



Daniel Leonardo Silva Zuluaga

Juan Pablo Suárez Martínez

Estudio sistemático de la literatura sobre la aplicación del machine learning en el sector de agronegocios (2020–2026)

Universidad Militar Nueva Granada

Administración de empresas

Facultad de Ciencias Económicas

26/04/2026

Tabla de Contenido

1. Título de la Propuesta	4
2. Resumen	4
Abstract	4
3. Introducción	5
4. Problema de Investigación	6
4.1 Planteamiento del problema	6
4.2 Pregunta de investigación	7
5. Objetivos	8
5.1. Objetivo general	8
5.2. Objetivos específicos:	8
6. Justificación	8
6.1 Delimitación del estudio	9
7. Marcos de referencia	10
7.1 Estado del arte	10
7.2 Marco conceptual	11
7.3 Marco legal	12
7.4 Marco teórico	14
7.4.1 Machine Learning	15
7.4.2 Agronegocios	17
7.4.3 Brechas y desafíos en la implementación del Machine Learning en el sector agrícola	18
7.4.4 Clústeres de decisión y tipos de problemas gerenciales	20
8. Diseño metodológico	20
8.1 Tipo de investigación	20
8.2 Paradigma	21
8.3 Enfoque	22
8.4 Diseño de la Investigación.	23
8.4.1	23
8.4.2 Fase de Cribado o Screening	24
8.4.3 Fase de inclusión	25
8.5 Línea investigativa	26
8.5.1 Área y Línea de Investigación	26
8.6 Técnicas e instrumentos de recolección	26

9. Resultados	27
9.1 Análisis de Resultados	27
9.1.1 Matriz de Análisis Documental	27
9.1.2 Diagrama de Flujo PRISMA 2020	45
9.1.3 Proceso de Selección de Información (Diagrama PRISMA)	46
9.1.4 Análisis de Resultados (Matriz de Análisis Documental)	47
9.2 Conclusiones	48
9.3 Recomendaciones	50
10. Referencias	51

1. Título de la Propuesta

Estudio sistemático de la literatura sobre la aplicación del machine learning en el sector de agronegocios (2020–2026)

2. Resumen

La presente investigación analiza la producción académica indexada entre los años 2020 y 2026 en temas de Machine Learning y agronegocios, mediante una revisión de artículos con el método PRISMA, para el estudio se realizó búsquedas en las bases de datos científicos como SCOPUS y Web of Science, identificando inicialmente 435 artículos, de los cuales 50 fueron eliminados por duplicado, tras la aplicación de criterios de inclusión y exclusión, se seleccionaron 41 artículos. El estudio permitió que se identificaran clústeres de decisión y los diferentes problemas gerenciales y los desafíos en la implementación y adopción del Machine Learning en el sector agrícola y los agronegocios. El Machine Learning es parte de la inteligencia artificial que permite a los programas aprender de datos y generar modelos predictivos para tomar decisiones, siendo integrada con herramienta como drones, sensores, satélites que permiten tener una optimización de los recursos y sus procesos productivos. El Machine Learning es utilizado principalmente para predicción de rendimientos, detección de enfermedades y plagas, gestión eficiente de recursos. logrando tener una mejor planificación agrícola, un mejor monitoreo de cultivos y llevar un control de calidad.

Los resultados evidencian que la mayoría de los artículos se enfocan en la aplicación y predicción de rendimientos, detección de enfermedades y plagas, gestión de la cadena de suministros, monitoreo con datos en tiempo real, así mismo se confirma que para el éxito en la implementación del Machine Learning en el sector agrícola y los agronegocios es fundamental reducir la brecha existente entre el conocimiento académico y la realidad operativa de los agricultores. Limitados por la calidad de los datos, los altos costos tecnológicos y la necesidad de una buena infraestructura. existiendo una diferencia entre los grandes y pequeños productores, así como las dificultades para una buena capacitación y comprensión de los resultados, el Machine Learning se posiciona cada vez más como una herramienta tecnológica estratégica para el sector agrícola y los agronegocios, pero su adopción depende de la capacidad económica y operativa.

Abstract

This research analyzes the indexed academic production published between 2020 and

2026 on topics related to Machine Learning and agribusiness through a systematic literature review using the PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) method. The study involved structured searches in scientific databases such as SCOPUS and Web of Science, initially identifying 435 articles, of which 50 were removed due to duplication. After applying inclusion and exclusion criteria, a final sample of 41 articles was selected for analysis.

