



Asesorías y Tutorías para la Investigación Científica en la Educación Puig-Salabarria S.C.
 José María Pino Suárez 400-2 esq a Lerdo de Tejada. Toluca, Estado de México. 7223898475
 RFC: ATII120618V12

Revista Dilemas Contemporáneos: Educación, Política y Valores.

<http://www.dilemascontemporaneoseducacionpoliticayvalores.com/>

Año: XIII Número: 2 Artículo no.:48 Período: 1 de enero del 2026 al 30 de abril del 2026

TÍTULO: Aplicaciones de la Inteligencia Artificial en la Educación Agrícola Superior.

AUTORES:

1. Máster. Luis Arturo Cervantes-Gómez.
2. Máster. Antonio Fidel Santos-Hernández.
3. Dra. Alejandra Sahagún-García.

RESUMEN: Este artículo investiga las aplicaciones de la Inteligencia Artificial (IA) en la educación superior en general y en la educación agrícola en particular mediante revisiones de literatura. Lo anterior se hace con el propósito de sentar las bases para la mejora del proceso educativo con la inclusión curricular de la IA para preparar a los estudiantes ante los desafíos del sector agrícola moderno, concluyendo con la importancia del uso de herramientas para una educación agrícola de excelencia.

PALABRAS CLAVES: agricultura, docencia, innovación educativa, aprendizaje automático.

TITLE: Artificial Intelligence Applications in Higher Agricultural Education.

AUTHORS:

1. Master. Luis Arturo Cervantes-Gómez.
2. Master. Antonio Fidel Santos-Hernández.
3. PhD. Alejandra Sahagún-García.

ABSTRACT: This article investigates artificial intelligence (AI) applications in higher education in general and in agricultural education in particular through literature reviews. The above is done with the purpose of laying the foundations for the improvement of the educational process through the curricular inclusion of AI to preparing students to address the challenges of the contemporary agricultural sector, concluding with the importance of using tools for high-quality agricultural education.

KEY WORDS: agriculture, teaching, educational innovation, machine learning.

INTRODUCCIÓN.

La educación, pilar del desarrollo humano, ha cambiado significativamente gracias a la tecnología. Según Bellman (1978), el término Inteligencia Artificial (IA) surgió en 1956 para describir la automatización de procesos de pensamiento humano, como toma de decisiones y aprendizaje.

En este contexto, la IA en educación superior está revolucionando metodologías y redefiniendo el aprendizaje (García Peñalvo et al., 2024), planteando desafíos y oportunidades para garantizar una formación acorde con el siglo XXI. En educación superior, la IA transforma cómo los estudiantes acceden, procesan y aplican el conocimiento (Gallent-Torres et al., 2023).

El marco TPACK guía la integración de tecnologías emergentes como la IA en la enseñanza (Herring et al., 2016).

El uso de redes neuronales artificiales (ANN), que son estructuras computacionales que están inspiradas en el funcionamiento del cerebro humano, han permitido avances significativos dentro del *Machine Learning* (ML)¹ o aprendizaje automático; y estas, a su vez, también han permitido avances importantes dentro del *Deep Learning* (DL) o aprendizaje profundo, puesto que al tener múltiples capas ocultas,

¹ Según Mitchell (1997) el concepto de ML (un tipo particular de IA) se refiere al estudio de algoritmos informáticos que mejoran automáticamente a través de la experiencia; es decir, se refiere al desarrollo de programas que pueden aprender y mejorar su desempeño en tareas específicas conforme se les entrena con nueva información (etiquetada) o de entrenamiento. En ese sentido, en el ámbito educativo y profesional, el ML permite la creación de sistemas que optimizan procesos complejos (incluida la parte técnico-práctica y enseñanza-aprendizaje de una diversidad de disciplinas agronómicas, dependiendo del contexto y la tarea específica a desarrollar).

permiten modelar relaciones no lineales complejas (Haykin, 1998). En particular, Goodfellow et al. (2016) mencionan que las ANN utilizan múltiples capas para aprender datos con niveles de abstracción.

En educación agrícola, el DL optimiza modelos predictivos para comprender patrones en la producción agrícola y en el manejo de los recursos naturales, con lo que es posible abordar desafíos técnicos y pedagógicos (Macías et al., 2016), e incluso, a su vez, también plantea oportunidades para mejorar la docencia.

Las Ciencias Agronómicas, esenciales para la seguridad alimentaria y sostenibilidad, requieren profesionales que implementen prácticas eficientes y sostenibles de manera práctica, y las diferentes técnicas de IA mencionadas pueden facilitar y optimizar este proceso (Macías et al., 2016). En este mismo sentido, la formación actualizada de tales profesionales resulta esencial para garantizar la seguridad alimentaria y el desarrollo agrícola sostenible a nivel local y global. Puesto que en un mundo interconectado y digitalizado, el uso de tecnologías como la IA es clave para enfrentar desafíos y aprovechar oportunidades dentro de las disciplinas agronómicas (Bampasidou et al., 2024).

La IA ofrece herramientas para analizar grandes volúmenes de datos, optimizar procesos y tomar decisiones informadas en tiempo real (Bolaño-García & Duarte-Acosta, 2024).

El objetivo general del artículo es investigar las aplicaciones de la IA en la educación superior en general y en la educación agrícola en particular. Se realizó una revisión bibliográfica exhaustiva con búsquedas sistemáticas en la base de datos Scopus, cuyos artículos fueron analizadas con gestores de datos como bibliometrix y VOSviewer para identificar patrones y tendencias clave, con énfasis en educación agrícola, estructurándose en cuatro secciones: ventajas, desventajas y herramientas de IA; revisión sistemática de la IA en Ciencias Agronómicas; aplicaciones específicas; y propuestas potenciales en enseñanza.

DESARROLLO.

Sección 1. Ventajas, desventajas y limitaciones del uso de la IA en la educación superior y posibles aplicaciones de la IA en la enseñanza.

En esta sección se analizarán las aplicaciones y limitaciones de la IA en la enseñanza en Educación Superior con base en revisiones de literatura previa (Torres et al., 2024).

En la Tabla 1 se presentan los resultados del proceso. Para implementar la IA en la enseñanza de Ciencias Agronómicas, se deben considerar tanto su parte teórica, que se ajusta al marco, como su parte práctica, que requiere un análisis distinto. Entre las ventajas destacan la personalización del aprendizaje, la evaluación automatizada y el acceso a educación de calidad. La IA permite adaptar el aprendizaje a cada estudiante, mejorando la experiencia educativa y el éxito. La personalización facilita que los estudiantes avancen a su ritmo, y la evaluación automatizada mejora la retroalimentación, optimizando el tiempo de los profesores (Calderón et al., 2024).

Otro punto interesante es el acceso a la educación de calidad, particularmente relevante para estudiantes que residen en áreas remotas o que poseen de necesidades especiales. La IA puede equilibrar el acceso a la educación, permitiendo que más personas tengan acceso a este derecho (Calderón et al., 2024). Entre las desventajas de la IA en educación están los riesgos éticos, como la privacidad de datos y el sesgo algorítmico, que pueden limitar su efectividad y generar inequidad para poblaciones de bajos recursos. El cambio en el rol del docente puede deshumanizar la educación y afectar la interacción profesor-alumno. Además, las desigualdades sociales son preocupantes, ya que muchas escuelas rurales carecen de acceso a tecnología, electricidad e internet (Calderón et al., 2024). Otra desventaja es la falta de capacitación docente, ya que muchos docentes con mayor experiencia se niegan a usar nuevas tecnologías. Además, la popularidad y mala reputación de los chatbots han llevado a que el público limite su percepción de la IA a estas interfaces, ignorando su amplio potencial en otras áreas.

Tabla 1. Ventajas, desventajas, limitaciones y herramientas de IA en la Educación Superior.

Ventajas	Desventajas	Limitaciones	Cita
<p>Personalización del aprendizaje: La IA adapta el aprendizaje a las necesidades individuales, mejorando la experiencia educativa.</p> <p>Evaluación automatizada: Facilita una evaluación más eficiente y precisa.</p> <p>Acceso a educación de calidad: Mejora el acceso para estudiantes en áreas remotas o con necesidades especiales,</p>	<p>Riesgos éticos: La IA puede generar problemas de privacidad de datos y sesgo algorítmico.</p> <p>Cambio en el rol del docente: Transforma su papel, afectando la calidad de la enseñanza.</p> <p>Desigualdades educativas: Podría exacerbar desigualdades en regiones con menos recursos tecnológicos.</p>	<p>Sostenibilidad y escalabilidad: Los altos costos e infraestructura especializada necesaria plantean dudas sobre su sostenibilidad.</p> <p>Calidad educativa: El cambio en el rol docente puede afectar la calidad y las relaciones en el aula.</p> <p>Desafíos técnicos y éticos: Deben abordarse para garantizar un uso responsable de la IA.</p>	<p>(Calderón et al., 2024; Torres et al., 2024).</p>
		Capacitación docente insuficiente o inexistente.	Análisis propio.

Entre las limitaciones, la sostenibilidad y escalabilidad son clave, ya que los altos costos y la infraestructura necesaria pueden ser inaccesibles, especialmente en zonas rurales, profundizando la desigualdad social y limitando el acceso a educación de calidad. La calidad educativa podría verse afectada por cambios en el rol docente, alterando la interacción profesor-alumno. Además, los desafíos técnicos y éticos, como la privacidad de datos y el sistema algorítmico, requieren atención constante. Para un impacto positivo y equitativo, es fundamental planificar cuidadosamente currículos, capacitación docente y regulación legislativa, evitando deshumanizar la educación y reduciendo desigualdades (Calderón et al., 2024).

En la Tabla 2 se presentan herramientas de IA para optimizar el proceso de enseñanza-aprendizaje en educación superior. Estas facilitan el acceso a la información y personalizan la experiencia educativa según las necesidades de cada estudiante.

Chatbots educativos brindan asistencia en tiempo real, mientras que los sistemas de tutoría inteligente adaptan contenido y metodología según el progreso del alumno. El análisis predictivo identifica estudiantes en riesgo de fracaso académico, permitiendo intervenciones tempranas. Las plataformas de aprendizaje adaptativo ajustan contenidos según el rendimiento, fomentando motivación y retención. Estas herramientas mejoran la eficiencia docente y la experiencia educativa.

Tabla 2. Herramientas de IA que se pueden aplicar a la enseñanza de Educación Superior.

