

# Visión artificial para el diagnóstico de suelos cafetaleros: revisión sistemática de la literatura

## *(Machine Vision for the Diagnosis of Coffee Soils: A Systematic Literature Review)*

Aldrich Arath Irisson Aburto<sup>1</sup>, María Salomé Alejandre Apolinar<sup>1</sup>, Hugo Amores Pérez<sup>1</sup>,  
Yadeneyro de la Cruz Elizondo<sup>2</sup>

<sup>1</sup> TecNM/Instituto Tecnológico Superior de Xalapa, Xalapa, México

<sup>2</sup> Universidad Veracruzana, Xalapa, México

247001212@itsx.edu.mx, salome.aa@xalapa.tecnm.mx, hugo.ap@xalapa.tecnm.mx, ydelacruz@uv.mx

**Resumen:** En Jilotepec, Veracruz, la producción de café enfrenta retos asociados con la degradación del suelo y la baja productividad agrícola. Este trabajo se enfoca en una Revisión Sistemática de la Literatura (RSL) sobre el uso de visión artificial para el diagnóstico de suelos cafetaleros, con el fin de identificar técnicas efectivas que permitan desarrollar herramientas tecnológicas aplicables al contexto local. La RSL se realizó bajo un protocolo riguroso que incluyó criterios de inclusión/exclusión, búsqueda en bases de datos científicas reconocidas y análisis temático de estudios entre 2019 y 2024. Los resultados destacan el potencial de la visión artificial en tareas como segmentación de imágenes, análisis de textura y detección de características fisicoquímicas del suelo. Como aporte principal, se identifican tendencias, vacíos y oportunidades que fundamentan la creación de un software de diagnóstico de suelos más rápido, accesible y preciso para cafetaleros. Esta investigación sienta las bases para soluciones innovadoras en agricultura sustentable y digital.

**Palabras clave:** Análisis de suelos, gestión agrícola, independencia tecnológica, segmentación de imágenes y tecnología asistida.

**Abstract:** In Jilotepec, Veracruz, coffee production faces challenges associated with soil degradation and low agricultural productivity. This work focuses on a Systematic Literature Review (SLR) on the use of computer vision for the diagnosis of coffee-growing soils, aiming to identify effective techniques that enable the development of technological tools applicable to the local context. The SLR was conducted under a rigorous protocol that included inclusion/exclusion criteria, a search in recognized scientific databases, and thematic analysis of studies between 2019 and 2024. The results highlight the potential of computer vision in tasks such as image segmentation, texture analysis, and the detection of physicochemical soil characteristics. As a main contribution, the review identifies trends, gaps, and opportunities that support the creation of faster, more accessible, and accurate soil diagnostic software for coffee producers. This research lays the groundwork for innovative solutions in sustainable and digital agriculture.

**Keywords:** Soil analysis, agricultural management, technological independence, image segmentation, assisted technology.

## 1. INTRODUCCIÓN

La cafecultura es una de las actividades agrícolas más representativas en México [1], no solo por su impacto económico en zonas rurales, sino también por su relevancia social, cultural y ambiental. Esta actividad tiene especial importancia en regiones montañosas como Jilotepec,

Veracruz, donde el cultivo del café constituye el eje central de la economía local y forma parte del modo de vida de las comunidades. En esta región, el 48 % de la superficie total está dedicada a actividades agrícolas, siendo el café el principal cultivo tanto en términos de superficie sembrada como de ingreso generado para los productores [2].

Sin embargo, en los últimos años la productividad de los cafetales en Jilotepec se ha visto amenazada por diversos factores, siendo uno de los más preocupantes la degradación progresiva del suelo. Esta problemática obedece, en gran medida, a prácticas inadecuadas de manejo agrícola, así como a procesos erosivos que se han intensificado debido a la compleja topografía del lugar y al impacto creciente del cambio climático [3]. Ante este panorama, se vuelve indispensable evaluar con precisión el estado actual del suelo con el fin de diseñar e implementar estrategias eficaces de conservación, restauración y mejora de las prácticas agrícolas que permitan garantizar la sostenibilidad de la producción cafetalera en el mediano y largo plazo.

Tradicionalmente, la evaluación de la calidad del suelo se realiza mediante procedimientos manuales de muestreo y análisis en laboratorio. Si bien estos métodos ofrecen resultados precisos y confiables, también presentan importantes limitaciones: suelen ser costosos, requieren de tiempo considerable y demandan recursos especializados que no siempre están al alcance de los pequeños productores [4]. Esto genera una barrera de acceso al diagnóstico del suelo, limitando la capacidad de muchos agricultores para tomar decisiones informadas sobre el manejo de sus parcelas.

En respuesta a estas limitaciones, la visión artificial ha emergido como una alternativa tecnológica prometedora para el diagnóstico del suelo y de los cultivos a partir del análisis automatizado de imágenes digitales. Esta tecnología permite detectar ciertas características físicas y químicas del terreno de manera más rápida y con menor necesidad de intervención humana, ofreciendo así una vía eficiente y escalable para obtener información útil sobre la condición del suelo [5], [6], [7].

No obstante, a pesar del potencial que representa esta tecnología, aún existe una brecha considerable en cuanto a su aplicación directa en cultivos específicos como el café, especialmente en contextos rurales donde el acceso a herramientas digitales es limitado y la infraestructura tecnológica es escasa. En particular, en regiones como Jilotepec, la integración de la Visión Artificial en los procesos agrícolas se encuentra en etapas tempranas, lo cual plantea tanto un reto como una oportunidad para el desarrollo de soluciones adaptadas a este entorno.

