utilizaran técnicas de procesamiento de imágenes y análisis morfológico similares a los requeridos para la identificación de estructuras embriogénicas.

La selección de estos artículos no fue arbitraria, sino que se basó en criterios específicos de similitud metodológica. Se priorizaron investigaciones que emplearan modelos de aprendizaje automático para el análisis de características morfológicas microscópicas, cambios estructurales en tejidos vegetales, y clasificación de diferentes estados de desarrollo o condición en material vegetal. Estas similitudes técnicas permiten la extrapolación de metodologías y la evaluación comparativa de modelos que, aunque aplicados en contextos diferentes, comparten fundamentos computacionales y de procesamiento de imágenes relevantes para nuestro objeto de estudio.

De esta manera, en los estudios analizados sobre detección de enfermedades en plantas, se observa que la combinación de **Redes Neuronales Convolucionales (CNN)** con **Máquinas de Soporte Vectorial (SVM)** alcanzó la mayor precisión entre todos los modelos evaluados, con

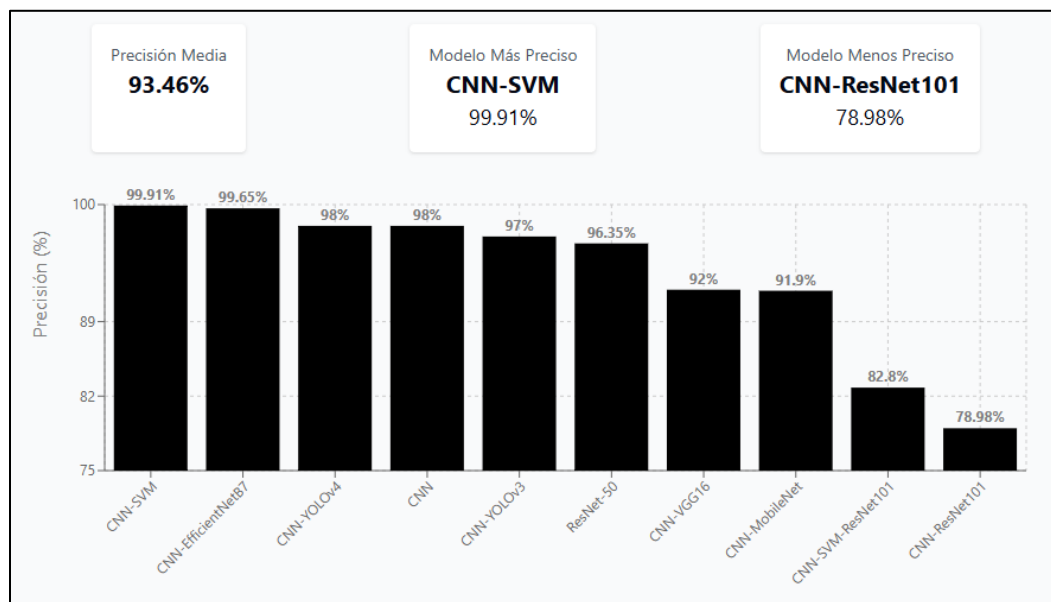
un **99.91%** como se muestra en la Figura 4. Este modelo CNN-SVM se destaca significativamente sobre otras arquitecturas, incluyendo **CNN-EfficientNetV2 (99.65%)** y **CNN-YOLO v4 (98%)**.

Así mismo, el modelo CNN-SVM proporciona un equilibrio óptimo entre la complejidad del modelo y la precisión de clasificación, característica que la hace particularmente adecuada para implementaciones prácticas en entornos agrícolas reales (Paul et al., 2024). Esta combinación aprovecha la capacidad de extracción de características de las CNN junto con la efectividad clasificatoria de SVM, resultando en un sistema de alta fiabilidad para la identificación temprana de patologías vegetales. Cabe destacar que la mayoría de los modelos analizados en la revisión documental implementan arquitecturas derivadas de redes neuronales convolucionales, por lo que, al calcular el promedio de precisión de estos modelos, se obtiene un 93.46%, lo que evidencia la alta eficacia de estas arquitecturas para este tipo de investigaciones. Esta elevada precisión demuestra el potencial de las redes neuronales convolucionales como herramienta fundamental para el procesamiento y análisis de datos en este campo de estudio, consolidándose como una metodología confiable para futuras implementaciones.

En síntesis, de la revisión sistemática, los modelos con menor desempeño  **fueron CNN-SVM-ResNet101 (82.8%) y CNN-ResNet101 (78.98%)**, lo que resulta interesante considerando que ResNet101 es una arquitectura más profunda que ResNet-50. Esto sugiere que el uso de redes neurales no necesariamente conduce a mejores resultados en este contexto específico y que la complejidad adicional podría incluso resultar contraproducente.