Herramienta de IA	¿Qué es?	Ejemplos de sub-herramientas.	¿Para qué sirve?
Chatbots educativos.	Sistemas basados en IA que simulan una conversación con los usuarios.	ChatGPT, IBM Watson Assistant, Botsify, Tars, ChatPDF, Jenni.	Ayudan a resolver dudas frecuentes de los estudiantes y proporcionan soporte 24/7.
Sistemas de análisis predictivo.	Algoritmos de IA que analizan datos académicos.	RapidMiner, Microsoft Azure Machine Learning, IBM SPSS, Tableau, Google Cloud AI, KNIME.	Predicen el rendimiento de los estudiantes y ayudan a identificar aquellos en riesgo de fracaso.
Plataformas de aprendizaje adaptativo.	Plataformas que utilizan IA para ajustar los contenidos según el rendimiento del estudiante.	Smart Sparrow, DreamBox, Realizeit, Cerego.	Personalizan el contenido educativo para adaptarse a las necesidades y ritmo de cada estudiante.
Asistentes de voz	Programas que responden preguntas mediante reconocimiento de voz.	Alexa for Education, Google Assistant, Siri, Cortana, Bixby, Mycroft.	Facilitan el acceso a información educativa y permiten responder preguntas sin necesidad de una pantalla.
Generadores de contenido automatizado	Herramientas que utilizan IA para crear materiales educativos.	Quizlet AI, Contentbot.ai, Copysmith, Jasper, Writesonic, Ryt.	Ayudan a los profesores a generar cuestionarios, resúmenes y otros recursos de manera rápida.

Análisis del aprendizaje (Learning Analytics).	Tecnología que analiza datos de la interacción del estudiante con plataformas.	Tableau, Power BI, Moodle Analytics, Blackboard Analytics, Brightspace Insights, Zoomi.	Proporciona información a docentes y administradores para mejorar la experiencia educativa.
Evaluación automatizada.	Algoritmos que califican exámenes y tareas.	Gradescope, Turnitin, OpenAI, Eval.ai, Inspera.	Reducen la carga de trabajo de los docentes al corregir trabajos y proporcionar retroalimentación automática.

Fuente: Elaboración propia.

Sección 2. Revisión Sistémica del uso de la IA en Educación Agrícola Superior.

Esta sección se creó con el fin explorar el uso de la IA en la enseñanza de educación agrícola, analizando su aplicación en artículos científicos incluidos en Scopus. Uno de los principales repositorios bibliográficos reconocido a nivel mundial es Scopus (Zhu & Weishu, 2020). Se eligió debido a la amplia cobertura científica que ofrece, abarcando diferentes idiomas (Baceta et al., 2019) y área del conocimiento, incluidas las ciencias sociales (Malanski et al., 2021).

Se realizó una investigación cuantitativa para obtener datos de diferentes publicaciones a nivel mundial en la base de datos científica Scopus con la siguiente fórmula: TITLE-ABS-KEY ((universit* AND education) OR (universit* AND student*) OR "undergraduate students" OR "graduate students" OR "postgraduate students" OR "associate degree" OR "higher technicians" OR "PhD students" OR ("Doctor of Philosophy" AND student*) OR "doctoral students" OR "master students" OR "bachelor students" OR "higher education" OR "tertiary education" OR "graduate education" OR "postgraduate education" OR "professional education") AND (agriculture OR farming OR cultivation OR agronomy OR "crop science" OR "soil science" OR horticulture OR ("forestry students") OR "forest science" OR "forest engineering" OR (agricultu* OR farm*) AND biotechnology) OR "agricultural economics" OR "agricultural

engineering" OR zootechnics OR phytotechnics OR phytotechnology OR "irrigation engineering" OR "veterinary medicine" OR "agricultural parasitology" OR ("mechanical engineering" AND (agricultur* OR farming OR cultivation)) OR "agricultural business" OR "agricultural management" OR agribusiness OR "crop protection" OR "agricultural entomology" OR phytopathology OR "plant breeding" OR "animal breeding") AND ("artificial intelligence" OR "machine learning" OR "deep learning" OR "neural networks") AND (LIMIT-TO (PUBSTAGE,"final") AND (LIMIT-TO (DOCTYPE,"re") OR LIMIT-TO (DOCTYPE,"ar")). La búsqueda se efectuó el 05 de agosto de 2024. Con dicha fórmula se buscó encontrar estudios que tuvieran relación con la IA y la educación agrícola superior (higher education, tertiary education, etc.; y estudiantes de diferentes niveles y disciplinas agronómicas, incluyendo aspectos agrícolas, forestales, hortícolas, sociales y económico-administrativos).

En la Tabla 3 se presentan los resultados de la revisión, que comenzó con 160 estudios, de los cuales solo 4, publicados en los últimos dos años, fueron seleccionados tras un riguroso cribado. Los estudios, provenientes de Australia, Estados Unidos, Turquía y Grecia, reflejan el carácter emergente de la investigación sobre IA en la enseñanza agronómica.

En Turquía, se analizaron las opiniones de estudiantes sobre la IA en la formación veterinaria, destacando su aceptación en la mayoría de las encuestas. En Estados Unidos, se exploró el uso de plataformas digitales para reducir desigualdades en el acceso a tecnologías agrícolas. En Australia, se investigó el uso de ChatGPT como herramienta de apoyo en Medicina Veterinaria, mostrando su potencial en la enseñanza.

En Grecia, se describió el uso de robots para desarrollar habilidades técnicas en educación agrícola, enfocándose en maquinaria y automatización. La

Tabla 4 detalla los tipos de estudio y las teorías que los sustentan.

Tabla 3. Categorización de los estudios.

País de origen	Año	Universidad de aplicación	Disciplina Agrícola	Contexto	Cita
Turquía	2024	Universidad de Ankara.	Medicina Veterinaria	Opinión de los estudiantes sobre el concepto de IA.	(Yerlikaya & Kúçúkaslan, 2024).
Estados Unidos	2024	Universidad Estatal de Luisiana.	Economía Agrícola	Superación de Brechas digitales para la agricultura digital.	(Bampasidou et al., 2024).
Australia	2024	Universidad de Sídney.	Medicina Veterinaria	ChatGPT práctico y relevante para los estudiantes.	(Worthing et al., 2024).
Grecia	2022	Universidad Agrícola de Atenas.	Ingeniería Agrícola	Utilización de robots para el desarrollo estudiantil.	(Loukatos et al., 2022).

Tabla 4. Tipos de estudios y teorías para los estudios revisados.

Tipo de estudio	Método	Teoría educativa utilizada	Cita
Investigación descriptiva, con enfoque en la percepción y conocimiento de los estudiantes de veterinaria.	Aplicado a 529 estudiantes, el cuestionario constaba de 10 preguntas demográficas y de conocimiento, y 26 preguntas tipo Likert para medir opiniones sobre IA. Los datos se analizaron con pruebas estadísticas, como Chi-cuadrado.	Aunque no se menciona una teoría educativa específica, se propone la inclusión de cursos optativos sobre IA, alineados con enfoques constructivistas que buscan contextualizar el aprendizaje y desarrollar habilidades aplicables.	(Yerlikaya & Kúçúkaslan, 2024).
Estudio de tipo argumentativo y analítico.	Teórico, basado en el análisis y la revisión de literatura sobre la agricultura digital y la educación superior.	Se basa en un enfoque interdisciplinario y constructivista para la transformación digital en la educación agrícola.	(Bampasidou et al., 2024).
Investigación transversal.	Se utilizó una encuesta basada en el Modelo de Aceptación Tecnológica (TAM) para evaluar las percepciones de los estudiantes de veterinaria sobre el uso de ChatGPT.	Foco en la teoría constructivista.	(Worthing et al., 2024).

<p>Experimental. El experimento desarrolló dos robots agrícolas autónomos, uno para recolección de frutas y otro para pulverización y monitoreo. Utilizaron tecnologías como Raspberry Pi, Arduino, cámaras, GPS RTK y materiales reciclados, controlados por apps móviles y comandos de voz. Con paneles solares para mayor autonomía, se evaluaron la precisión de navegación (10 cm), respuesta a comandos y eficiencia energética. También se resaltó su impacto educativo en el aprendizaje práctico de los estudiantes de ingeniería.</p>	<p>Implementación práctica y educativa de robots controlados por IA.</p>	<p>Se utilizó el modelo basado en proyectos, que fomenta el aprendizaje activo a través de la participación directa en proyectos relevantes, también se utilizó el modelo de aprendizaje colaborativo, donde en equipos, los estudiantes abordaron los desafíos del proyecto.</p>	<p>(Loukatos et al., 2022).</p>
---	--	---	---------------------------------

La revisión sistemática expone la creciente adopción de la IA en la educación agrícola superior, destacando teorías educativas y métodos utilizados. El enfoque constructivista, que promueve el aprendizaje activo mediante experiencia y reflexión, es central en varios estudios; por ejemplo, en Turquía, se investigó la percepción de estudiantes de Medicina Veterinaria sobre la IA mediante encuestas que vinculan conocimientos previos con nuevas tecnologías. En Australia, el uso de ChatGPT se evaluó con el modelo TAM, analizando la percepción de utilidad y facilidad de uso, promoviendo el aprendizaje contextual y profesional.

En cuanto a los métodos, los estudios incluyen enfoques descriptivos, transversales y experimentales. En Turquía, un cuestionario detallado capturó percepciones estudiantiles sobre la IA. En contraste, en Estados Unidos, Bampasidou et al. (2024) adoptaron un enfoque teórico-analítico sobre cómo la IA democratiza

el acceso a tecnologías agrícolas, en contraste con las limitaciones (estructurales, propias de la sociedad) de acceso desigual a estas tecnologías (Calderón et al., 2024); ello en el sentido de que con la IA se fomentaría un acceso más diferenciado a la tecnología en general y que incluso esta podría repercutir en una mayor diferenciación de las clases sociales, por lo que este aspecto y sus implicaciones necesitan ser más investigados y discutidos.

El estudio experimental en Grecia utilizó proyectos donde estudiantes desarrollaron robots agrícolas, proporcionando experiencia práctica en IA y fomentando habilidades técnicas, pensamiento crítico y trabajo en equipo. Esta combinación de constructivismo y métodos experimentales preparó a los estudiantes para un mercado laboral competitivo.

Desde los currículos educativos, la integración de la IA permite adquirir competencias técnicas en sistemas de automatización, promoviendo un aprendizaje práctico y adaptativo. Los estudios resaltan que la IA optimiza procesos agrícolas y reduce desigualdades en acceso al conocimiento (Bampasidou et al., 2024).

En resumen, la aplicación de la IA en la educación agrícola es un campo emergente con gran potencial. Su integración en currículos mediante enfoques constructivistas, métodos experimentales y tecnologías avanzadas es esencial para preparar a los estudiantes para un sector en modernización y digitalización global.

Sección 3. Análisis de las aplicaciones de la IA en las Ciencias Agronómicas.

Revisión razonada de la literatura.