Con base en lo anterior, este artículo presenta una Revisión Sistemática de la Literatura (RSL) orientada a identificar las técnicas de visión artificial más utilizadas en el diagnóstico de suelos agrícolas. El propósito de esta revisión es sentar las bases científicas necesarias para el desarrollo futuro de herramientas digitales que respondan a las características específicas de los cafetales de Jilotepec. Como aporte principal, se identifican los avances, vacíos y tendencias presentes en la literatura académica reciente, lo que permitirá orientar futuras investigaciones e iniciativas tecnológicas dirigidas al manejo sostenible del suelo en zonas cafetaleras.


El artículo se organiza de la siguiente manera: en la sección 2 se describe la metodología empleada para llevar a cabo la revisión sistemática; en la sección 3 se presentan los resultados obtenidos y su análisis correspondiente; y finalmente, en la sección 4 se discuten los hallazgos y se formulan conclusiones junto con posibles líneas de trabajo futuro.

## **2. METODOLOGÍA**

Este estudio se realizó bajo el enfoque metodológico propuesto por Barbara Kitchenham y Stuart M. Charters [8] para la elaboración de RSL en el ámbito de la ingeniería del software, el

cual ha sido adaptado rigurosamente al contexto de la visión artificial aplicada al diagnóstico de suelos agrícolas, particularmente en cultivos de café. Esta metodología proporciona un marco estructurado que asegura la trazabilidad, transparencia, objetividad y replicabilidad de cada una de las etapas de la revisión.

La aplicación de este enfoque permite construir un mapa actualizado del conocimiento disponible, identificar vacíos en la literatura y guiar futuras investigaciones con una base sólida (ver Figura 1).



**Figura 1.** Fases de la metodología RSL de acuerdo con [8]

## 2.1. Procedimiento

### Fase 1. Planificar la revisión

Durante esta fase inicial, se estableció un protocolo que dirigió todo el proceso de revisión. El protocolo incluyó los siguientes elementos clave:

- **Pregunta principal de investigación:**  
¿Qué técnicas de visión artificial se han aplicado exitosamente al diagnóstico de suelos agrícolas?
- **Objetivo:**  
Identificar, clasificar y analizar las técnicas de visión artificial utilizadas en el diagnóstico de suelos agrícolas, especialmente aquellas con potencial de aplicación en cafetales.
- **Criterios de inclusión:**  
Se consideraron artículos publicados entre 2019 y 2024, redactados en inglés o español, disponibles en texto completo y revisados por pares, que presenten una aplicación concreta de técnicas de visión artificial al análisis de suelos.
- **Criterios de exclusión:**  
Se excluyeron trabajos sin relación directa con el análisis de suelos, artículos duplicados, estudios sin acceso completo (solo resumen) y publicaciones de carácter teórico u opinativo sin evidencia empírica o técnica.

Para localizar la literatura relevante, se diseñaron y aplicaron cadenas de búsqueda utilizando operadores booleanos y términos controlados, contruidos a partir de un conjunto de conceptos clave y sus respectivos sinónimos. La Tabla 1 muestra los términos principales considerados para las búsquedas.

**Tabla 1.** Términos clave y sinónimos

<b>Términos</b>	<b>Sinónimos</b>
<b>“computer vision”</b>	machine vision, deep learning
<b>“soil quality assessment”</b>	soil evaluation, agricultural soil analysis

A partir de estos términos, se formularon diversas cadenas de búsqueda, las cuales se aplicaron en las bases de datos seleccionadas para recuperar el mayor número de estudios relevantes posibles. La Tabla 2 presenta las cadenas de búsqueda utilizadas.

**Tabla 2.** Cadenas de búsqueda

<b>ID</b>	<b>Cadena de búsqueda</b>
<b>C1</b>	("computer vision" OR "machine vision" OR "deep learning") AND ("soil quality assessment" OR "soil evaluation" OR "agricultural soil analysis")
<b>C2</b>	("computer vision" OR "machine vision" OR "deep learning") AND ("soil assessment" OR "soil evaluation" OR "soil analysis")
<b>C3</b>	("computer vision" OR "machine vision" OR "deep learning") AND ("soil quality" OR "soil evaluation" OR "soil analysis")

Estas cadenas de búsqueda se ejecutaron en las bases de datos académicas más relevantes en el área, seleccionadas por su cobertura, especialización temática y relevancia científica. La Tabla 3 presenta el criterio de elección de cada base de datos utilizada.

**Tabla 3.** Bases de datos para la búsqueda de literatura

<b>Base de datos académicas</b>	<b>Criterio de elección</b>
<b>Google Scholar</b>	Motor de búsqueda académico amplio que indexa literatura científica de diversas fuentes, incluyendo ScienceDirect, MDPI, ResearchGate y otras plataformas. Es útil para acceder a trabajos interdisciplinarios.
<b>IEEE Xplore</b>	Base de datos especializada en ingeniería eléctrica, electrónica y ciencias computacionales. Contiene artículos altamente técnicos y relevantes para el análisis automatizado de imágenes.
<b>Springer Nature Link</b>	Repositorio multidisciplinario de publicaciones científicas que incluye libros, artículos de revistas y conferencias. Su cobertura en ciencias aplicadas permite encontrar estudios en agrotecnología y visión computacional.
<b>ACM Digital Library</b>	Fuente clave para investigaciones en ciencias de la computación. Incluye artículos revisados por pares relacionados con algoritmos, procesamiento de imágenes y tecnologías emergentes aplicadas al análisis agrícola.
<b>Consensus</b>	Plataforma basada en inteligencia artificial diseñada para sintetizar resultados de investigación científica de múltiples disciplinas. Permite acceder a respuestas respaldadas por evidencia a partir de literatura revisada por pares, siendo útil para identificar enfoques actualizados y tendencias emergentes en temas especializados.

