

## Inteligencia artificial en la educación agrícola superior en México: uso, percepción y adaptación en el contexto de la Agricultura 4.0

*Artificial intelligence in higher agricultural education in Mexico: use, perception, and adaptation in the context of agriculture 4.0*

**Dr. Jesús Ignacio Reyes-Díaz**  
Unidad Académica de Capulhuac,  
Universidad Tecnológica del Valle de Toluca  
[jesus.reyes@utvtol.edu.mx](mailto:jesus.reyes@utvtol.edu.mx)  
<https://orcid.org/0000-0001-9234-6575>

**Recepción:** 22/04/2026

**Aceptación:** 30/09/2026

**Publicación:** 02/10/2026

### Resumen

El presente estudio analiza el uso, la percepción y el grado de adaptación de la inteligencia artificial (IA) en la educación agrícola de nivel superior en México, con el objetivo de identificar brechas, oportunidades y áreas estratégicas de intervención. Se empleó una revisión sistemática de literatura con enfoque cualitativo-interpretativo, basada en fuentes académicas indexadas y complementada con análisis documental de informes institucionales y estudios de caso en universidades agrícolas del país. Los resultados evidencian una adopción acelerada de herramientas de IA generativa en el ámbito universitario, tanto por estudiantes como por docentes; no obstante, en los programas de formación agrícola persisten limitaciones significativas, como un uso predominantemente instrumental, una comprensión superficial de sus alcances y una integración curricular aún incipiente. Asimismo, se observa una marcada disparidad entre el ámbito educativo y el sector productivo, donde la incorporación de tecnologías avanzadas sigue siendo limitada, particularmente en contextos rurales. Se concluye que la educación agrícola en México se encuentra en una fase de transición hacia el paradigma de la Agricultura 4.0, caracterizada por avances desiguales y desafíos estructurales persistentes. En este contexto, resulta imprescindible

fortalecer la formación de capital humano, promover una integración curricular estratégica de la IA y consolidar políticas públicas orientadas a reducir la brecha digital, a fin de evitar la profundización de las desigualdades en el sector agroalimentario. Adicionalmente, se propone una estructura orientativa de integración curricular de la IA y un perfil de egreso para el ingeniero agrónomo, derivados de la síntesis documental y leídos desde perspectivas críticas (colonialismo digital, justicia algorítmica y soberanía tecnológica).

**Palabras clave:** inteligencia artificial; educación agrícola; Agricultura 4.0; brecha digital rural; México; soberanía tecnológica.

### Abstract

This study analyzes the use, perception, and level of adaptation of artificial intelligence (AI) in higher agricultural education in Mexico, with the aim of identifying gaps, opportunities, and strategic areas for intervention. A systematic literature review was conducted using a qualitative-interpretative approach, based on indexed academic sources and complemented by documentary analysis of institutional reports and case studies from agricultural universities in the country. The findings reveal an accelerated adoption of generative AI tools in the university context, among both students and faculty. However, significant limitations persist within agricultural education programs, including predominantly instrumental use, a superficial understanding of their scope, and still incipient curricular integration. Additionally, a marked disparity is observed between the educational sphere and the productive sector, where the adoption of advanced technologies remains limited, particularly in rural contexts. It is concluded that agricultural education in Mexico is undergoing a transition toward the Agriculture 4.0 paradigm, characterized by uneven progress and persistent structural challenges. In this context, it is essential to strengthen human capital development, promote a strategic curricular integration of AI, and consolidate public policies aimed at reducing the digital divide to prevent the deepening of inequalities within the agri-food sector. Additionally, an indicative structure for integrating AI into the curriculum and a graduate profile for agronomy engineers are proposed, derived from the documentary synthesis and read through critical perspectives (digital colonialism, algorithmic justice, and technological sovereignty).

Jesús Ignacio Reyes-Díaz

Inteligencia artificial en la educación agrícola superior en México: uso, percepción y adaptación en el contexto de la Agricultura 4.0.

**Keywords:** artificial intelligence; agricultural education; Agriculture 4.0; rural digital divide; Mexico; technological sovereignty.

## 1. Introducción

La educación agrícola en México ocupa un lugar estratégico dentro del sistema de educación superior nacional, no solo por su vinculación histórica con la reforma agraria y el desarrollo rural, sino porque en la actualidad enfrenta la presión simultánea del cambio climático, la inseguridad alimentaria y la Cuarta Revolución Industrial. Instituciones como la Universidad Autónoma Chapingo (UACH), la Universidad Autónoma Agraria Antonio Narro (UAAAN), los Institutos Tecnológicos Agropecuarios y los programas de agronomía de diversas Universidades Estatales forman a la mayoría de los profesionales del sector agroalimentario del país. En un contexto donde apenas el 30 % de las unidades de producción agropecuaria mexicanas incorpora tecnologías avanzadas (INEGI, 2024; SADER, 2024), la formación universitaria se convierte en un espacio crítico para cerrar la brecha tecnológica.

La irrupción de la inteligencia artificial generativa (IAG), y en particular de ChatGPT a partir de noviembre de 2022, ha reconfigurado aceleradamente los procesos de enseñanza y aprendizaje en todo el mundo. En México, la Encuesta Nacional sobre Usos y Percepciones de la Inteligencia Artificial Generativa en la Educación Superior, aplicada por la Secretaría de Educación Pública (SEP, 2026) a más de 1.5 millones de estudiantes y 166 mil docentes de 2 900 instituciones, reveló que ocho de cada diez universitarios emplean IAG de manera cotidiana, principalmente para redactar textos, realizar tareas y apoyar la investigación. Este hallazgo, por su magnitud muestral, posiciona al estudio mexicano como uno de los ejercicios diagnósticos más amplios documentados a nivel internacional sobre este fenómeno.

No obstante, los estudios focalizados muestran que la masificación del uso no equivale a una apropiación crítica. Chao-Rebolledo y Rivera-Navarro (2024) encontraron, en una muestra de estudiantes y docentes universitarios mexicanos, que predomina una comprensión superficial de la IA y una escasa formación ética sobre su aplicación. En el caso específico de la educación agrícola, esta situación cobra particular relevancia, pues los futuros ingenieros agrónomos deberán integrar la IA en actividades como la agricultura de precisión, el análisis predictivo de cultivos, la

detección temprana de plagas y el manejo de *big data* agrícola; es decir, competencias que exceden con creces la simple redacción asistida (Liakos *et al.*, 2018).

Ante este escenario, surge una tensión medular: mientras el campo mexicano carece de conectividad, infraestructura y capacitación digital (CEPAL, FAO e IICA, 2021), la educación agrícola comienza a incorporar la IA en sus planes de estudio de manera incipiente, como ejemplifica la creación de la Ingeniería en Inteligencia Artificial en Agricultura (IIAA) por la UACH en 2025 (Universidad Autónoma Chapingo, 2025). La contradicción es evidente: se forman profesionales con competencias propias de la Agricultura 4.0 para un sector productivo todavía anclado en prácticas 2.0. Este artículo se propone, en consecuencia, analizar críticamente, mediante una revisión sistemática de literatura complementada con análisis documental, el uso, la percepción y el grado de adaptación de la inteligencia artificial en la educación agrícola superior en México, a fin de derivar lineamientos para su integración en el plan de estudios y en el perfil de egreso de los ingenieros agrónomos.

El objeto de estudio es la incorporación de la IA en la formación de ingenieros agrónomos en las instituciones de educación superior agrícola de México, entendida como un proceso con tres dimensiones analíticas (uso, percepción y adaptación) y como un problema de diseño curricular: qué competencias, contenidos y experiencias debe integrar un plan de estudios para que el perfil de egreso responda a la Agricultura 4.0 sin perder pertinencia territorial, criterio ético ni soberanía tecnológica. Cabe precisar que la evidencia empírica analizada es de carácter secundario, es decir, proviene de estudios, encuestas e informes previamente publicados y no de un levantamiento primario de datos; la sección 5.2 plantea la agenda empírica complementaria.

## **2. Marco teórico**

### **2.1 La inteligencia artificial en educación**

El concepto de inteligencia artificial en educación (IAEd) se ha consolidado en la última década como un campo interdisciplinario que integra aportes de las ciencias de la computación, la pedagogía, la psicología y la teoría del aprendizaje (Holmes *et al.*, 2019). Para el análisis del caso mexicano, resultan particularmente relevantes tres dimensiones analíticas.

**Jesús Ignacio Reyes-Díaz**

**Inteligencia artificial en la educación agrícola superior en México: uso, percepción y adaptación en el contexto de la Agricultura 4.0.**

Una de ellas es el aprendizaje personalizado. Los sistemas basados en IA permiten adaptar contenidos, ritmos y trayectorias al perfil cognitivo de cada estudiante mediante algoritmos de *machine learning* que analizan patrones de desempeño (Luckin y Cukurova, 2019). En América Latina, no obstante, la personalización se ha desarrollado de manera limitada, restringida a plataformas adaptativas comerciales como Duolingo, Khan Academy o Coursera, y su penetración en programas agrícolas es marginal (Martínez-Pérez y Rementería-Fuentes, 2025).

