

Machine learning como herramienta para mejorar la sostenibilidad y eficiencia en el cultivo de fresa en Colombia: revisión de literatura

Angie Natalia Garzón Rivera

Asesor

Jorge Luis Quintero Lopez

Universidad Nacional Abierta y a Distancia UNAD
Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI
Especialización En Ciencia De Datos y Analítica
2025

Jorge Luis Quintero Lopez

Jurado

Jurado

Dedicatoria

A mis padres Hildebrando y Sofia, con todo mi amor y gratitud, por haber sido mi ejemplo constante de esfuerzo y perseverancia. Gracias por apoyarme desde mis primeros pasos académicos, por creer en mí y por brindarme las oportunidades que me han permitido llegar hasta aquí. Su apoyo en mi carrera de pregrado fue el pilar que hizo posible que hoy culmine esta especialización.

A mis hermanos Jessica, Mariana y Juan, quienes con sus locuras, risas y cariño me llenan de energía y me inspiran a ser cada día una mejor hermana, aquella que ellos puedan admirar y seguir.

A los Daniels, por su paciencia, amor y por acompañarme en cada momento de duda o cansancio. Gracias por ser ese impulso que me levanta cada vez que caigo y por recordarme siempre mi fortaleza.

Y a todos mis familiares que, con un abrazo, una palabra de aliento o un gesto sincero, han sido fuente de inspiración y motivación en este camino.

A cada uno de ustedes, gracias por creer en mí y ser parte fundamental de este logro.

Agradecimientos

A mis padres, por ser ejemplo constante de perseverancia y dedicación, valores que han guiado mi formación personal y profesional.

A mis hermanos, por recordarme la importancia del apoyo mutuo y del trabajo conjunto para alcanzar las metas propuestas.

A mi pareja, por ser un pilar fundamental de apoyo y por motivarme a salir de la zona de confort para continuar creciendo personal y profesionalmente.

A mis familiares y amigos cercanos, por su compañía, sus palabras y anécdotas que se convirtieron en fuente de inspiración y fortaleza durante este proceso.

A mis docentes, por los valiosos conocimientos, la orientación y el acompañamiento brindado a lo largo de toda la especialización. En especial, quiero expresar mi sincero agradecimiento a mi director, cuyo enfoque paciente, sabio y siempre disponible, me permitió avanzar con claridad y dedicación en cada etapa de este proyecto

A la Universidad Nacional Abierta y a Distancia (UNAD), por ofrecer la posibilidad de adelantar mis estudios de manera virtual y facilitar la formación académica en diferentes contextos.

Finalmente, a mis jefes, por su respaldo y por impulsarme a continuar mi preparación profesional, fortaleciendo mis conocimientos y habilidades para el ejercicio laboral.

Resumen

Esta revisión de literatura consolida cómo se han aplicado el análisis de datos y el machine learning en el cultivo de fresa, con énfasis en los aportes más relevantes para la producción y la comercialización. Se identifican tres enfoques con mayor número de estudios: el análisis del fruto, orientado a evaluar calidad y rendimiento; el análisis del suelo y la planta, centrado en estimar nutrientes y vigor; y la detección de enfermedades y plagas mediante técnicas de visión e inteligencia artificial. Los otros estudios están enfocados a la gestión general del cultivo y se incluye un estudio basado en Twitter que demuestra el potencial del análisis de redes sociales para apoyar la comercialización.

Los resultados muestran que estas tecnologías mejoran la precisión, permiten predicciones más rápidas y facilitan la detección temprana de problemas, aunque todavía enfrentan limitaciones relacionadas con disponibilidad de datos, validación en campo y dependencia de sensores especializados. En general, los estudios coinciden en que el machine learning puede contribuir de manera importante a optimizar el manejo agronómico y fortalecer la competitividad del cultivo.

Se recomienda avanzar en la generación de datos locales para Colombia, validar modelos en diferentes regiones productoras y promover el uso de herramientas que integren análisis agronómicos y de mercado para mejorar la sostenibilidad y competitividad del cultivo de fresa.

Palabras claves: Machine learning, Fresas, agricultura, sostenibilidad

Abstract

This literature review consolidates the application of data analysis and machine learning in strawberry cultivation, emphasizing the most relevant contributions to production and marketing. Three approaches with most studies are identified: fruit analysis, focused on evaluating quality and yield; soil and plant analysis, centered on estimating nutrients and vigor; and disease and pest detection using vision and artificial intelligence techniques. Other studies focused on general crop management and included a Twitter-based study demonstrating the potential of social media analysis to support marketing.

The results show that these technologies improve accuracy, enable faster predictions, and facilitate early problem detection, although they still face limitations related to data availability, field validation, and dependence on specialized sensors for data collection. Overall, the studies agree that machine learning can significantly contribute to optimizing agronomic management and strengthening crop competitiveness.

It is recommended to advance the generation of local data for Colombia, validate models in different producing regions, and promote the use of tools that integrate agronomic and market analyses to improve the sustainability and competitiveness of strawberry cultivation in Colombia.

Keywords: machine learning, strawberry, agriculture, sustainability

Tabla de Contenido

Introducción	10
Justificación	12
Objetivos.....	14
Objetivo General	14
Objetivos Específicos.....	14
Pregunta Problema	14
Búsqueda y Selección de Documentos	15
Diseño y Mejora de la Ecuación de Búsqueda.....	15
Selección y Análisis de la Literatura.....	18
Análisis Comparativo de los Artículos Identificados	29
Recomendaciones Preliminares en Colombia.....	49
Calidad de los Estudios Seleccionados	52
Conclusiones.....	62
Recomendaciones	64
Referencias Bibliográficas	66

Lista de Tablas

Tabla 1 <i>Documentos Seleccionados Después de la Depuración</i>	20
Tabla 2 <i>Metodologías y Limitaciones de los Documentos Seleccionados</i>	29
Tabla 3 <i>Clasificación de los Artículos por Enfoque de Estudio</i>	46
Tabla 4 <i>Matriz DOFA</i>	49
Tabla 5 <i>Calidad de los Documentos Seleccionados</i>	54

Lista de Figuras

Figura 1 <i>Resultados Iniciales de la Ecuación de Búsqueda</i>	15
Figura 2 <i>Gráfico de Relación de las Palabras Clave en VOSviewer</i>	16
Figura 3 <i>Países Identificados en la Búsqueda Inicial</i>	17
Figura 4 <i>Año de Publicación de los Documentos Identificados</i>	18
Figura 5 <i>Ilustración de Método PRISMA Usado en la Selección de Documentos</i>	19
Figura 6 <i>Países Identificados en la Selección Final</i>	26
Figura 7 <i>Año de Publicación de los Documentos Seleccionados</i>	27
Figura 8 <i>Gráfico de Relación de las Palabras Clave en VOSviewer Documentos Finales</i>	28

Introducción

La agricultura es uno de los sectores fundamentales para la economía colombiana, debido a que esta representa cerca del 10% del PIB nacional (UPRA (Unidad de Planificación Rural Agropecuaria), n.d.) y emplea a más de 3 millones de personas. Sin embargo, el sector enfrenta desafíos significativos para alcanzar la sostenibilidad y la eficiencia, tales como la variabilidad climática, la escasez de recursos hídricos, la degradación del suelo, la pérdida de biodiversidad y la disponibilidad de terrenos para siembra. (Juan Esteban Baena Tapias, 2021).

Colombia presenta niveles significativos de pérdidas y desperdicios de alimentos, de acuerdo con el estudio, (DNP (Departamento Nacional de Planeación) & Dirección de Seguimiento y Evaluación de Políticas Públicas, 2016), de la oferta de 28,5 millones de toneladas de alimentos, el 34% de los alimentos se pierden y se desperdician. Y de estos alimentos desperdiciados el 64% se da entre las etapas de producción y procesamiento y un 36% corresponde a la distribución y ventas. Estas pérdidas afectan directamente los costos asumidos por los agricultores e impactan la oferta disponible, (Calderón Gómez, 2015) (Tovar-Quiroz, 2023) generando variaciones en los precios y contribuyendo a problemas como la inseguridad alimentaria. (Sánchez-Céspedes et al., 2022)

En este panorama, cultivos como la fresa tienen especial relevancia, pues representan una actividad económica importante en departamentos como Cundinamarca, Antioquia y Cauca. Sin embargo, investigaciones nacionales muestran que el cultivo de fresa enfrenta múltiples limitaciones: enfermedades foliares frecuentes, uso no optimizado de insumos agrícolas, problemas de calidad, variabilidad en el microclima y pérdidas considerables en cosecha y postcosecha (Castellanos & Baldovino, 2021). También existen dificultades logísticas

relacionadas con la cadena de frío, el transporte y la comercialización (Calderón Gómez, 2015), lo que incrementa aún más las pérdidas del producto antes de llegar al consumidor.

Teniendo en cuenta las pérdidas de los alimentos en las etapas de producción y procesamiento industrial al identificar por medio de la analítica de datos los factores que están afectando los cultivos de fresa y la zona en donde está el problema, permitiría no solo invertir menos recursos en el control y mejora del cultivo sino que también aumentaría la productividad, logrando mayor cantidad de producto con menor costo invertido, permitiendo que se garanticen precios competitivos y sostenibles en el mercado.

Frente a estos retos, la analítica de datos y el machine learning se posicionan como herramientas clave para mejorar la sostenibilidad y la eficiencia en los sistemas productivos. Estas tecnologías permiten identificar patrones, anticipar problemas, optimizar recursos y tomar decisiones basadas en información precisa y oportuna (Tovar-Quiroz, 2023); (Garzón Echeverry et al., n.d.). En cultivos sensibles como la fresa, donde la calidad del fruto y el rendimiento dependen de múltiples factores que cambian día a día, la posibilidad de analizar datos ambientales, agronómicos, sanitarios y logísticos abre la puerta a prácticas más inteligentes y eficientes.

Justificación

El cultivo de fresa en Colombia constituye una de las actividades frutícolas más importantes en departamentos como Cundinamarca, Boyacá, Antioquia, Nariño y Cauca, donde representa una fuente significativa de ingresos para pequeños y medianos productores de acuerdo con estudios realizados por el (Ministerio de Agricultura, 2021). Sin embargo, diversos estudios nacionales han evidenciado que este cultivo enfrenta múltiples desafíos que limitan su sostenibilidad y eficiencia. Entre los principales problemas se incluyen enfermedades foliares recurrentes, alta susceptibilidad a variaciones climáticas, uso no optimizado de insumos agrícolas, limitaciones en prácticas de postcosecha y pérdidas significativas durante la comercialización (Calderón Gómez, 2015), (Castellanos & Baldovino, 2021). Adicionalmente, diagnósticos institucionales muestran la persistencia de brechas tecnológicas y dificultades para implementar sistemas de monitoreo precisos que permitan anticipar riesgos o gestionar adecuadamente la productividad del cultivo.

De acuerdo con los estudios identificados y el desarrollo de la agricultura, la analítica de datos emerge como una herramienta para optimizar la eficiencia y sostenibilidad de la agricultura. Debido a que permite a los agricultores tomar decisiones basadas en datos precisos y oportunos sobre sus cultivos (Tovar-Quiroz, 2023), lo que puede ayudar a mejorar la productividad, reducir costos y minimizar el impacto ambiental (Garzón Echeverry & Caycedo Gutiérrez, 2022) . Sin embargo, a pesar de estos avances, la aplicación de la analítica de datos en la agricultura colombiana y particularmente en los cultivos de fresa es baja, aunque existen estudios agronómicos, logísticos y fitosanitarios que generan datos relevantes, hay un vacío en la integración de esta información mediante modelos predictivos y sistemas de apoyo a la decisión.