## Fase 2. Conducir la revisión

Una vez definidas las cadenas de búsqueda, se procedió a su ejecución sistemática en cada una de las bases de datos académicas seleccionadas. El objetivo de esta fase fue identificar cuál de las combinaciones de términos ofrecía un mayor número de resultados relevantes, permitiendo así maximizar la recuperación de literatura potencialmente útil para el estudio. Las búsquedas fueron realizadas durante el mes de febrero del año 2025, siguiendo un mismo criterio de aplicación en todas las plataformas para asegurar la uniformidad del procedimiento.

Posteriormente, se aplicó un primer filtrado a los resultados obtenidos, considerando los criterios de inclusión definidos previamente: intervalo de publicación entre los años 2019 y 2024, idioma inglés o español, disponibilidad en texto completo y clasificación como artículos académicos revisados por pares. Esta depuración inicial permitió eliminar estudios que no cumplían con las condiciones mínimas de calidad y pertinencia, así como duplicados o documentos sin acceso libre, así como detectar la cadena que da mayor cantidad de resultados.

Con base en los artículos resultantes de la mejor cadena de búsqueda, se llevó a cabo una segunda ronda de filtrado. En esta etapa se revisaron los títulos de los estudios para evaluar su pertinencia específica con el objeto de estudio, y se eliminaron aquellos que estaban duplicados o que no abordaban directamente la aplicación de visión artificial en el diagnóstico de suelos agrícolas. Este paso sirvió para asegurar la precisión y relevancia de la literatura seleccionada para el análisis final.

## Fase 3. Documentar la revisión

Los documentos seleccionados se analizaron en profundidad en la tercera fase del estudio, con el objetivo de identificar patrones, técnicas recurrentes, algoritmos utilizados, tipos de datos procesados y contextos de aplicación relacionados con la visión artificial y el análisis de suelos.

## 3. RESULTADOS Y DISCUSIÓN

Los resultados de la Fase 2 se presentan de forma resumida en la Tabla 4, donde se muestra la cantidad total de documentos recuperados por cada cadena de búsqueda (C1, C2 y C3) en cada una de las bases de datos.

**Tabla 4.** Resultados de búsqueda general de literatura

Base de datos académica	C1	C2	C3
Google Scholar	666	4.800	10.700
IEEE	3	35	73
ACM	5	19	75
Springer Nature Link	31	302	867
Consensus	37	66	120
<b>Total</b>	<b>742</b>	<b>5.222</b>	<b>11.835</b>

Como puede observarse, la cadena de búsqueda C3 generó el mayor número de resultados en todas las bases de datos, superando ampliamente a C1 y C2. Esto sugiere que C3 posee una estructura de términos más amplia y efectiva para abarcar el enfoque temático del estudio.

La Tabla 5 muestra la comparación entre los resultados totales y los artículos que cumplieron con los criterios de aceptación.

**Tabla 5.** Resultados de la aplicación de los criterios de aceptación

<b>Base de datos académica</b>	<b>C1</b>		<b>C2</b>		<b>C3</b>	
<b>Google Scholar</b>	666	→ 97	4.800	→ 572	10.700	→ 1.530
<b>IEEE</b>	3	→ 0	35	→ 1	73	→ 2
<b>ACM</b>	5	→ 5	19	→ 18	75	→ 73
<b>Springer Nature Link</b>	31	→ 2	302	→ 32	867	→ 87
<b>Consensus</b>	37	→ 12	66	→ 34	120	→ 15
<b>Total</b>	742	→ 116	5.222	→ 657	11.835	→ 1.707

A partir de esta comparación, se concluyó que la cadena de búsqueda C3 no solo era la que generaba mayor cantidad de resultados, sino también la que conservaba el mayor número de artículos relevantes tras aplicar los filtros de inclusión. Por esta razón, se eligió la cadena C3 como la cadena principal para el proceso de selección final. La Tabla 6 presenta el número definitivo de artículos considerados por base de datos.

**Tabla 6.** Filtrado final de literatura

<b>Base de datos académica</b>	<b>Filtrado 1</b>	<b>Filtrado 2</b>	<b>Filtrado 3</b>
<b>Google Scholar</b>	10.700	1.530	20
<b>IEEE</b>	73	2	2
<b>ACM</b>	75	73	4
<b>Springer Nature Link</b>	867	87	8
<b>Consensus</b>	120	15	6
<b>Total</b>	11.835	1.707	40

El proceso de filtrado descrito dio como resultado un conjunto final de cuarenta (40) artículos altamente relevantes que constituyen la base documental de esta Revisión Sistemática de la Literatura. Estos documentos fueron analizados en profundidad en la fase 3 del estudio, y en la Tabla 7 se muestra veintitrés (23) artículos del conjunto final, a modo de representación de los hallazgos obtenidos.