**Figura 4**

*Comparación de Precisión de Modelos de Aprendizaje Automático en la Clasificación de Enfermedades en Plantas*



En la Figura 5 se observan los modelos de aprendizaje automático con mayor relevancia en el enfoque de la embriogénesis somática, donde destaca el **modelo de Regresión de Soporte Vectorial (SVR) con una precisión del 96.6%**. Este modelo sobresale por proporcionar una metodología computacional robusta, además de confiable para predecir y optimizar los procesos de cultivo de tejidos vegetales, superando significativamente tanto los enfoques tradicionales como otros métodos de aprendizaje automático en este ámbito (Hesami et al., 2020).

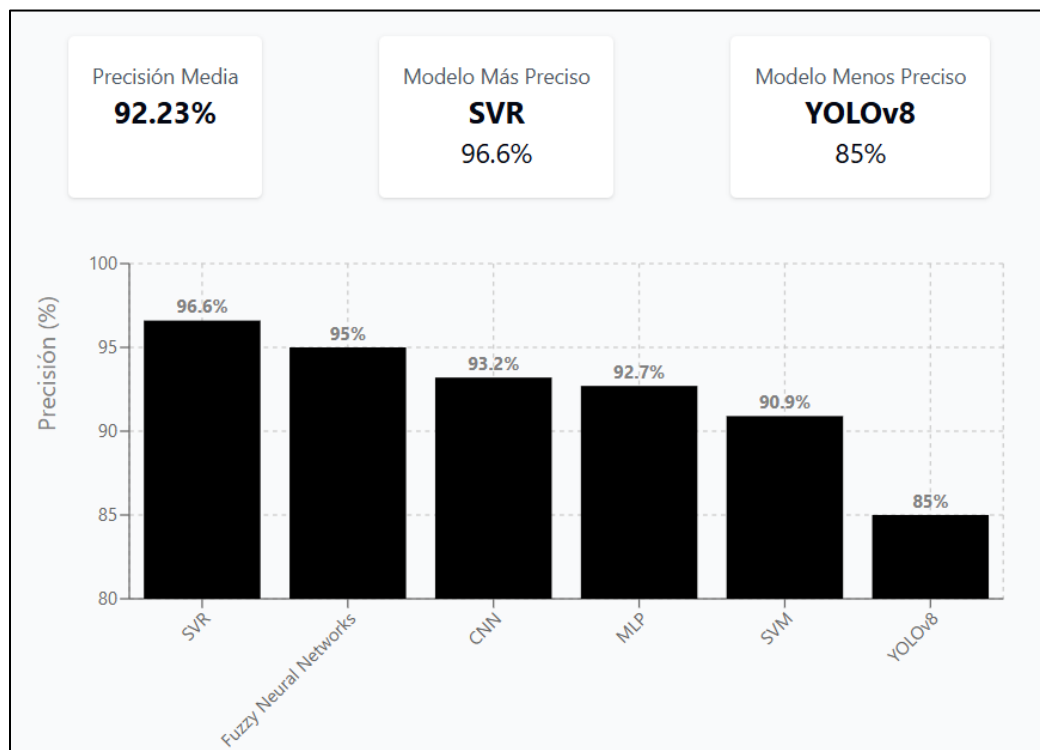
Así mismo, la precisión media general de los modelos analizados alcanza un 92.23%, lo que evidencia el alto potencial del aprendizaje automático en la caracterización morfológica de estructuras embriogénicas.

Por otra parte, el modelo con menor desempeño identificado en este análisis corresponde a **YOLOv8, con una precisión del 85%**. Pese a esta menor precisión relativa, en el estudio

“Advanced Plant Growth Recognition Model with Deep learning for the Coconut tissue culture” se destaca su importante utilidad práctica, al señalar que "al emplear YOLOv8 para la detección de objetos y la estimación de puntos clave, el estudio permite la medición precisa de métricas de crecimiento de plantas, incluyendo longitud de brotes, ancho de hojas y atributos estructurales, independientemente de la postura de la planta" (Sathisrajan et al., 2024) . Esta característica resulta particularmente valiosa en condiciones de cultivo in vitro donde las estructuras vegetales pueden presentar orientaciones variables, lo que posiciona a YOLOv8 como una alternativa viable a pesar de no ser el modelo con mayor precisión.

### Figura 5

Comparación de la Precisión de Modelos de Aprendizaje Automático en la Identificación de Fases de Embriogénesis Somática



Con el fin de contextualizar los modelos de aprendizaje automático utilizados en investigaciones previas, se realizó una revisión de artículos académicos relevantes. En la Tabla 1 se presentan los documentos seleccionados para el desarrollo del estudio, donde se detalla el nombre del artículo, el año de publicación, el modelo aplicado y el enfoque abordado en cada caso.