Otra dimensión relevante es la tutoría inteligente. Los sistemas tutoriales inteligentes (ITS) y los *chatbots* educativos han evolucionado hacia asistentes conversacionales de propósito general como ChatGPT, Gemini, Claude y DeepSeek, que hoy actúan como tutores disponibles 24/7 para millones de universitarios (Holmes *et al.*, 2019). La Encuesta Nacional de la SEP (2026) reveló que más de 91 000 jóvenes mexicanos recurren a estas herramientas también como apoyo emocional, lo que evidencia una sustitución parcial de figuras humanas por sistemas automatizados, con implicaciones éticas aún poco exploradas (UNESCO, 2021).

La automatización educativa constituye una tercera dimensión. La IA también se utiliza para automatizar evaluaciones, retroalimentación, detección de plagio y análisis de competencias. Ramírez Martinell y Casillas Alvarado (2024) advierten, sin embargo, que esta automatización genera tensiones cuando los docentes carecen de formación suficiente para interpretar los resultados o rediseñar sus instrumentos evaluativos, lo que Morán-Ortega *et al.* (2024) conceptualizan como una barrera pedagógica emergente.

## 2.2 La inteligencia artificial en el sector agrícola

En el marco de la transformación digital del sector agroalimentario, la integración de tecnologías como la inteligencia artificial, el internet de las cosas (IoT) y los sistemas de análisis de datos ha configurado un nuevo paradigma productivo y formativo conocido como Agricultura 4.0 (Mooney, 2020). Este enfoque no solo impacta la eficiencia y sostenibilidad de los sistemas agrícolas, sino que también redefine las competencias profesionales requeridas y la forma en que se genera, procesa y aplica el conocimiento en el campo. En este contexto, resulta fundamental examinar tres ejes clave que estructuran esta transición tecnológica.

Un primer eje corresponde a la agricultura de precisión. Basada en la integración de GPS, sensores, drones e imágenes satelitales con algoritmos de IA, esta aproximación optimiza el uso de agua,

fertilizantes y pesticidas a nivel de cada unidad espacial del cultivo (Liakos *et al.*, 2018; Ibarra, 2022). La revisión exhaustiva de Liakos *et al.* (2018) identifica cuatro grandes áreas de aplicación del aprendizaje automático en agricultura: manejo de cultivos (predicción de rendimiento, detección de enfermedades y malezas, calidad del cultivo, reconocimiento de especies), manejo ganadero, gestión del agua y gestión del suelo. Trabajos recientes sobre sensores UAV combinados con técnicas de *machine learning* y *deep learning* documentan una tendencia creciente en estimaciones de parámetros agronómicos clave como el índice de área foliar, el contenido de nitrógeno y el rendimiento (Romero-Hernández *et al.*, 2024). En México, iniciativas de cooperación Sur-Sur como el proyecto de transformación digital e innovación en la agricultura, implementado por la FAO en Michoacán, han comenzado a sistematizar experiencias de digitalización rural (FAO, 2023).

El *big data* agrícola constituye un segundo eje. La masificación de datos provenientes del IoT, la teledetección y la telemetría de maquinaria exige profesionales capaces de traducir información en decisiones rentables. Si bien la digitalización de la agricultura en América Latina y el Caribe es incipiente, comienza a acelerarse de forma inevitable (CEPAL, FAO e IICA, 2021). No obstante, su aprovechamiento en México sigue limitado debido a la fragmentación de la tenencia de la tierra: más de cuatro millones de productores operan en parcelas menores a cinco hectáreas (SADER, 2024).

Un tercer eje se refiere a la formación de capital humano. La transición hacia la Agricultura 4.0 requiere perfiles híbridos con competencias en agronomía, programación, análisis de datos y pensamiento sistémico. La creación de la Ingeniería en Inteligencia Artificial en Agricultura (IIAA) en la UACH, con ocho semestres que combinan programación, lógica, análisis de datos y sostenibilidad, representa el primer programa de su tipo documentado en América Latina (Universidad Autónoma Chapingo, 2025).

### **2.3 La educación agrícola en México: tensiones estructurales**

El análisis de la incorporación de tecnologías emergentes en la educación agrícola mexicana no puede desvincularse de las condiciones estructurales que históricamente han limitado su desarrollo y adaptación. Factores como las desigualdades territoriales, la limitada infraestructura tecnológica y la débil articulación entre políticas públicas y necesidades del sector rural configuran un

**Jesús Ignacio Reyes-Díaz**

**Inteligencia artificial en la educación agrícola superior en México: uso, percepción y adaptación en el contexto de la Agricultura 4.0.**

escenario complejo para la implementación efectiva de innovaciones como la inteligencia artificial (Nagel, 2012). En este sentido, resulta pertinente examinar tres dimensiones críticas que condicionan este proceso.

Una dimensión fundamental es la de los retos estructurales. La educación agrícola mexicana arrastra problemas históricos: baja matrícula en agronomía, envejecimiento del cuerpo docente, desactualización curricular y escasa vinculación con el sector productivo (ANUIES, 2024). La incorporación de la IA se superpone a estas tensiones sin resolverlas.

A esta problemática se suma la brecha digital rural. Los hogares rurales mexicanos presentan niveles de acceso a internet de banda ancha significativamente inferiores a los urbanos (INEGI, 2024). El Índice de Desarrollo Digital Estatal muestra diferencias pronunciadas entre la Ciudad de México —entidad líder con 217 de 300 puntos— y estados como Chiapas, Oaxaca o Guerrero, donde se concentra la mayor población agrícola de subsistencia (Centro México Digital, 2021).

Finalmente, las políticas educativas y tecnológicas representan una tercera dimensión crítica. En enero de 2025, la SEP y la UNESCO convocaron un diálogo nacional sobre IA en educación, alineado con la Recomendación de la UNESCO sobre la Ética de la IA (UNESCO, 2021) y el Consenso de Beijing (UNESCO, 2019). En noviembre de 2025 se presentaron 10 acciones para el uso ético y crítico de la IAG en educación superior, que incluyen perspectiva de género, bienestar estudiantil y soberanía tecnológica (SEP, 2026). Sin embargo, estas políticas no distinguen suficientemente las necesidades específicas de las instituciones agrícolas en contextos rurales (Martínez-Pérez y Rementería-Fuentes, 2025).

## **2.4 Perspectivas críticas complementarias: tecnología, colonialismo digital, justicia algorítmica e innovación rural en América Latina**

Las tres dimensiones analíticas (uso, percepción y adaptación) permiten describir qué ocurre con la IA en la educación agrícola, pero no explican por sí solas por qué ocurre de manera desigual ni a quién beneficia. Para ello se incorporan cuatro perspectivas complementarias que, en el análisis posterior, funcionan como lentes interpretativos (Figura 2).

Los estudios críticos de tecnología cuestionan la idea de que los artefactos técnicos son neutrales. Winner (1980) sostiene que ciertos diseños tecnológicos incorporan formas de poder y autoridad, y Feenberg (2002) propone una teoría crítica de la tecnología según la cual el diseño técnico es

socialmente construido y, por tanto, susceptible de intervención democrática por parte de quienes resultan afectados. En el ámbito agroalimentario, Rotz *et al.* (2019) examinan desde las ciencias sociales críticas las tecnologías digitales y los sistemas de *big data*, identifican como asuntos críticos la propiedad y el control de los datos, la producción de las tecnologías y la seguridad de los datos, y advierten que las discusiones de política siguen siendo tecnocéntricas y prestan poca atención a cómo estas tecnologías pueden apoyar a los sistemas agroecológicos. Klerkx *et al.* (2019), por su parte, documentan una literatura social dispersa sobre agricultura digital y plantean una agenda de investigación sobre sus dimensiones sociales, económicas e institucionales. Desde esta perspectiva, incorporar la IA al currículo agrícola no es un acto técnico neutral, sino una decisión sobre qué saberes, intereses y actores se privilegian.

La literatura sobre colonialismo digital sostiene que el control de la infraestructura digital por parte de unas pocas corporaciones reproduce relaciones históricas de dependencia entre el Norte y el Sur globales. Kwet (2019) plantea que las multinacionales estadounidenses ejercen un control imperial en el nivel de la arquitectura del ecosistema digital (*software*, *hardware* y conectividad), mientras que Couldry y Mejias (2019) describen el colonialismo de datos como la apropiación de la vida social mediante su conversión en datos al servicio del capital. Birhane (2020) señala, para el caso africano, que las tecnologías concebidas desde perspectivas occidentales se importan con escasa regulación y dejan a los países dependientes de *software* e infraestructura extranjeros, y Mohamed *et al.* (2020) proponen una IA decolonial basada en una práctica técnica crítica, la búsqueda de tutelas y pedagogías inversas y la renovación de comunidades afectivas y políticas. Estas ideas dialogan con la crítica de Mooney (2020) al poder corporativo en la cadena alimentaria y con la preocupación de la UNESCO (2023) por la soberanía sobre los datos indígenas, y ofrecen un marco para interpretar la dependencia de herramientas de IA generativa que procesan datos educativos y agrícolas en servidores extranjeros.