Los veintitrés (23) artículos incluidos en la Tabla 7 comparten como objetivo principal la mejora o automatización de la evaluación del suelo o de condiciones relacionadas mediante visión artificial. Algunos trabajos se enfocan en desarrollar modelos precisos para segmentación de residuos agrícolas [9], otros en predecir propiedades como textura del suelo con imágenes tomadas por smartphones [10], mientras que algunos ofrecen revisiones amplias del estado del arte en clasificación de suelos [6], [13]. Además, se identificaron propuestas novedosas como CollembolAI, que, aunque no evalúa el suelo directamente, utiliza visión artificial para analizar bioindicadores asociados a su calidad [11].

**Tabla 7.** Análisis de literatura

<b>Técnica</b>	<b>Algoritmo/ modelo</b>	<b>Cultivo o suelo</b>	<b>Datos utilizados</b>	<b>Resultados clave</b>	<b>Ventajas/ Desventajas</b>	<b>Base de datos académica</b>	<b>Año</b>
<b>Visión artificial y deep learning</b>	U-Net	Suelo con residuos de maíz y soja	Imágenes RGB terrestres de alta resolución	89 % de precisión en segmentación de residuos	Alta precisión; requiere entrenamiento intensivo	Google Scholar [9]	2021
<b>Visión artificial y deep learning</b>	CNN, SVM, RF, VGGNet, ResNet50, PCA, K-Means	Suelos diversos	Imágenes de cámaras, móviles, satélite, sensores; bases creadas por autores	Precisión hasta 98,72 % con ResNet50, SVM > 95 %	Alta precisión; algunos métodos requieren alto poder de cómputo; posible bajo costo con móviles	Google Scholar [6]	2021
<b>Visión artificial con DLAC y CNN</b>	DLAC-CNN-RF	12 tipos de suelos (arcilla, limo, arena)	Imágenes de suelos capturadas con smartphone y datos de textura (hidrómetro)	Precisión de 99,67 % en la predicción de textura del suelo; R2 de 0,99; Mejor rendimiento que KNN y VGG16-RF	Alta precisión y bajo costo; requiere calibración del sistema y limitación en la distancia de la cámara	Consensus [10]	2022
<b>Macrofotografía, visión por computadora</b>	Faster R-CNN con SAHI (Detectron2)	Mesofauna del suelo (12 especies de Collembola y Acari)	36 imágenes compuestas, 5.671 anotaciones (entreno), 442 (prueba); cámara DSLR, muestras en etanol	Precisión 94 %, Recall 91,8 %, mAP@0.5 = 0,868; bajo 2,7 % de falsos positivos por fondo	Alta precisión, reutilizable, accesible; requiere anotación inicial y buena calidad de imagen	Consensus [11]	2022

<b>Revisión de visión artificial + DL</b>	CNN, YOLO, SSD, GANs, ViT	Múltiples cultivos y suelos agrícolas	Imágenes RGB/hiperespectrales, UAV, sensores, bases de datos públicas y privadas	Alta precisión (>95 %) en tareas de detección; generación sintética de datos con GANs	Cobertura completa; desafíos de datos masivos, potencia computacional y variabilidad en campo	Consensus [12]	2022
<b>Visión por computadora basada en texturas y colores</b>	SVM (Sel_FS), ANN, MR, DT	Ocho clases de suelo (clay, sandy, silt, etc.)	38,912 imágenes RGB (aumentadas) capturadas con smartphone + características seleccionadas	Precisión de 99,79 % con SVM; mejora sobre estudios previos en ~37 %	Alta precisión, sistema económico y portátil; necesita anotación manual y selección de características óptima	Springer Nature Link [13]	2022
<b>Big Data, Visión artificial, IoT</b>	CNN, RNN, DBN, GAN, DRN, sensores IoT	Diversos cultivos (general)	Sensores, UAVs, imágenes, IoT, datos abiertos, plataformas en la nube	Alta aplicabilidad tecnológica, pero con retos en datos, infraestructura y adopción	Muy completo y actualizado; no enfocado en un cultivo o suelo específico	ACM [14]	2023
<b>Procesamiento o satelital, DL</b>	DLCA (CNN, K-means, KNN, NB)	Arroz (paddy), suelos de Thanjavur	Imágenes Sentinel-2, Landsat, Copernicus (2019)	98,52 % de precisión, F1-score 99,02 %, MCC 98,43 %	Alta precisión y cobertura multietapa; requiere preprocesamiento y recursos de cómputo	ACM [15]	2023
<b>Deep Learning</b>	DNNR	Suelos rojos y negros (India)	Datos de laboratorio (pH, OC, P, K), sensores IoT, humedad, temperatura (2016–2020)	Precisión del 96,7 % en predicción de calidad; mejor que ANN, KNN y otros modelos previos	Alta precisión, eficiente y adaptable; no incluye visión artificial; requiere datos bien preprocesados	Consensus [16]	2023