Para ampliar la información respecto a la precisión obtenida por cada modelo en los respectivos estudios, se recomienda consultar la sección de apéndices de la presente monografía.

**Tabla 1**

*Resumen de Estudios Aplicados*

Cita	Nombre documento	Año	Modelo Utilizado	Enfoque
(Davidson et al., 2024)	Deep learning for automated segmentation and counting of hypocotyl and cotyledon regions in mature <i>Pinus radiata</i> D. Don. somatic embryo images	2024	Red neuronal convolucional	Embriogénesis somática
(Chatterjee et al., 2024)	Machine Learning based Sorting of Somatic Embryos for In-Line processing in Automated SE Fluidics System	2024	Maquinas de soporte vectorial	Embriogénesis somática
(Hesami et al., 2020)	Development of support vector machine-based model and comparative analysis with artificial neural network for modeling the plant tissue culture procedures: effect of	2020	Multilayer Perceptron (MLP) Support Vector	Embriogénesis somática

Cita	Nombre documento	Año	Modelo Utilizado	Enfoque
	plant growth regulators on somatic embryogenesis of chrysanthemum, as a case study		Regression (SVR)	
(Zielińska & Kępczyńska, 2013)	Neural modeling of plant tissue cultures: a review	2013	Multilayer Perceptron (MLP) Fuzzy Neural Networks	Embriogénesis somática
(Shavindi et al., 2024)	Effectiveness of Deep Learning and IoT for Disease Classification and Characterizing Tissue Culture Calli	2024	CNN	Embriogénesis somática
(Sathisrajan et al., 2024)	Advanced Plant Growth Recognition Model with Deep learning for the Coconut tissue culture	2024	YOLOv8	Embriogénesis somática
(Aliabad et al., 2023)	Evaluation of the ability to measure morphological structures of plants obtained from tissue culture applying image processing techniques	2023	SVM	Embriogénesis somática
(Archana et al., 2023)	Plant Disease Detection using ResNet	2023	ResNet-50	Análisis de enfermedades
(Muhammad et al., 2019)	A Pattern Analysis-based Segmentation to Localize Early and Late Blight Disease	2019	Tasa de verdaderos positivos	Análisis de enfermedades

Cita	Nombre documento	Año	Modelo Utilizado	Enfoque
(Balakrishna et al., 2022)	Lesions in Digital Images of Plant Leaves Tomato Leaf Disease Detection Using Deep Learning: A CNN Approach	2021	VGG16	Análisis de enfermedades
(Alhwaiti et al., 2025)	Leveraging YOLO deep learning models to enhance plant disease identification	2025	YOLOv3 YOLOv4	Análisis de enfermedades
(Verma et al., 2024)	Plant Disease Detection and Severity Assessment Using Image Processing and Deep Learning Techniques	2024	CNN SVM	Análisis de enfermedades
(Bouni et al., 2024)	Synergistic use of handcrafted and deep learning features for tomato leaf disease classification	2024	MobileNet	Análisis de enfermedades
(Hemalatha & Jayachandran, 2024)	A Multitask Learning-Based Vision Transformer for Plant Disease Localization and Classification	2024	PDLC-ViT	Análisis de enfermedades
(Paul et al., 2024)	A study and comparison of deep learning based potato leaf disease detection and classification techniques using explainable AI	2024	CNN-SVM	Análisis de enfermedades
(Kulkarni et al., 2024)	Effective and efficient automatic detection, prediction and prescription of	2024	CNN MobileNet	Análisis de enfermedades

Cita	Nombre documento	Año	Modelo Utilizado	Enfoque
(Saleki & Tahmoresnezhad, 2024)	potential disease in berry family Agry: a comprehensive framework for plant diseases classification via pretrained EfficientNet and convolutional neural networks for precision agriculture	2024	EfficientNetB7	Análisis de enfermedades

*Nota.* Los estudios se realizaron en relación a la identificación de fases de embriogénesis somática y enfermedades en plantas mediante aprendizaje automático.

## Conclusiones

A partir de la exploración presentada en esta monografía, se concluye que la implementación de modelos de aprendizaje automático emerge como una estrategia para optimizar la identificación de las fases de embriogénesis somática en el cultivo de arándano. La destacada precisión alcanzada por los modelos evaluados, con el SVR sobresaliendo con un 96.6%, no solo subraya la viabilidad de la inteligencia artificial en este ámbito, sino que también proyecta un futuro prometedor para la automatización de la caracterización morfológica vegetal. Esta automatización conlleva beneficios sustanciales, incluyendo la reducción de la subjetividad inherente a los métodos tradicionales, el incremento de la eficiencia operativa y la disminución de riesgos de contaminación; elementos relevantes para el avance de la agricultura de precisión en Colombia y en otros contextos agropecuarios.