La presente revisión se justifica por la necesidad de explorar y analizar la aplicación de la analítica de datos y el machine learning en los cultivos de fresa, identificando oportunidades, desafíos y aplicaciones potenciales para el contexto colombiano. El documento también busca contribuir al campo de conocimiento en la intersección de la analítica de datos en la agricultura, y proporcionar recomendaciones prácticas para los agricultores de cultivos de fresa que buscan promover la sostenibilidad y la eficiencia los cultivos de fresa en Colombia, por medio de la implementación de alternativas innovadoras.

Objetivos

Objetivo General

Desarrollar una revisión sistemática de la literatura sobre el uso de la analítica de datos y machine learning como herramientas para mejorar la sostenibilidad y eficiencia en los cultivos de fresa en Colombia.

Objetivos Específicos

Identificar modelos de analítica de datos y agricultura, por medio de revisión de literatura, que podrían ser implementados en los cultivos de fresa en el país.

Analizar los principales beneficios y desafíos que enfrentan los cultivos de fresa en Colombia al incorporar modelos de analítica de datos.

Generar un conjunto de recomendaciones basadas en evidencia que ayuden a los agricultores a aprovechar la analítica de datos para mejorar la eficiencia y sostenibilidad de los cultivos de fresa en Colombia.

Pregunta Problema

¿Qué enfoques de analítica de datos y machine learning se han documentado en la literatura para mejorar la eficiencia y sostenibilidad en cultivos de fresa, y cuáles son sus implicaciones para su adopción en Colombia?

Búsqueda y Selección de Documentos

Diseño y Mejora de la Ecuación de Búsqueda

Teniendo en cuenta la selección del cultivo de fresa y la técnica de ciencia de datos el machine learning, y los objetivos propuestos se realizó una búsqueda inicial con las palabras machine learning, agricultura, fresa y sostenibilidad

De acuerdo con el título y los objetivos definidos orientados a la búsqueda de documentos de análisis de datos con machine learning, en la agricultura en cultivos de fresa, se define la siguiente ecuación de búsqueda:

"Machine learning" AND (strawberry OR strawberries) AND Agriculture AND sustainability

Figura 1

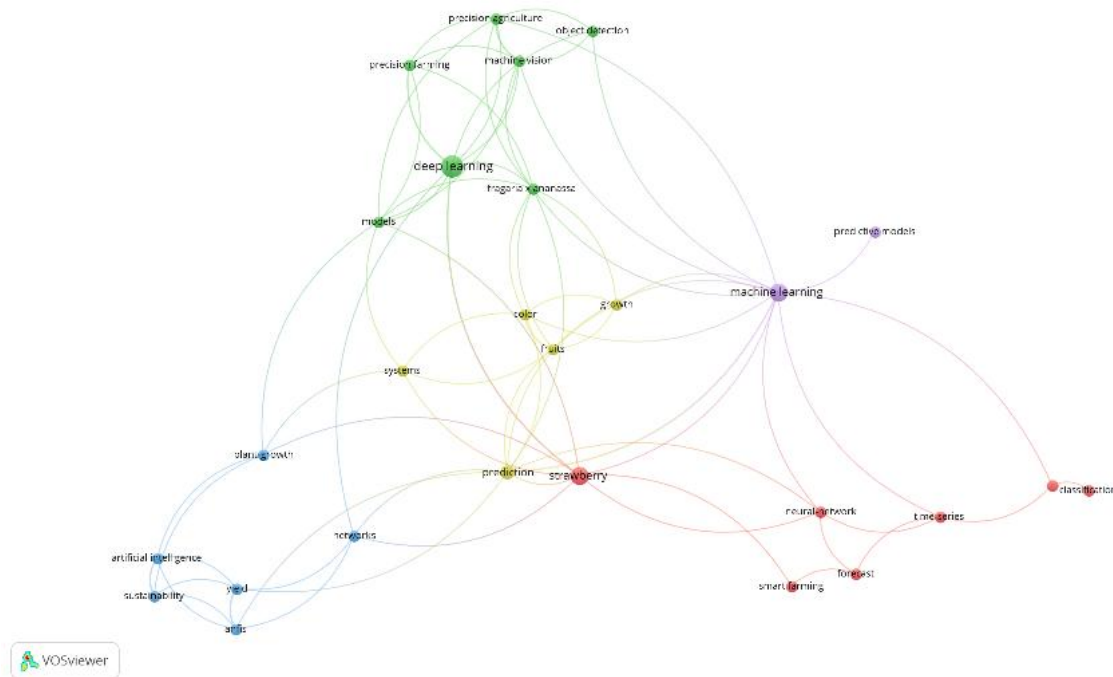
Resultados Iniciales de la Ecuación de Búsqueda

The figure displays two search result interfaces. On the left is the ScienceDirect interface, showing a search bar with the query "machine learning" AND (strawberry OR strawberries) AND Agriculture AND sustainability. It indicates "1 result found" and lists a research article titled "Developing a multi-label tinyML machine learning model for an active and optimized greenhouse microclimate control from small-scale sensor data" by Ibrahim Alkhatib et al. On the right is the Web of Science interface, showing "30 results from Web of Science Core Collection for: 'machine learning' AND (strawberry OR strawberries) AND Agriculture AND sustain...". It displays a list of results, including conference papers from the "Intelligent Computing and Intelligent Systems (ICIS 2022)" conference.

Para esta primera ecuación se identificaron 30 resultados en Web of Science, 1 documento en ScienceDirect y 4 en Scopus.

Figura 2

Gráfico de Relación de las Palabras Clave en VOSviewer



A partir de la primera ecuación de búsqueda, se generó un mapa de coocurrencias de las palabras clave (Figura 2), la cual permitió identificar los principales términos asociados con la búsqueda. En este mapa se observan agrupaciones centradas en conceptos como machine learning, deep learning, prediction, agriculture y sustainability, lo que evidencia una relación directa entre el aprendizaje automático y las prácticas agrícolas sostenibles. Sin embargo, los términos relacionados con el cultivo de la fresa (strawberry, fragaria) presentaban menor representatividad dentro de la red, lo que sugiere la necesidad de refinar la búsqueda para capturar con mayor precisión los estudios específicos de esta especie.

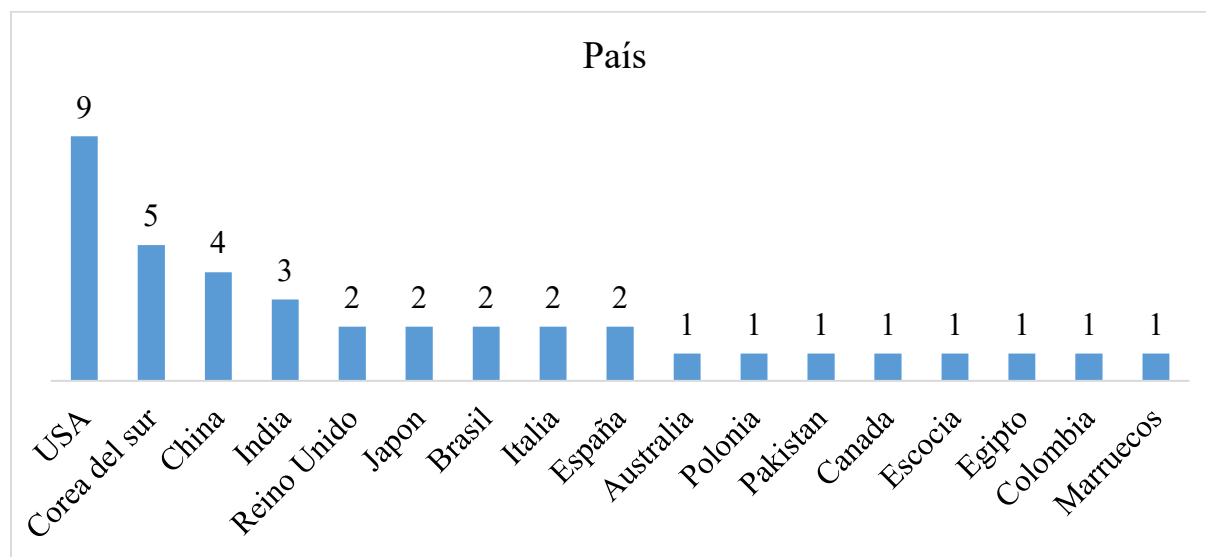
Con base en este análisis, se decidió ajustar la ecuación de búsqueda incorporando de manera explícita los términos strawberry, strawberries y fragaria, en combinación con conceptos agrícolas y de sostenibilidad, por lo cual se determinó la siguiente ecuación:

"Machine learning" AND (strawberry OR strawberries OR fragaria) AND (agriculture OR "crop production" OR farming) AND (sustainability)

Con esta ecuación se encontraron 31 documentos en Web of Science, 2 en ScienceDirect y 6 en Scopus, para un total de 39 documentos. De acuerdo con los resultados obtenidos en la búsqueda bibliográfica, se considera que la ecuación de búsqueda propuesta resulta pertinente para los objetivos del estudio. En consecuencia, se adoptará esta ecuación como definitiva y se procederá con la aplicación de la metodología PRISMA para la evaluación, selección y análisis de los artículos identificados.

Figura 3

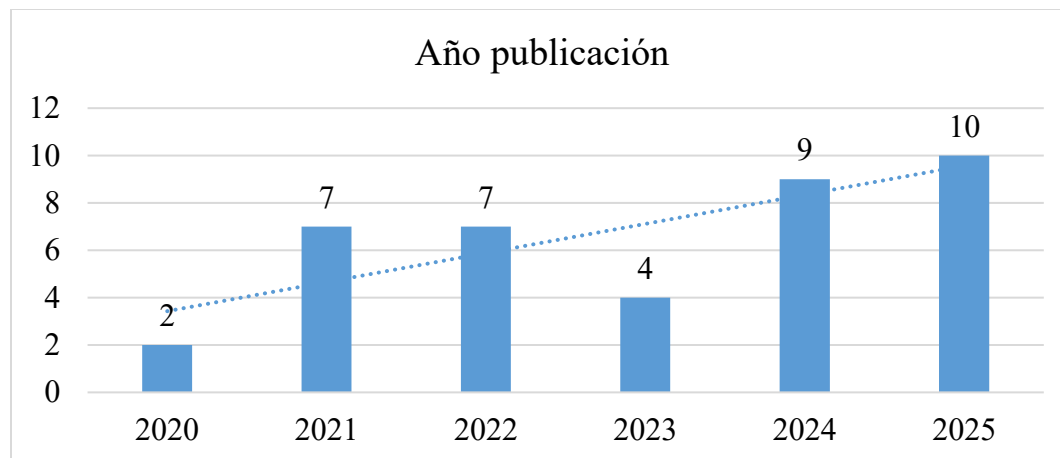
Países Identificados en la Búsqueda Inicial



En esta búsqueda inicial los países con mayor cantidad de estudios son EE. UU., Corea del Sur, China, e India, lo que sugiere que estos países están liderando la investigación en el área. En cuanto a Colombia se identifica un solo documento.

Figura 4

Año de Publicación de los Documentos Identificados



Las publicaciones identificadas se concentran en los últimos 6 años (2021-2025), con una mayor presencia de publicaciones en 2025. Esto sugiere que el tema en cuestión es relativamente reciente, y que las investigaciones han aumentado de forma considerable en los últimos años.

Selección y Análisis de la Literatura

Teniendo en cuenta los objetivos del trabajo y con el fin de identificar investigaciones que apliquen técnicas de Machine Learning en los cultivos de fresa, buscando una producción agrícola sostenible, se establecieron los siguientes criterios de selección:

1. Estudios sin aplicación práctica o sin datos experimentales (solo teóricos o de simulación sin validación en campo).
2. Trabajos que no aborden la agricultura o la sostenibilidad (como, Machine Learning en biología molecular, postcosecha o mercadeo).

3. Artículos que no mencionen ni analítica de datos ni machine learning explícitamente.
4. Publicaciones sin texto completo, duplicadas o no revisadas por pares (ej. resúmenes de conferencias, tesis, informes técnicos).
5. Estudios centrados en otros cultivos (no fresa) salvo que presenten modelos transferibles o generalizables a este cultivo.