<b>Visión artificial</b>	SSD MobileNet v2, EfficientDet D0	Plantas con clorosis férrica	Imágenes de hojas (web), anotadas con LabelImg	mAP: 22 (SSD), 33,6 (EfficientDet); Precisión > 98 %	Alta precisión; EfficientDet más lento pero más exacto	IEEE [17]	2023
<b>Visión artificial (CNN)</b>	U-Net con EfficientNet-B4	Trigo	Más de 120.000 imágenes RGB top-down (2017–2021), múltiples sitios y condiciones	Precisión > 94 % en Dice e IoU; segmentación robusta del dosel vegetal	Alta precisión, no destructivo, escalable; requiere entrenamiento con muchos datos	Springer Nature Link [18]	2023
<b>Teledetección, deep learning</b>	CNN, NDVI	Franco-arcilloso y arcilloso; trigo, guisante, forrajes	Imágenes Landsat 2013–2022, NDVI, 275 puntos de control, muestreo de suelos	Precisión >0,95 (CNN); NDVI ↑ 0,19; mejoras en EC, Mg, limo, etc.	Alta precisión y cobertura espacial; Limitación por resolución Landsat y condiciones de humedad variables	Springer Nature Link [19]	2023
<b>Visión, señales RF (Wi-Fi)</b>	ResNet, modelado matemático	Suelo agrícola, mezcla arena/compost	Imágenes de smartphone, señales Wi-Fi, sensores comerciales	91 % de R <sup>2</sup> sin secado de muestra; bajo costo y buena precisión	Bajo costo; sin preparación; menor precisión en suelos naturales con baja variabilidad	ACM [20]	2024
<b>Machine Learning</b>	SVM, ID3, C4.5, Random Forest	Suelo: Arenoso, arcilloso y franco	Sensores de campo, portales ICAR/TNAU, observación de síntomas	Reglas de correlación para recomendar abonos según deficiencias y tipo de suelo	Reglas detalladas y prácticas; no se enfoca en visión artificial, resultados aún teóricos	ACM [21]	2024

<b>Revisión de visión por computadora y aprendizaje profundo</b>	CNN, YOLO, ViT, GANs, SVM, etc.	Diversos cultivos (trigo, tomate, arroz, etc.)	Imágenes RGB, térmicas, hiperspectrales y multiespectrales; datasets públicos y de campo	Precisión > 99 % en modelos personalizados; mejoras en diagnóstico y eficiencia agrícola	Alta precisión y automatización; requiere muchos datos etiquetados, gran poder de cómputo, problemas de interpretabilidad	Consensus [22]	2024
<b>ML, DL y visión satelital</b>	ANN, LSTM, GMA, PCA, HCA, GIS, RS	Suelo agrícola general	Propiedades físico-químicas y biológicas, imágenes satelitales	Modelos DL precisos; GMA mostró alta sensibilidad en Egipto	ML/DL permiten rapidez y precisión; requerimientos computacionales altos	Consensus [23]	2024
<b>Imágenes hiperspectral es, ML</b>	CNN, SVM, XGBoost, etc.	Suelos agrícolas con distintas propiedades	Imágenes HSI (satélite, drones, sensores terrestres), muestras físicas	Alta precisión en estimación de SOC, textura, humedad, metales pesados y nutrientes	No destructivo; alta precisión; alto costo; necesidad de gran preprocesamiento	Google Scholar [24]	2024
<b>Visión artificial (DL)</b>	YOLO, Mask R-CNN, U-Net, EfficientNet, CNN	Cultivos hortícolas en invernadero	Imágenes RGB, térmicas, hiperspectrales, sensores IoT, drones	Alta precisión en monitoreo, detección y automatización agrícola en invernaderos	Revisión completa; técnicas modernas; necesidad de más datos etiquetados y robustez en entornos reales	IEEE [25]	2024
<b>IoT, aprendizaje profundo</b>	RNN con GRU + recomendaciones contrafactuales	Suelo para cultivo de café en Karnataka (India)	Datos de sensores IoT (20 semanas), 640 muestras históricas, app móvil, AWS Cloud	Precisión 94,25 %; mejor que SVM, GAN, FFNN, etc. Transformación real de suelos	Alta precisión y usabilidad; alto costo de hardware, desafíos en climas extremos y adopción por pequeños agricultores	Springer Nature Link [26]	2024

<b>Revisión de CNN en visión artificial</b>	CNN (VGG, ResNet, DenseNet, ViT, etc.)	Cultivo de papa	Imágenes RGB (2–6 clases); datasets de 900–10.000 imágenes; múltiples países	Precisión hasta 99,98 % con Deep Ensemble; modelos robustos y generalizables	Alta precisión y múltiples enfoques; limitaciones en datos, variabilidad de síntomas y costos computacionales	Springer Nature Link [27]	2024
<b>Visión espectral. IA en madurez de frutas</b>	SVM, RF, ANN, KNN, clustering	Frutas (manzana, mango, etc.)	Datos de sensores destructivos y no destructivos (vis/NIR, HPLC, espectroscopía, etc.)	Modelos ML eficientes con fusión sensorial; mejores índices: °Brix, firmeza, color	Alta eficiencia y precisión; necesita calibración por tipo de fruta y dataset extenso	Springer Nature Link [28]	2024
<b>Agro-deep learning, visión artificial</b>	ADLF (CNN, DL)	Cultivos globales (arroz, trigo, etc.)	56.717 muestras; imágenes satelitales, sensores IoT, clima, Kaggle dataset	Precisión 84,87 %, F1-score 88,91 %, mejor que SVM, RF, DLBO, etc.	Altamente preciso, adaptable y eficiente; complejo de entrenar, requiere múltiples fuentes de datos	Springer Nature Link [29]	2024
<b>Visión artificial, MLP, CNN</b>	WaveVision Net (MLP+CNN +HDC)	Hojas de 26 variedades de mango	16.646 imágenes (MangoFolioBD); cámaras móviles; datos aumentados y con ruido	Precisión 97,23 % sin ruido, 95,21 % con ruido; AUC 0,9831; F1 = 0,9544	Alta precisión y robustez; necesita entrenamiento intensivo y hardware compatible para despliegue	Springer Nature Link [30]	2024