Además de los beneficios en precisión y eficiencia, una ventaja destacada del uso de modelos de aprendizaje automático en la identificación de fases de embriogénesis somática es que el análisis se realiza a partir de imágenes, sin requerir la manipulación directa de los tejidos vegetales. Esta característica permite preservar las condiciones de esterilidad del cultivo in vitro, disminuyendo considerablemente el riesgo de contaminación por microorganismos externos que podrían afectar negativamente el desarrollo embrionario. La reducción del contacto físico con el material vegetal no solo protege la viabilidad del cultivo, sino que también mejora la reproducibilidad de los procesos y favorece una mayor uniformidad en los resultados. De este modo, la implementación de sistemas automatizados basados en visión artificial no solo aporta precisión en la clasificación morfológica, sino que también representa una mejora significativa en las condiciones sanitarias del laboratorio, alineándose con los objetivos de eficiencia, sostenibilidad y estandarización que promueve la agricultura de precisión.

No obstante, el camino hacia una aplicación efectiva de estas tecnologías requiere una atención a ciertos aspectos: la calidad de los datos de entrada, particularmente la homogeneidad y nitidez de las imágenes, se revela como un factor determinante para el rendimiento óptimo de los modelos. Asimismo, la intrínseca variabilidad morfológica entre las distintas variedades de arándano exige estrategias de adaptación y ajuste continuo de los modelos. La disponibilidad de bases de datos etiquetadas y específicas para este cultivo, así como la mitigación de artefactos visuales como sombras y brillos, constituyen desafíos que deben abordarse. En este sentido, si bien la inteligencia artificial ostenta un potencial transformador para el análisis morfológico del arándano, su exitosa integración requiere una preparación técnica y metodológica cuidadosa, asegurando así una transición fluida hacia prácticas agrícolas más precisas y eficientes.

### Referencias Bibliográficas

- ADEX. (2009). *Ficha de requisitos técnicos de acceso al mercado de EE.UU.*  
[http://www.agrobit.com/Info\\_tecnica/alternativos/horticultura/AL\\_000001ho.htm](http://www.agrobit.com/Info_tecnica/alternativos/horticultura/AL_000001ho.htm)
- Agüera Vega, J., & Gil Ribes, J. A. (2004). Nuevas tecnologías en Agricultura de Conservación control de la compactación y técnicas de agricultura de precisión. *Agricultura: Revista Agropecuaria*, 730–733.
- Alhwaiti, Y., Khan, M., Asim, M., Siddiqi, M. H., Ishaq, M., & Alruwaili, M. (2025). Leveraging YOLO deep learning models to enhance plant disease identification. *Scientific Reports*, 15. <https://doi.org/10.1038/s41598-025-92143-0>
- Aliabad, F. A., aliabad, K., Habbab, E., & Bello, A. M. (2023). *Evaluation of the ability to measure morphological structures of plants obtained from tissue culture applying image processing techniques.* <https://doi.org/10.21203/rs.3.rs-3153365/v1>
- Archana, U., Khan, A., Sudarshanam, A., Sathya, C., Koshariya, A. K., & Krishnamoorthy, R. (2023). Plant Disease Detection using ResNet. *6th International Conference on Inventive Computation Technologies, ICICT 2023 - Proceedings*, 614–618.  
<https://doi.org/10.1109/ICICT57646.2023.10133938>
- Amazon Web Services. (2022). *¿Qué es el machine learning?* <https://aws.amazon.com/es/what-is/machine-learning/>
- Balakrishna, N., Sunitha, G., Karthik, A., Madhavi, K. R., & Avanija, J. (2022). Tomato Leaf Disease Detection Using Deep Learning: A CNN Approach. *2022 International Conference on Data Science, Agents and Artificial Intelligence, ICDSAAI 2022.*  
<https://doi.org/10.1109/ICDSAAI55433.2022.10028922>