De acuerdo con el criterio del tipo de publicación se realizó una revisión preliminar de los tipos de documentos, con el fin de garantizar la calidad y pertinencia de las fuentes incluidas. Se descartaron los 3 documentos clasificados como actas de conferencias, ya que generalmente presentan resultados parciales, y no ofrecen información metodológica suficiente para un análisis comparativo riguroso. Adicionalmente al unificar los resultados de la búsqueda se identificó que un artículo se encontró en la búsqueda de dos bases de datos (Web Of Science y Scopus), por lo tanto, se elimina el que se encuentra duplicado.

Al aplicar los criterios de exclusión se obtuvieron los siguientes resultados:

Figura 5

Ilustración de Método PRISMA Usado en la Selección de Documentos

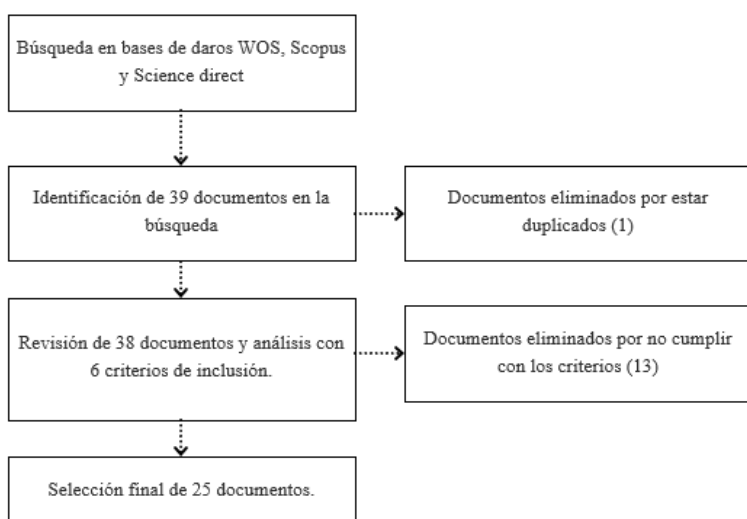


Tabla 1*Documentos Seleccionados Después de la Depuración*

Título del documento	Año de publicación	Metodología	Resultados
Remote Sensing and Machine Learning in Crop Phenotyping and Management, with an Emphasis on Applications in Strawberry Farming	2021	Uso de sensores remotos y machine learning para la fenotipificación y manejo de cultivos de fresa	Mejora en la predicción del rendimiento y características del cultivo, optimización de recursos en la agricultura de fresa
Precision Agriculture Using Soil Sensor Driven Machine Learning for Smart Strawberry Production	2023	Integración de sensores de suelo con machine learning para optimizar la producción de fresas.	Aumento en la eficiencia del uso de nutrientes y agua, mejora de la calidad y rendimiento de la producción de fresas.
A Multi-Farm Global-to-Local Expert-Informed Machine Learning System for Strawberry Yield Forecasting	2024	Sistema de machine learning global a local con información experta para predecir el rendimiento de fresas.	Predicciones precisas del rendimiento de fresas a diferentes escalas, optimización de recursos y planificación de la cosecha.
Smart Strawberry Farming Using Edge Computing and IoT	2022	Uso de computación en el borde (edge computing) e IoT para el monitoreo y control inteligente de cultivos de fresa.	Mejora en la gestión en tiempo real de los cultivos de fresa, reduciendo el uso de recursos y mejorando la sostenibilidad.

Título del documento	Año de publicación	Metodología	Resultados
From Simulation to Field Validation: A Digital Twin-Driven Sim2real Transfer Approach for Strawberry Fruit Detection and Sizing	2025	Enfoque de gemelo digital para la simulación y validación en campo de la detección y dimensionamiento de frutas de fresa.	Mejora en la precisión de la detección y clasificación de fresas, aplicando simulaciones y validaciones en el campo real.
Prediction of Strawberry Leaf Color Using RGB Mean Values Based on Soil Physicochemical Parameters Using Machine Learning Models	2022	Predicción del color de las hojas de fresa usando valores promedio RGB y parámetros fisicoquímicos del suelo con machine learning.	Establece un modelo predictivo preciso del color de las hojas, útil para determinar el estado de salud de las plantas.
Detection of fusarium wilt-induced physiological impairment in strawberry plants using hyperspectral imaging and machine learning	2024	Uso de imágenes hiperespectrales y machine learning para detectar daños fisiológicos causados por Fusarium en fresas.	Detección temprana y precisa de la enfermedad de Fusarium, mejorando la intervención temprana para el control de enfermedades.
AI-driven time series analysis for predicting strawberry weekly yields integrating fruit monitoring and weather data for optimized harvest planning	2025	Análisis de series temporales impulsado por IA para predecir el rendimiento semanal de fresas utilizando datos de monitoreo de frutas y clima.	Predicción precisa del rendimiento semanal, lo que permite una planificación de cosechas más eficiente.

Título del documento	Año de publicación	Metodología	Resultados
Decision Trees to Forecast Risks of Strawberry Powdery Mildew Caused by <i>Podosphaera aphanis</i>	2021	Uso de árboles de decisión para pronosticar riesgos de mildiu polvoriento en fresas.	Mejora en la predicción y control de la enfermedad, reduciendo la necesidad de tratamientos químicos.
Application of automated image colour analyses for the early-prediction of strawberry development and quality.	2022	Aplicación de análisis automatizado del color de imágenes para la predicción temprana del desarrollo y calidad de las fresas.	Predicción temprana y precisa del desarrollo de las fresas, mejorando la calidad y el tiempo de cosecha.
Characteristics of compound low-temperature and limited-light events in southern China and their effects on greenhouse grown strawberry	2022	Análisis de eventos de baja temperatura y luz limitada en invernaderos y su efecto en las fresas en el sur de China.	Mejora de las condiciones de cultivo en invernaderos, optimización de las condiciones para el crecimiento de fresas en climas fríos.
Identification of plant leaf phosphorus content at different growth stages based on hyperspectral reflectance	2021	Identificación del contenido de fósforo en las hojas de fresa mediante reflectancia hiperespectral en diferentes etapas de crecimiento.	Identificación precisa del contenido de fósforo, optimizando el uso de fertilizantes y mejorando el crecimiento de las plantas.
Identification and Analysis of Strawberries' Consumer Opinions on Twitter for Marketing Purposes	2021	Análisis de opiniones de consumidores de fresas en Twitter utilizando machine learning para fines de marketing.	Mejora en las estrategias de marketing al entender las preferencias y opiniones de los consumidores sobre las fresas.

Título del documento	Año de publicación	Metodología	Resultados
CAFM-Enhanced YOLOv8: A Two-Stage Optimization for Precise Strawberry Disease Detection in Complex Field Conditions	2025	Optimización de YOLOv8 para la detección precisa de enfermedades en fresas bajo condiciones complejas de campo.	Aumento en la precisión de la detección de enfermedades, mejorando el manejo y control de enfermedades en cultivos de fresas.
Detection of gray mold disease and its severity on strawberry using deep learning networks	2022	Detección de la enfermedad del moho gris y su severidad en fresas utilizando redes de aprendizaje profundo.	Identificación temprana y precisa del moho gris, lo que permite intervenciones oportunas para evitar pérdidas.
Prediction of Strawberry Dry Biomass from UAV Multispectral Imagery Using Multiple Machine Learning Methods	2022	Predicción de biomasa seca de fresas utilizando imágenes multiespectrales de UAV y machine learning.	Predicciones precisas de la biomasa, lo que permite una mejor gestión del cultivo y optimización de recursos.
Deep learning-based identification system of weeds and crops in strawberry and pea fields for a precision agriculture sprayer	2021	Sistema de identificación basado en deep learning para detectar maleza y cultivos en campos de fresas y guisantes.	Mejora en la precisión del control de maleza, reduciendo el uso de herbicidas y mejorando la eficiencia agrícola.
Advanced canopy size estimation in strawberry production: a machine learning approach using YOLOv11 and SAM	2025	Estimación avanzada del tamaño del dosel en la producción de fresas utilizando machine learning con YOLOv11 y SAM.	Mejora en la estimación del tamaño del dosel, lo que facilita la planificación y manejo del cultivo.

Título del documento	Año de publicación	Metodología	Resultados
Fruit Ripeness Prediction Based on DNN Feature Induction from Sparse Dataset	2021	Predicción de la madurez de la fruta utilizando inducción de características DNN a partir de un conjunto de datos disperso.	Predicción precisa de la madurez de la fruta, lo que permite mejorar el momento de la cosecha y la calidad.
Performance of Neural Networks in the Prediction of Nitrogen Nutrition in Strawberry Plants	2024	Evaluación del rendimiento de redes neuronales para predecir la nutrición nitrogenada en plantas de fresa.	Mejora en la predicción de las necesidades de nitrógeno, optimizando el uso de fertilizantes y mejorando el rendimiento de las fresas.
Channel randomisation: Self-supervised representation learning for reliable visual anomaly detection in speciality crops	2024	Enfoque de auto-supervisión para la detección de anomalías visuales en cultivos especializados, incluyendo fresas.	Mejora en la detección temprana de anomalías visuales, lo que permite una intervención rápida y eficiente.
Investigation to answer three key questions concerning plant pest identification and development of a practical identification framework	2024	Investigación para identificar plagas de plantas y desarrollar un marco práctico de identificación.	Desarrollo de un sistema robusto para identificar plagas en cultivos, ayudando en la protección de las fresas.
Developing a multi-label tinyML machine learning model for an active and optimized greenhouse	2022	Desarrollo de un modelo TinyML multi-etiqueta para el control optimizado del microclima de invernaderos.	Mejora en el control del microclima, optimizando las condiciones para el crecimiento de las fresas en invernaderos.

Título del documento	Año de publicación	Metodología	Resultados
microclimate control from multivariate sensed data A framework for predicting soft-fruit yields and phenology using embedded, networked microsensors, coupled weather models and machine-learning techniques	2020	Marco para predecir los rendimientos y la fenología de frutas blandas utilizando microsensores embebidos y técnicas de machine learning.	Predicciones precisas de los rendimientos y ciclos fenológicos, mejorando la gestión agrícola de fresas.
Utilizing High-Resolution Imaging and Artificial Intelligence for Accurate Leaf Wetness Detection for the Strawberry Advisory System (SAS)	2024	Uso de imágenes de alta resolución e IA para la detección precisa de la humedad en las hojas de fresa en el sistema de asesoramiento de fresas (SAS).	Detección precisa de la humedad en las hojas, lo que ayuda a gestionar las condiciones de riego y enfermedades.

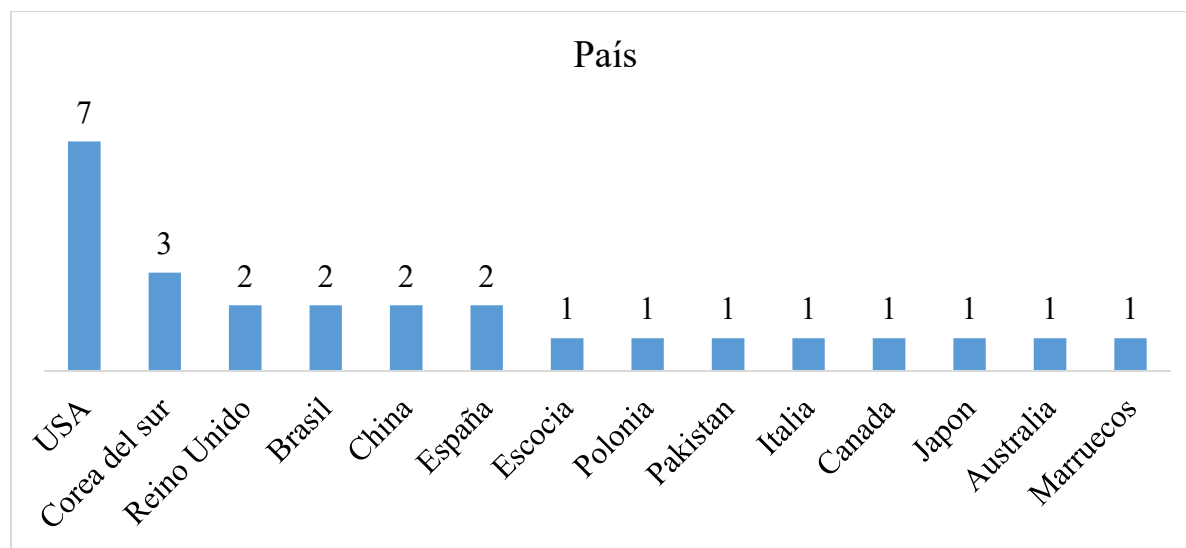
Nota. Tabla resumen con metodología y resultados identificados.