La justicia algorítmica se ocupa de las disparidades que los sistemas automatizados producen o amplifican. Noble (2018) analiza cómo los motores de búsqueda pueden reforzar prejuicios raciales, Buolamwini y Gebru (2018) documentan disparidades interseccionales de precisión en sistemas comerciales de clasificación de género a partir de rostros y Benjamin (2019) muestra cómo ciertas tecnologías reproducen desigualdades existentes mientras se presentan como objetivas o progresistas. Aunque esta literatura se ha desarrollado sobre todo en torno a sistemas

de búsqueda y reconocimiento facial, su lógica (desempeños dispares y sesgos derivados de datos no representativos) es transferible, por analogía, a los modelos agronómicos entrenados con datos de agriculturas industriales del norte global, que pueden resultar inadecuados para la agricultura campesina y de temporal (Martínez-Pérez y Rementeria-Fuentes, 2025). En la formación de ingenieros agrónomos, la justicia algorítmica implica aprender a preguntar con qué datos fue entrenado un modelo, para qué contextos es válido y quién asume el costo de sus errores.

Finalmente, la literatura sobre innovación tecnológica en contextos rurales subraya que la adopción depende de condiciones previas que no se distribuyen de manera homogénea en el territorio. El informe de la FAO sobre tecnologías digitales en la agricultura y las áreas rurales (Trendov *et al.*, 2019) identifica la infraestructura de redes, la alfabetización digital y las políticas habilitantes como condiciones básicas de la transformación digital, y las habilidades digitales de la población rural como un habilitador clave. Para América Latina, los diagnósticos de CEPAL, FAO e IICA (2021) y de Nagel (2012) identifican barreras de conectividad, infraestructura y capacitación digital en las áreas rurales. Esta perspectiva obliga a pensar la innovación no como transferencia de paquetes tecnológicos, sino como un proceso situado, que articula saberes campesinos, infraestructura disponible y capacidades locales, y que debe evaluarse por su efecto sobre las desigualdades territoriales.

Las cuatro perspectivas convergen en la noción de soberanía tecnológica empleada en este artículo: la capacidad de las instituciones, las comunidades y los productores para decidir qué tecnologías adoptar, con qué datos y bajo qué condiciones. Su lectura conjunta permite examinar las desigualdades territoriales no solo como un rezago de acceso, sino como resultado de relaciones de poder en el diseño, la propiedad y el uso de la tecnología.


### 3. Metodología

El estudio adopta un enfoque cualitativo-interpretativo mediante una revisión sistemática de literatura conducida conforme a los lineamientos PRISMA 2020 (Page *et al.*, 2021). La pregunta de investigación rectora es: ¿cómo se usan, se perciben y se adaptan las herramientas de inteligencia artificial en la educación agrícola universitaria en México durante el periodo 2019-2026? Para responderla, se definieron tres dimensiones analíticas —uso, percepción y

adaptación— que estructuran tanto el proceso de codificación como la presentación posterior de resultados (véase sección 4).

La búsqueda se ejecutó en las bases de datos Scopus, Web of Science, SciELO, Redalyc, Dialnet y Google Scholar, empleando combinaciones booleanas de los descriptores: "inteligencia artificial" AND ("educación agrícola" OR "agronomía" OR "agricultura") AND "México", así como sus equivalentes en inglés. Se aplicaron filtros por año (2019-2026), idioma (español, inglés, portugués) y tipo documental (artículos arbitrados, capítulos de libro, tesis doctorales e informes de organismos oficiales como SEP, ANUIES, UNESCO, FAO, CEPAL, IICA y SADER).

De un total de 312 documentos identificados inicialmente, se depuraron duplicados y se aplicaron criterios de inclusión —pertinencia temática, rigor metodológico y foco geográfico en México o América Latina— obteniendo una muestra final de 38 documentos analíticos, de los cuales 25 corresponden a artículos arbitrados y 13 a informes institucionales o capítulos de libro. El proceso de selección se reporta conforme a las cuatro fases PRISMA (identificación, cribado, elegibilidad e inclusión), sintetizadas gráficamente en la Figura 1.



**Figura 1.**

#### **Diagrama de flujo PRISMA 2020 del proceso de selección de estudios**

Fuente: elaboración propia con base en Page *et al.* (2021).

Complementariamente, y con el propósito de triangular la evidencia documental, se analizaron tres estudios de caso seleccionados mediante muestreo intencional por su relevancia analítica: (i) la Universidad Autónoma Chapingo, por representar la primera institución en América Latina en crear una licenciatura específica en IA aplicada a la agricultura; (ii) la Encuesta Nacional de la SEP

**Jesús Ignacio Reyes-Díaz**

**Inteligencia artificial en la educación agrícola superior en México: uso, percepción y adaptación en el contexto de la Agricultura 4.0.**

(2026), por constituir el ejercicio diagnóstico más amplio disponible sobre uso y percepción de IAG en educación superior mexicana; y (iii) los programas de transformación digital agrícola implementados en el marco de la cooperación Sur-Sur FAO-SADER en México, por evidenciar la interfaz entre formación académica y sector productivo (FAO, 2023).

El análisis de contenido se apoyó en una matriz de categorización construida a partir de las tres dimensiones preestablecidas —uso, percepción y adaptación—, con subcategorías emergentes derivadas del proceso inductivo de codificación. Cada documento fue codificado de forma independiente y los resultados fueron contrastados para garantizar la consistencia interpretativa. Las dimensiones y subcategorías se presentan sintéticamente en la Tabla 1.

**Tabla 1. Matriz analítica de codificación**

| Dimensión  | Subcategorías                                                                                             | Fuentes analíticas                                                                                                                                                    |
|------------|-----------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Uso        | Herramientas utilizadas; aplicaciones en agronomía; frecuencia de uso; impacto en rendimiento académico   | SEP (2026); Molina-Montalvo <i>et al.</i> (2025); Galindo-Domínguez <i>et al.</i> (2024); Liakos <i>et al.</i> (2018); Romero-Hernández <i>et al.</i> (2024)          |
| Percepción | Perspectiva estudiantil; perspectiva docente; beneficios percibidos; riesgos éticos y epistemológicos     | Chao-Rebolledo y Rivera-Navarro (2024); Ramírez Martinell y Casillas Alvarado (2024); Nevárez Montes y Elizondo-García (2025); Das y Madhusudan (2024); UNESCO (2021) |
| Adaptación | Adopción institucional; adopción productiva; barreras de infraestructura, capacitación y política pública | INEGI (2024); SADER (2024); CEPAL, FAO e IICA (2021); Centro México Digital (2021); Universidad Autónoma Chapingo (2025)                                              |

Fuente: elaboración propia con base en la revisión sistemática.

### 3.1 Rigor analítico y limitaciones del estudio

Con el fin de explicitar el rigor del análisis, se describen a continuación los procedimientos aplicados (Tabla 2), tomando como referencia los criterios de calidad de la investigación cualitativa (Nowell *et al.*, 2017) y los pasos de la síntesis temática de estudios cualitativos en revisiones sistemáticas (Thomas y Harden, 2008).

**Procedimientos de codificación.** La codificación combinó una lógica deductiva, basada en las tres dimensiones preestablecidas, con una lógica inductiva para las subcategorías. Siguiendo las tres etapas de la síntesis temática (Thomas y Harden, 2008), se codificaron los extractos relevantes

de cada documento, se agruparon en temas descriptivos (las subcategorías de la Tabla 1) y, a partir de su comparación, se generaron temas analíticos que dieron lugar a las brechas y tensiones presentadas en los resultados y en la discusión. Para cada subcategoría se elaboró una definición operativa con criterios de inclusión y exclusión, y las decisiones analíticas relevantes se registraron en memorandos, de modo que el proceso fuera trazable.

**Validación de categorías.** La validez de la matriz se sustentó en cuatro estrategias: (a) una codificación piloto sobre un subconjunto de documentos para depurar las definiciones antes de codificar el *corpus* completo; (b) la revisión iterativa de las subcategorías hasta que ningún documento adicional generó categorías nuevas; (c) la triangulación entre tipos de fuentes (artículos arbitrados, informes institucionales y estudios de caso); y (d) la trazabilidad entre cada categoría y los documentos que la sustentan, expuesta en la Tabla 1 y en el registro de decisiones (Nowell *et al.*, 2017).

**Control de sesgos.** Se atendieron cuatro fuentes de sesgo. El sesgo de selección se redujo mediante un protocolo con criterios de inclusión definidos antes del cribado, seis bases de datos y tres idiomas. El sesgo de publicación se mitigó incorporando literatura gris institucional (informes de organismos oficiales y tesis), aunque persiste el predominio de estudios sobre universidades urbanas, que se reconoce como limitación. El sesgo de calidad se controló procurando distinguir, en los resultados, la evidencia empírica primaria (por ejemplo, encuestas y estudios con muestra declarada) de la evidencia interpretativa o de opinión. Finalmente, el sesgo del investigador se abordó mediante la codificación independiente y el registro reflexivo de decisiones, que explicita la posición del investigador como actor del sistema de educación superior.

**Confiabilidad y consistencia interpretativa.** Dado el tamaño del *corpus* (38 documentos) y el carácter interpretativo del análisis, la consistencia se evaluó mediante el contraste entre codificaciones independientes y la discusión de las discrepancias hasta alcanzar un acuerdo documentado, procedimiento de acuerdo negociado que la literatura reconoce como una vía para mejorar la reproducibilidad de los esquemas de codificación (Campbell *et al.*, 2013). Se atendieron además los criterios de credibilidad, transferibilidad, fiabilidad (*dependability*) y confirmabilidad (Nowell *et al.*, 2017): la credibilidad se apoyó en la triangulación; la transferibilidad, en la descripción del contexto mexicano y de los casos; la fiabilidad, en el protocolo PRISMA y en el

registro de decisiones; y la confirmabilidad, en la vinculación explícita de cada afirmación con sus fuentes.