Con el fin de tener un panorama más amplio del uso potencial y real de la IA en las Ciencias Agronómicas se realizó una revisión razonada de las aplicaciones de la IA en estas, se utilizó en Scopus la siguiente formula: TITLE (("artificial intelligence") OR ("deep learning") OR ("machine learning") OR ("neural network") AND (applicatio*) AND (agriculture OR farming OR agronomy OR forestry OR horticultur* OR pisciculture OR agrofores*)) AND (LIMIT-TO (DOCTYPE , "ar") OR LIMIT-TO (DOCTYPE , "re")) AND (LIMIT-TO (PUBSTAGE, "final")); realizada el 10 de septiembre de 2024, de la cual

resultaron un artículo retractado y 85 publicaciones (29 revisiones y 56 artículos, si bien la mayoría de estos últimos también eran revisiones; 82 publicaciones estaban en idioma inglés, 2 en chino y 1 en polaco); en general, todas ellas se ajustaron a nuestro objetivo. Frecuencia de las publicaciones: en 1997, 2013, 2016 y 2017 se publicó un estudio en cada caso, 2 en 2018, 4 en 2019, 14 en 2015, 15 en 2021, 11 en 2022, 21 en 2023, y 15 en 2024.

Debido a la redundancia de varios estudios, se omitieron varios casos de estos para evitar la duplicidad de información, así como casos muy específicos (debido a su bajo grado de generalización o su reciente emergencia); por lo que aquí solo se presentan los casos más representativos (variados en cuanto a aplicaciones): ver Tabla 5. Si bien tal clasificación tuvo por fin sistematizar los estudios, lo cierto es que varias categorías podrían ser fácilmente intercambiables (dependiendo de la claridad teórico-conceptual de sus autores), contener a más de una disciplina agrícola o esta no haber sido explícita.

Por otro lado, dado que la implementación de la IA en las Ciencias Agronómicas casi siempre va de la mano con técnicas de percepción remota o teledetección, es común que varias de estas disciplinas hagan uso de esta para situarse dentro de los nuevos paradigmas tecnológicos y así poder “llevar el complemento nominal” inteligente o de precisión (como la piscicultura, ganadería, silvicultura, agroforestería; si bien apenas fueron representativos sus casos). Si bien no se comentan las limitaciones de cada publicación, estas son generalizables al uso de la IA en casi cualquier contexto, las cuales serán discutidas más adelante.

Tabla 5- Aplicaciones de la IA en las Ciencias Agronómicas.

Disciplina agrícola	Campo específico de la aplicación	Aplicaciones específicas	Cita
Agricultura (en general).	IA en la agricultura (estudios estadísticos y de meta-revisión).	Gestión de riego, Control de calidad; Estudio de la fenología, Manejo de plagas y suelos; Reconocimiento de especies; Gestión de cultivos; Control de malezas, Control de pesticidas; Procesamiento de alimentos; Dominios diversos (incluido el uso en ganadería).	(Araújo et al., 2023; Sarkar et al., 2022).

Agricultura 4.0	IA en la Agricultura 4.0	Uso de datos digitales; Captura de datos mediante dispositivos y sensores y su gestión mediante visión por computadora; Monitoreo y predicción de atributos de producción agrícola; Procesamiento de datos acústicos con IA.	(Megeto et al., 2020).
Agricultura de precisión.	Integración de IoT y AI en este tipo de agricultura.	Toma de decisiones basada en datos; Optimización de la asignación de recursos; Mejora y control de sistemas de monitoreo.	(Senoo et al., 2024).
Agricultura inteligente (horticultura).	De NN en la optimización y automatización de invernaderos (integración ML e IoC).	Uso de IoT y ML: Predicción del microclima en invernaderos; Control del gasto energético; Control del dióxido de carbono.	(Escamilla-García et al., 2020).
Ganadería de precisión.	*Prácticas y aplicaciones de sistemas de visión por computadora (o visión artificial) basadas en CNN.	Mejora del manejo del ganado; Clasificación de imágenes; Detección de objetos; Segmentación semántica/instancia; Estimación de la pose y seguimiento del animal.	(Li et al., 2021).
PR-Agroforestería.	Estimación de biomasa aérea con ML y PR.	Uso de imágenes de alta y muy resolución para estimar biomasa aérea (y monitorear carbono) con ML (<i>Random Forest, Stochastic Gradient Boosting y Support Vector Regression</i>) y PR en sistemas agroforestales.	(Thapa et al., 2023).
PR-Agricultura.	Métodos de conteo basados en DL y otros usos.	Conteo automatizado de objetos; Estimación de rendimiento; Detección de estrés; Prevención de enfermedades.	(Farjon et al., 2023).
PR-Silvicultura.	Nuevas aplicaciones de métodos de DL en silvicultura.	Evaluación de calidad superficial de madera aserrada; Muestreo de recursos forestales; Identificación de especies arbóreas; Predicción del contenido de humedad de la madera; Clasificación de textos de información forestal.	(Wang et al., 2021).

Piscicultura inteligente.	Aplicaciones variadas del DL.	Identificación de peces vivos, clasificación de especies, análisis de comportamiento, toma de decisiones sobre alimentación, estimación de tamaño o biomasa y predicción de calidad del agua.	(Yang et al., 2021).
Piscicultura de precisión.	Tareas de DL en piscicultura inteligente.	Regulación de factores clave de calidad del agua (salinidad, oxígeno disuelto, pH y temperatura); mantenimiento de niveles óptimos de pH y turbidez; sistemas basados en IA para mejorar el crecimiento de peces.	(Kaur et al., 2023).
Protección agrícola.	Detección de enfermedades en hojas de algodón con ML (<i>Support Vector Machine</i>) y uso de aplicaciones móviles (IoT basado en 5G) para difundir la información.	Detección de enfermedades en hojas de algodón; Monitoreo remoto de calidad del suelo; Detección de parámetros de humedad y temperatura; Aplicación de ML para análisis de imágenes; Notificación a agricultores mediante aplicación Android; Control del sistema de riego y aplicación de agroquímicos.	(Murugamani et al., 2022).

*No se dice en el resumen que pertenezca a esta disciplina agrícola, pero se obvia. N: número de publicaciones incluidas por el estudio. PR: percepción remota. ML: *machine learning* (aprendizaje automático), DL: *deep learning* (aprendizaje profundo), DNN: redes neuronales profundas, CNN: redes neuronales convolucionales, ANN: redes neuronales artificiales, NN: redes neuronales (en general).

En la siguiente tabla (ver Tabla 6) se presentan ventajas y limitaciones del uso de la IA en la agricultura (Oliveira & Silva, 2023). Entre las ventajas destacan la optimización de recursos como agua y pesticidas mediante robots y drones, predicciones de rendimiento y monitoreo eficiente con sistemas inteligentes, aumentando productividad y sostenibilidad. Las limitaciones incluyen altos costos, baja disponibilidad de soluciones cognitivas, complejidad de sistemas, barreras de difusión y comercialización, preocupaciones sobre privacidad y seguridad de datos, y resistencia al riesgo en pequeñas y medianas explotaciones agrícolas.

Tabla 6. Ventajas y limitaciones de las aplicaciones de la IA en la Agricultura.

Ventajas	Limitaciones
Los robots y los drones optimizan el uso del agua y los pesticidas y aumentan la productividad y la calidad.	Baja oferta y alto costo de soluciones cognitivas que necesitan ser más asequibles para su popularización.
Sistema de bajo costo con monitoreo remoto, portátil, liviano y fácil de usar.	Los principales desafíos identificados están relacionados con la difusión y comercialización de la tecnología desarrollada.
Promoción del manejo sostenible del riego y la fertilización en la agricultura de precisión.	Identificar parámetros como las proporciones entre el agua y los fertilizantes, su impacto en la función de producción del cultivo y los costos de aplicación de la tecnología IoT.
Reducciones de costos, prevención de catástrofes, impactos económicos positivos e interacciones hombre-máquina más seguras.	Los investigadores agrícolas, a menudo las pequeñas y medianas explotaciones, son más reacias al riesgo.
Los sistemas inteligentes utilizan aplicaciones de <i>big data</i> para predecir información sobre la cadena de suministro de alimentos.	Es necesario abordar los desafíos: propiedad y privacidad de los datos; calidad de los datos en tiempo real; procesamiento y análisis inteligentes; Integración sostenible de fuentes de <i>big data</i> .
Sistemas inteligentes que utilizan la nube para procesar, analizar y visualizar de manera precisa y rápida los datos recopilados de vehículos aéreos no tripulados.	Popularización y comercialización del sistema Agroview (software basado en la nube para analizar datos de drones).

Fuente: Modificado de (Oliveira & Silva, 2023).

La revisión sobre el uso de la IA en la agricultura destaca tanto sus ventajas como sus limitaciones.

Herramientas como aprendizaje automático, aprendizaje profundo y redes neuronales optimizan la producción de biomasa, gestión del agua, detección de enfermedades y manejo de plagas. Técnicas como percepción remota, cómputo en la nube e integración con IoT apoyan la agricultura de precisión e inteligente.

Entre las ventajas destacan la optimización de recursos, el aumento de productividad y la mejora de la calidad en cultivos. Las limitaciones incluyen altos costos, complejidad de sistemas, desafíos en difusión y comercialización, y problemas de privacidad y seguridad de datos, lo que es especialmente controversial para pequeñas y medianas explotaciones agrícolas (las más comunes en el Centro y Sur del país: de tipo agricultura de subsistencia).

Minería de textos de los artículos que tratan sobre IA y agricultura.

Para contextualizar las tendencias de la investigación en torno a la IA en la agricultura, se llevó a cabo un breve análisis de minería de textos (de 2020 a 2024) usando Scopus como base de datos y códigos modificados de minería de textos (Silge & Robinson, 2017); en RStudio con el apoyo de ChatGPT extrae información y patrones de grandes volúmenes de datos textuales no estructurados. Esta técnica se integra en el descubrimiento de conocimiento en bases de datos y utiliza el Procesamiento de Lenguaje Natural (PLN) y técnicas de IA para analizar, clasificar y predecir información. Sus aplicaciones en ciencias sociales (y de la educación) son diversas y dependen del contexto del estudio; sin embargo, enfrenta limitaciones como la necesidad de datos de calidad y la dificultad para captar contextos lingüísticos como el sarcasmo y la negación, lo que puede afectar la validez e interpretabilidad de los resultados (Mariñelarena-Dondena et al., 2017).

La fórmula que se empleó fue: TITLE-ABS-KEY (agriculture OR farming OR cultivation OR agronomy OR "crop science" OR "soil science" OR horticulture OR forestry OR agroforestry OR ((agricultu* OR farm*) AND biotechnology) OR "agricultural economics" OR "agricultural engineering" OR zootechnics OR phytotechnics OR phytotechnology OR "irrigation engineering" OR "veterinary medicine" OR "agricultural parasitology" OR ("mechanical engineering" AND (agricultur* OR farming)) OR "agricultural business" OR "agricultural management" OR agribusiness OR "crop protection" OR "agricultural entomology" OR phytopathology OR "plant breeding" OR "animal breeding") AND ("artificial intelligence" OR "machine learning" OR "deep learning")) AND PUBYEAR > 2019 AND

PUBYEAR < 2025 AND (LIMIT-TO (DOCTYPE, "ar") OR LIMIT-TO (DOCTYPE, "re")). La búsqueda fue realizada el 15 de septiembre de 2024. Se obtuvieron 19,610 publicaciones, las cuales fueron filtradas por año: se excluyeron 1,426 revisiones, 511 *preprints* y de un idioma distinto al inglés (812 casos). Con lo cual se obtuvo un total de 16,861 publicaciones originales.