De acuerdo con los documentos identificados los enfoques de machine learning aplicados al cultivo de fresas, abarcan desde la predicción de rendimiento y la madurez de la fruta hasta la detección temprana de enfermedades y el control de plagas.

Los modelos más comunes incluyen redes neuronales, árboles de decisión, machine learning supervisado y no supervisado, y deep learning. Estas técnicas permiten una predicción de los rendimientos, el monitoreo en tiempo real de las condiciones del cultivo y la identificación temprana de factores que puedan afectar el rendimiento de los cultivos. Algunos de los estudios usan imágenes hiperespectrales, redes de deep learning y modelos predictivos como herramientas efectivas para manejar los desafíos fitosanitarios, lo cual es fundamental para reducir el consumo de agroquímicos y aumentar la sostenibilidad de la producción.

Figura 6

Países Identificados en la Selección Final

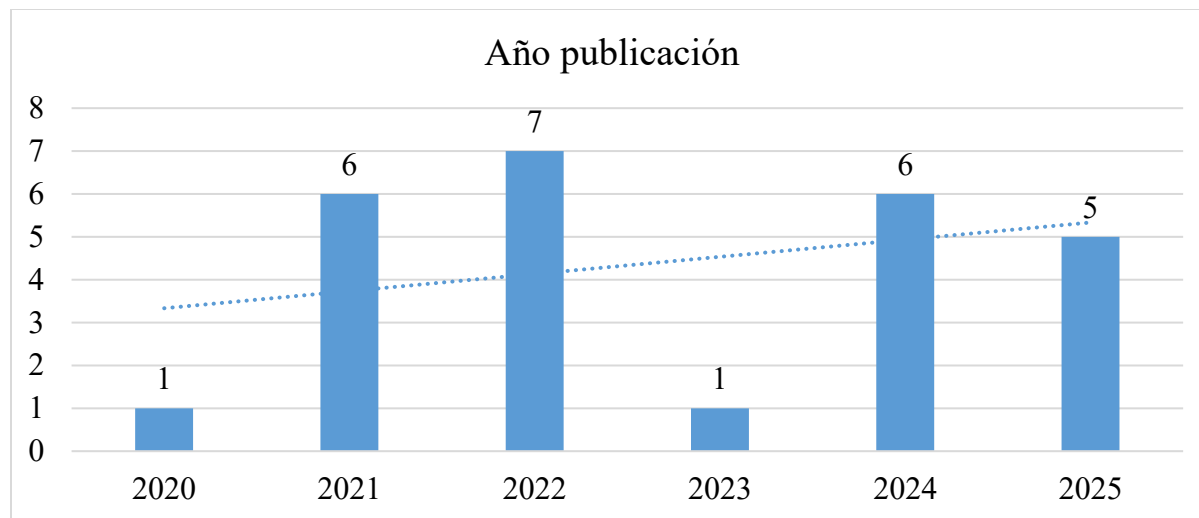


De los 39 documentos iniciales obtenidos en las búsquedas se identificó que los países con mayor estudio en el machine learning como herramienta para mejorar la sostenibilidad en los cultivos de fresa son Estados Unidos, Corea del sur y Reino Unido. En cuando al documento de

Colombia es una revisión de literatura que muestra como la agricultura 4.0 es una herramienta valiosa para el monitoreo de los cultivos, sin embargo, lo hace muy general no se enfoca en los cultivos de fresa.

Figura 7

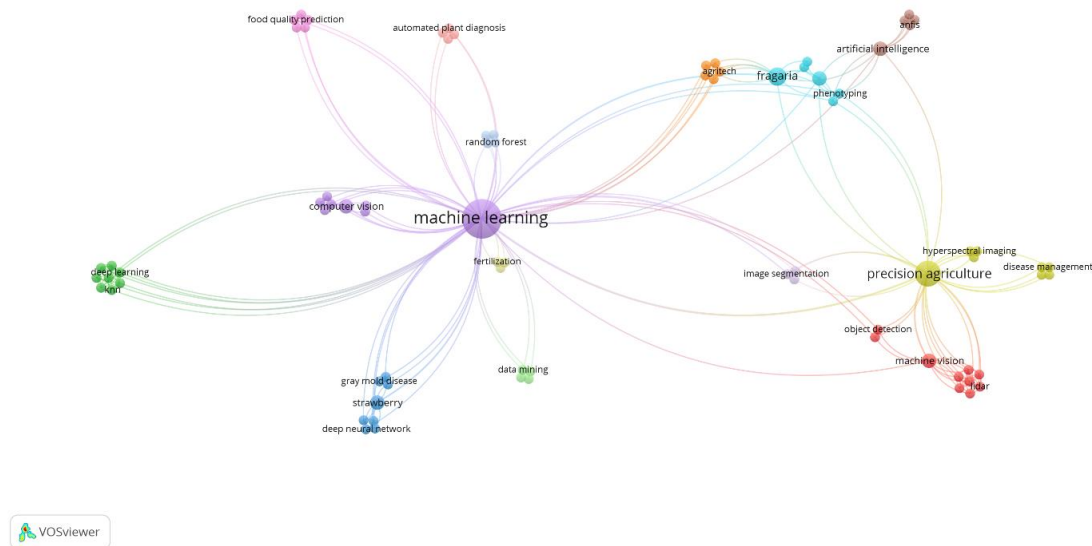
Año de Publicación de los Documentos Seleccionados



Al realizar la depuración de los documentos se observa que las publicaciones identificadas tienen una tendencia hacia los últimos años, confirmando que los estudios en el análisis de datos se han venido fortaleciendo en los últimos años.

Figura 8

Gráfico de Relación de las Palabras Clave en VOSviewer Documentos Finales



Tras la depuración de los documentos identificados, se generó un mapa de coocurrencias de las palabras clave mediante VOSviewer. En este se observa que “machine learning”, actúa como nodo principal y se relaciona directamente con áreas complementarias de la agricultura de precisión (precision agriculture), la visión por computador (computer vision) y el procesamiento de imágenes (image segmentation, object detection, machine vision).

El mapa se observa que el análisis se centra en el machine learning hacia el uso de visión artificial y aprendizaje profundo para optimizar la eficiencia y sostenibilidad de los cultivos de fresa, especialmente en procesos de detección temprana de enfermedades, predicción de calidad y manejo de recursos. Asimismo, se evidencia que hay investigaciones hacia la integración de IoT y modelos predictivos, lo que abre una oportunidad de transferencia tecnológica al contexto colombiano, el cual no cuenta con documentos en el campo de acuerdo con la búsqueda.

Análisis Comparativo de los Artículos Identificados

Con el fin de identificar las metodologías, métricas y limitaciones de los modelos utilizados en los documentos seleccionados se realizó la tabla 2.

Tabla 2

Metodologías y Limitaciones de los Documentos Seleccionados

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	VARIABLES DE ENTRADA	Limitaciones metodológicas
1	Remote Sensing and Machine Learning in Crop Phenotyping and Management, with an Emphasis on Applications in Strawberry Farming	SVM, ANN, RF, CNN (Faster/Mask R-CNN)	Accuracy 83–96%, R ² 0.72–0.94, RMSE bajo	Imágenes RGB, multiespectrales, hiperespectrales; LiDAR; nubes de puntos; índices de vegetación; firmas espectrales; datos bioquímicos; indicadores de estrés; fenología	Varios modelos funcionan solo en condiciones controladas; datasets limitados; alto costo de sensores (LiDAR, espectrales); necesidad de grandes datos para deep learning; falta de integración de datos múltiples; pocas implementaciones comerciales

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	Variables de entrada	Limitaciones metodológicas
2	Precision Agriculture Using Soil Sensor Driven Machine Learning for Smart Strawberry Production	ANN, Gaussian Process Regression	Error $\pm 9\%$ color, $\pm 14\%$ SSC	Datos del suelo a través de sensores instalados (en una finca comercial de fresas) - Variables fisicoquímicas del suelo (por contexto del artículo) - Posiblemente variables de riego, fertilización, humedad, etc. (<details implícitas en el artículo>)	Puede que el estudio esté limitado a una finca comercial específica y condiciones particulares, lo que puede afectar la generalización a otros cultivos, ambientes o variedades de fresa. Necesidad de sensores en el suelo distribuidos: lo cual puede aumentar coste y complejidad de implementación en campo comercial.
3	A Multi-Farm Global- to-Local Expert- Informed Machine Learning System for Strawberry Yield Forecasting	XGBoost + modelo experto	RMSE 0.085–0.087	Variables climáticas (ERA5 + estación) Variables fenológicas definidas por expertos Series históricas de rendimiento	- Dependencia del criterio experto- Generalización limitada entre fincas- Mejora marginal al usar ERA5 → sensibilidad al tipo de datos climáticos

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	Variables de entrada	Limitaciones metodológicas
4	Smart Strawberry Farming Using Edge Computing and IoT	YOLOv5, Isolation Forest	YOLOv5 accuracy 92%	<p>Sensores de humedad y temperatura del aire (DHT11) en nodos Arduino</p> <p>Comunicación LoRa para transmitir datos entre nodos sensores y nodo recolector.</p> <p>Imágenes capturadas con cámara conectada al Raspberry Pi para visión por computador.</p>	<p>Dataset de imágenes para entrenamiento está basado en un conjunto público (Kaggle) con imágenes etiquetadas.</p> <p>Dependencia de conectividad LoRa y Wi-Fi para funcionamiento de la plataforma.</p> <p>No se reportan validaciones exhaustivas de falsos positivos / falsos negativos más allá de la “accuracy”.</p>

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	Variables de entrada	Limitaciones metodológicas
5	From Simulation to Field Validation: A Digital Twin-Driven Sim2real Transfer Approach for Strawberry Fruit Detection and Sizing	Mask R-CNN	F1 0.81–0.92, R ² 0.92, RMSE 1.4 mm	<p>Imágenes RGB simuladas generadas por un digital twin (gemelo digital) de la finca de fresa.</p> <p>Datos LiDAR simulados para validar la geometría y topografía del campo virtual vs real.</p> <p>Imágenes reales capturadas por un vehículo con cámaras estéreo en la finca para validación en campo.</p> <p>Medidas reales de frutos con calibrador (“calipers”) para obtener diámetros verdaderos como “ground truth”.</p>	<p>Aunque entrenan solo con datos sintéticos, la brecha puede afectar especialmente en escenarios con iluminación variable, oclusión de hojas y frutos verdes.</p> <p>No hay una comparación directa entre detección automática de todos los frutos y conteo manual total de fruta en campo.</p> <p>Requiere hardware bastante específico (cámara estéreo, vehículo, simulador) para replicar el pipeline.</p>

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	VARIABLES DE ENTRADA	Limitaciones metodológicas
6	Prediction of Strawberry Leaf Color Using RGB Mean Values Based on Soil Physicochemical Parameters Using Machine Learning Models	GBR, MLR	R^2 0.56–0.77, RMSE 5.6–9.1	Parámetros fisicoquímicos del suelo: pH, conductividad eléctrica (EC), temperatura del suelo (ST), N, P, K. Edad de la planta (plant age) como variable adicional. Valores medios RGB (canales R, G, B) extraídos de imágenes de hojas de fresa mediante procesamiento de imágenes.	El experimento se realizó en invernadero, lo que puede limitar la aplicabilidad de los modelos a condiciones de campo reales. El dataset es relativamente pequeño (400 hojas) y las imágenes fueron capturadas manualmente, lo que podría limitar la generalización y aumentar el riesgo de sobreajuste.
7	Detection of fusarium wilt-induced physiological impairment in strawberry plants using hyperspectral imaging and machine learning	ANN, DT, KNN, SVM, Logistic Regression	$F1 = 0.85$, $R^2 = 0.84$	Firma espectral hiperespectral de hojas (197 bandas usadas después de procesamiento) Mediciones de gas de hoja: conductancia estomática y tasa de fotosíntesis Severidad de la enfermedad (cuatro clases: sano, leve, moderado, severo)	El experimento se realizó en condiciones controladas, no en campo: se requiere validar los modelos bajo estrés múltiple en condiciones reales. Dataset relativamente pequeño y desbalanceado entre clases; Requiere captura hiperespectral costosa y procesamiento intensivo de datos.