The study identifies decision clusters, as well as the main managerial problems and challenges associated with the implementation and adoption of Machine Learning in the agricultural and agribusiness sectors. Machine Learning, as a branch of artificial intelligence, enables systems to learn from data and generate predictive models that support decision-making processes. It has been integrated with technological tools such as drones, sensors, and satellites, allowing the optimization of resources and productive processes. Its primary applications include yield prediction, disease and pest detection, and efficient resource management, contributing to improved agricultural planning, crop monitoring, and quality control.

The results reveal that most studies focus on yield prediction, disease and pest detection, agricultural supply chain management, and real-time monitoring through advanced data technologies. Furthermore, the findings confirm that successful implementation of Machine Learning in agribusiness depends on reducing the gap between academic knowledge and the operational realities of farmers. Key limitations include data quality issues, high technological costs, and the need for adequate infrastructure. Significant differences were identified between large-scale and small-scale producers, as well as challenges related to training and the interpretation of technological results. Despite these challenges, Machine Learning is increasingly positioned as a strategic technological tool for strengthening the agricultural and agribusiness sectors, although its adoption largely depends on economic and operational capacity.

3. Introducción

En la actualidad el sector agrícola enfrenta un momento decisivo impulsado por la gran variabilidad climática y la necesidad de optimizar insumos y recursos finitos, debido a desafíos actuales como las sequías extremas y la urgencia de una sostenibilidad agrícola. La integración del Machine Learning se ha convertido en una herramienta estratégica que define la competitividad en los agronegocios actualmente. Esta evolución se puede describir como la “Agricultura 4.0” (Quadras et al., 2023) que se fundamenta en la transición de una observación empírica o tradicional hacia una gestión autónoma de precisión. La producción académica indexada actual destaca y resalta que la efectividad operativa de los agronegocios depende hoy en día de la sinergia entre algoritmos de machine learning e instrumentos tecnológicos de alta resolución como los satélites, que en conjunto son capaces de predecir rendimientos con una precisión bastante alta.

La presente investigación analiza la producción académica indexada en temas de Machine Learning y agronegocios entre 2020-2026, basada en una matriz de análisis

documental de 41 artículos rigurosamente seleccionados de alto impacto. Dicho análisis comprende una exploración global de los temas relacionados. Desde potencias agrícolas como Brasil, Estados Unidos y China hasta países con contextos emergentes como Kenia y Colombia, revisando aplicaciones tecnológicas que van desde un diagnóstico técnico de los cultivos hasta la incorporación de tecnologías de punta en ámbitos agrícolas.

Mediante esta revisión se describen las tendencias de temáticas más importantes, enfoques metodológicos y dominios de la aplicación que están evolucionando el sector agrícola. Con esta perspectiva, la presente investigación plantea analizar cómo la transformación de datos de alta complejidad en conocimiento aplicable fortalece la posición estratégica en la toma de decisiones de los productores agrícolas. De igual manera, el presente estudio busca comprobar que la combinación entre los modelos algoritmos de Machine Learning y la gestión de los agronegocios es un factor determinante para que los productores logren una sostenibilidad y una mayor capacidad de respuesta ante diversas exigencias y factores críticos y cambiantes como el clima.

4. Problema de Investigación

4.1 Planteamiento del problema

El sector agrícola a nivel mundial presenta desafíos complejos derivados de diferentes causas dentro de las cuales las que más se destacan son el cambio climático y la expansión demográfica, que proyecta se alcanzarán 10.000 millones de personas para el año 2050 (Aijaz et al., 2025). Esta proyección obliga a realizar una transición tecnológica que permita mitigar efectos devastadores y mejorar la seguridad nutricional y la sostenibilidad de los sistemas productivos agrícolas. Por otro lado, en América Latina y el Caribe, la necesidad de implementar nuevos sistemas en pro de la agricultura es aún más evidente, ya que el sector agrícola es fundamental para América Latina y el Caribe, con una proporción casi del 7% del PIB de la región (Conroy et al., 2024) y el 18% del empleo, además que es responsable de entre el 21% y 35% de las emisiones totales de efecto invernadero (Sotomayor et al., 2023).

Para mejorar la eficiencia y disminuir impactos negativos el uso de tecnologías innovadoras como el machine learning han surgido con el fin de mejorar y optimizar prácticas agrícolas. La puesta en marcha de estas tecnologías en el agro podría llegar a generar incrementos de hasta un 25% en la productividad de los cultivos y ahorrar el consumo de agua en un 20% (Aijaz et al., 2025). Este aumento en la productividad es exigente, considerando que para el año 2030 se proyecta que el 20% de las tierras agrícolas a nivel mundial podrían estar degradadas, lo que exige una transición urgente hacia prácticas que optimicen cada recurso disponible (Waqas et al., 2025).