**Tabla 2. Protocolo de rigor analítico de la revisión**

| Aspecto                        | Procedimiento                                                                                                                                            | Criterio de calidad                                                                      |
|--------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------|
| Codificación                   | Lógica deductivo-inductiva; síntesis temática en tres etapas; definiciones operativas y memorandos analíticos                                            | Trazabilidad (Thomas y Harden, 2008)                                                     |
| Validación de categorías       | Codificación piloto; revisión iterativa hasta que no surgen categorías nuevas; triangulación de tipos de fuentes                                         | Credibilidad (Nowell <i>et al.</i> , 2017)                                               |
| Control de sesgos              | Protocolo previo (PRISMA); seis bases de datos y tres idiomas; literatura gris; distinción entre evidencia primaria e interpretativa; registro reflexivo | Transparencia y confirmabilidad (Page <i>et al.</i> , 2021; Nowell <i>et al.</i> , 2017) |
| Confiabilidad e interpretación | Codificación independiente; acuerdo negociado entre codificaciones; vinculación de cada afirmación con sus fuentes                                       | Fiabilidad y reproducibilidad (Campbell <i>et al.</i> , 2013)                            |

Fuente: elaboración propia con base en Thomas y Harden (2008), Nowell *et al.* (2017), Campbell *et al.* (2013) y Page *et al.* (2021).

Las limitaciones del estudio incluyen el sesgo de publicación hacia universidades urbanas, la escasez de investigación empírica específicamente focalizada en instituciones agrícolas mexicanas y la evolución acelerada de las herramientas de IA, que exige actualización permanente de los hallazgos. Estas limitaciones se retoman en la discusión crítica (sección 5).

Adicionalmente, la naturaleza documental del estudio implica que los hallazgos describen lo que reportan la literatura y los informes disponibles, no necesariamente lo que ocurre en cada institución. Por ello, el perfil de egreso y la estructura curricular propuestos en la sección 7.1 constituyen una propuesta orientativa derivada de la síntesis, cuya validación empírica con docentes, estudiantes, egresados y empleadores se plantea en la sección 5.2.

#### 4. Resultados

Los resultados se organizan conforme a las tres dimensiones analíticas establecidas en la matriz de codificación (Tabla 1). Cada apartado articula la evidencia documental con los hallazgos de los

estudios de caso, y cierra con una lectura crítica de sus implicaciones para la educación agrícola mexicana.

#### 4.1 Uso de la inteligencia artificial en la educación agrícola mexicana

Los datos de la Encuesta Nacional de la SEP (2026), aplicada a 2 900 instituciones y más de 1.5 millones de estudiantes y 166 mil docentes, constituyen hasta la fecha la evidencia empírica más robusta sobre el uso de inteligencia artificial generativa en México. El 80% de los estudiantes utiliza estas herramientas para la generación de textos académicos, más del 60% de los docentes las emplea diariamente y nueve de cada diez encuestados conoce qué es la IAG. Si bien la encuesta no desagrega resultados por área del conocimiento, estudios focalizados en disciplinas afines muestran patrones similares o ligeramente inferiores. Molina-Montalvo *et al.* (2025), en un estudio cuantitativo con 403 estudiantes de diez universidades mexicanas, reportaron que cerca de la mitad utiliza ChatGPT con frecuencia, principalmente para consultar información, generar ideas y comprender temas complejos, y evidenciaron además una brecha significativa en alfabetización ética sobre el uso de estas herramientas.

En cuanto a las herramientas más utilizadas, ChatGPT domina el ecosistema, seguido por Gemini, Copilot, DeepSeek y Claude (SEP, 2026). En contextos agrícolas, los estudiantes comienzan a explorar aplicaciones especializadas como Plantix para el diagnóstico de plagas mediante imágenes, FieldView para la gestión de cultivos, y plataformas de cómputo numérico como MATLAB o Python con bibliotecas de visión computacional (TensorFlow, PyTorch). No obstante, su uso se concentra en posgrados y en programas de vanguardia como la Ingeniería en Inteligencia Artificial en Agricultura de Chapingo (Universidad Autónoma Chapingo, 2025).

Las aplicaciones en agronomía abarcan múltiples frentes, conforme a la clasificación propuesta por Liakos *et al.* (2018) para el aprendizaje automático en sistemas agrícolas. La IA se emplea en agricultura de precisión mediante drones con cámaras multiespectrales para la detección de plagas, enfermedades y estrés hídrico; en riego inteligente a través de sensores IoT conectados con algoritmos que ajustan automáticamente la irrigación; en la predicción de rendimientos con modelos de *machine learning*; y en robótica agrícola para la cosecha selectiva. Romero-Hernández *et al.* (2024), en una revisión sistemática de 62 artículos indexados en Scopus y Web of Science, documentan una tendencia creciente al uso de UAV equipados con sensores RGB,

Jesús Ignacio Reyes-Díaz

Inteligencia artificial en la educación agrícola superior en México: uso, percepción y adaptación en el contexto de la Agricultura 4.0.

multiespectrales, hiperspectrales y LiDAR, combinados con técnicas de *machine learning* y *deep learning*, para estimar parámetros clave como el índice de área foliar, el contenido de nitrógeno y el rendimiento de cultivos. En México, estas tecnologías se implementan gradualmente en proyectos piloto impulsados por la FAO (2023) en cooperación con SADER y CONAGUA en entidades como Michoacán.

El impacto de la IA en el rendimiento académico es, sin embargo, ambivalente. Galindo-Domínguez *et al.* (2024), en un análisis sobre el uso de ChatGPT en educación superior, hallaron que el uso intensivo se correlaciona positivamente con la eficiencia en la elaboración de tareas, pero presenta tensiones con el desarrollo del pensamiento crítico y la creatividad. Solís Peralta *et al.* (2024) reportaron, a partir de la opinión de estudiantes universitarios mexicanos, que estos perciben un aumento en la productividad académica, aunque reconocen riesgos de dependencia. Das y Madhusudan (2024), en un estudio con estudiantes de educación superior, documentaron que la facilidad de uso de ChatGPT puede generar dependencia y reducir la capacidad de pensamiento crítico. Este patrón resulta especialmente preocupante en carreras como agronomía, donde la resolución de problemas en campo exige un razonamiento contextual situado que la IA aún no logra replicar con la profundidad requerida.

#### 4.2 Percepción de la inteligencia artificial entre estudiantes y docentes

Desde la perspectiva estudiantil, los alumnos valoran positivamente tres aspectos fundamentales: el ahorro de tiempo, la accesibilidad y el apoyo para comprender ideas complejas (Das y Madhusudan, 2024; Soto Ortiz y Reyes Flores, 2024). Sin embargo, un porcentaje significativo desconoce las implicaciones éticas de su uso, situación que Chao-Rebolledo y Rivera-Navarro (2024) caracterizan como una brecha de alfabetización ética y tecnológica. En el contexto agrícola, esta brecha se agrava porque los estudiantes provienen mayoritariamente de entornos rurales con menor exposición previa a tecnologías digitales (ANUIES, 2024).

En cuanto a la perspectiva docente, Ramírez Martinell y Casillas Alvarado (2024) junto con Morán-Ortega *et al.* (2024) documentan que los profesores mexicanos expresan una postura ambivalente: reconocen el potencial transformador de la IAG, pero manifiestan confusión sobre su confiabilidad, dificultades para detectar usos inadecuados y una escasa formación específica. De particular relevancia es el estudio de Nevárez Montes y Elizondo-García (2025), quienes aplicaron una encuesta a 208 docentes universitarios en México para medir su aceptación y uso de

IAG conforme al Modelo de Aceptación Tecnológica (TAM) y la Teoría de la Acción Razonada. Los autores identifican que la aceptación docente se correlaciona con la edad, la antigüedad y la disciplina, de modo que los profesores más jóvenes y aquellos adscritos a áreas técnicas muestran mayor disposición. En las facultades de agronomía, el cuerpo docente suele tener un perfil mixto con predominio de especialistas en ciencias biológicas y agronómicas sin formación en ciencias computacionales, lo que limita la integración didáctica de la IA.

Entre los beneficios percibidos destacan la eficiencia en los procesos administrativos y docentes, la personalización del aprendizaje (Luckin y Cukurova, 2019), el acceso a información actualizada, el apoyo a estudiantes con dificultades de escritura académica y las posibilidades de innovación en investigación agrícola, tales como el análisis de imágenes, la predicción de cosechas y la simulación de escenarios climáticos.

Por su parte, los riesgos percibidos con mayor recurrencia incluyen la dependencia cognitiva, la deshonestidad académica, el debilitamiento del pensamiento crítico, el sesgo algorítmico, la pérdida de privacidad de los datos y la amenaza a la autoría intelectual (Lozada Lozada *et al.*, 2023; UNESCO, 2021). En el ámbito agrícola se suma un riesgo específico identificado por Martínez-Pérez y Rementería-Fuentes (2025): la dependencia de algoritmos entrenados con datos provenientes de agriculturas industriales del norte global, que pueden resultar inadecuados para contextos de agricultura campesina, tradicional o de temporal, predominantes en el sur-sureste mexicano.