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	Variables de entrada	Limitaciones metodológicas
8	AI-driven time series analysis for predicting strawberry weekly yields integrating fruit monitoring and weather data for optimized harvest planning	YOLOv8n, MLR, VAR-GBM, RF, LSTM, TCN	mAP 0.69–0.91, R ² 0.52–0.90	<p>Datos de imágenes sin síntomas visibles (tejido foliar aparentemente sano)</p> <p>Imágenes RGB de flores y frutos (1473)</p> <p>Variables climáticas (23)</p> <p>Conteos automáticos (YOLOv8n)</p>	<p>Sensación es difícil de predecir (sensibilidad varietal)-</p> <p>Conteo de inmaduros con baja precisión- Dependencia de imágenes de buena calidad</p> <p>Integración multifuente aumenta complejidad</p>

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	Variables de entrada	Limitaciones metodológicas
9	Decision Trees to Forecast Risks of Strawberry Powdery Mildew Caused by <i>Podosphaera aphanis</i>	CART/DT	Accuracy 0.82–0.97	21 variables seleccionadas (inóculo aéreo, hojas susceptibles, humedad relativa, horas 18-30 °C, horas presión de vapor)	Generalización geográfica limitada; dependencia de estimación de inóculo; cuatro clases de severidad gruesas; no incluye muchos factores de manejo
10	Application of automated image colour analyses for the early-prediction of strawberry development and quality.	Regresiones basadas en color	R ² 0.72–0.90	Medidas de color de la imagen El estado de desarrollo actual del fruto La longitud actual del fruto	Condiciones de crecimiento controladas. Dependencia de color solamente, sin tener presente otros factores. Sensible a iluminación
11	Characteristics of compound low-temperature and limited-light events in southern China and their effects on greenhouse grown strawberry	Modelos ML para microclima (no especificados)	Pérdida potencial >70%	Datos meteorológicos diarios mínimos (temperatura mínima) simulados para invernaderos plásticos. Datos climáticos históricos de la región (no solo del invernadero). Datos experimentales de fresa: rendimiento y	No se detallan los algoritmos ML utilizados, lo que limita la reproducibilidad. El modelo puede no capturar completamente la variabilidad real del microclima de invernaderos (ventilación, radiación, estructura).

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	Variables de entrada	Limitaciones metodológicas
				<p>contenido de sólidos solubles bajo estrés de baja temperatura y luz (LTLL).</p>	
12	<p>Identification of plant leaf phosphorus content at different growth stages based on hyperspectral reflectance</p>	<p>RF, SVM, NB, BNN</p>	<p>Precisión 40–100%</p>	<p>Reflectancia hiperespectral 400–2500 nm. Preprocesamiento: segunda derivada (Savitzky–Golay). Datos de pigmentos/bioquímica medidos en laboratorio (clorófilas, carotenoides) usados para validar / correlacionar.</p>	<p>Solo clasificación, no regresión (no predice P continuo). Estudio en condiciones controladas - invernadero. Otros factores nutricionales/ambientales no completamente controlados. Necesidad de equipos hiperespectrales (costosos) y procesamiento intensivo de datos.</p>

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	Variables de entrada	Limitaciones metodológicas
13	Identification and Analysis of Strawberries' Consumer Opinions on Twitter for Marketing Purposes	GTM, análisis de redes	Análisis cualitativo (no ML predictivo)	Hashtags de Twitter extraídos mediante API (tweets con “#strawberries” y “#fresas”) Frecuencia de hashtags (conteo) Relaciones entre hashtags (red de co-ocurrencia) Contexto de uso (idioma: tweets en inglés vs español) Entrevistas con consumidores y productores para triangulación (GTM)	Los hashtags no capturan toda la riqueza del significado emocional; pueden no expresar sentimientos, ironía o sarcasmo. Usuarios de Twitter no representativos de toda la población de consumidores de fresa. No se utiliza un modelo ML clásico de predicción (como regresión, clasificación) sino métodos de análisis de contenido, por lo que las métricas son más cualitativas / descriptivas que predictivas.
14	CAFM-Enhanced YOLOv8: A Two-Stage Optimization for Precise Strawberry Disease Detection in Complex Field Conditions	YOLOv8 + atención CAFM	mAP50 = 0.96	3146 imágenes clasificadas en 7 enfermedadesDataset de RoboflowAnotación VOC → YOLO	Dataset limitado en iluminación extrema; no cubre todos los estadios fenológicos; tamaño del modelo mayor que YOLOv8 estándar; complejidad computacional ligeramente superior

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	VARIABLES DE ENTRADA	Limitaciones metodológicas
15	Detection of gray mold disease and its severity on strawberry using deep learning networks	UNet, XGBoost, K-means, Otsu	IoU ~0.80–0.82, Dice 0.85–0.89	Imágenes RGB; segmentación de lesiones; características morfológicas; etiquetas de severidad	Dataset limitado: número reducido de imágenes y condiciones de captura controladas. Necesidad de un conjunto de datos etiquetado para segmentación. Requiere potencia de cómputo considerable para entrenar la red U-Net. Variabilidad de iluminación y fondos no totalmente representada
16	Prediction of Strawberry Dry Biomass from UAV Multispectral Imagery Using Multiple Machine Learning Methods	MLR, RF, SVM, MARS, XGBoost, ANN	R ² 0.83–0.93	UAV multispectral imágenes; parámetros de copa (área, altura, volumen); 5 bandas + 20 índices de vegetación	El estudio se centra en biomasa seca, no directamente en rendimiento comercial (frutos). Dependencia de sensores UAV multispectrales y procesamiento especializado.

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	VARIABLES DE ENTRADA	Limitaciones metodológicas
17	Deep learning-based identification system of weeds and crops in strawberry and pea fields for a precision agriculture sprayer	Deep CNN	Accuracy 94.7%, Kappa 0.89	Imágenes UAV de alta resolución en campos de fresa y arveja. Segmentación de píxeles (o regiones) para distinguir flores / cultivos y malezas. (modelo de clasificación	Podría necesitar muchas imágenes de alta resolución para generalizar bien en diferentes campos o variedades. osible sobreajuste si las condiciones visuales (iluminación, altura del UAV, densidad de plantación) varían mucho en otros escenarios.
18	Advanced canopy size estimation in strawberry production: a machine learning approach using YOLOv11 and SAM	YOLOv11 + SAM	IoU 0.71–0.89	Imágenes aéreas RGB; cajas detectadas por YOLOv11	Menor desempeño con solapamientos. Necesidad de calibrar puntos/offsets Dependencia de condiciones de iluminación.

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	Variables de entrada	Limitaciones metodológicas
19	Fruit Ripeness Prediction Based on DNN Feature Induction from Sparse Dataset	VGG, ResNet, Inception + ML tradicional	Accuracy 78–90%	<p>Imágenes de fruta (fresas y tomates) recolectadas de una web, etiquetadas en 4 etapas de madurez: “unripe”, “partially ripe”, “ripe” y “overripe”</p> <p>Características extraídas por los DNN preentrenados (vectores de características profundas).</p> <p>Las características profundas se usan luego como entrada para los algoritmos ML para clasificar la etapa de madurez.</p>	<p>El dataset de imágenes es muy pequeño: solo ~250 imágenes de fresa (aprox. 60 por etapa) y ~300 de tomate.</p> <p>Las imágenes provienen de una web, lo que podría introducir sesgos en iluminación, calidad de imagen y representatividad de condiciones reales de campo.</p> <p>No se reporta si el modelo fue validado con imágenes tomadas en campo real</p>

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	Variables de entrada	Limitaciones metodológicas
20	Performance of Neural Networks in the Prediction of Nitrogen Nutrition in Strawberry Plants	CNN personalizada, ResNet-50	Accuracy 78%, F1 0.69–0.72	Imágenes de hojas de fresa (RGB) escaneadas en un escáner plano a alta resolución. Tres niveles de fertilización de nitrógeno (50%, 100%, 150%) para clase de etiqueta Segmentos (“blocks”) de imagen (224 × 224 píxeles) extraídos para alimentar las CNNs.	Escaneo de hojas (no imágenes de planta en campo), lo que limita la generalización a sistemas de producción naturales. No se evaluó en distintos cultivares o en condiciones ambientales distintas (solo un entorno de invernadero). Se requieren imágenes escaneadas de hojas, lo que es menos práctico para monitoreo en tiempo real en campo.
21	Channel randomisation: Self-supervised representation learning for reliable visual anomaly detection in speciality crops	Self-supervised + CH-Rand	AUC-ROC 0.80–0.94	Imágenes RGB de cultivos (incluyendo fresa); combinaciones de canales; características espaciales y cromáticas; tareas auto-supervisadas.	Dependiente de colores: variaciones de iluminación pueden afectar desempeño. Solo anomalías visuales, no detecta estrés o enfermedades no visibles. No evalúa implementación en campo real.

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	Variables de entrada	Limitaciones metodológicas
22	Investigation to answer three key questions concerning plant pest identification and development of a practical identification framework	CNN + ROI detector	Accuracy 91%, F1 0.88	<p>Conjunto de imágenes: ~334,000 imágenes de 78 combinaciones (cuatro partes de planta: hoja frente y reverso, fruta, flor) de varios cultivos (incluida fresa) capturadas en 27 fincas. márgenes etiquetadas con 20 especies de plagas.</p> <p>Datos de microclima del invernadero: temperatura, humedad del aire, humedad de suelo, iluminancia solar, concentración de CO₂.</p> <p>Sensores IoT en el invernadero que envían datos multivariados para tomar decisiones de control.</p> <p>Etiquetado multi-etiqueta: 5 acciones de control posibles</p>	<p>Algunas clases de plaga pueden tener poca representación o imágenes de baja calidad, afectando la generalización.</p> <p>La recolección de datos en 27 granjas da variabilidad, pero aún puede haber sesgos geográficos, variaciones de iluminación o fondos que no estén representados en otras regiones.</p>
23	Developing a multi-label tinyML machine learning model for an active and optimized greenhouse microclimate control from multivariate sensed data	MLP TinyML	Accuracy 96–97%	<p>Datos de microclima del invernadero: temperatura, humedad del aire, humedad de suelo, iluminancia solar, concentración de CO₂.</p> <p>Sensores IoT en el invernadero que envían datos multivariados para tomar decisiones de control.</p> <p>Etiquetado multi-etiqueta: 5 acciones de control posibles</p>	<p>Aunque el modelo es muy compacto y eficiente, la validación se realizó con datos de un solo invernadero, lo que puede limitar su generalización a otros entornos.</p>

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	Variables de entrada (vector de 5 bits) para manejo activo del microclima.	Limitaciones metodológicas
24	A framework for predicting soft-fruit yields and phenology using embedded, networked microsensors, coupled weather models and machine-learning techniques	GLM, modelos trigonométricos	R ² 0.87–0.97	Sensores: T°, HR%, humedad suelo, PAR- Estación climática: T°, HR%, viento, presión Datos fenológicos y productivos: rendimiento, °Brix	Solo evalúa tipo de cultivo (“Malling Centenary”), lo que limita la generalización.; alta necesidad de sensores; mediciones manuales; La automatización completa dependería de tecnologías emergentes (hiperespectral, imágenes térmicas) aún costosas.