La técnica predominante fue el uso de redes neuronales convolucionales (CNN), presente en la mayoría de los artículos [6], [10], [12], [19], [27], (ver Figura 2). En particular, modelos como U-Net [9], [18], R-CNN, YOLO, ResNet y variantes personalizadas como DLAC-CNN-RF [10] demostraron alta eficacia en tareas de clasificación y segmentación (ver Figura 3). También se observaron técnicas de aprendizaje profundo combinadas con métodos estadísticos como Random Forest y SVM, lo cual permite mejorar la robustez de los modelos [13], [21].

### Distribución de la popularidad del algoritmo de aprendizaje automático



**Figura 2.** Principales algoritmos/modelos de análisis

### Algoritmos y Modelos en Visión Artificial



**Figura 3.** Clasificación de algoritmos/modelos en visión artificial


La diversidad de suelos fue notable. Se analizaron suelos arcillosos, arenosos, limosos, suelos de la India (Tamil Nadu), y agrícolas cubiertos con residuos de maíz o soya [9], [12], [22], [29]. En el caso de cultivos, se observaron aplicaciones en trigo, arroz, tomate, pepino, entre otros [14], [18], [25], (ver Figura 4). Algunos estudios no se centraron en un tipo de cultivo específico, sino en la clasificación de muestras de suelo a partir de sus propiedades físicas [24].

### Análisis de Tipos de Suelo y Cultivo

Tipo analizado	Porcentaje
Suelos diversos	20 %
Trigo	11,43 %
Maíz	8,57 %
Arroz	8,57 %
Tomate	8,57 %
Pepino	5,72 %
Otros/No especificado	37,14 %

**Figura 4.** Tipos de suelo y cultivos analizados

Las fuentes de datos más frecuentes fueron imágenes RGB, muchas de ellas capturadas por cámaras digitales, drones, o smartphones de alta gama [10], [13], [20]. También se emplearon imágenes hiperespectrales (HSI) y datos satelitales [19]. Algunos estudios utilizaron microscopía o sistemas de macrofotografía automatizados como parte de entornos experimentales personalizados [11] (ver Figura 5).



**Figura 5.** Fuentes de datos utilizadas

En términos de precisión, los modelos analizados lograron resultados destacados: U-Net superó el 89 % [9], y DLAC-CNN-RF alcanzó un rendimiento sobresaliente en predicción de textura [10]. Modelos avanzados como X101-FPN con SAHI también mostraron una precisión promedio del 86 % en tareas especializadas [11]. Los autores coinciden en que las técnicas de visión artificial pueden sustituir o complementar métodos tradicionales de análisis de suelo, siempre que se ajusten a las condiciones locales y se disponga de datos suficientes [18], [29].

#### 4. CONCLUSIONES

Este estudio consistió en una RSL orientada a identificar y analizar las técnicas de visión artificial aplicadas al análisis de suelos agrícolas. La metodología implicó el examen exhaustivo de cuarenta artículos científicos, evaluados en función de su relevancia técnica y aplicabilidad práctica. Lo que permitió clasificar y comparar de manera sistemática los objetivos, algoritmos, tipos de suelo, fuentes de datos y principales hallazgos reportados en cada investigación.

Los hallazgos muestran que las CNN son las técnicas más empleadas, con modelos como U-Net, ResNet y DLAC-CNN-RF mostrando altos niveles de precisión en tareas de segmentación y clasificación. En cuanto a los datos, las imágenes RGB capturadas por smartphones o cámaras digitales fueron la fuente más común, aunque también se identificaron enfoques más avanzados con imágenes hiperespectrales o satelitales. Se abordaron diversos tipos de suelos y cultivos, lo que demuestra la versatilidad de estas herramientas.

Se concluye que la visión artificial representa una alternativa no destructiva, precisa y eficiente para el diagnóstico del suelo. Sin embargo, aún existen vacíos en la literatura, especialmente en aplicaciones dirigidas a cultivos como el café y en contextos rurales con bajo acceso tecnológico. Como trabajo futuro, se propone el desarrollo de modelos entrenados con datos locales y de bajo costo computacional, que permitan implementar soluciones reales en comunidades cafetaleras como las de Jilotepec, Veracruz.