### 4.3 Adaptación e implementación institucional

El nivel de adopción institucional de la IA en la educación agrícola mexicana es incipiente y heterogéneo. Mientras la UACH lanza la primera Ingeniería en IA en Agricultura documentada en América Latina en el ciclo 2025-2026 (Universidad Autónoma Chapingo, 2025), la mayoría de los institutos tecnológicos agropecuarios y las escuelas de agronomía estatales todavía no han incorporado contenidos formales sobre IA en sus currículos de licenciatura. La adopción informal —es decir, el uso de ChatGPT por parte de estudiantes y docentes sin lineamientos institucionales— es generalizada, pero carece de regulación (SEP, 2026).

En el sector productivo, la situación es igualmente compleja. En México, apenas el 30% de las unidades de producción agropecuaria incorpora tecnologías avanzadas en sus procesos, (INEGI,

Jesús Ignacio Reyes-Díaz

Inteligencia artificial en la educación agrícola superior en México: uso, percepción y adaptación en el contexto de la Agricultura 4.0.

2024). Esta cifra resulta contundente: la oferta de competencias propias de la Agricultura 4.0 se produce en un mercado que todavía no demanda masivamente tales competencias. La paradoja señalada por Mooney (2020) —la denominada "insostenible Agricultura 4.0"— se vuelve tangible en el caso mexicano, donde la digitalización corporativa avanza en agroindustrias del norte, dedicadas al aguacate, berries, tomate y maíz comercial, mientras la agricultura campesina del sureste permanece rezagada (CEPAL, FAO e IICA, 2021).

Las barreras para la adopción pueden agruparse en tres categorías interrelacionadas. La primera es la infraestructura: la brecha de conectividad afecta a más de cuatro millones de productores rurales (SADER, 2024). Las diferencias geográficas, poblacionales, económicas e institucionales condicionan el desarrollo de la infraestructura de telecomunicaciones y las posibilidades de capacitación digital en las zonas rurales (CEPAL, FAO e IICA, 2021). Iniciativas de conectividad satelital de órbita baja (LEO) ofrecen alternativas promisorias, pero aún no son accesibles para los pequeños productores ni para la mayoría de las escuelas agrícolas rurales.

La segunda barrera es la capacitación docente. Un porcentaje importante de profesores no ha recibido formación específica para integrar la IA en sus prácticas pedagógicas (Molina-Montalvo *et al.*, 2025; Nevárez Montes y Elizondo-García, 2025). La brecha de alfabetización digital se combina así con la brecha de alfabetización ética. La SEP (2026) reconoció esta deficiencia en su decálogo de acciones, proponiendo programas nacionales de capacitación docente en IAG.

La tercera barrera se refiere a las políticas públicas. Hasta 2025, México carecía de una estrategia nacional coherente sobre IA en educación. El anuncio del Observatorio de la IA en la Educación, coordinado por la ANUIES, la SEP y la UNESCO, así como las 10 acciones presentadas en noviembre de 2025, representan un primer paso significativo, pero aún no se traducen en programas presupuestales, infraestructura ni normatividad específica para las instituciones agrícolas en contextos rurales (SEP, 2026; UNESCO, 2025).

#### **4.4 Síntesis comparativa e integración de los resultados**

Para integrar los hallazgos de las tres dimensiones, la Tabla 3 contrasta, con base exclusivamente en la evidencia documental revisada, tres niveles del sistema: los programas de vanguardia en IA agrícola (representados por la IIAA de la UACH), la educación agrícola superior en general y el sector productivo. La comparación muestra que las diferencias principales no se dan tanto entre

herramientas como entre niveles de institucionalización y de acceso a infraestructura, y que la dimensión de percepción cuenta con evidencia específica escasa fuera del conjunto de la educación superior.

**Tabla 3. Comparación documental de tres niveles del sistema según las dimensiones analíticas**


| Dimensión  | Programas de vanguardia en IA agrícola (UACH, IIAA)                                                                                                                                 | Educación agrícola superior en general                                                                                                                                                                                                                                      | Sector productivo agroalimentario                                                                                                                                                                                                              |
|------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Uso        | Uso especializado (Plantix, FieldView, MATLAB o Python con TensorFlow y PyTorch), concentrado en posgrados y en programas como la IIAA (Universidad Autónoma Chapingo, 2025).       | Predominio de IA generativa de propósito general (ChatGPT, Gemini, Copilot, DeepSeek, Claude) para redactar textos y apoyar tareas; la encuesta nacional no desagrega por área del conocimiento (SEP, 2026).                                                                | Solo cerca del 30 % de las unidades de producción incorpora tecnologías avanzadas (INEGI, 2024); proyectos piloto con la FAO en Michoacán (FAO, 2023).                                                                                         |
| Percepción | Evidencia específica escasa en el <i>corpus</i> revisado.                                                                                                                           | Valoración positiva (ahorro de tiempo, accesibilidad) junto con riesgos éticos y de dependencia; docentes ambivalentes y con escasa formación (Chao-Rebolledo y Rivera-Navarro, 2024; Ramírez Martinell y Casillas Alvarado, 2024; Nevárez Montes y Elizondo-García, 2025). | No se documenta la percepción de productores y empleadores en la evidencia analizada.                                                                                                                                                          |
| Adaptación | Primera ingeniería en IA aplicada a la agricultura documentada en América Latina, con ocho semestres de programación, lógica, análisis de datos y sostenibilidad (ciclo 2025-2026). | La mayoría de los institutos tecnológicos agropecuarios y de las escuelas estatales aún no incorpora contenidos formales de IA; adopción informal sin lineamientos (SEP, 2026); barreras de conectividad, capacitación docente y política pública.                          | Digitalización concentrada en la agroindustria corporativa frente al rezago de la agricultura campesina del sur-sureste (CEPAL, FAO e IICA, 2021); más de cuatro millones de productores con parcelas menores a cinco hectáreas (SADER, 2024). |

Fuente: elaboración propia con base en la revisión sistemática y en las fuentes indicadas en cada celda.

Jesús Ignacio Reyes-Díaz

Inteligencia artificial en la educación agrícola superior en México: uso, percepción y adaptación en el contexto de la Agricultura 4.0.

La Figura 2 sintetiza el modelo analítico que articula estos resultados: las tres dimensiones aportan la evidencia; de ella se desprenden cuatro brechas (uso instrumental y comprensión superficial, alfabetización ética y crítica insuficiente, integración curricular incipiente y brecha digital rural); las perspectivas críticas de la sección 2.4 permiten interpretar su origen y sus efectos; y la respuesta se traduce en ejes curriculares y en un perfil de egreso (sección 7.1), con la soberanía tecnológica y la pertinencia territorial como principio rector.



**Figura 2. Modelo analítico integrador: de la evidencia documental al perfil de egreso**

Fuente: elaboración propia con base en la revisión sistemática.

## 5. Discusión

Los hallazgos anteriores permiten articular cuatro tensiones críticas que atraviesan la adopción de la IA en la educación agrícola mexicana, en diálogo con la literatura internacional.

Primero, la relación entre educación agrícola y desarrollo rural se vuelve asimétrica: las universidades forman profesionales con competencias 4.0 que difícilmente encontrarán empleo en

el amplio segmento del sector productivo que opera en economías de subsistencia o transición. Esta desconexión reproduce la crítica de Nagel (2012) sobre las barreras estructurales para la adopción de las TIC en áreas rurales: los egresados tienden a migrar hacia la agroindustria corporativa del norte o al extranjero, en lugar de catalizar el desarrollo de sus comunidades de origen.

Segundo, el impacto de la IA en la formación de ingenieros agrónomos es ambivalente. Por un lado, democratiza el acceso a herramientas analíticas sofisticadas que antes eran exclusivas de posgrados avanzados (Luckin y Cukurova, 2019). Por otro, riesgo debilitar competencias tradicionales como el diagnóstico de campo, el conocimiento local del suelo y el diálogo directo con productores. Las universidades agrícolas deben reflexionar sobre qué dimensiones del saber agronómico son irremplazables y cuáles pueden —o deben— ser complementadas por IA, siguiendo la lógica del *learning sciences-driven approach* propuesto por Luckin y Cukurova (2019).

Tercero, el riesgo de desigualdad tecnológica es estructural. Mientras la UACH, el Tecnológico de Monterrey o la UNAM pueden ofrecer programas en IA agrícola, los institutos tecnológicos agropecuarios en estados con alta marginación (Chiapas, Guerrero, Oaxaca) carecen incluso de infraestructura básica de conectividad estable (Centro México Digital, 2021). Si la IA se convierte en filtro de acceso al mercado laboral del sector, la brecha educativa se traducirá en brecha socioeconómica, como advierten Martínez-Pérez y Rementería-Fuentes (2025) para el conjunto de América Latina.

Cuarto, la comparación internacional es reveladora. Mientras países como Brasil han avanzado significativamente en la digitalización de sus unidades productivas, México, con la IIAA de la UACH, inicia tardíamente pero con una oportunidad única: diseñar currículos contextualizados a la diversidad agroecológica nacional y a los saberes campesinos, en lugar de replicar modelos importados (CEPAL, FAO e IICA, 2021).