Nº	Título del estudio	Algoritmos ML utilizados	Métricas reportadas	Variables de entrada	Limitaciones metodológicas
25	Utilizing High-Resolution Imaging and Artificial Intelligence for Accurate Leaf Wetness Detection for the Strawberry Advisory System (SAS)	CNN + clasificadores por categoría	Accuracy 92–98%, sistema 95.8%	Imágenes RGB HD; recortes; timestamp (hora/minutos); clasificación previa por condiciones de luz	Degradación de placa; falsos negativos por gotas muy pequeñas; falsos positivos por polvo/insectos; dependencia de iluminación; mantenimiento manual; fallas de energía/conectividad

Nota. Tabla con los 25 artículos que identifica las variables y limitaciones de los modelos.

De acuerdo con las metodologías usadas por los artículos y los resultados obtenidos por los mismos, se identifica que los trabajos que emplean visión por computador (YOLO, Mask R-CNN, Faster R-CNN, UNet, CNN) presentan métricas elevadas de desempeño, con precisiones que superan el 90% en tareas como detección de frutos, identificación de flores y segmentación de lesiones. Esto confirma que las técnicas basadas en imágenes RGB, multiespectrales o hiperspectrales constituyen actualmente la aproximación más robusta para automatizar procesos antes manuales y sujetos a variabilidad humana.

Por otra parte, los estudios orientados a predicción de rendimiento y análisis fenológico muestran valores de R^2 superiores al 0.80 en la mayoría de los casos (XGBoost, modelos logísticos, MLR y redes neuronales recurrentes), lo que evidencia la capacidad de los modelos para integrar datos climáticos, fenológicos y de sensores en estimaciones confiables. Sin embargo, varios artículos resaltan limitaciones relacionadas con la sensibilidad, la disponibilidad de datos históricos y la dependencia de la calidad de los registros climáticos, lo que sugiere que la extrapolación a otras regiones o tipos de cultivo sigue siendo un desafío.

En el ámbito del análisis del suelo y la planta, los estudios basados en parámetros fisicoquímicos, imágenes de hojas o reflectancia hiperspectral muestran que los modelos son capaces de predecir variables críticas como color foliar, contenido de nutrientes nitrógeno y fósforo o biomasa con precisión moderada a alta (R^2 entre 0.70 y 0.90). No obstante, se observa una fuerte dependencia de condiciones controladas en invernadero o laboratorio, lo que limita la generalización en ambientes productivos reales. La necesidad de sensores especializados y equipos costosos, especialmente en estudios hiperspectrales, constituye una barrera frecuente para la escalabilidad comercial.

Los enfoques orientados a gestión integral del cultivo con análisis en variables como el microclima, IoT, control de malezas, humedad foliar demuestran avances relevantes hacia la automatización en los cultivos de fresa. Modelos como MLP en plataformas TinyML, o sistemas con sensores de múltiples variables, exhiben altas precisiones ($\geq 95\%$) y muestran el potencial de combinar datos ambientales con decisiones de manejo en tiempo real. Sin embargo, dichos estudios continúan siendo altamente dependientes del contexto local de captura de datos, del hardware utilizado y de la calidad de la conectividad en campo.

Teniendo en cuenta que los artículos identificados pueden clasificarse por el enfoque de estudio, se realizó la tabla 3, para identificar mejor el comportamiento de las investigaciones.

Tabla 3

Clasificación de los Artículos por Enfoque de Estudio

Enfoque	N.º de artículos	Tipo de datos utilizados	Algoritmos predominantes	Aplicaciones principales	Limitaciones comunes
Análisis del fruto	11	Imágenes RGB, UAV, multiespectrales, datos de fruto	CNN, YOLO, DNN, RF	Detección de fruto, estimación de biomasa, madurez, predicción de rendimiento	Variabilidad de iluminación, datasets pequeños, alto costo computacional
Análisis del suelo/planta	8	Sensores de suelo, reflectancia, química, RGB hoja	RF, SVM, ANNs	Diagnóstico nutricional, salud vegetal, monitoreo fisiológico	Dependencia de calibración, ruido en sensores,

Enfoque	N.º de artículos	Tipo de datos utilizados	Algoritmos predominantes	Aplicaciones principales	Limitaciones comunes
					poca generalización
Enfermedades y plagas	7	Imágenes HR, hiperespectrales, clima	CNN, ViT, Árboles, SVM	Detección temprana, clasificación de enfermedades	Condiciones de campo variables, escasez de datos anotados
Gestión integral del cultivo (IoT/Edge/TinyML)	4	IoT, clima, sensores de humedad, temperatura, CO ₂	TinyML, ML embebido, CNN ligeras	Automatización de invernadero, control microclima	Limitaciones de hardware, latencia, energía
Análisis del mercado	1	Texto, metadatos	NLP, SVM, Topic Modeling	Preferencias del consumidor, marketing	Ruido semántico, polaridad ambigua

Nota. Tabla con la clasificación por enfoque del artículo, de acuerdo con la variable a predecir.

De acuerdo con la tabla 3, se identifica que de los 25 estudios seleccionados el uso de técnicas de machine learning (ML) y deep learning (DL) en el cultivo de fresa se concentra principalmente en tres áreas de aplicación; la primera es el análisis del fruto con 11 artículos, el cual se centra particularmente en detección, clasificación o calidad del fruto, madurez y detección automática de frutos mediante modelos basados en imágenes, la segunda es el enfoque

en el suelo y planta con 8 documentos, abordan la estimación del estado nutricional, propiedades del suelo, fertilidad, retención de agua y nutrientes, la caracterización del crecimiento y la evaluación de condiciones fisiológicas; mediante sensores, datos espectrales y modelos predictivos. Finalmente, la tercera es el diagnóstico de enfermedades y plagas destaca por el uso de visión computacional para la identificación temprana de síntomas, permitiendo intervenir con mayor precisión y oportunidad.

Estos tres grupos reflejan los principales intereses de investigación actuales y evidencian cómo el ML se está aplicando en diferentes componentes del sistema productivo de fresa.

De acuerdo con los artículos identificados, es posible identificar que, si bien el machine learning y el Deep Learning están transformando la agricultura de precisión en cultivos de fresa, la literatura presenta limitaciones recurrentes como; dataset pequeños, condiciones de captura controladas, falta de validaciones externas, y dependencia de hardware especializado.

El campo con menor número de estudios es el análisis de mercado, sin embargo, en la revisión analiza el uso de machine learning aplicado a datos provenientes de Twitter para apoyar la comercialización del cultivo de fresa. El artículo muestra que modelos de clasificación y análisis de sentimiento permiten identificar tendencias de consumo, percepciones del mercado y comportamientos de compradores en tiempo real. Estos modelos, entrenados con publicaciones, menciones y hashtags relacionados con fresas, logran detectar periodos de mayor demanda, cambios en la preferencia del consumidor y oportunidades de promoción digital. La evidencia demuestra que el análisis de redes sociales, aunque poco explorado en el contexto agrícola, puede convertirse en una herramienta útil para la toma de decisiones comerciales.

Recomendaciones Preliminares en Colombia

Tabla 4

Matriz DOFA

Fortalezas		Debilidades	
F1	Condiciones agroecológicas favorables en Sabana y provincias de Cundinamarca	D1	Alta dependencia de mano de obra y costos crecientes en cosecha y manejo postcosecha
F2	Conocimiento empírico del agricultor y experiencia acumulada	D2	Limitada adopción de tecnologías de agricultura de precisión en pequeños productores
F3	Potencial para integrar ML con variables disponibles (clima, suelos, índices NDVI)	D3	Pérdidas postcosecha elevadas por manejo inadecuado, variaciones de temperatura y logística deficiente
F4	Producción estable y presencia de mercados regionales	D4	Fragmentación productiva y poca asociatividad empresarial
F5	Presencia de instituciones de investigación regional (U. Nacional, AGROSAVIA)(Garzón Echeverry & Caycedo Gutiérrez, 2022)	D5	Carencia de estandarización en variables agronómicas para modelos de ML (sensores, teledetección)
Amenazas		Oportunidades	
A1	Variabilidad climática y aumento de eventos extremos (heladas, sequías)	O1	Crecimiento del mercado nacional y demanda de fresa en Cundinamarca
A2	Pérdida de competitividad frente a países con agricultura altamente tecnificada.	O2	Avances globales en teledetección, visión computacional y ML aplicados al cultivo de fresa
A3	Presión de plagas y enfermedades intensificada por el cambio climático	O3	Programas de apoyo para tecnificación agrícola en Colombia
A4	Dificultad para financiar hardware, infraestructura digital y mantenimiento.	O4	Uso de sensores económicos y drones para monitoreo del cultivo
A5	Riesgo de perder mercados por incumplimiento de límites de residuos y BPA.	O5	Posibilidad de construir un sistema de datos regional para toma de decisiones agrícolas.

Nota. Matriz que identifica las fortalezas, debilidades, oportunidades y amenazas de acuerdo con los estudios identificados y los estudios relacionados al cultivo en el país.

El análisis de la literatura, junto con la evaluación del contexto productivo colombiano, evidencia que los cultivos de fresa se encuentran en un punto decisivo para la adopción de tecnologías avanzadas de analítica de datos y machine learning. La disponibilidad de estudios sobre sensores IoT, visión artificial, modelos de predicción de rendimiento, UAVs multispectrales, hiperspectrales y gemelos digitales demuestra que estas herramientas no solo han madurado técnicamente, sino que son cada vez más accesibles y aplicables a sistemas productivos diversificados como los de Colombia, los cuales varían entre municipios y departamentos.

Adicionalmente, los estudios revisados muestran que la predicción de rendimiento y la detección temprana de enfermedades, los cuales mejoran significativamente cuando se integran datos de temperatura, humedad, radiación y humedad foliar. Se recomienda implementar estaciones agroclimáticas de bajo costo o sensores IoT para capturar información continua y localizada, especialmente en zonas con alta variabilidad climática como Cundinamarca y Antioquia, sin embargo, una limitante para estos análisis es que los cultivos para realizar seguimiento tendrán mejor desempeño en los que están cubiertos por la facilidad para realizar mediciones y controlar variables como la temperatura y humedad.

Los modelos basados en deep learning como YOLO, UNet o CNNs, han demostrado una buena efectividad en la identificación de hongos como moho gris o fusariosis. Y teniendo en cuenta que esta es una de las principales enfermedades que afecta los cultivos. Es posible explorar aplicaciones móviles o sistemas de captura de imágenes que permitan al productor identificar síntomas iniciales y tomar decisiones oportunas para reducir pérdidas.

De acuerdo con el análisis realizado sobre la aplicación del machine learning en los cultivos de fresa, demuestran que las decisiones en cuanto a fertilización, riego, control de plagas

y planificación de cosechas se favorecen. Por lo que, en Colombia, donde las pérdidas postcosecha y el uso indiscriminado de insumos aún son desafíos, se recomienda dirigir la investigación hacia prácticas más sostenibles que reduzcan costos y mejoren la calidad del fruto.

Calidad de los Estudios Seleccionados

Se realizó una evaluación de los documentos relacionados de acuerdo con los objetivos del presente trabajo, evaluando variables como; las citas recibidas por cada artículo, la solidez del diseño, las métricas utilizadas, aplicabilidad en términos de costo y reproducibilidad.