Se revisó la frecuencia de publicaciones por año, nubes de palabras y su aparición en títulos (monogramas y bigramas), redes de bigramas de títulos y tendencias de palabras clave frecuentes. Un bigrama es una unidad de análisis de dos palabras consecutivas que capta relación y contexto, mientras que un monograma analiza una sola palabra (Silge & Robinson, 2017).

Se nota una tendencia al alza en las frecuencias de las publicaciones (ver Figura 1) que tratan de IA y agricultura para el periodo analizado (2020-2024); se ha observado una tendencia análoga en años previos (Zhu et al., 2018).

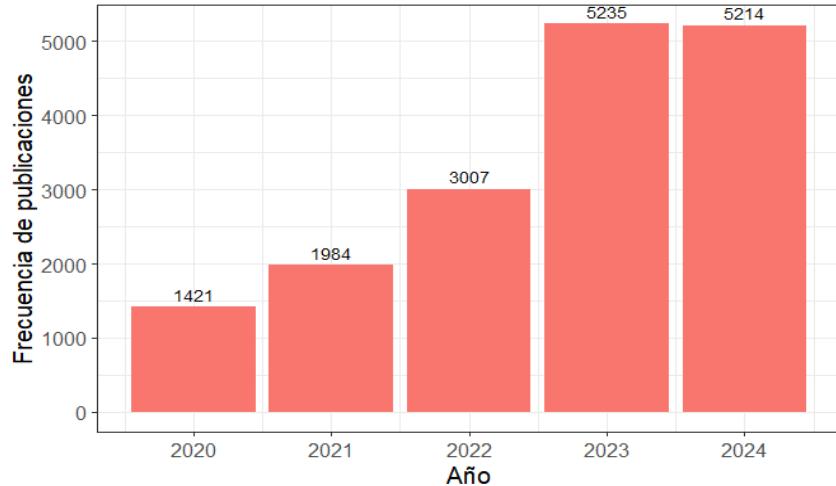


Figura 1. Frecuencia de las publicaciones por año.

En la Figura 2 (la red de bigramas de los títulos), se indica que las técnicas de IA ocupan los nodos centrales (denotados por un color más oscuro en la flecha; la dirección de la flecha indica la forma de leer los bigramas).

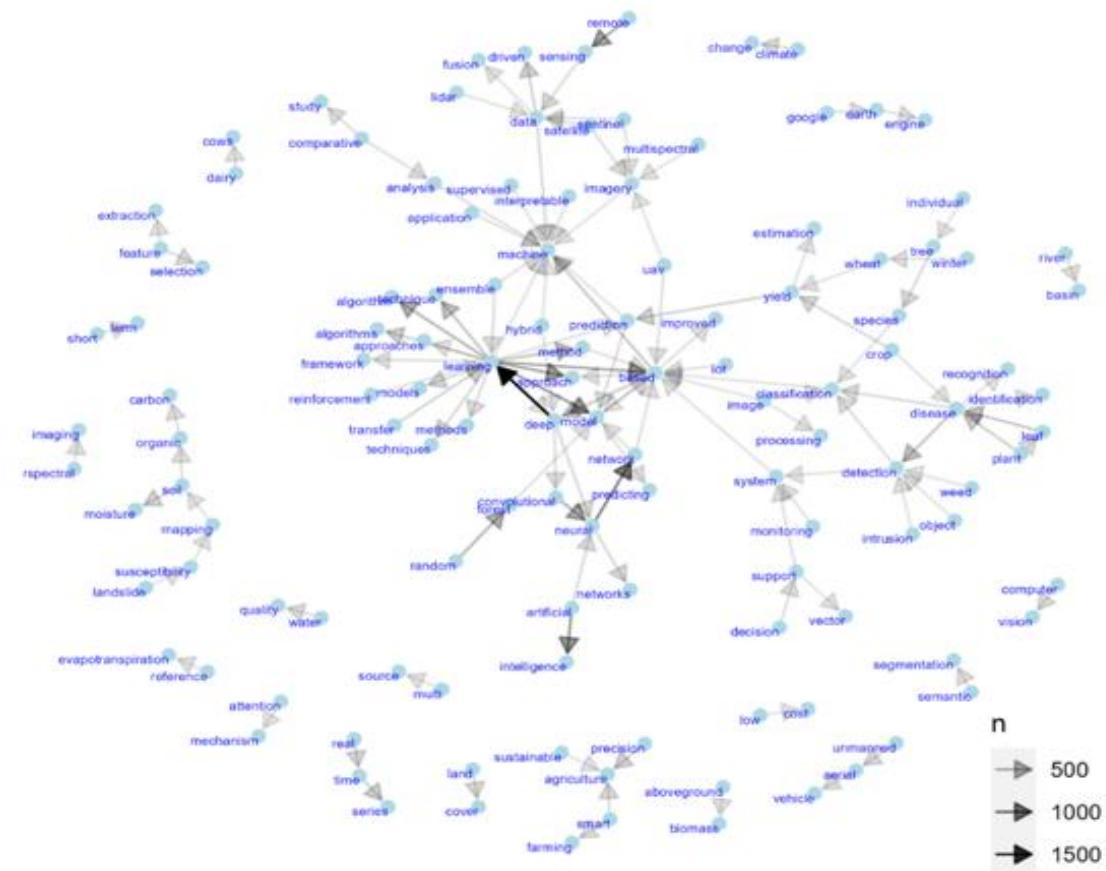


Figura 2. Red de bigramas ($n > 50$) de los títulos (tras el reemplazo de las 20 palabras plurales más comunes por sus equivalentes singulares).

Se nota, que ML es clave en la innovación agrícola, aplicándose en detección de enfermedades, clasificación de cultivos y monitoreo remoto con drones y sensores. Persisten desafíos en calidad de datos, precisión de predicciones y adaptación a contextos específicos. El uso limitado de técnicas como *reinforcement learning, ensemble models* y *transfer learning* sugiere esfuerzos por mejorar eficiencia y aplicabilidad en escenarios agrícolas.

Las nubes de palabras generadas (ver Figura 3), junto con la frecuencia de términos (Figura 4)

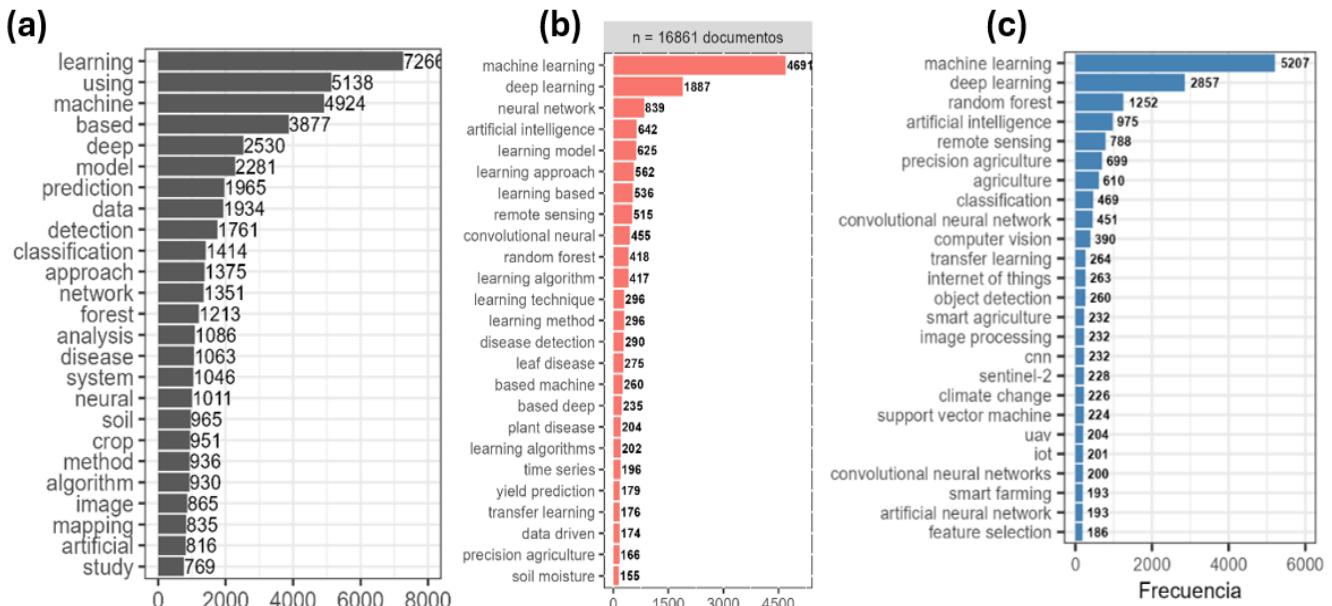


Figura 4. Frecuencia de los 25 términos más frecuentes. En (a) monogramas y (b) bigramas en los títulos (tras el remplazo de las 20 palabras plurales más comunes por sus equivalentes singulares), así como (c) en las palabras clave de los autores.