## REFERENCIAS

- [1] A. C. Hernández, G. H. Martínez, y R. Manson, “La cafecultura mexicana: el caso del proyecto biocafé”, en *III Congresso Brasileiro de Agroecologia*, Florianópolis, Brasil, Oct. 2005. [En línea]. Disponible en: <https://acortar.link/Hm4zAz>
- [2] SEFIPLAN, “Sistema de Información Estadística y Geográfica del Estado de Veracruz de Ignacio de la Llave (SIEGVER)”, Secretaría de Finanzas y Planeación, Jilotepec, Cuadernillos Municipales. Jilotepec, 2024. [En línea]. Disponible en: [https://cieg.gobiernodigital.gob.mx/wp-content/uploads/sites/21/2024/11/Jilotepec\\_CM\\_2024\\_Ver.2.pdf](https://cieg.gobiernodigital.gob.mx/wp-content/uploads/sites/21/2024/11/Jilotepec_CM_2024_Ver.2.pdf)
- [3] D. Geissert, A. Mólgora-Tapia, S. Negrete-Yankelevich, y R. Hunter Manson, “Efecto del manejo de la cobertura vegetal sobre la erosión hídrica en cafetales de sombra”, *AGROCIENCIA*, vol. 51, no. 2, pp. 119–133, Mar. 2017, [En línea]. Disponible en: <https://www.agrociencia-colpos.org/index.php/agrociencia/article/view/1282>
- [4] O. Santillán, y M. E. Rentería Rodríguez, “Agricultura de Precisión”, Oficina de Información Científica y Tecnológica para el Congreso de la Unión [INCYTU], Ciudad de México, 15, Abr. 2018. [En línea]. Disponible en: <https://www.foroconsultivo.org.mx/INCYTU/index.php/notas/sociedad/94-15-agricultura-de-precision-n-2>
- [5] J. F. Sotomayor, A. P. Gómez, y A. F. Cela, “Sistema de Visión Artificial para el Análisis de Imágenes de Cultivo basado en Texturas Orientadas”, *Rev. Politécnica*, vol. 33, no. 1, Jan. 2014, [En línea]. Disponible en: [https://revistapolitecnica.epn.edu.ec/ojs2/index.php/revista\\_politecnica2/article/view/104](https://revistapolitecnica.epn.edu.ec/ojs2/index.php/revista_politecnica2/article/view/104)
- [6] P. Srivastava, A. Shukla, y A. Bansal, “A comprehensive review on soil classification using deep learning and computer vision techniques”, *Multimed. Tools Appl.*, vol. 80, no. 10, pp. 14887–14914, Abr. 2021. [En línea]. Disponible en: <https://doi.org/10.1007/s11042-021-10544-5>
- [7] M. Javaid, A. Haleem, I. H. Khan, y R. Suman, “Understanding the potential applications of Artificial Intelligence in Agriculture Sector”, *Adv. Agrochem*, vol. 2, no. 1, pp. 15–30, Oct. 2022. [En línea]. Disponible en: <https://doi.org/10.1016/j.aac.2022.10.001>
- [8] B. Kitchenham, y S. Charters, “Guidelines for performing Systematic Literature Reviews in Software Engineering”, vol. 2, Jul. 2007, [En línea]. Disponible en: <https://www.researchgate.net/publication/302924724>
- [9] F. A. Diaz-Gonzalez, J. Vuelvas, C. A. Correa, V. E. Vallejo, y D. Patino, “Machine learning and remote sensing techniques applied to estimate soil indicators – Review”, *Ecol. Indic.*, vol. 135, pp. 108517, Dec. 2021. [En línea]. Disponible en: <https://doi.org/10.1016/j.ecolind.2021.108517>
- [10] Z. Zhao, W. Feng, J. Xiao, X. Liu, S. Pan, y Z. Lian g, “Rapid and Accurate Prediction of Soil Texture Using an Image-Based Deep Learning Autoencoder Convolutional Neural Network Random Forest (DLAC-CNN-RF) Algorithm”, *MDPI*, vol. 12, no. 12, Dec. 2022. [En línea]. Disponible en: <https://doi.org/10.3390/agronomy12123063>