Teniendo en cuenta las citas y los años de publicación se determinó una relación entre las citas y los años que tiene de publicación el artículo, calificando como alta los documentos con más de 10 citas por año, calidad media a los documentos entre 2 – 9 citas y calidad baja con menos de 2 citas.

Para la solidez del diseño, se tuvo en cuenta si el estudio se realizó en un campo real, invernadero o simulación, definiendo como alta calidad (2) los estudios multi-granja, varias temporadas, datos in situ, etiquetado experto, calidad media (1) un solo invernadero, dataset pequeño, validación limitada y calidad baja, los datos sintéticos sin validación real, imágenes de internet.

Para las métricas utilizadas en los modelos, se evaluó el número de métricas utilizadas los documentos clasificados como alta calidad (2), fueron los que utilizaron múltiples métricas, ideales para el problema con comparaciones y como media calidad (1), los que usaron solo accuracy en dataset pequeño.

En el caso de la aplicabilidad práctica del estudio, se evaluó la facilidad de uso para la agricultura en el país teniendo en cuenta las limitaciones en costos, calificando como alta aplicabilidad (2); sensores comunes, drones accesibles, cámaras RGB y baja aplicabilidad: LiDAR de alta gama, gemelos digitales complejos (1).

En cuanto a la reproducibilidad se evaluó si los estudios se pueden repetir, calificando como alta calidad los documentos con código y dataset disponible, como calidad media que

tenga la metodología bien descrita, pero sin código y/o dataset disponible y calidad baja que sea de escasa información técnica.

Tabla 5*Calidad de los Documentos Seleccionados*

Título del estudio	Año	Total Citas	Citas/año	Citas	Solidez - diseño	Métricas- modelos	Aplicable	Reproducible	Nivel
Remote Sensing and Machine Learning in Crop									
Phenotyping and Management, with an Emphasis on Applications in Strawberry Farming	2021	89	22,3	2	1	2	1	1	Medio
Precision Agriculture Using Soil Sensor Driven									
Machine Learning for Smart Strawberry Production	2023	14	7,0	1	1	1	1	0	Bajo
A Multi-Farm Global-to-Local Expert-Informed									
Machine Learning System for Strawberry Yield Forecasting	2024	3	3,0	1	2	1	1	1	Medio
Smart Strawberry Farming Using Edge Computing and IoT	2022	58	19,3	2	1	1	1	1	Medio

Título del estudio	Año	Total Citas	Citas/año	Citas	Solidez - diseño	Métricas- modelos	Aplicable	Reproducible	Nivel
From Simulation to Field Validation: A Digital Twin-Driven Sim2real Transfer Approach for Strawberry Fruit Detection and Sizing	2025	3	3,0	1	1	2	1	0	Bajo
Prediction of Strawberry Leaf Color Using RGB Mean Values Based on Soil Physicochemical Parameters Using Machine Learning Models	2022	20	6,7	1	1	2	2	1	Medio
Detection of fusarium wilt-induced physiological impairment in strawberry plants using hyperspectral imaging and machine learning	2024	4	4,0	1	1	2	1	0	Bajo
AI-driven time series analysis for predicting strawberry weekly yields integrating fruit monitoring and weather data for optimized harvest planning	2025	<u>5</u>	5,0	1	2	2	1	1	Medio

Título del estudio	Año	Total Citas	Citas/año	Citas	Solidez - diseño	Métricas-modelos	Aplicable	Reproducible	Nivel
Decision Trees to Forecast Risks of Strawberry									
Powdery Mildew Caused by Podosphaera aphanis	2021	<u>11</u>	2,8	1	1	2	1		Medio
Application of automated image colour analyses for the early-prediction of strawberry development and quality.									
Characteristics of compound low-temperature and limited-light events in southern China and their effects on greenhouse grown strawberry	2022	4	1,3	1	1	1	2	0	Bajo
Identification of plant leaf phosphorus content at different growth stages based on hyperspectral reflectance									
Identification and Analysis of Strawberries' Consumer Opinions on Twitter for Marketing Purposes	2021	13	3,3	1	2	1	2	1	Medio

Título del estudio	Año	Total Citas	Citas/año	Citas	Solidez - diseño	Métricas- modelos	Aplicable	Reproducible	Nivel
CAFM-Enhanced YOLOv8: A Two-Stage Optimization for Precise Strawberry Disease Detection in Complex Field Conditions	2025	0	0,0	0	1	2	1	1	Bajo
Detection of gray mold disease and its severity on strawberry using deep learning networks	2022	44	14,7	2	1	2	1	1	Medio
Prediction of Strawberry Dry Biomass from UAV Multispectral Imagery Using Multiple Machine Learning Methods	2022	38	12,7	2	2	2	1	1	Alto
Deep learning-based identification system of weeds and crops in strawberry and pea fields for a precision agriculture sprayer	2021	136	34,0	2	1	2	1	1	Medio
Advanced canopy size estimation in strawberry production: a machine learning approach using YOLOv11 and SAM	2025	11	11,0	2	1	1	2	1	Medio

Título del estudio	Año	Total Citas	Citas/año	Citas	Solidez - diseño	Métricas- modelos	Aplicable	Reproducible	Nivel
Fruit Ripeness Prediction Based on DNN Feature Induction from Sparse Dataset	2021	12	3,0	1	0	1	2	0	Bajo
Performance of Neural Networks in the Prediction of Nitrogen Nutrition in Strawberry Plants	2024	4	4,0	1	1	2	2	0	Medio
Channel randomisation: Self-supervised representation learning for reliable visual anomaly detection in speciality crops	2024	1	1,0	1	1	2	2	1	Medio
Investigation to answer three key questions concerning plant pest identification and development of a practical identification framework	2024	8	8,0	1	2	2	2	1	Alto
Developing a multi-label tinyML machine learning model for an active and optimized	2022	15	5,0	1	1	2	1	1	Medio

Título del estudio	Año	Total Citas	Citas/año	Citas	Solidez - diseño	Métricas- modelos	Aplicable	Reproducible	Nivel
greenhouse microclimate control from multivariate sensed data									
A framework for predicting soft-fruit yields and phenology using embedded, networked microsensors, coupled weather models and machine-learning techniques	2020	33	6,6	1	1	2	1	0	Bajo
Utilizing High-Resolution Imaging and Artificial Intelligence for Accurate Leaf Wetness Detection for the Strawberry Advisory System (SAS)	2024	3	3,0	1	1	2	2	1	Bajo

Nota. Tabla con las calificaciones de calidad de los artículos de acuerdo con criterios de citas por año, diseño del modelo, métricas, aplicabilidad y reproducibilidad.

La evaluación de calidad de los 25 estudios incluidos muestra heterogeneidad en términos de citas del documento, solidez del diseño experimental, aplicabilidad práctica y reproducibilidad. En general, el 60% de los artículos se ubican en un nivel de calidad medio, seguido por un 32% de calidad baja y un 8% de las investigaciones clasificadas como de calidad alta, las cuales tuvieron una calificación promedio de 1.6. Esto refleja un campo de investigación dinámico, pero aún en consolidación, especialmente en aplicaciones específicas para el cultivo de fresa, en términos de aplicabilidad por costo y reproducibilidad.

Los artículos con mayor volumen de citas tienden a ser aquellos publicados antes de 2022 y que abordan enfoques consolidados como visión computacional, fenotipado por imágenes y estimación de biomasa. Sin embargo, varios artículos recientes publicados entre 2024–2025 presentan valores bajos debido a su limitada exposición temporal, más que a su calidad intrínseca. Esto sugiere que parte del conocimiento más innovador aún se encuentra en fase temprana de difusión, lo que podría explicar la menor relación a los documentos.

Las dos categorías más críticas dentro de la evaluación fueron la aplicabilidad y reproducibilidad. Aunque muchos estudios presentan buenos resultados a nivel experimental, la aplicabilidad práctica suele limitarse por factores como; el uso de sensores o equipos especializados de alto costo, requerimientos computacionales altos, dependencia de grandes volúmenes de datos, imágenes de alta resolución y/o condiciones climáticas específicas del país del estudio. Y en reproducibilidad, varios artículos reciben baja calificación debido a la ausencia de acceso a datos, modelos, hiperparámetros o código, lo que dificulta replicar los experimentos en otros contextos. Los estudios de nivel alto destacan precisamente por ofrecer datasets abiertos, metodologías transparentes y descripciones detalladas del flujo de trabajo.

Los resultados muestran que, aunque la literatura internacional ofrece modelos valiosos, solo una parte de ellos tiene el nivel de madurez suficiente para ser implementados directamente en Colombia. La baja reproducibilidad y la limitada disponibilidad de datos en varios estudios indican que, para avanzar, será necesario; fortalecer infraestructura de recolección de datos de cultivos en el país, crear repositorios nacionales abiertos, desarrollar experimentos locales que validen y adapten los modelos y fomentar las colaboraciones entre academia, agricultores y sector público, beneficiando tanto los costos de la aplicación como los datos abiertos para otros estudios.

Conclusiones

La presente revisión sistemática permitió identificar, analizar y sintetizar los principales enfoques, metodologías y aplicaciones del machine learning en el cultivo de fresa. Los estudios revisados muestran aplicaciones que abarcan la predicción de rendimientos, el fenotipado, el manejo nutricional, la estimación de biomasa, el monitoreo del microclima, la detección temprana de enfermedades y la clasificación de estados fenológicos. Estos usos confirman que el machine learning ML no se limita a resolver un único tipo de problema, sino que contribuye de manera integral a la gestión del cultivo.

Los algoritmos como CNN, YOLO, Unet, Faster R-CNN y redes neuronales fueron los más utilizados, gracias a su capacidad para procesar imágenes de campo, estimar el grado de madurez del fruto, segmentar estructuras de la planta y detectar plagas y enfermedades. La integración de IoT, microclima, sensores ópticos, imágenes RGB y datos históricos demostró generar modelos más robustos y precisos, consolidando la importancia del enfoque multisensorial. Estos hallazgos permiten comprender cómo estas tecnologías incrementan la precisión y eficiencia de los sistemas productivos.

Aunque pocos estudios mencionan explícitamente la sostenibilidad, sus resultados evidencian beneficios como reducción de insumos, menor riesgo fitosanitario, riego más eficiente y disminución de pérdidas, lo que contribuye a sistemas productivos más sostenibles. Sin embargo, también se identifican desafíos clave para Colombia: la limitada disponibilidad de sensores, infraestructura digital, datos locales y capacidades técnicas, elementos necesarios para implementar estos modelos de forma efectiva.

Finalmente, aunque la mayoría de las investigaciones provienen de Europa, Asia y Norteamérica, los principios, técnicas y resultados identificados son transferibles al contexto

colombiano. Esto es relevante en un país donde los productores enfrentan desafíos como enfermedades recurrentes, fluctuaciones de oferta, variabilidad climática y altos costos de insumos. La adopción progresiva de modelos basados en analítica de datos y machine learning representa una oportunidad estratégica para mejorar la productividad, competitividad y sostenibilidad del cultivo de fresa.

Recomendaciones

Dado que los mejores resultados identificados en la literatura se obtienen en entornos con sensores, drones, cámaras especializadas y estaciones meteorológicas, se recomienda que los sistemas productivos de fresa en Colombia avancen hacia la adopción progresiva de estas tecnologías. La instalación de sensores de humedad, estaciones climáticas básicas y cámaras RGB de bajo costo sería un primer paso viable para pequeños y medianos productores.

La revisión evidenció que los modelos más robustos son aquellos que integran múltiples fuentes de información (microclima, reflectancia espectral, IoT, registros históricos). Por ello, se recomienda implementar protocolos estandarizados de recopilación de datos en finca, que incluyan variables de clima, suelo, fenología, incidencias de enfermedades y manejo agronómico. Esto permitirá construir bases de datos comparables y aptas para entrenamiento de modelos locales.