- Beleño Saenz, K. de J. (2016). Clasificación de los frutos de café según su estado de maduración y detección de la broca mediante técnicas de procesamiento de imágenes. *Prospectiva*, 14(1), 15. <https://doi.org/10.15665/rp.v14i1.640>
- Bobadilla, J. (2021). *Machine Learning y Deep Learning Usando Python, Scikit y Keras* (Ediciones de la U, Ed.; 1st ed., Vol. 1).
- Bouni, M., Hssina, B., Douzi, K., & Douzi, S. (2024). Synergistic use of handcrafted and deep learning features for tomato leaf disease classification. *Scientific Reports*, 14(1), 26822. <https://doi.org/10.1038/s41598-024-71225-5>
- Cabrera, Sabel R., Aguilar Torres, M. Á., & Malzano Agugliaro, F. (2024). Procesamiento y análisis de imágenes y teledetección. In *Introducción a la Teledetección en Agronomía y ciencias afines* (1st ed., Vol. 1, pp. 78–85).
- Castañeda, R. A. M. (2021). Implementation of the vector support machines method in spatial databases for supervised classification analysis in remote sensor images. *Revista Cartografica*, 2021(102), 27–42. <https://doi.org/10.35424/rcarto.i102.830>
- Chatterjee, P., Weerasekara, A., Egertsdotter, U., & Aidun, C. (2024). Machine Learning based Sorting of Somatic Embryos for In-Line processing in Automated SE Fluidics System. *Woodruff School of Mechanical Engineering*, 28(1). <https://doi.org/10.19080/ARTOAJ.2024.28.556399>
- Científico, A., Montes-Cruz, S. I., Lalama-Aguirre II, J. M., Echeverría-Félix III, J. M., Toromoreno-Arévalo, L. I., Salazar-Torres V, S. M., Benavides-Burgos VI, E. S., & Atiaja-Llamba VII, J. A. (2017). *Ciencias Agrícolas*. 3(2), 918–942. <https://doi.org/10.23857/dom.cien.pocaip.2017.3.2.918-942>

- Davidson, S. J., Saggese, T., & Krajňáková, J. (2024). Deep learning for automated segmentation and counting of hypocotyl and cotyledon regions in mature *Pinus radiata* D. Don. somatic embryo images. *Frontiers in Plant Science*, *15*.  
<https://doi.org/10.3389/fpls.2024.1322920>
- Delgado-Paredes, G. E., Vásquez-Díaz, C., Esquerre-Ibañez, B., Bazán-Sernaqué, P., & Rojas-Idrogo, C. (2021). In vitro tissue culture in plants propagation and germplasm conservation of economically important species in Peru. *Scientia Agropecuaria*, *12*(3), 337–349. <https://doi.org/10.17268/SCI.AGROPECU.2021.037>
- Dodeman, V., Ducreux, G., & Kreis, M. (1997). Zygotic embryogenesis versus somatic embryogenesis. *Journal of Experimental Botany*.
- García Molina, J. J. (n.d.). *XXI Jornadas de ingeniería del software y bases de datos*.
- García-Godos, P., Prado-Sumari, I., Estrada, R., & Millán, B. (2022). Caracterización morfológica in situ de 34 accesiones de *Physalis peruviana* L. del departamento de Ayacucho (Perú). *Información Tecnológica*, *33*(2), 169–180.  
<https://doi.org/10.4067/s0718-07642022000200169>
- Ghosh, A., Igamberdiev, A. U., & Debnath, S. C. (2018). Thidiazuron-induced somatic embryogenesis and changes of antioxidant properties in tissue cultures of half-high blueberry plants. *Scientific Reports*, *8*(1). <https://doi.org/10.1038/s41598-018-35233-6>
- González-Castro, V., Alegre, E., & Fidalgo, E. (n.d.). *Clasificación de imágenes con bag of visual words*.
- Hemalatha, S., & Jayachandran, J. J. B. (2024). A Multitask Learning-Based Vision Transformer for Plant Disease Localization and Classification. *International Journal of Computational Intelligence Systems*, *17*(1). <https://doi.org/10.1007/s44196-024-00597-3>

- Hernández Villareal, A. (2013). Caracterización morfológica de recursos fitogénicos. *Revista Bio Ciencias*, 113–118.
- Hesami, M., Naderi, R., Tohidfar, M., & Yoosefzadeh-Najafabadi, M. (2020). Development of support vector machine-based model and comparative analysis with artificial neural network for modeling the plant tissue culture procedures: Effect of plant growth regulators on somatic embryogenesis of chrysanthemum, as a case study. *Plant Methods*, 16(1). <https://doi.org/10.1186/s13007-020-00655-9>
- Hine-Gómez, A., & Abdelnour-Esquivel, A. (n.d.). In vitro establishment of blueberry (*Vaccinium corymbosum* L). In *Tecnología en Marcha* (Vol. 26).
- IBM. (2022). *¿Qué es machine learning (ML)?* <https://www.ibm.com/mx-es/topics/machine-learning>
- ICA. (2023, April 18). *El nutritivo y delicioso sabor de los arándanos colombianos llega a Canadá*. Instituto Colombiano Agropecuario. <https://www.ica.gov.co/noticias/arandanos-colombianos-llegan-a-canada>
- Jiménez, R., Diana, M., & Ovalle Martínez, M. (n.d.). *Arquitecturas de red neuro-convolucional para aplicaciones de robótica asistencial*.
- Karatas, G., Demir, O., & Koray, O. (2018). *Deep Learning in Intrusion Detection Systems*. IEEE. <https://doi.org/10.1109/IBIGDELFT.2018.8625278>
- Kulkarni, R. R., Sharma, A. D., Koundinya, B. K., Anirudh, C., & N, Y. (2024). Effective and efficient automatic detection, prediction and prescription of potential disease in berry family. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-024-19896-0>
- Leifert, C., Waites, W., & Ritchie, J. (1991). Contaminants of plant-tissue and cell cultures. *World Journal of Microbiology and Biotechnology*. <https://doi.org/10.1007/BF00303371>