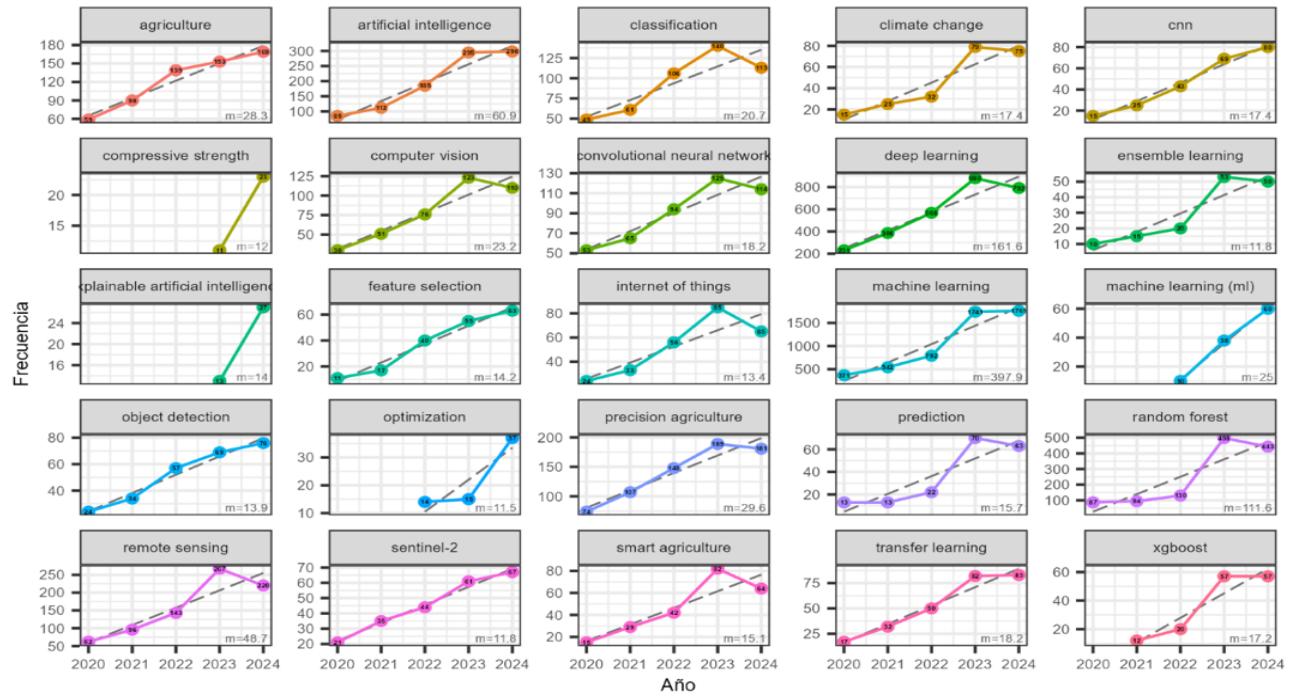


Figura 5. Tendencias de las 25 palabras clave de los autores con mayor pendiente (o mayor crecimiento) con al menos 10 registros. Fuente: elaboración propia en RStudio con datos de la búsqueda de Scopus.

, también proporcionan una visualización de los temas más destacados en la literatura. Este enfoque complementa la comprensión de la información, a pesar de las limitaciones que presentan las nubes de palabras, tales como la inestabilidad y la posible omisión de términos clave (sobre todo de las más frecuentes), por lo que es más objetivo representar la frecuencia de estas.

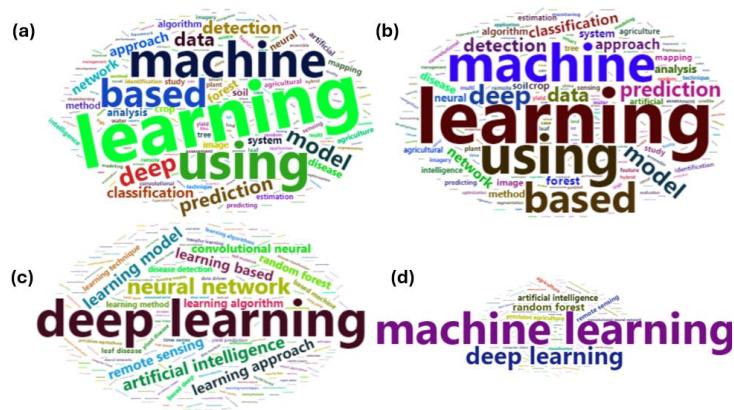


Figura 3. Nubes de palabras. De (a) monogramas dentro de títulos, (b) monogramas entre títulos, (c) bigramas en los títulos y (d) palabras clave de los autores.

En la

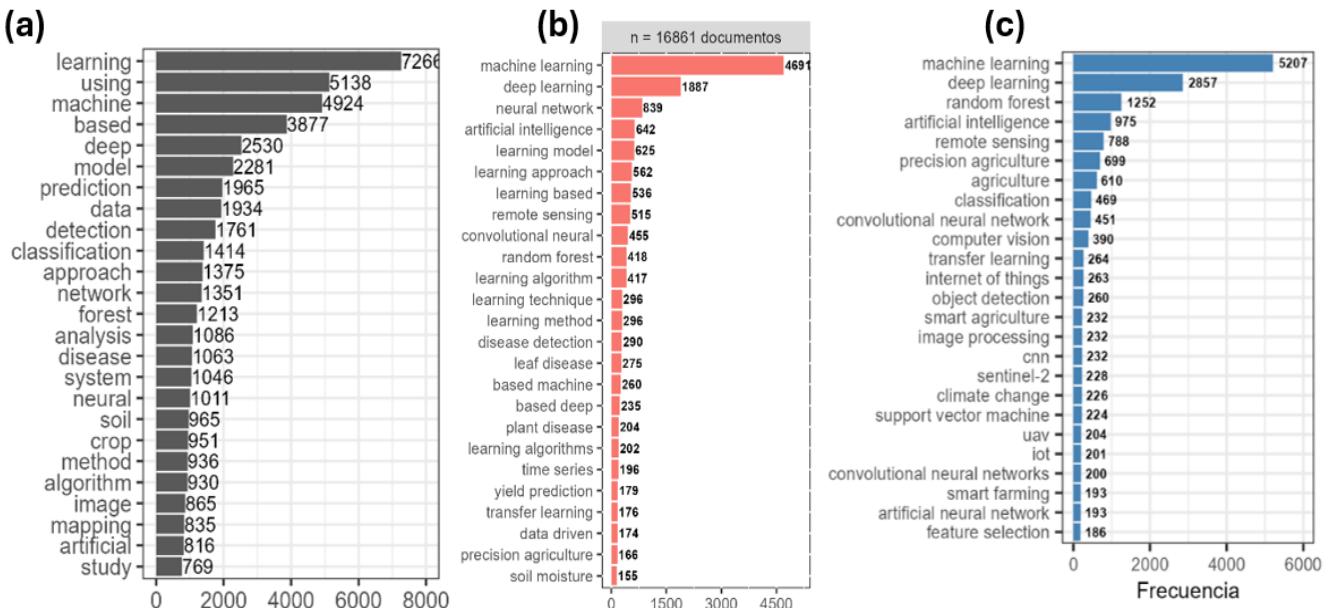


Figura 4. Frecuencia de los 25 términos más frecuentes. En (a) monogramas y (b) bigramas en los títulos (tras el remplazo de las 20 palabras plurales más comunes por sus equivalentes singulares), así como (c) en las palabras clave de los autores.

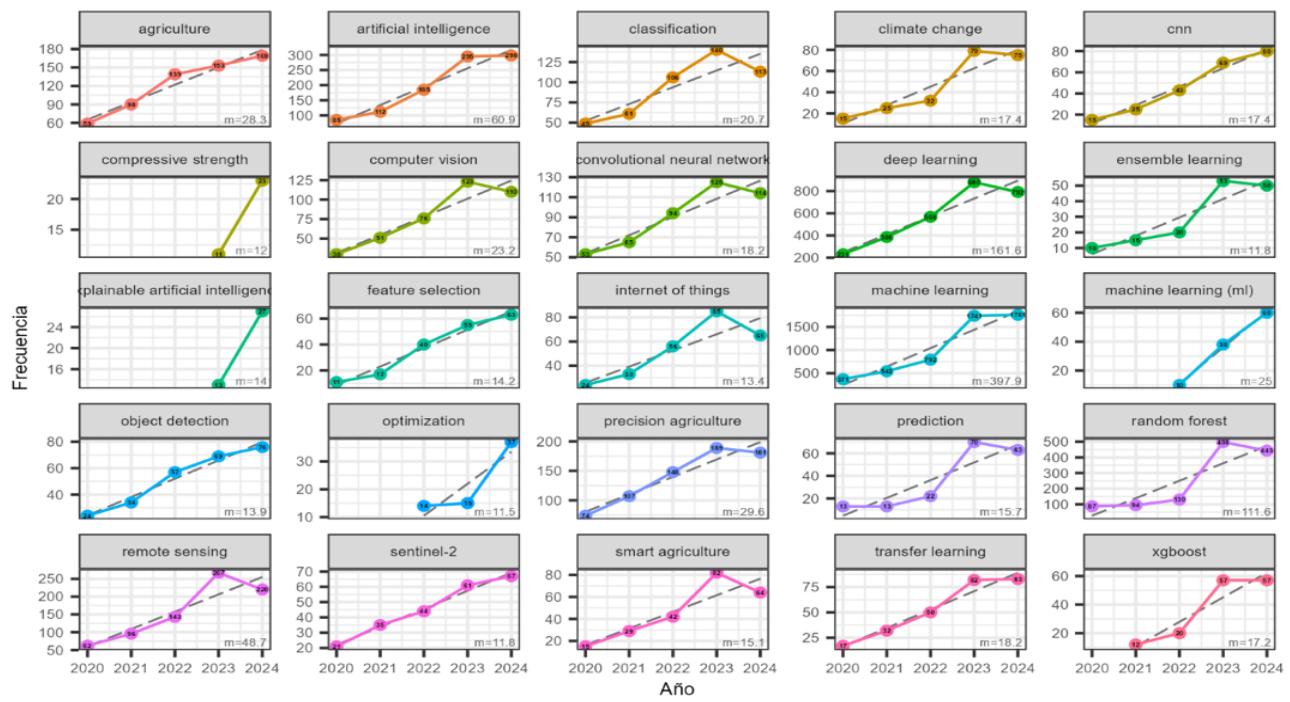


Figura 5. Tendencias de las 25 palabras clave de los autores con mayor pendiente (o mayor crecimiento) con al menos 10 registros. Fuente: elaboración propia en RStudio con datos de la búsqueda de Scopus.

(b) aparecen términos como *machine learning*, *deep learning*, y *neural network* en los primeros lugares, lo cual indica el enfoque de la aplicación de una técnica de IA específica. Términos como *remote sensing* (percepción remota) (que se refiere al uso de datos y técnicas remotas para el monitoreo agrícola), *random forests* (algoritmo de ML basado en múltiples árboles de decisión y/o regresión) y *yield prediction* son muy frecuentes.

En (c) se refleja un panorama de palabras clave orientado a la agricultura aplicada con *precision agriculture*, *classification*, *computer vision*, *transfer learning*, *internet of things*, *object detection* y *smart agriculture* como términos adicionales y muy recurrentes, lo cual indica enfoques orientados hacia la optimización de los modelos estadísticos, el rendimiento agrícola, y por tanto, la toma de decisiones basadas en tecnologías relacionadas con la IA (sistemas de riego-climatización, robots agrícolas, drones, teléfonos inteligentes, internet de las cosas, redes 5G, etc.).

El análisis de las 25 palabras clave más comunes y sus tendencias de crecimiento (Figura 5) indican áreas emergentes (y algunas en pleno crecimiento) de investigación que pueden ser relevantes para el futuro del sector.