Antes de escalar modelos avanzados como CNN o Faster R-CNN, se sugiere desarrollar pilotos locales en departamentos productores como Cundinamarca, Antioquia, Nariño que permitan validar la pertinencia de modelos predictivos de rendimiento, detección temprana de enfermedades o clasificación de madurez utilizando datasets colombianos. Estos pilotos pueden iniciarse con cámaras RGB y sensores accesibles, incrementando la complejidad de forma gradual.

Es importante fortalecer el trabajo conjunto entre productores, instituciones educativas y el sector público. Esto implica avanzar en procesos de capacitación para el uso de tecnologías y manejo de datos, mientras se crean espacios de cooperación que permitan desarrollar modelos ajustados a las condiciones actuales y facilitar su implementación en los cultivos de fresa. Esta

articulación es clave para cerrar brechas, aprovechar mejor la tecnología y apoyar de manera real la modernización del sector.

Referencias Bibliográficas

Baena Tapias J. E. (2021). Análisis del estado del arte del internet de las cosas aplicado a cultivos aeropónicos e hidropónicos a nivel nacional e internacional.

<https://doi.org/https://repository.unad.edu.co/handle/10596/44574>

Bhujel, A., Khan, F., Basak, J. K., Jaihuni, M., Sihalath, T., Moon, B. E., Park, J., & Kim, H. T. (2022). Detection of gray mold disease and its severity on strawberry using deep learning networks. *Journal of Plant Diseases and Protection*, 129(3), 579–592.

<https://doi.org/10.1007/s41348-022-00578-8>

Beddows, M., & Leontidis, G. (2024). A Multi-Farm Global-to-Local Expert-Informed Machine Learning System for Strawberry Yield Forecasting. *Agriculture*, 14(6), 883.

<https://doi.org/10.3390/agriculture14060883>

Borrero, J. D., & Zabalo, A. (2021). Identification and Analysis of Strawberries' Consumer Opinions on Twitter for Marketing Purposes. *Agronomy*, 11(4), 809.

<https://doi.org/10.3390/agronomy11040809>

Calderón Gómez, L. E. (2015). *Caracterización del sistema de comercialización de la fresa*.

<https://doi.org/https://hdl.handle.net/10654/6451>

Castellanos, L., & Baldovino, A. (2021). Enfermedades foliares más importantes del cultivo de la fresa en la zona de Pamplona. *REVISTA AMBIENTAL AGUA AIRE Y SUELO*, 12, 1–

11. <https://doi.org/https://doi.org/10.24054/raaas.v12i1.2569>

Carisse, O., & Fall, M. L. (2021). Decision Trees to Forecast Risks of Strawberry Powdery Mildew Caused by *Podosphaera aphanis*. *Agriculture*, 11(1), 29.

<https://doi.org/10.3390/agriculture11010029>

- Castro-Valdecantos, P., Egea, G., Borrero, C. et al. Detection of fusarium wilt-induced physiological impairment in strawberry plants using hyperspectral imaging and machine learning. *Precision Agric* 25, 2958–2976 (2024). <https://doi.org/10.1007/s11119-024-10173-6>
- Cho, W. H., Kim, S. K., Na, M. H., & Na, I. S. (2021). Fruit Ripeness Prediction Based on DNN Feature Induction from Sparse Dataset. *Computers, Materials and Continua*, 69(3), 4003–4024. <https://doi.org/10.32604/cmc.2021.018758>
- Choi, T., Would, O., Salazar-Gomez, A., Liu, X., & Cielniak, G. (2024). Channel randomisation: Self-supervised representation learning for reliable visual anomaly detection in speciality crops. *Computers and Electronics in Agriculture*, 226, 109416. <https://doi.org/10.1016/j.compag.2024.109416>
- Cruz, M., Mafra, S., Teixeira, E., & Figueiredo, F. (2022). Smart Strawberry Farming Using Edge Computing and IoT. *Sensors*, 22(15), 5866. <https://doi.org/10.3390/s22155866>
- DNP (Departamento Nacional de Planeación), & Dirección de Seguimiento y Evaluación de Políticas Públicas. (2016). *PÉRDIDA Y DESPERDICIO DE ALIMENTOS EN COLOMBIA*. www.dnp.gov.co
- Elashmawy, R., & Uysal, I. (2023). Precision Agriculture Using Soil Sensor Driven Machine Learning for Smart Strawberry Production. *Sensors*, 23(4), 2247. <https://doi.org/10.3390/s23042247>
- Garzón Echeverry, R y Caycedo Gutiérrez, M. (2022). Análisis de los cambios generados en la producción agrícola con la implementación de tecnología e innovación en Colombia. Fundación Universitaria del Área Andina. Disponible en: <https://digitk.areandina.edu.co/handle/areandina/5080>

- Gómez, L. E. C. (2015). Caracterización del sistema de comercialización de la fresa en Colombia, Universidad Militar Nueva Granada. Repositorio UMNG.
<https://repository.umng.edu.co/server/api/core/bitstreams/37497732-91c5-421d-b696-814957868b75/content>
- Huang, Z., Lee, W. S., Yang, P., Ampatzidis, Y., Shinsuke, A., & Peres, N. A. (2025). *Advanced canopy size estimation in strawberry production: A machine learning approach using YOLOv11 and SAM*. *Computers and Electronics in Agriculture*, 233, 110501.
<https://doi.org/10.1016/j.compag.2025.110501>
- Castellanos, L., & Baldovino, A. (2021). Enfermedades foliares más importantes del cultivo de la fresa en la zona de Pamplona. *REVISTA AMBIENTAL AGUA AIRE Y SUELO*, 12, 1–11. <https://doi.org/https://doi.org/10.24054/raaas.v12i1.2569>
- Ihoume, I., Tadili, R., Arbaoui, N., Benchrifa, M., Idrissi, A., & Daoudi, M. (2022). Developing a multi-label tinyML machine learning model for an active and optimized greenhouse microclimate control from multivariate sensed data. *Artificial Intelligence in Agriculture*, 6, 129–137. <https://doi.org/10.1016/j.aiia.2022.08.003>
- Khan, S., Tufail, M., Khan, M. T., Khan, Z. A., & Anwar, S. (2021). Deep learning-based identification system of weeds and crops in strawberry and pea fields for a precision agriculture sprayer. *Precision Agriculture*, 22(6), 1711–1727.
<https://doi.org/10.1007/s11119-021-09808-9>
- Kondaparthi, A. K., Lee, W. S., & Peres, N. A. (2024). Utilizing High-Resolution Imaging and Artificial Intelligence for Accurate Leaf Wetness Detection for the Strawberry Advisory System (SAS). *Sensors*, 24(15), 4836. <https://doi.org/10.3390/s24154836>

- Lee, M. A., Monteiro, A., Barclay, A., Marcar, J., Miteva-Neagu, M., & Parker, J. (2020). A framework for predicting soft-fruit yields and phenology using embedded, networked microsensors, coupled weather models and machine-learning techniques. *Computers and Electronics in Agriculture*, 168. <https://doi.org/10.1016/j.compag.2019.105103>
- Li, H., Liu, J., Han, K., & Cai, X. (2025). CAFM-Enhanced YOLOv8: A Two-Stage Optimization for Precise Strawberry Disease Detection in Complex Field Conditions. *Applied Sciences*, 15(18), 10025. <https://doi.org/10.3390/app151810025>
- Liu, S., Ampatzidis, Y., Zhou, C., & Lee, W. S. (2025). *AI-driven time series analysis for predicting strawberry weekly yields integrating fruit monitoring and weather data for optimized harvest planning*. *Computers and Electronics in Agriculture*, 233, 110212. <https://doi.org/10.1016/j.compag.2025.110212>
- Madhavi, B. G. K., Basak, J. K., Paudel, B., Kim, N. E., Choi, G. M., & Kim, H. T. (2022). Prediction of Strawberry Leaf Color Using RGB Mean Values Based on Soil Physicochemical Parameters Using Machine Learning Models. *Agronomy*, 12(5), 981. <https://doi.org/10.3390/agronomy12050981>
- Ministerio de Agricultura. (2021). *Cadena de la Fresa- Dirección de Cadenas Agrícolas y Forestales*. <https://doi.org/https://sioc.minagricultura.gov.co/Fresa/Documentos/2021-03-31%20Cifras%20Sectoriales.pdf>
- Mirbod, O., Choi, D., & Schueller, J. K. (2025). From Simulation to Field Validation: A Digital Twin-Driven Sim2real Transfer Approach for Strawberry Fruit Detection and Sizing. *AgriEngineering*, 7(3), 81. <https://doi.org/10.3390/agriengineering7030081>
- Regazzo, J. R., Silva, T. L. d., Tavares, M. S., Sardinha, E. J. d. S., Figueiredo, C. G., Couto, J. L., Gomes, T. M., Tech, A. R. B., & Baesso, M. M. (2024). Performance of Neural

- Networks in the Prediction of Nitrogen Nutrition in Strawberry Plants. *AgriEngineering*, 6(2), 1760-1770. <https://doi.org/10.3390/agriengineering6020102>
- Siedliska, A., Baranowski, P., Pastuszka-Woźniak, J., Zubik, M., & Krzyszczak, J. (2021). Identification of plant leaf phosphorus content at different growth stages based on hyperspectral reflectance. *BMC Plant Biology*, 21(1), 28. <https://doi.org/10.1186/s12870-020-02807-4>
- Sánchez-Céspedes, J.-M., Rodríguez-Miranda, J.-P., & Salcedo-Parra, O.-J. (2022). Aplicación de la inteligencia artificial en la formulación de políticas públicas relacionadas con la vocación agrícola de las regiones. *Revista Científica*, 44(2), 172–187. <https://doi.org/10.14483/23448350.18576>
- Tapias, J. E. (2021). *Análisis del estado del arte del internet de las cosas aplicado a cultivos aeropónicos e hidropónicos a nivel nacional e internacional*. [Monografía]. Repositorio Institucional UNAD. <https://repository.unad.edu.co/handle/10596/44574>
- Tovar-Quiroz, A. D. (2023). Agricultura 4.0: uso de tecnologías de precisión y aplicación para pequeños productores. *Informador Técnico*, 87(2). <https://doi.org/10.23850/22565035.5536>
- UPRA(Unidad de Planificación Rural Agropecuaria). (n.d.). *Producto Interno Bruto - PIB I trimestre de 2024*.
- Wayama, R., Sasaki, Y., Kagiwada, S., Iwasaki, N., & Iyatomi, H. (2024). Investigation to answer three key questions concerning plant pest identification and development of a practical identification framework. *Computers and Electronics in Agriculture*, 222, 109021. <https://doi.org/10.1016/j.compag.2024.109021>

- Wise, K., Wedding, T., & Selby-Pham, J. (2022). Application of automated image colour analyses for the early-prediction of strawberry development and quality. *Scientia Horticulturae*, 304, 111316. <https://doi.org/https://doi.org/10.1016/j.scienta.2022.111316>
- Zhang, Q., Zhang, X., Zheng, Q., Yao, M., & Yang, Z. (2022). Characteristics of compound low-temperature and limited-light events in southern China and their effects on greenhouse grown strawberry. *Theoretical and Applied Climatology*, 150(1–2), 155–165. <https://doi.org/10.1007/s00704-022-04158-6>
- Zheng, C., Abd-elrahman, A., & Whitaker, V. (2021). Remote sensing and machine learning in crop phenotyping and management, with an emphasis on applications in strawberry farming. In *Remote Sensing* (Vol. 13, Issue 3, pp. 1–29). MDPI AG. <https://doi.org/10.3390/rs13030531>
- Zheng, C., Abd-Elrahman, A., Whitaker, V., & Dalid, C. (2022). Prediction of Strawberry Dry Biomass from UAV Multispectral Imagery Using Multiple Machine Learning Methods. *Remote Sensing*, 14(18). <https://doi.org/10.3390/rs14184511>