- León León, R. A., Barrantes Vargas, C. A., & Bacilio De La Cruz, F. D. (2024). Desarrollo de un Sistema de Visión Artificial con la Red Neuronal Convolutiva (YOLO v8) para Clasificar el Arándano por su Grado de Madurez. *Memorias de La Vigésima Tercera Conferencia Iberoamericana En Sistemas, Cibernética e Informática: CISCI 2024*, 475–482. <https://doi.org/10.54808/cisci2024.01.475>
- Llavisaca, S., Cevallos, J. C., Mendoza, J., Piña, F., Peralta, E., Timm, E. S., & Flores, J. (2020). In vitro Propagation of Mortiño (*Vaccinium floribundum* Kunth.). *Plant Tissue Culture and Biotechnology*, 30(2), 167–177. <https://doi.org/10.3329/ptcb.v30i2.50687>
- Mata, A., Allan, Q., & Quirós, M. (n.d.). *Tesis de Maestría 2013*.
- Mazurek, M., Siekierzyńska, A., Piechowiak, T., Spinardi, A., & Litwińczuk, W. (2024). Comprehensive Analysis of Highbush Blueberry Plants Propagated In Vitro and Conventionally. *International Journal of Molecular Sciences*, 25(1). <https://doi.org/10.3390/ijms25010544>
- Méndez-Hernández, H. A., Ledezma-Rodríguez, M., Avilez-Montalvo, R. N., Juárez-Gómez, Y. L., Skeete, A., Avilez-Montalvo, J., De-La-Peña, C., & Loyola-Vargas, V. M. (2019). Signaling overview of plant somatic embryogenesis. In *Frontiers in Plant Science* (Vol. 10). Frontiers Media S.A. <https://doi.org/10.3389/fpls.2019.00077>
- Muhammad, A., Mohd, M., & Ullah, U. (2019). A Pattern Analysis-based Segmentation to Localize Early and Late Blight Disease Lesions in Digital Images of Plant Leaves. *IEEE*.
- Norouzi, O., Hesami, M., Pepe, M., Dutta, A., & Jones, A. M. P. (2022). In vitro plant tissue culture as the fifth generation of bioenergy. *Scientific Reports*, 12(1). <https://doi.org/10.1038/s41598-022-09066-3>

- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. In *The BMJ* (Vol. 372). BMJ Publishing Group.  
<https://doi.org/10.1136/bmj.n71>
- Paul, H., Ghatak, S., Chakraborty, S., Pandey, S. K., Dey, L., Show, D., & Maity, S. (2024). A study and comparison of deep learning based potato leaf disease detection and classification techniques using explainable AI. *Multimedia Tools and Applications*, 83(14), 42485–42518. <https://doi.org/10.1007/s11042-023-17235-3>
- Quirós, M. (2013). *Evaluación de dos protocolos para la inducción de embriogénesis somática en clones de cacao*.
- Ramírez Gil, W. A., & Ramírez Gil, C. M. (2023). *Programación de Inteligencia Artificial. Curso Práctico* (Ra-Ma 2023, Vol. 1).
- Rodríguez-Garay, B., Lomelí-Sención, J. A., Tapia-Campos, E., Gutiérrez-Mora, A., García-Galindo, J., Rodríguez-Domínguez, J. M., Urbina-López, D., & Vicente-Ramírez, I. (2009). Industrial Crops and Products. *Morphological and Molecular Diversity of Agave Tequilana Weber Var. Azul and Agave Angustifolia Haw. Var. Lineño*, 29(1), 220–228.
- Salaverría, J. L., & Sánchez Cuevas, M. C. (2004). *Control de la oxidación y la contaminación en el cultivo in vitro de fresa (Fragaria X ananassa Duch.)*.
- Saleki, S., & Tahmoresnezhad, J. (2024). Agry: a comprehensive framework for plant diseases classification via pretrained EfficientNet and convolutional neural networks for precision