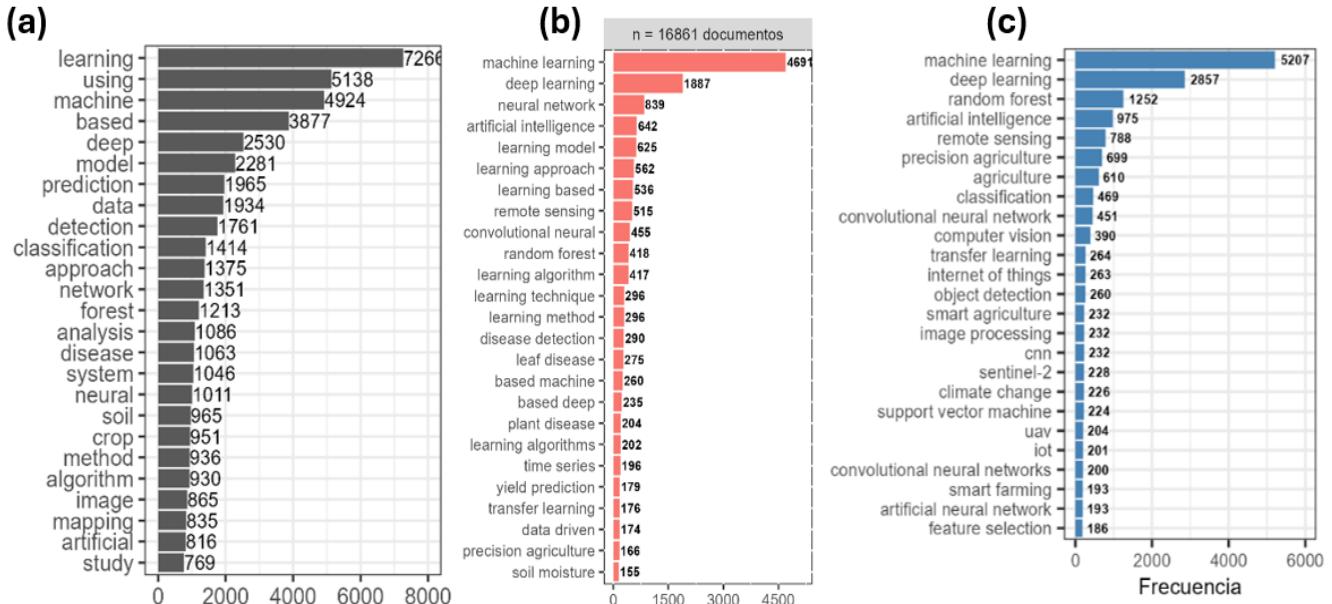


Figura 4. Frecuencia de los 25 términos más frecuentes. En (a) monogramas y (b) bigramas en los títulos (tras el remplazo de las 20 palabras plurales más comunes por sus equivalentes singulares), así como (c) en las palabras clave de los autores.

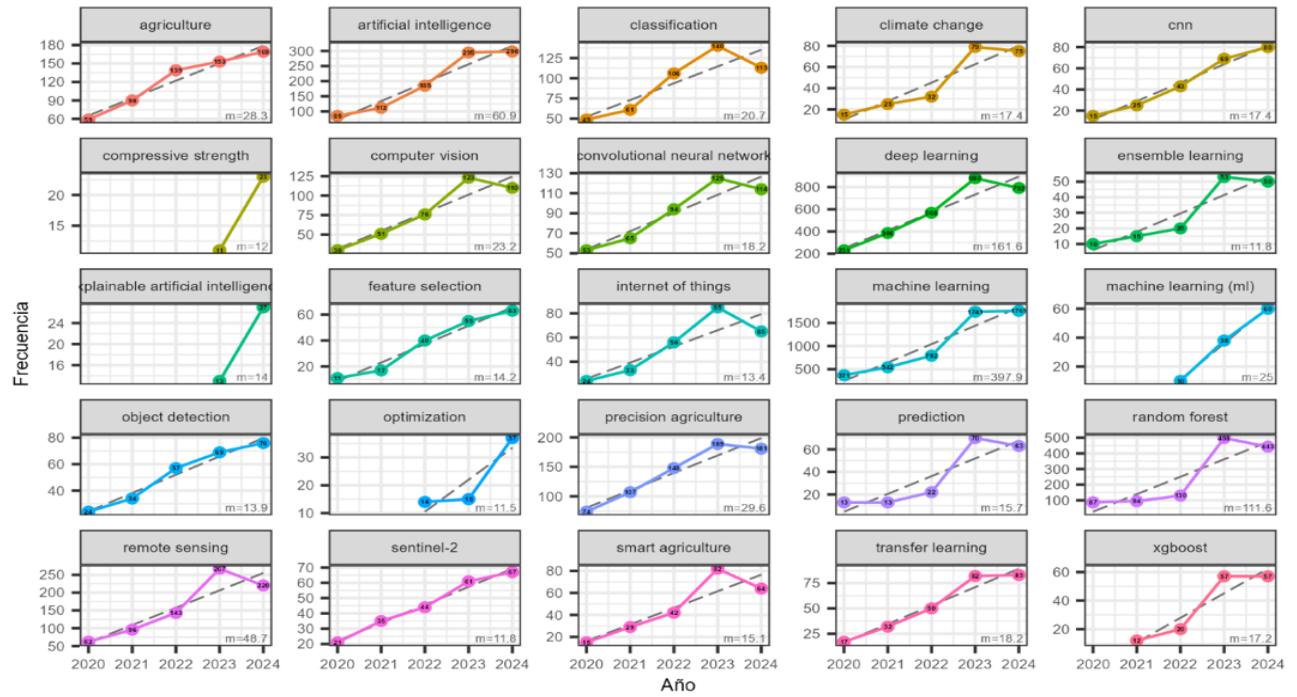


Figura 5. Tendencias de las 25 palabras clave de los autores con mayor pendiente (o mayor crecimiento) con al menos 10 registros. Fuente: elaboración propia en RStudio con datos de la búsqueda de Scopus.

ML se destaca con la mayor frecuencia (1761 casos en 2024) y la pendiente más pronunciada, mostrando su amplia adopción en estudios agrícolas. DL sigue un patrón similar con 880 palabras clave en el año 2023 y 792 en el 2024 (con menor pendiente), reflejando su popularidad en clasificación de imágenes y predicciones, mientras que IA presenta menor crecimiento y casos.

Términos de crecimiento acelerado, como *explainable AI* y *transfer learning* ganan relevancia por reducir tiempo y costos al reutilizar conocimiento. Por su parte, agricultura de precisión y percepción remota presentan una alta frecuencia y un crecimiento constante debido a que optimizan el manejo agrícola y el monitoreo de cultivos, respectivamente; estos se constituyen como nuevos paradigmas tecnológico-científicos y se retroalimentan entre sí.

Términos emergentes como *Sentinel-2*, *Explainable AI* y *Optimization*, aunque con baja frecuencia, muestran una tendencia creciente con potencial para mejorar el procesamiento e interpretación de datos en agricultura de precisión (y su aplicación con teledetección).

La sección 4 abordará cómo estas herramientas de IA pueden transformar la formación de futuros profesionales en Ciencias Agronómicas y su comprensión de nuevos paradigmas tecnológicos.

Sección 4. Aplicaciones potenciales de la IA en la educación agrícola.

En esta sección, presentaremos ejemplos de cómo las herramientas de IA utilizadas en el sector agrícola pueden integrarse en la educación superior de esta misma ciencia. Ejemplificaremos cómo la IA puede aplicarse en la enseñanza de Ciencias Agronómicas para mejorar el aprendizaje, tomando en cuenta que estas tecnologías pueden personalizar la enseñanza y facilitar el acceso a recursos educativos, fomentando la colaboración en proyectos, aunado a que pueden mejorar los procesos y modelos de análisis agrícolas; de modo, que al utilizar la IA en este contexto se pueda modernizar la enseñanza y preparar a los estudiantes para los retos tecnológicos del futuro próximo.

Aprendizaje Automático (Machine Learning, ML).

Actividad: Análisis de datos de cultivos / ganado con ML.

Disciplina: Zootecnia / fitotecnia.

Objetivo: Aprender a utilizar los modelos de ML para analizar datos de producción de cultivos / ganado y predecir rendimientos.

Descripción: Los estudiantes trabajarán con un conjunto de datos reales de cultivos (como rendimiento, calidad del suelo y clima) y usarán un software de ML para entrenar un modelo que prediga el rendimiento de la próxima cosecha.

Método: Regresión lineal (fases de entrenamiento y validación).

Herramienta: Scikit-learn (biblioteca de Python).

Teoría Educativa: Constructivismo. Se basa en el aprendizaje activo, donde los estudiantes construyen su conocimiento al trabajar directamente con los datos y el modelo.

Aprendizaje Profundo (Deep Learning, DL).

Actividad: Predicción de estrés hídrico usando imágenes térmicas.

Disciplina: Fitotecnia.

Objetivo: Aprender a usar redes neuronales profundas para analizar imágenes térmicas de cultivos y detectar signos de estrés hídrico.

Descripción: Los estudiantes trabajarán con imágenes térmicas de cultivos, utilizarán una red neuronal convolucional (CNN) para segmentar el dosel y calcular el índice de estrés hídrico. Interpretarán los resultados y sugerirán intervenciones.

Método: Redes Neuronales Convolucionales (CNN).

Herramienta: Keras (API de redes neuronales).

Teoría Educativa: Cognitivismo. Los estudiantes comprenderán cómo el procesamiento y análisis de información puede llevar a una mejor toma de decisiones en el manejo agrícola.

Redes Neuronales Artificiales.

Actividad: Predicción del microclima en invernaderos.

Disciplina: Irrigación.

Objetivo: Aprender a predecir condiciones como temperatura y humedad en un invernadero mediante ANN.

Descripción: Los estudiantes diseñarán y entrenarán una red neuronal utilizando datos históricos del microclima en invernaderos. Por último usarán el modelo para hacer predicciones y proponer mejoras en la gestión.

Método: Modelo de Perceptrón Multicapa (MLP).

Herramienta: RapidMiner (plataforma de análisis de datos).

Teoría Educativa: Teoría de la Zona de Desarrollo Próximo. Se fomenta el trabajo en pares, con estudiantes más avanzados ayudando a los menos experimentados a entender conceptos complejos de redes neuronales.

Support Vector Machines.

Actividad: Clasificación de datos de enfermedades en cultivos.

Disciplina: Fitotecnia.

Objetivo: Clasificar imágenes a través de SVM de sanas y enfermas.

Descripción: Los estudiantes recibirán un conjunto de imágenes etiquetadas y aprenderán a usar un software de SVM para entrenar un modelo que detecte enfermedades. Compararán la precisión del modelo con otros métodos de clasificación.

Método: Clasificación con SVM.

Herramienta: Cómputo en la nube (Agroview, WEKA o Google Earth Engine).

Teoría Educativa: Aprendizaje Basado en Problemas. Los estudiantes resolverán el problema de la detección de enfermedades, desarrollando habilidades técnicas y prácticas en el uso de SVM.