Por último, la dimensión ética y de soberanía tecnológica exige atención especial. La mayoría de las herramientas de IA que usan estudiantes y docentes mexicanos pertenecen a corporaciones estadounidenses o asiáticas, lo que implica que los datos agrícolas y educativos del país se procesan en servidores extranjeros, bajo regulaciones ajenas (UNESCO, 2023, 2025). La soberanía

**Jesús Ignacio Reyes-Díaz**

**Inteligencia artificial en la educación agrícola superior en México: uso, percepción y adaptación en el contexto de la Agricultura 4.0.**

tecnológica emerge así no como nacionalismo defensivo, sino como condición para que la IA responda a los valores culturales, lingüísticos y agroecológicos mexicanos, incluyendo los saberes de los pueblos indígenas sobre milpa, agroforestería y manejo del agua. Este planteamiento es consistente con la Recomendación sobre la Ética de la Inteligencia Artificial de la UNESCO (2021) y con el informe específico Inteligencia artificial centrada en los pueblos indígenas (UNESCO, 2023), que subrayan la necesidad de marcos éticos contextualizados al Sur global y de soberanía sobre los datos indígenas.

### 5.1 Lectura de los hallazgos desde perspectivas críticas

Desde los estudios críticos de tecnología, la tensión entre formación y mercado laboral no puede resolverse únicamente con más contenidos técnicos, porque la adopción de la IA no es neutral: depende de quién diseña las herramientas, quién posee los datos y qué modelos de agricultura se consideran el horizonte deseable (Winner, 1980; Rotz *et al.*, 2019). Si el currículo se limita a formar usuarios de herramientas concebidas para agriculturas industriales, la universidad reproduce esa orientación; si forma profesionales capaces de evaluarlas y adaptarlas, puede ampliar el margen de decisión de las comunidades rurales (Feenberg, 2002).

La perspectiva del colonialismo digital ayuda a interpretar la dependencia de herramientas de IA generativa y de plataformas agrícolas cuya infraestructura, datos y reglas pertenecen a corporaciones extranjeras (Kwet, 2019; Couldry y Mejias, 2019; Birhane, 2020). La respuesta no es el aislamiento tecnológico, sino el desarrollo de capacidades locales: formar egresados que comprendan cómo funcionan estos sistemas, puedan auditarlos y participen en el diseño de alternativas con datos y lenguas del país, en la línea de la IA decolonial propuesta por Mohamed *et al.* (2020).

La justicia algorítmica añade una exigencia específica para la formación agronómica: preguntarse por la representatividad de los datos de entrenamiento y por quién asume el costo de los errores de un modelo. Un modelo entrenado con datos de agricultura industrial puede resultar inadecuado para la milpa o la agricultura de temporal (Martínez-Pérez y Rementería-Fuentes, 2025); este tipo de disparidad, estudiada en otros dominios por Noble (2018), Buolamwini y Gebru (2018) y Benjamin (2019), debe convertirse en contenido curricular y no solo en una advertencia ética.

Finalmente, la literatura sobre innovación en contextos rurales latinoamericanos advierte que los beneficios de la IA dependen de condiciones previas de infraestructura, alfabetización digital y políticas habilitantes (Trendov *et al.*, 2019; CEPAL, FAO e IICA, 2021). Esto refuerza la necesidad de que los planes de estudio incluyan competencias de extensión y de co-diseño con productores, y de que las políticas de IA en educación superior reconozcan a las instituciones agrícolas rurales como espacios estratégicos. En conjunto, estas perspectivas desplazan la discusión de la brecha de acceso hacia la distribución del poder tecnológico, que es el eje de la soberanía tecnológica planteada en este estudio.

## 5.2 Limitaciones y agenda de investigación empírica complementaria

El estudio se sustenta en una revisión sistemática y en el análisis documental de tres casos; por tanto, sus conclusiones describen la evidencia publicada y no sustituyen la evidencia primaria de las instituciones. Las perspectivas de docentes, estudiantes, egresados y empleadores del sector agrícola, así como la comparación entre universidades agrícolas, se identifican como la principal vía para fortalecer y validar los hallazgos. Se propone una agenda en cuatro líneas (Tabla 4), cuya aplicación requeriría la aprobación de un comité de ética institucional, el consentimiento informado de los participantes y la protección de los datos personales.

**Tabla 4. Agenda de investigación empírica complementaria**

| Línea                                | Participantes y muestreo                                                                                | Técnica e instrumento                                                     | Aporte a las dimensiones                                                               |
|--------------------------------------|---------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------|----------------------------------------------------------------------------------------|
| Entrevistas a docentes y estudiantes | Docentes y estudiantes de programas de agronomía; muestreo intencional por tipo de institución y región | Entrevistas semiestructuradas y grupos focales                            | Uso y percepción: prácticas reales, criterios de evaluación y necesidades de formación |
| Percepción institucional             | Directivos, coordinadores de programa y responsables de planes de estudio                               | Cuestionario institucional; análisis de lineamientos y mapas curriculares | Adaptación: grado de institucionalización y barreras                                   |

Jesús Ignacio Reyes-Díaz

Inteligencia artificial en la educación agrícola superior en México: uso, percepción y adaptación en el contexto de la Agricultura 4.0.

| Línea                                                       | Participantes y muestreo                                                                                                                                                            | Técnica e instrumento                                               | Aporte a las dimensiones                                           |
|-------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------|--------------------------------------------------------------------|
| Egresados y empleadores                                     | Egresados recientes; empleadores de agroindustria, asistencia técnica, instituciones públicas y organizaciones de productores                                                       | Encuesta y entrevistas; análisis de perfiles de puesto              | Adaptación productiva y pertinencia del perfil de egreso (Tabla 5) |
| Estudio comparativo entre universidades agrícolas mexicanas | Muestra estratificada por tipo de institución (universidades autónomas, institutos tecnológicos, universidades estatales y tecnológicas) y por región (norte, centro y sur-sureste) | Análisis comparado de planes de estudio; estudio de casos múltiples | Brechas territoriales y comparabilidad entre contextos             |

Fuente: elaboración propia.

Los resultados de estas líneas permitirían contrastar la estructura curricular y el perfil de egreso propuestos en la sección 7.1 mediante juicio de expertos (por ejemplo, con técnicas de consenso como el método Delphi) y su revisión con empleadores y egresados, y alimentarían el observatorio propuesto en las recomendaciones.

## 6. Conclusiones

El análisis realizado permite sostener que la educación agrícola mexicana se encuentra en un momento de transición acelerada pero fragmentada hacia la integración de la inteligencia artificial. Los datos empíricos más recientes (SEP, 2026) confirman una adopción masiva del uso de IA generativa por estudiantes (80 %) y docentes (más del 60 %), pero esta adopción convive con tres déficits estructurales documentados de forma convergente en la literatura: una comprensión superficial de las herramientas (Chao-Rebolledo y Rivera-Navarro, 2024), una formación ética y crítica insuficiente (Molina-Montalvo *et al.*, 2025; Lozada Lozada *et al.*, 2023), y una integración curricular incipiente.

En el ámbito productivo, la brecha es mayor: solo el 30% de las unidades agropecuarias adopta tecnologías avanzadas (INEGI, 2024), lo que configura una paradoja: se forma capital humano 4.0

para un campo todavía anclado en prácticas 2.0 y 3.0. La educación agrícola, en consecuencia, no puede limitarse a incorporar IA como un contenido curricular más; debe articularse con políticas de desarrollo rural, conectividad digital, inclusión de saberes locales y soberanía tecnológica (UNESCO, 2021, 2023, 2025).

Las implicaciones educativas son claras: (1) la integración curricular de la IA debe ser transversal y crítica, no meramente instrumental; (2) la formación docente es condición necesaria, no opcional; (3) la ética y la perspectiva de género deben cruzar todos los programas, como propone la SEP (2026); (4) los contenidos deben dialogar con la diversidad agroecológica mexicana, incluyendo agricultura de temporal, milpa y producción campesina; y (5) la política pública debe reconocer a las instituciones agrícolas rurales como espacios estratégicos y dotarlas de infraestructura y recursos.

En respuesta al objetivo planteado, el estudio propone en la sección 7.1 una estructura orientativa de integración curricular y un perfil de egreso para el ingeniero agrónomo. Ambos se derivan de la síntesis documental y de las perspectivas críticas incorporadas, y deberán validarse con evidencia empírica primaria antes de su adopción institucional.

## 7. Recomendaciones

En primer lugar, se recomienda una integración curricular sustantiva de la inteligencia artificial en todos los programas de agronomía. Ello implica incorporar al menos una asignatura obligatoria sobre fundamentos de ciencia de datos y ética algorítmica, complementada con módulos transversales en agricultura de precisión, *big data* y *machine learning* aplicado (Liakos *et al.*, 2018; Romero-Hernández *et al.*, 2024), así como un eje optativo avanzado para quienes deseen especializarse en estas áreas.

En segundo lugar, resulta indispensable diseñar programas nacionales de capacitación docente sostenida y certificada, que incluyan becas para posgrados en áreas de inteligencia artificial aplicada a la agronomía. La SEP, la ANUIES y la UNESCO pueden coordinar un programa tripartito con instituciones como la UACH, el Colegio de Postgraduados, la UAAAN y el Centro Internacional de Mejoramiento de Maíz y Trigo. Esta recomendación responde directamente a las brechas de formación docente identificadas por Ramírez Martinell y Casillas Alvarado (2024), Morán-Ortega *et al.* (2024) y Nevárez Montes y Elizondo-García (2025).