- agriculture. *Multimedia Tools and Applications*, 83(24), 64813–64851.  
<https://doi.org/10.1007/s11042-023-17952-9>
- Sánchez Jhong, K., Cabrera Pintado, R., & Jiménez D, J. (2019). Induction of somatic embryogenesis from foliar explants in three varieties of coffee. *Scientia Agropecuaria*, 10(2), 259–264. <https://doi.org/10.17268/sci.agropecu.2019.02.11>
- Sathisrajan, N., Chandeeep, H. M. A., Rathnayake, S. C., Vidhanaarachchi, S., & Vidhanaarachchi, V. R. M. (2024). Advanced Plant Growth Recognition Model with Deep learning for the Coconut tissue culture. *Proceedings of ICITR 2024 - 9th International Conference on Information Technology Research: Harnessing the Potential of Information Technology*. <https://doi.org/10.1109/ICITR64794.2024.10857788>
- Sayali Bharat, J., Vaishnavi Nandkishor, Z., Sonali Natha, T., Aishwarya Avinash, S., & Deepak sitaram, M. (2020). *PLANT TISSUE CULTURE* (Vol. 7). JETIR. [www.jetir.org](http://www.jetir.org)
- Shavindi, H. D. M., Kumarasiri, D. K. N., Tissera, W., Vidhanaarachchi, S., Joseph, J., & Vidhanaarachchi, V. (2024). Effectiveness of Deep Learning and IoT for Disease Classification and Characterizing Tissue Culture Calli. *2024 6th International Conference on Advancements in Computing, ICAC 2024*, 522–527.  
<https://doi.org/10.1109/ICAC64487.2024.10851116>
- Uribe, C. P., Sandra, G., Fonseca, L., Gustavo, R., Bernal, E., Carlos, R., Contreras, A., Oscar, P., Castellanos, F., & Bogotá, D. (2011). *Sembrando innovación para la competitividad del sector agropecuario colombiano autores*.
- Verma, S., Chug, A., Singh, A. P., & Singh, D. (2024). Plant Disease Detection and Severity Assessment Using Image Processing and Deep Learning Techniques. *SN Computer Science*, 5(1). <https://doi.org/10.1007/s42979-023-02417-5>

- Wanjari, K., & Verma, P. (2025). A Review on the Applications of Machine Learning and Deep Learning Algorithms for Image Recognition. *2025 4th International Conference on Sentiment Analysis and Deep Learning (ICSADL)*, 1707–1711.  
<https://doi.org/10.1109/ICSADL65848.2025.10933346>
- Zhang, Y., & Zheng, X. (2022). Development of Image Processing Based on Deep Learning Algorithm. *2022 IEEE Asia-Pacific Conference on Image Processing, Electronics and Computers, IPEC 2022*, 1226–1228. <https://doi.org/10.1109/IPEC54454.2022.9777479>
- Zielińska, S., & Kępczyńska, E. (2013). Neural modeling of plant tissue cultures: a review. In *Computational Biology and Bionanotechnology* (Vol. 94).

## Apéndices

### Apéndice A

#### *Modelos para la Identificación Morfológica en Embriogénesis Somática y su Precisión*

Cita	Nombre del documento	Precisión del modelo utilizado
Identificación morfológica de la embriogénesis somática	(Davidson et al., 2024)	<p>Deep learning for automated segmentation and counting of hypocotyl and cotyledon regions in mature <i>Pinus radiata</i> D. Don. somatic embryo images</p> <p>Red neuronal convolucional (CNN) de segmentación semántica:</p> <p>Cotiledones: F1-score: 0.929</p> <p>Hipocótilo: F1-score: 0.932</p> <p>Red para segmentación por instancias (Instance Segmentation Network): cotiledones 0.96</p>
	(Chatterjee et al., 2024)	<p>Machine Learning based Sorting of Somatic Embryos for In-Line processing in Automated SE Fluidics System</p> <p>SVM (Support Vector Machine): logró altas tasas de precisión hasta 90.9%, para clasificar embriones somáticos</p>
	(Chatterjee et al., 2024)	<p>Development of support vector machine-based model and comparative analysis with artificial neural network for modeling the plant tissue culture procedures: effect of plant growth regulators on somatic embryogenesis of <i>chrysanthemum</i>, as a case study</p> <p>Multilayer Perceptron (MLP) — una red neuronal artificial: tasa callos: 0.893 tasa embriones 0.927</p>
	(Zielińska & Kępczyńska, 2013)	<p>Neural modeling of plant tissue cultures: a review</p> <p>Support Vector Regression (SVR): tasa callos: 0.928, tasa embriones: 0.966</p>
		<p>MLP en sistema jerárquico clasificación de embriones entre el 80% y 90%</p> <p>Fuzzy Neural Networks (FNN-A y FNN-B):</p>