Internet de las Cosas (IoT).

Actividad: Control automático del riego mediante sensores IoT.

Disciplina: Irrigación.

Objetivo: Implementar un sistema de riego automatizado utilizando IoT y analizar su efectividad.

Descripción: Los estudiantes configurarán sensores de humedad en un campo y conectarán el sistema a un software de control para automatizar el riego. Evaluarán la eficiencia del sistema y propondrán mejoras.

Método: Riego automatizado con sensores.

Herramienta: Raspberry Pi (minicomputadora para el control del sistema de riego).

Teoría Educativa: Teoría del Aprendizaje Situado. Los estudiantes aprenden en un contexto auténtico, lo cual hace que el aprendizaje sea más relevante y aplicable a la práctica agrícola.

Chatbots.

Actividad 1: Uso de un chatbot para resolver problemas sobre manejo de plagas.

Disciplina: Fitotecnia / Parasitología agrícola.

Objetivo: Aprender a identificar y manejar plagas utilizando información proporcionada por un Chatbot Agrícola.

Descripción: Los estudiantes interactuarán con un chatbot especializado en agricultura para describir una plaga que encuentren en el campo, seguirán las recomendaciones dadas por el chatbot y compararán las respuestas con los métodos tradicionales de control de plagas.

Método: Interacción con un chatbot preexistente de soporte agrícola.

Herramienta: Plantix (aplicación de asesoría agrícola).

Teoría Educativa: Constructivismo. Los estudiantes construyen su propio conocimiento al experimentar y comparar las respuestas del chatbot con sus conocimientos previos y lo aprendido en clase.

Actividad 2: Monitoreo del estado nutricional de cultivos con ayuda de un chatbot.

Disciplina: Fitotecnia / Irrigación.

Objetivo: Aprender a utilizar un chatbot para evaluar el estado nutricional de un cultivo y aprender a ajustar el plan de fertilización.

Descripción: Los estudiantes interactuarán con un chatbot especializado en nutrición de cultivos para analizar deficiencias nutricionales en las plantas según la sintomatología. A partir de la recomendación del chatbot, realizarán ajustes en el plan de fertilización y verificarán los resultados en campo o simulación.

Método: Diagnóstico y consulta nutricional.

Herramienta: Crop Nutrition Advisor (chatbot especializado en nutrición vegetal).

Teoría Educativa: Aprendizaje Experiencial. Los estudiantes aplican el conocimiento obtenido a través del chatbot en situaciones reales o simuladas, lo que les permite aprender haciendo y experimentar los efectos de sus decisiones.

No hay que olvidar que otras disciplinas agronómicas no mencionadas anteriormente (incluidas aquellas de las ciencias sociales) pueden apoyarse de la IA para el análisis de sus datos y la mejora de sus procesos.

Estas actividades abarcan diferentes áreas de la IA y el aprendizaje automático, proporcionando a los estudiantes la oportunidad de aprender haciendo, resolviendo problemas reales y desarrollando habilidades prácticas esenciales para el campo de la agronomía. Además, permiten a los estudiantes familiarizarse con herramientas tecnológicas ya disponibles, como el uso de chatbots para mejorar la productividad agrícola y tomar decisiones fundamentadas en la información proporcionada por la IA.

Estos son algunos casos potenciales que muestran la variabilidad de aplicaciones prácticas en las que la IA puede usarse en el contexto de enseñanza agrícola superior, no omitiendo que existen mucho más herramientas y casos específicos potenciales.

Discusión.

El uso de la IA en la educación agrícola representa un panorama altamente prometedor, especialmente considerando la amplitud de sus usos, incluidos los previamente mencionados. Las instituciones educativas deben adaptarse con agilidad, ya que la IA tiene el potencial de mejorar los procesos de aprendizaje, personalizar la enseñanza y ampliar el acceso a recursos formativos. Estas capacidades son particularmente relevantes en el contexto actual, marcado por una creciente demanda de alimentos y

recursos naturales. En consecuencia, se vuelve indispensable formar profesionistas capaces de integrar y optimizar estas tecnologías dentro de los sistemas agronómicos y educativos enunciados.

Resulta crucial abordar los desafíos de la integración de la IA, como la brecha digital y las desigualdades tecnológicas, para evitar mayores disparidades; además, es esencial formar a los docentes para un uso efectivo de estas herramientas.

La ética en el uso de IA en la educación es imprescindible, se deben establecer marcos que garanticen el respeto a los derechos de estudiantes y profesores, además de dar los créditos a las IA con lo que se promovería un entorno más inclusivo (Nguyen et al., 2023).

CONCLUSIONES.

La integración de la IA en la educación agrícola representa una oportunidad significativa para reinventar los métodos de enseñanza y aprendizaje, para mejorar la calidad educativa y facilitar el acceso a recursos prácticos y educativos avanzados.

A través de la personalización del aprendizaje y la automatización de evaluaciones, la IA puede adaptarse a las necesidades individuales de los estudiantes, promoviendo un enfoque centrado en el alumno que fomente el éxito académico; sin embargo, es fundamental abordar las limitaciones éticas y prácticas que surgen con su implementación, así como las brechas digitales que pueden afectar la equidad en el acceso a la educación.

Para maximizar el potencial de la IA en este campo, es esencial que se realicen investigaciones continuas y que se capacite a los docentes en el uso de estas tecnologías y las aplicaciones potenciales (de la IA en la agricultura; las aquí analizadas y las que devengan en el futuro). Solo así se podrá preparar a las futuras generaciones para enfrentar los retos del sector agrícola en constante evolución, el cual debería estar alineado a una cultura ecológica para un futuro sustentable, y a la vez, que se garantice que todos los estudiantes tengan las herramientas necesarias para contribuir a la modernización y sostenibilidad de la agricultura, así como al manejo racional de los recursos naturales del país y del mundo en general.

REFERENCIAS BIBLIOGRÁFICAS.

1. Araújo, S. O., Peres, R. S., Ramalho, J. C., Lidon, F., & Barata, J. (2023). Machine Learning Applications in Agriculture: Current Trends, Challenges, and Future Perspectives. *Agronomy*, 13(12), 2976. <https://doi.org/10.3390/agronomy13122976>
2. Baceta, M. Á., Thelwall, M., & Kousha, K. (2019). Web of Science and Scopus language coverage. *Scientometrics*, 121(3), 1803-1813. <https://doi.org/10.1007/s11192-019-03264-z>
3. Bampasidou, M., Goldgaber, D., Gentimis, T., & Mandalika, A. (2024). Overcoming ‘Digital Divides’: Leveraging higher education to develop next generation digital agriculture professionals. *Computers and Electronics in Agriculture*, 224, 1-8. <https://doi.org/10.1016/j.compag.2024.109181>
4. Bellman, R. (1978). An introduction to artificial intelligence: can computers think? Boyd & Fraser Pub. Co. https://books.google.com.mx/books/about/An_Introduction_to_Artificial_Intelligen.html?id=84xQA_AAAQAAJ&redir_esc=y
5. Bolaño-García, M., & Duarte-Acosta, N. (2024). Una revisión sistemática del uso de la inteligencia artificial en la educación. *Revista Colombiana de Cirugía*, 39(1), 51-63. <https://doi.org/10.30944/20117582.2365>
6. Calderón, J. A., Apolo, N. P., Escandón, J. D., & Luján, M. G. (2024). Integración de la Inteligencia Artificial en la educación superior: un análisis bibliométrico de la literatura reciente. *Runas*, 5(10), 176. <https://doi.org/10.46652/runas.v5i10.176>
7. Escamilla-García, A., Soto-Zarazúa, G. M., Toledano-Ayala, M., Rivas-Araiza, E., & Gastélum-Barrios, A. (2020). Applications of Artificial Neural Networks in Greenhouse Technology and Overview for Smart Agriculture Development. *Applied Sciences*, 10(11), 3835. <https://doi.org/10.3390/app10113835>

8. Farjon, G., Huijun, L., & Edan, Y. (2023). Deep-learning-based counting methods, datasets, and applications in agriculture: a review. *Precision Agriculture*, 24(5), 1683–1711. <https://doi.org/10.1007/s11119-023-10034-8>
9. Gallent-Torres, C., González, A. Z., & Ortego-Hernando, J. L. (2023). El impacto de la inteligencia artificial generativa en educación superior: una mirada desde la ética y la integridad académica. *Relieve. Revista Electrónica de Investigación y Evaluación Educativa*, 29(3). <https://doi.org/10.30827/relieve.v29i2.29134>
10. García Peñalvo, F. J., Llorens-Largo, F., & Vidal, J. (2024). The new reality of education in the face of advances in generative artificial intelligence. *RIED-Revista Iberoamericana de Educación a Distancia*, 27(1), 9-39 <https://doi.org/10.5944/ried.27.1.37716>
11. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press. <https://www.deeplearningbook.org/>
12. Haykin, S. (1998). Neural Networks: A Comprehensive Foundation. Prentice Hall. https://books.google.com.mx/books/about/Neural_Networks.html?hl=es&id=bX4pAQAAQAAJ&redir_esc=y
13. Herring, M. C.; Koehler, Matthew J.; Mishra, Punya; Rosenberg, Joshua M.; Teske, J. (2016) Introduction to the Second Edition of the TPACK Handbook. En: Punya Mishra, Matthew J. Koehler (2016) Handbook of technological pedagogical content knowledge (TPACK) for educators (2nd ed., pp. 1-8). Taylor & Francis. <https://doi.org/10.4324/9781315771328>
14. Kaur, G., Adhikari, N., Krishnapriya, S., Wawale, S. G., Malik, R. Q., Zamani, A. S., Perez-Falcon, J., & Osei-Owusu, J. (2023). Recent Advancements in Deep Learning Frameworks for Precision Fish Farming Opportunities, Challenges, and Applications. *Journal of Food Quality*, 2023, 1–11. <https://doi.org/10.1155/2023/4399512>