- [11] S. Sys, S. Weißbach, L. Jakob, S. Gerber, y C. Schneider, “CollembolAI, a macrophotography and computer vision workflow to digitize and characterize samples of soil invertebrate communities preserved in fluid”, *Methods Ecol. Evol.*, vol. 13, no. 12, pp. 2729–2742, Oct. 2022. [En línea]. Disponible en: <https://doi.org/10.1111/2041-210X.14001>
- [12] V. G. Dhanya *et al.*, “Deep learning based computer vision approaches for smart agricultural applications”, *Artif. Intell. Agric.*, vol. 6, pp. 211–229, Sep. 2022. [En línea]. Disponible en: <https://doi.org/10.1016/j.aiaa.2022.09.007>
- [13] M. Uddin, y Md. R. Hassan, “A novel feature based algorithm for soil type classification”, *Complex Intell. Syst.*, vol. 8, no. 4, pp. 3377–3393, Feb. 2022. [En línea]. Disponible en: <https://doi.org/10.1007/s40747-022-00682-0>
- [14] D. Han, y M. Rodriguez, “Big Data Analytics, Data Science, ML&AI for Connected, Data-driven Precision Agriculture and Smart Farming Systems: Challenges and Future Directions”, en *Proceedings of Cyber-Physical Systems and Internet of Things Week 2023*, San Antonio TX USA: ACM, May 2023, pp. 378–384. [En línea]. Disponible en: <https://doi.org/10.1145/3576914.3588337>
- [15] R. Sathiya Priya, y U. Rahamathunnisa, “A Novel Clustering Algorithm for Monitoring Paddy Growth Through Satellite Image Processing.”, *ACM Trans. Sens. Netw.*, p. 3579358, May 2023. [En línea]. Disponible en: <https://doi.org/10.1145/3579358>
- [16] P. Sumathi, V. V. Karthikeyan, M. S. Kavitha, y S. Karthik, “Improved Soil Quality Prediction Model Using Deep Learning for Smart Agriculture Systems”, *Comput. Syst. Sci. Eng.*, vol. 45, no. 2, pp. 1545–1559, Nov. 2023. [En línea]. Disponible en: <https://doi.org/10.32604/csse.2023.027580>
- [17] M. Majdalawieh, S. Khan, y Md. T. Islam, “Using Deep Learning Model to Identify Iron Chlorosis in Plants”, *IEEE Access*, vol. 11, pp. 46949–46955, May 2023. [En línea]. Disponible en: <https://doi.org/10.1109/ACCESS.2023.3273607>
- [18] M. Awais *et al.*, “AI and machine learning for soil analysis: an assessment of sustainable agricultural practices”, *Bioresour. Bioprocess.*, vol. 10, no. 1, p. 90, Dic. 2023. [En línea]. Disponible en: <https://doi.org/10.1186/s40643-023-00710-y>
- [19] M. Kazemi Garajeh, K. Hassangholizadeh, A. R. Bakhshi Lomer, A. Ranjbari, L. Ebadi, y M. Sadeghnejad, “Monitoring the impacts of crop residue cover on agricultural productivity and soil chemical and physical characteristics”, *Sci. Rep.*, vol. 13, no. 1, p. 15054, Sep. 2023. [En línea]. Disponible en: <https://doi.org/10.1038/s41598-023-42367-9>
- [20] J. Ding, R. Chandra, R. Lal, y L. Tassiulas, “Cost-Effective Soil Carbon Sensing with Wi-Fi and Optical Signals”, en *Proceedings of the 30th Annual International Conference on Mobile Computing and Networking*, Washington D.C. DC USA: ACM, Dic. 2024, pp. 1015–1029. doi: <https://doi.org/10.1145/3636534.3690675>
- [21] B. R. A *et al.*, “Exploratory Study of Soil Parameters to Generate Correlations to Recommend Organic Manure”, en *Proceedings of the 2024 Sixteenth International Conference on Contemporary Computing*, Noida India: ACM, Aug. 2024, pp. 162–169. [En línea]. Disponible en: <https://doi.org/10.1145/3675888.3676046>
- [22] A. Upadhyay *et al.*, “Deep learning and computer vision in plant disease detection: a comprehensive review of techniques, models, and trends in precision agriculture”, *Artif. Intell. Rev.*, vol. 58, no. 3, pp. 92, Dic. 2024. [En línea]. Disponible en: <https://doi.org/10.1007/s10462-024-11100-x>



- [23] R. A. El Behairy *et al.*, “How Can Soil Quality Be Accurately and Quickly Studied? A Review”, *Agronomy*, vol. 14, no. 8, pp. 1682, Jul. 2024. [En línea]. Disponible en: <https://doi.org/10.3390/agronomy14081682>
- [24] N. A. Sharma, K. Kumar, R. R. Chand, y M. A. Kabir, “Utilizing Hyperspectral Imaging with Machine Learning Techniques for Soil Analysis”, Feb. 2024. [En línea]. Disponible en: [https://doi.org/10.1007/978-3-031-83127-0\\_5](https://doi.org/10.1007/978-3-031-83127-0_5)
- [25] J. U. M. Akbar, S. F. Kamarulzaman, A. J. M. Muzahid, Md. A. Rahman, y M. Uddin, “A Comprehensive Review on Deep Learning Assisted Computer Vision Techniques for Smart Greenhouse Agriculture”, *IEEE Access*, vol. 12, pp. 4485–4522, Jan. 2024. [En línea]. Disponible en: <https://doi.org/10.1109/ACCESS.2024.3349418>
- [26] R. Selvanarayanan, S. Rajendran, S. Algburi, O. Ibrahim Khalaf, y H. Hamam, “Empowering coffee farming using counterfactual recommendation based RNN driven IoT integrated soil quality command system”, *Sci. Rep.*, vol. 14, no. 1, p. 6269, Mar. 2024. [En línea]. Disponible en: <https://doi.org/10.1038/s41598-024-56954-x>
- [27] B. Gülmez, “A Comprehensive Review of Convolutional Neural Networks based Disease Detection Strategies in Potato Agriculture”, *Potato Res.*, Aug. 2024. [En línea]. Disponible en: <https://doi.org/10.1007/s11540-024-09786-1>
- [28] M. Islam, S. Bijjahalli, T. Fahey, A. Gardi, R. Sabatini, y D. W. Lamb, “Destructive and non-destructive measurement approaches and the application of AI models in precision agriculture: a review”, *Precis. Agric.*, vol. 25, no. 3, pp. 1127–1180, Feb. 2024. [En línea]. Disponible en: <https://doi.org/10.1007/s11119-024-10112-5>
- [29] J. Logeshwaran *et al.*, “Improving crop production using an agro-deep learning framework in precision agriculture”, *BMC Bioinformatics*, vol. 25, no. 1, pp. 341, Nov. 2024. [En línea]. Disponible en: <https://doi.org/10.1186/s12859-024-05970-9>
- [30] Md. F. Ul-Islam, A. Chakrabarty, R. Rahman, H. Moon, y Md. J. Piran, “Advancing mango leaf variant identification with a robust multi-layer perceptron model”, *Sci. Rep.*, vol. 14, no. 1, p. 27406, Nov. 2024. [En línea]. Disponible en: <https://doi.org/10.1038/s41598-024-74612-0>