Jesús Ignacio Reyes-Díaz

En tercer lugar, se requiere priorizar la conectividad digital rural como política de Estado. Las acciones concretas deberían incluir la ampliación de la Red Compartida a todas las cabeceras municipales rurales, el subsidio de conectividad satelital de órbita baja para escuelas agrícolas en zonas marginadas y la vinculación de programas como Sembrando Vida y Producción para el Bienestar con estrategias de capacitación digital (SADER, 2024; CEPAL, FAO e IICA, 2021).

En cuarto lugar, se propone promover modelos híbridos que combinen la inteligencia artificial con la enseñanza tradicional. Esto implica desarrollar pedagogías que articulen el diagnóstico de campo presencial, el diálogo directo con productores y el uso crítico de las herramientas de IA. La práctica agrícola no puede reducirse a la modelización algorítmica, pues requiere observación directa, tacto del suelo y escucha comunitaria.

En quinto lugar, se recomienda avanzar hacia la soberanía tecnológica y una ética contextualizada. Ello significa fomentar el desarrollo de herramientas de inteligencia artificial propias, construidas con datos agrícolas mexicanos, lenguas indígenas y modelos adaptados a la biodiversidad nacional. Asimismo, se debe integrar la Recomendación de la UNESCO sobre la Ética de la Inteligencia Artificial (UNESCO, 2021) y el informe sobre IA centrada en los pueblos indígenas (UNESCO, 2023) como marcos transversales en todos los planes de estudio.

Finalmente, se sugiere consolidar un observatorio permanente. El Observatorio de IA en Educación Superior anunciado por la SEP y la ANUIES en 2025 debe fortalecerse con una mesa específica para la educación agrícola y rural, que monitoree la evolución del uso, la percepción y la adaptación de la inteligencia artificial, y formule recomendaciones periódicas de política pública con base en evidencia actualizada (SEP, 2026; UNESCO, 2025).

### **7.1 Propuesta de integración curricular y perfil de egreso del ingeniero agrónomo**

En coherencia con la primera recomendación y con el objetivo del estudio, se propone una estructura orientativa para integrar la IA en el plan de estudios de las carreras de ingeniería agronómica y definir el perfil de egreso correspondiente. La propuesta es de carácter conceptual: deriva de los hallazgos y de las perspectivas críticas de la sección 2.4, y su distribución en semestres, créditos y asignaturas dependerá del modelo educativo y de los lineamientos de cada institución.

Se establecen cinco principios de diseño derivados de los resultados: (1) transversalidad crítica, para superar el uso instrumental; (2) progresión formativa, que lleve al estudiante de comprender a aplicar y crear; (3) pertinencia territorial, que incorpore la agricultura de temporal, la milpa y la producción campesina; (4) ética, justicia algorítmica y soberanía de datos como contenido y no solo como advertencia; y (5) vinculación con productores y comunidades. Como referencia conceptual para la progresión se adopta el marco de competencias en IA para estudiantes de la UNESCO (Miao y Shiohira, 2024), que organiza doce competencias en cuatro dimensiones (mentalidad centrada en el ser humano, ética de la IA, técnicas y aplicaciones de la IA, y diseño de sistemas de IA) y tres niveles de progresión (comprender, aplicar y crear). Dado que ese marco fue concebido para la educación escolar, aquí se emplea solo como orientación y se adapta a la formación profesional agrícola.

El perfil de egreso resultante se organiza en cinco dimensiones de competencia (Tabla 5).

**Tabla 5. Perfil de egreso del ingeniero agrónomo en el contexto de la Agricultura 4.0**

| Dimensión                                        | Competencias esperadas del egresado                                                                                                                                                                | Progresión           | Fundamento en los hallazgos                                                                                     |
|--------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------|-----------------------------------------------------------------------------------------------------------------|
| Fundamentos de datos e IA                        | Comprende los principios de la ciencia de datos y del aprendizaje automático; maneja datos agrícolas (recolección, depuración y análisis) y reconoce las capacidades y los límites de los modelos. | Comprender y aplicar | Comprensión superficial y uso instrumental (Chao-Rebolledo y Rivera-Navarro, 2024; sección 4.2)                 |
| IA aplicada a los sistemas agrícolas             | Aplica herramientas de agricultura de precisión, teledetección, riego inteligente y predicción de rendimientos a problemas agronómicos concretos.                                                  | Aplicar y crear      | Aplicaciones agronómicas (Liakos <i>et al.</i> , 2018; Romero-Hernández <i>et al.</i> , 2024; sección 4.1)      |
| Ética, justicia algorítmica y soberanía de datos | Evalúa críticamente sesgos, datos de entrenamiento, privacidad y autoría; decide con criterio qué herramientas usar y cuáles no; comprende la gobernanza de los datos agrícolas.                   | Comprender y aplicar | Riesgos éticos y dependencia tecnológica (UNESCO, 2021; Martínez-Pérez y Rementería-Fuentes, 2025; sección 2.4) |

Jesús Ignacio Reyes-Díaz

| Dimensión                             | Competencias esperadas del egresado                                                                                                                                 | Progresión      | Fundamento en los hallazgos                                                                                           |
|---------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------|-----------------------------------------------------------------------------------------------------------------------|
| Saberes locales y pensamiento situado | Articula la IA con el diagnóstico de campo, la agroecología y los saberes campesinos; valida las recomendaciones algorítmicas en el contexto local.                 | Aplicar         | Riesgo de modelos inadecuados para la agricultura campesina (Martínez-Pérez y Rementería-Fuentes, 2025; UNESCO, 2023) |
| Innovación y vinculación rural        | Diseña con productores y comunidades soluciones viables con la infraestructura disponible y contribuye a su capacitación y a reducir la brecha digital territorial. | Aplicar y crear | Brecha digital rural y desigualdad territorial (CEPAL, FAO e IICA, 2021; Trendov <i>et al.</i> , 2019)                |

Fuente: elaboración propia con base en los resultados del estudio y, para los niveles de progresión, en Miao y Shiohira (2024).

La estructura curricular se organiza en tres ciclos (básico, profesional y de integración) y cinco ejes que desarrollan estas competencias de manera progresiva, junto con un eje transversal sobre el uso crítico de la IA generativa en el aprendizaje y la evaluación y con la formación y certificación docente propuestas en la segunda recomendación (Figura 3). Los ejes E1 a E3 concretan la primera recomendación (una asignatura obligatoria de ciencia de datos y ética algorítmica, módulos de agricultura de precisión, *big data* y aprendizaje automático, y un componente optativo avanzado), mientras que los ejes E4 y E5 responden a la pertinencia territorial y a la vinculación con productores.



**Figura 3. Esquema orientativo de integración curricular de la IA en la formación del ingeniero agrónomo**

Fuente: elaboración propia.

Su implementación puede seguir cinco pasos: (1) diagnóstico institucional del uso y de las capacidades de docentes y estudiantes; (2) definición participativa del perfil de egreso con empleadores, egresados y organizaciones de productores; (3) elaboración del mapa curricular y de los lineamientos de uso de la IA generativa; (4) formación docente previa y simultánea a la implementación; y (5) evaluación periódica y actualización con apoyo del observatorio propuesto.

**Jesús Ignacio Reyes-Díaz**

**Inteligencia artificial en la educación agrícola superior en México: uso, percepción y adaptación en el contexto de la Agricultura 4.0.**

## 8. Referencias

- Asociación Nacional de Universidades e Instituciones de Educación Superior [ANUIES]. (2024). Inteligencia artificial en la educación superior. Universidad Iberoamericana. <https://iagen.unam.mx/recursos/ANUIES---IA-en-ES-Mx---2025.pdf>
- Benjamin, R. (2019). Race after technology: Abolitionist tools for the New Jim Code. *Polity*.
- Birhane, A. (2020). Algorithmic colonization of Africa. *SCRIPTed*, 17(2), 389-409. <https://doi.org/10.2966/scrip.170220.389>
- Buolamwini, J., y Gebru, T. (2018). Gender shades: Intersectional accuracy disparities in commercial gender classification. *Proceedings of Machine Learning Research*, 81, 77-91.
- Campbell, J. L., Quincy, C., Osserman, J., y Pedersen, O. K. (2013). Coding in-depth semistructured interviews: Problems of unitization and intercoder reliability and agreement. *Sociological Methods & Research*, 42(3), 294-320. <https://doi.org/10.1177/0049124113500475>
- Centro México Digital. (2021). Índice de Desarrollo Digital Estatal (IDDE®) 2021. <https://centromexico.digital/idde/2021/>
- Chao-Rebolledo, C., y Rivera-Navarro, M. Á. (2024). Usos y percepciones de herramientas de inteligencia artificial en la educación superior en México. *Revista Iberoamericana de Educación*, 95(1), 57-72. <https://doi.org/10.35362/rie9516259>
- Comisión Económica para América Latina y el Caribe [CEPAL], Organización de las Naciones Unidas para la Alimentación y la Agricultura [FAO] e Instituto Interamericano de Cooperación para la Agricultura [IICA]. (2021). Perspectivas de la agricultura y del desarrollo rural en las Américas: una mirada hacia América Latina y el Caribe 2021-2022. IICA. <https://repositorio.cepal.org/handle/11362/47208>
- Couldry, N., y Mejias, U. A. (2019). The costs of connection: How data is colonizing human life and appropriating it for capitalism. Stanford University Press.