---

		clasificación de embriones del 95%
		YOLOv8: Segmentación por forma de callos: (Ear-shaped, Frilly-shaped, Globular-shaped): Precisión en validación del 85%
(Shavindi et al., 2024)	Effectiveness of Deep Learning and IoT for Disease Classification and Characterizing Tissue Culture Calli	CNN (detección de callos): el primer filtro para seleccionar imágenes que contienen callos antes de clasificarlos, obtuvo un 88% de precisión
(Sathisrajan et al., 2024)	Advanced Plant Growth Recognition Model with Deep learning for the Coconut tissue culture	YOLOv8: Medición precisa de longitud de brote y hojas con puntos clave : 99.4%
		Evaluó la precisión de diferentes modelos:
(Aliabad et al., 2023)	Evaluation of the ability to measure morphological structures of plants obtained from tissue culture applying image processing techniques	SVM (el más preciso): 90.6 KNN: 89.4 Naïve Bayes: 89.4 Decision Tree : 75.0 Random Forest: 73.8

---

## Apéndice B

### *Modelos para la Identificación Morfológica de Enfermedades de Plantas y su Precisión*

Cita	Nombre del documento	Precisión de Modelo Utilizado
(Archana et al., 2023)	Plant Disease Detection using ResNet	Modelo ResNet-50 principal tuvo una precisión del 96.35%
(Muhammad et al., 2019)	A Pattern Analysis-based Segmentation to Localize Early and Late Blight Disease Lesions in Digital Images of Plant Leaves	Se evalúa a través de la tasa de verdaderos positivos (TP) con una precisión del 96.9%
(Balakrishna et al., 2022)	Tomato Leaf Disease Detection Using Deep Learning: A CNN Approach	El rendimiento superior del trabajo propuesto se confirma por una precisión del 92%. . Modelo VGG16
(Alhwaiti et al., 2025)	Leveraging YOLO deep learning models to enhance plant disease identification	YOLOv4: tuvo una precision del 98%, YOLOv3: tuvo una precision de 97%
(Verma et al., 2024)	Plant Disease Detection and Severity Assessment Using Image Processing and Deep Learning Techniques	Usando solo CNN para clasificación: CNN - AlexNet: 71.34% ResNet18: 66.88% ResNet50: 75.16% ResNet101: 78.98% (el mejor) SqueezeNet: 77.07% Inception V3: 71.34% Usando CNN para extracción de características + SVM para clasificación: AlexNet: 77.07% ResNet18: 72.61%

---

		ResNet50: 75.80%
		ResNet101: 82.80% (el mejor)
		SqueezeNet: 77.98%
		Inception V3: 75.16%
(Bouni et al., 2024)	Synergistic use of handcrafted and deep learning features for tomato leaf disease classification	El modelo con mejor rendimiento fue MobileNet v2 combinado con características artesanales, Precisión de entrenamiento: 91.90%
(Hemalatha & Jayachandran, 2024)	A Multitask Learning-Based Vision Transformer for Plant Disease Localization and Classification	El modelo PDLC-ViT evaluado en dos conjuntos de datos públicos logró una precisión del 99.97%
(Paul et al., 2024)	A study and comparison of deep learning based potato leaf disease detection and classification techniques using explainable AI	CNN-SVM (Convolutional Neural Network con Support Vector Machine) 99.91%, DenseNet1 69 99% Deep Ensemble (conjunto profundo) 99.98%, se revisaron otros modelos, pero con resultados menores.
(Kulkarni et al., 2024)	Effective and efficient automatic detection, prediction and prescription of potential disease in berry family	Se evaluaron tres modelos: Convolutional Neural Network (CNN), que obtuvo una precisión del 98%, VGG16, con una precisión del 96%, MobileNet que obtuvo una precisión del 86%
(Saleki & Tahmoresnezhad, 2024)	Agry: a comprehensive framework for plant diseases classification via	Se evaluaron diferentes modelos, los cuales tuvieron los siguientes valores en las precisiones:

---

---

pretrained EfficientNet and	AlexNet: $88.32\% \pm 0.58\%$
convolutional neural	ResNet50: $99.94\% \pm 0.06\%$
networks for precision	VGG16: $96.42\% \pm 0.50\%$
agriculture	EfficientNetB0: $99.41\% \pm 0.21\%$
	EfficientNetB3: $99.32\% \pm 0.21\%$
	EfficientNetB7: $99.65\% \pm 0.14\%$

---