15. Li, G., Huang, Y., Chen, Z., Chesser, G. D., Purswell, J. L., Linhoss, J., & Zhao, Y. (2021). Practices and Applications of Convolutional Neural Network-Based Computer Vision Systems in Animal Farming: A Review. *Sensors*, 21(4), 1492. <https://doi.org/10.3390/s21041492>
16. Loukatos, D., Kondoyanni, M., Kyrtopoulos, I.-V., & Arvanitis, K. (2022). Enhanced Robots as Tools for Assisting Agricultural Engineering Students' Development. *Electronics*, 11(755), 1-27. <https://doi.org/10.3390/electronics11050755>
17. Macías, M. R., Sánchez, M. L., & Marrero, D. G. (2016). La cultura agropecuaria y el uso de las TIC en la formación pedagógica. Atenas, 4(36). <https://www.redalyc.org/journal/4780/478055146019/478055146019.pdf>
18. Malanski, P. D., Dedieu, B., & Schiavi, S. (2021). Mapping the research domains on work in agriculture: A bibliometric review from Scopus database. *Journal of Rural Studies*, 81, 305–314. <https://doi.org/10.1016/j.jrurstud.2020.10.050>
19. Mariñelarena-Dondena, Luciana Errecalde, M. L., & Castro Solano, A. (2017). Extracción de conocimiento con técnicas de minería de textos aplicadas a la psicología. *Revista Argentina de Ciencias Del Comportamiento*, 9(2), 65–76. <https://www.redalyc.org/pdf/3334/333452119006.pdf>
20. Megeto, G. A. S., Silva, A. G. da, Bulgarelli, R. F., Bublitz, C. F., Valente, A. C., & Costa, D. A. G. da. (2020). Artificial intelligence applications in the agriculture 4.0. *Revista Ciência Agronômica*, 51(5). <https://doi.org/10.5935/1806-6690.20200084>
21. Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill Education. <https://www.cs.cmu.edu/~tom/files/MachineLearningTomMitchell.pdf>
22. Murugamani, C., Shitharth, S., Hemalatha, S., Kshirsagar, P. R., Riyazuddin, K., Naveed, Q. N., Islam, S., Mazher Ali, S. P., & Batu, A. (2022). Machine Learning Technique for Precision Agriculture Applications in 5G-Based Internet of Things. *Wireless Communications and Mobile Computing*, 2022, 1–11. <https://doi.org/10.1155/2022/6534238>

23. Nguyen, A., Ngo, H. N., Hong, Y., Dang, B., & Nguyen, B.-P. T. (2023). Ethical principles for artificial intelligence in education. *Education and Information Technologies*, 28(6), 4221–4241. <https://doi.org/10.1007/s10639-022-11316-w>
24. Oliveira, R. C., & Silva, R. D. (2023). Artificial Intelligence in Agriculture: Benefits, Challenges, and Trends. *Appl. Sci.*, 13(13), 7405. <https://doi.org/10.3390/app13137405>
25. Sarkar, U., Banerjee, G., & Ghosh, I. (2022). Artificial intelligence in agriculture: Application trend analysis using a statistical approach. *International Journal of Applied Science and Engineering*, 20(1), 1–8. [https://doi.org/10.6703/IJASE.202303_20\(1\).002](https://doi.org/10.6703/IJASE.202303_20(1).002)
26. Senoo, E. E. K., Anggraini, L., Kumi, J. A., Karolina, L. B., Akansah, E., Sulyman, H. A., Mendonça, I., & Aritsugi, M. (2024). IoT Solutions with Artificial Intelligence Technologies for Precision Agriculture: Definitions, Applications, Challenges, and Opportunities. *Electronics*, 13(10), 1894. <https://doi.org/10.3390/electronics13101894>
27. Silge, J., & Robinson, David. (2017). Text Mining with R: A Tidy Approach (First edit). O'REILLY ®. USA. <https://www.tidytextmining.com/>
28. Thapa, B., Lovell, S., & Wilson, J. (2023). Remote sensing and machine learning applications for aboveground biomass estimation in agroforestry systems: a review. *Agroforestry Systems*, 97(6), 1097–1111. <https://doi.org/10.1007/s10457-023-00850-2>
29. Torres, Á. F., Maigua, S. I., Carcelén, Y. M., & Loján-Ramírez, E. (2024). Inteligencia Artificial en Educación Superior: Análisis Bibliométrico. *Polo del conocimiento*, 9(9), 477-497. <https://polodelconocimiento.com/ojs/index.php/es/article/view/7946>
30. Wang, Y., Zhang, W., Gao, R., Jin, Z., & Wang, X. (2021). Recent advances in the application of deep learning methods to forestry. *Wood Science and Technology*, 55(5), 1171–1202. <https://doi.org/10.1007/s00226-021-01309-2>

31. Worthing, K. A., MadeleineRobert, & Šlapeta, J. (2024). Surveyed veterinary students in Australia find ChatGPT practical and relevant while expressing no concern about artificial intelligence replacing veterinarians. *Veterinary Record Open*, 11(1), e280. <https://doi.org/10.1002/vro2.80>
32. Yang, X., Zhang, S., Liu, J., Gao, Q., Dong, S., & Zhou, C. (2021). Deep learning for smart fish farming: Applications, opportunities and challenges. *Reviews in Aquaculture*, 13(1), 66–90. <https://doi.org/10.1111/raq.12464>
33. Yerlikaya, N., & Kúçúkaslan, Ö. (2024). Views of veterinary faculty students on the concept of Artificial Intelligence and its use in Veterinary Medicine practices: An example of Ankara University Faculty of Veterinary Medicine. *Research Article*, 71(3), 249-257. <https://doi.org/10.33988/auvfd.1221352>
34. Zhu, J., & Weishu, L. (2020). A tale of two databases: the use of Web of Science and Scopus in academic papers. *Scientometrics*, 123(1), 321-335. <https://doi.org/10.1007/s11192-020-03387-8>
35. Zhu, N., Liu, X., Liu, Z., Hu, K., Wang, Y., Tan, J., Huang, M., Zhu, Q., Ji, X., Jiang, Y., & Guo, Y. (2018). Deep learning for smart agriculture: Concepts, tools, applications, and opportunities. *International Journal of Agricultural and Biological Engineering*, 11(4), 32–44. <https://doi.org/10.25165/j.ijabe.20181104.4475>

BIBLIOGRAFÍA.

1. Addas, A., Tahir, M., & Ismat, N. (2023). Enhancing Precision of Crop Farming towards Smart Cities: An Application of Artificial Intelligence. *Sustainability*, 16(1), 355. <https://doi.org/10.3390/su16010355>
2. Chen, C.-H., Kung, H.-Y., & Hwang, F.-J. (2019). Deep Learning Techniques for Agronomy Applications. *Agronomy*, 9(3), 142. <https://doi.org/10.3390/agronomy9030142>

3. Cravero, A., & Sepúlveda, S. (2021). Use and Adaptations of Machine Learning in Big Data—Applications in Real Cases in Agriculture. *Electronics*, 10(5), 552. <https://doi.org/10.3390/electronics10050552>
4. Mahmud, M. S., Zahid, A., Das, A. K., Muzammil, M., & Khan, M. U. (2021). A systematic literature review on deep learning applications for precision cattle farming. *Computers and Electronics in Agriculture*, 187, 106313. <https://doi.org/10.1016/j.compag.2021.106313>
5. Mohan, P., & Patil, K. (2018). Deep Learning Based Weighted SOM to Forecast Weather and Crop Prediction for Agriculture Application. *International Journal of Intelligent Engineering and Systems*, 11(4), 167–176. <https://doi.org/10.22266/ijies2018.0831.17>
6. Nitin, & Bal Gupta, S. (2023). Artificial Intelligence in Smart Agriculture: Applications and Challenges. *Current Applied Science and Technology*, 24(2), e0254427. <https://doi.org/10.55003/cast.2023.254427>
7. Nturambirwe, J. F. I., & Opara, U. L. (2020). Machine learning applications to non-destructive defect detection in horticultural products. *Biosystems Engineering*, 189, 60–83. <https://doi.org/10.1016/j.biosystemseng.2019.11.011>
8. Opara, I. K., Opara, U. L., Okolie, J. A., & Fawole, O. A. (2024). Machine Learning Application in Horticulture and Prospects for Predicting Fresh Produce Losses and Waste: A Review. *Plants*, 13(9), 1200. <https://doi.org/10.3390/plants13091200>
9. Peng, W., & Karimi Sadaghiani, O. (2023). A review on the applications of machine learning and deep learning in agriculture section for the production of crop biomass raw materials. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 45(3), 9178–9201. <https://doi.org/10.1080/15567036.2023.2232322>

10. Pokhariyal, S., Patel, N. R., & Govind, A. (2023). Machine Learning-Driven Remote Sensing Applications for Agriculture in India—A Systematic Review. *Agronomy*, 13(9), 2302. <https://doi.org/10.3390/agronomy13092302>
11. Kneissl, S. M., Tichy, A., & Mitlacher, S. F. (2023). Flipped Classroom to Facilitate Deeper Learning in Veterinary Undergraduate Students: An Educational Change Pilot Study Limited to the Imaging Module Bones. *Animals*, 13(1540), 2-12. <https://doi.org/10.3390/ani13091540>
12. Sharma, A., Jain, A., Gupta, P., & Chowdary, V. (2021). Machine Learning Applications for Precision Agriculture: A Comprehensive Review. *IEEE Access*, 9, 4843–4873. <https://doi.org/10.1109/ACCESS.2020.3048415>
13. Then, S.-M., Kokolski, M., Mbaki, Y., Merrick, D., & Anderson, S. (2022). Un enfoque colaborativo internacional para el aprendizaje de la histología utilizando un microscopio virtual. *Revista de Medicina Veterinaria Serie C: Anatomía, Histología, Embriología*, 1(52), 21-30. <https://doi.org/10.1111/ahe.12888>
14. Tripodi, P., Nicastro, N., & Pane, C. (2022). Digital applications and artificial intelligence in agriculture toward next-generation plant phenotyping. *Crop & Pasture Science*, 74(6), 597–614. <https://doi.org/10.1071/CP21387>
15. 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. *Remote Sensing*, 13(3), 531. <https://doi.org/10.3390/rs13030531>
16. Zhou, Z., Majeed, Y., Diverres Naranjo, G., & Gambacorta, E. M. T. (2021). Assessment for crop water stress with infrared thermal imagery in precision agriculture: A review and future prospects for deep learning applications. *Computers and Electronics in Agriculture*, 182, 106019. <https://doi.org/10.1016/j.compag.2021.106019>

DATOS DE LOS AUTORES.

- 1. Luis Arturo Cervantes-Gómez.** Maestro en Educación. Doctorante en Ciencias en Educación Agrícola Superior de la Universidad Autónoma Chapingo, México. E-mail: arturcervago@outlook.com
Orcid: <https://orcid.org/0009-0005-7564-2133>
- 2. Antonio Fidel Santos-Hernández.** Maestro en Ciencias Forestales. Doctorante en Ciencias en Agricultura Multifuncional para el Desarrollo Sostenible de la Universidad Autónoma Chapingo, México. Email: antoniosantos196@gmail.com Orcid: <https://orcid.org/0000-0001-9142-0964>
- 3. Alejandra Sahagún-García.** Doctora en Ciencias en Educación Agrícola Superior. Adscripción en el Departamento de Fitotecnia de la Universidad Autónoma Chapingo donde es Profesora-Investigadora, México. E-mail: asahagung@chapingo.mx Orcid: <https://orcid.org/0000-0003-1250-7151> (autora de correspondencia).

RECIBIDO: 8 de septiembre del 2025.

APROBADO: 20 de octubre del 2025.