- Das, S. R., y Madhusudan, J. V. (2024). Perceptions of higher education students towards ChatGPT usage. *International Journal of Technology in Education*, 7(1), 86-106. <https://doi.org/10.46328/ijte.583>
- Feenberg, A. (2002). *Transforming technology: A critical theory revisited*. Oxford University Press.
- Galindo-Domínguez, H., Delgado, N., Campo, L., y Sainz de la Maza, M. (2024). Use of ChatGPT in higher education: An analysis based on students' gender, age, academic performance, academic year and university degree. *REDU. Revista de Docencia Universitaria*, 22(2), 16-30. <https://doi.org/10.4995/redu.2024.21647>
- Holmes, W., Bialik, M., y Fadel, C. (2019). *Artificial intelligence in education: Promises and implications for teaching and learning*. Center for Curriculum Redesign.
- Ibarra, G. E. R. (2022). Agricultura de precisión: la integración de las TIC en la producción agrícola. *Computer and Electronic Sciences: Theory and Applications*, 3(1), 34-38.
- Instituto Nacional de Estadística y Geografía [INEGI]. (2024). Censo Agropecuario 2022: adopción tecnológica en unidades de producción agropecuaria. INEGI. <https://www.inegi.org.mx/programas/cagf/2022/>
- Klerkx, L., Jakku, E., y Labarthe, P. (2019). A review of social science on digital agriculture, smart farming and agriculture 4.0: New contributions and a future research agenda. *NJAS - Wageningen Journal of Life Sciences*, 90-91, 100315. <https://doi.org/10.1016/j.njas.2019.100315>
- Kwet, M. (2019). Digital colonialism: US empire and the new imperialism in the Global South. *Race & Class*, 60(4), 3-26.
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., y Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674. <https://doi.org/10.3390/s18082674>
- Lozada Lozada, R. F., López Aguayo, E. M., Espinoza Suquilanda, M. de J., Arias Pico, N. de J., y Quille Vélez, G. E. (2023). Los riesgos de la inteligencia artificial en la educación.

- Ciencia Latina Revista Científica Multidisciplinar, 7(5), 7219-7234.  
[https://doi.org/10.37811/cl\\_rcm.v7i5.8301](https://doi.org/10.37811/cl_rcm.v7i5.8301)
- Luckin, R., y Cukurova, M. (2019). Designing educational technologies in the age of AI: A learning sciences-driven approach. *British Journal of Educational Technology*, 50(6), 2824-2838.  
<https://doi.org/10.1111/bjet.12861>
- Martínez-Pérez, D. Z., y Rementeria-Fuentes, J. J. (2025). Avances, retos éticos y perspectivas de la inteligencia artificial (IA) en la educación de América Latina. *Ciencia Latina Revista Científica Multidisciplinar*, 9(3).  
<https://ciencialatina.org/index.php/cienciala/article/view/18603>
- Miao, F., y Shiohira, K. (2024). AI competency framework for students. UNESCO.  
<https://doi.org/10.54675/JKJB9835>
- Mohamed, S., Png, M.-T., y Isaac, W. (2020). Decolonial AI: Decolonial theory as sociotechnical foresight in artificial intelligence. *Philosophy & Technology*, 33(4), 659-684.  
<https://doi.org/10.1007/s13347-020-00405-8>
- Molina-Montalvo, H., Macías Villarreal, J. C., y Haces Atondo, G. (2025). Impacto, percepciones y uso de ChatGPT en la formación de estudiantes de pedagogía y educación: un estudio diagnóstico en diez universidades de México. *Tecnología, Ciencia y Educación*, (31), 59-89. <https://doi.org/10.51302/tce.2025.24301>
- Mooney, P. (2020). La insostenible Agricultura 4.0: digitalización y poder corporativo en la cadena alimentaria. Grupo ETC.
- Morán-Ortega, S. A., Ruiz-Tirado, S. G., Simental-López, L. M., y Tirado-López, A. B. (2024). Barreras de la inteligencia artificial generativa en estudiantes de educación superior: percepción docente. *Revista de Investigación en Tecnologías de la Información*, 12(25), 26-37. <https://doi.org/10.36825/RITI.12.25.003>
- Nagel, J. (2012). Principales barreras para la adopción de las TIC en la agricultura y en las áreas rurales. Comisión Económica para América Latina y el Caribe (CEPAL).

- Nevárez Montes, J., y Elizondo-García, J. (2025). Faculty acceptance and use of generative artificial intelligence in their practice. *Frontiers in Education*, 10, 1427450. <https://doi.org/10.3389/feduc.2025.1427450>
- Noble, S. U. (2018). *Algorithms of oppression: How search engines reinforce racism*. New York University Press.
- Nowell, L. S., Norris, J. M., White, D. E., y Moules, N. J. (2017). Thematic analysis: Striving to meet the trustworthiness criteria. *International Journal of Qualitative Methods*, 16(1), 1-13. <https://doi.org/10.1177/1609406917733847>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura [FAO]. (2023, 15 de noviembre). FAO implementa sistema digital para mejorar el uso de agua en los sectores agrícolas de México. Naciones Unidas en México. <https://mexico.un.org/es/253015-fao-implementa-sistema-digital-para-mejorar-el-uso-de-agua-en-los-sectores-agricolas-de>
- Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura [UNESCO]. (2019). Consenso de Beijing sobre la inteligencia artificial y la educación. UNESCO. [https://unesdoc.unesco.org/ark:/48223/pf0000368303\\_spa](https://unesdoc.unesco.org/ark:/48223/pf0000368303_spa)
- Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura [UNESCO]. (2021). Recomendación sobre la ética de la inteligencia artificial. UNESCO. [https://unesdoc.unesco.org/ark:/48223/pf0000381137\\_spa](https://unesdoc.unesco.org/ark:/48223/pf0000381137_spa)
- Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura [UNESCO]. (2023). Inteligencia artificial centrada en los pueblos indígenas: perspectivas desde América Latina y el Caribe. UNESCO. [https://unesdoc.unesco.org/ark:/48223/pf0000387814\\_spa](https://unesdoc.unesco.org/ark:/48223/pf0000387814_spa)
- Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura [UNESCO]. (2025, 24 de enero). La inteligencia artificial estará al servicio de la educación y de las personas en México. <https://www.unesco.org/ethics-ai/es/articles/la-inteligencia-artificial-estara-al-servicio-de-la-educacion-y-de-las-personas-en-mexico>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J., Moher, D., y Vandenbroucke, J. P. (2021). The PRISMA 2020 statement: reporting guidelines for systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Jesús Ignacio Reyes-Díaz**
- Inteligencia artificial en la educación agrícola superior en México: uso, percepción y adaptación en el contexto de la Agricultura 4.0.**

- J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Ramírez Martinell, A., y Casillas Alvarado, M. A. (2024). Percepciones docentes sobre la inteligencia artificial generativa: el caso mexicano. *Revista Paraguaya de Educación a Distancia (REPED)*, 5(2), 44-55. <https://doi.org/10.56152/reped2024-dossierIA1-art4>
- Romero-Hernández, J. A., Rodríguez-Ramírez, J. F., y Cabrera-Muñoz, L. F. (2024). Monitoreo de cultivos y suelos en agricultura de precisión con UAV e inteligencia artificial: una revisión. *Ingeniería y Competitividad*, 26(3). [http://www.scielo.org.co/scielo.php?script=sci\\_arttext&pid=S0123-921X2024000400075](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0123-921X2024000400075)
- Rotz, S., Duncan, E., Small, M., Botschner, J., Dara, R., Mosby, I., Reed, M., y Fraser, E. D. G. (2019). The politics of digital agricultural technologies: A preliminary review. *Sociologia Ruralis*, 59(2), 203-229.
- Secretaría de Agricultura y Desarrollo Rural [SADER]. (2024). Diagnóstico de digitalización del sector agroalimentario mexicano. Gobierno de México.
- Secretaría de Educación Pública [SEP]. (2026). Encuesta Nacional sobre Usos y Percepciones de Inteligencia Artificial Generativa en la Educación Superior en México: informe de resultados. Subsecretaría de Educación Superior, Gobierno de México.
- Solís Peralta, F. M., Huerta Patraca, G. A., y Hernández Martínez, C. E. (2024). Inteligencia artificial en educación: la opinión de estudiantes universitarios sobre el uso del ChatGPT. *Revista Paraguaya de Educación a Distancia (REPED)*, 5(4), 55-71. <https://doi.org/10.56152/reped2024-dossierIA2-art6>
- Soto Ortiz, J. L., y Reyes Flores, M. (2024). Usos académicos de ChatGPT entre estudiantes universitarios mexicanos. *Revista de Investigación en Tecnologías de la Información*, 12(24), 80-95.
- Thomas, J., y Harden, A. (2008). Methods for the thematic synthesis of qualitative research in systematic reviews. *BMC Medical Research Methodology*, 8, Article 45. <https://doi.org/10.1186/1471-2288-8-45>

Trendov, N. M., Varas, S., y Zeng, M. (2019). Digital technologies in agriculture and rural areas: Status report. FAO. <http://www.fao.org/3/ca4985en/ca4985en.pdf>

Universidad Autónoma Chapingo. (2025). Oferta académica: Ingeniería en Inteligencia Artificial en Agricultura. Departamento de Ingeniería Mecánica Agrícola. <https://chapingo.mx/oferta-academica/>

Winner, L. (1980). Do artifacts have politics? *Daedalus*, 109(1), 121-136.