No obstante, la implementación de estas tecnologías innovadoras en los agronegocios se ve limitada por brechas como costos elevados de infraestructura y falta de capacitación de los productores (Aijaz et al., 2025). Además, la transición hacia modelos sostenibles también se ve frenada por una brecha de adaptación tecnológica. Según Doda et al. (2025), a pesar de los beneficios, los productores enfrentan limitaciones financieras y una resistencia cultural al cambio desde métodos tradicionales. Esta situación se agrava más en países en vía de desarrollo, donde existen brechas tecnológicas principalmente en conectividad, acceso a información y formación tecnológica, lo que deja en desventaja a productores para adoptar soluciones innovadoras en sus cultivos. Precisamente en Colombia, esta problemática se intensifica en el sector agrícola, debido a los bajos niveles de tecnificación y la limitada estructuración entre la disponibilidad de los datos y su uso estratégico. A pesar de la existencia de sistemas de información por parte del estado colombiano como lo son las Evaluaciones Agropecuarias Municipales (EVA), estos datos no podrían ser plenamente aprovechados mediante herramientas tecnológicas como el machine learning, lo que también evidencia una desconexión entre la información suministrada por las EVA y la toma de decisiones en el campo. Ya que, debido a factores adversos como las brechas tecnológicas, los productores agrícolas del país no pueden aprovechar los datos existentes para una mejor planificación en el campo.

Desde la perspectiva de las ciencias económicas y la gestión empresarial, surge una problemática adicional relacionada con la saturación y congestión de información científica disponible que resulta de gran complejidad para identificar que herramientas de machine learning son realmente de interés para un campesino o productor de agronegocios. A pesar del creciente volumen de publicaciones científicas en este sector, no existe una sistematización efectiva que permita identificar tendencias y aplicar mejores prácticas agrícolas. Esta brecha de conocimiento sobre la producción académica indexada entre 2020 y 2026 limita al sector agrícola en la toma de decisiones estratégicas sobre sus agronegocios. En consecuencia, dicha desconexión impide que los productores resuelvan problemas operativos de manera efectiva, retrasando la transición hacia la digitalización y sostenibilidad agrícola (Sotomayor et al., 2023).

De no abordar esta problemática, el sector agrícola en Colombia y en países en vía de desarrollo podrían enfrentar un retraso significativo en la adopción de nuevas prácticas tecnológicas en el sector, reduciendo la capacidad de reacción frente a desafíos globales e incertidumbre en ciertos aspectos; como el cambio climático que afecta de manera significativa al agro. Por lo tanto, se compromete el desarrollo económico sostenible de este sector.

4.2 Pregunta de investigación

¿Qué producción académica indexada en temas de Machine Learning y agronegocios se ha generado entre 2020 y 2026

5.Objetivos

5.1. Objetivo general

Analizar producción académica indexada en temas de Machine Learning y agronegocios se ha generado entre 2020 y 2026

5.2. Objetivos específicos:

- Describir las principales tendencias temáticas, enfoques metodológicos y dominios de aplicación presentes en la producción académica indexada sobre Machine Learning y agronegocios entre 2020 y 2026.
- Identificar los clústeres de decisión y los tipos de problemas gerenciales abordados en los estudios publicados en el periodo 2020–2026.
- Caracterizar los desafíos reportados en la literatura respecto a la implementación y adopción del Machine Learning en los agronegocios.

6. Justificación

Un crecimiento en las investigaciones sobre el Machine Learning en el sector agrícola, con las que se han realizado una gran cantidad de publicaciones en los últimos años. De estos estudios se logra evidenciar que el Machine Learning se ha posicionado como una herramienta tecnológica que mejora procesos, fortaleciendo la toma de decisiones (Botero-Valencia et al,2025). Junto con este crecimiento ha surgido la dificultad de identificar de manera estructurada las tendencias.

En la agricultura sostenible, Botero-Valencia et al (2025) menciona que en las investigaciones recientes se evidencia un aumento en el uso de herramientas como Machine Learning, herramienta usada para predecir los rendimientos, gestionar de manera efectiva los recursos y tener un mejor seguimiento ambiental. Reforzando lo mencionado por Botero, Sudha y Shajilin Loret (2025) logran demostrar que al momento de incorporar el Machine Learning en el sector agrícola, esto ha permitido ampliar las posibilidades de tener un monitoreo en tiempo real y lograr automatizar los cultivos.

De esta manera múltiples estudios han logrado demostrar que la inteligencia artificial y el Machine Learning, forman una parte estratégica dentro de los sistemas agrícolas, permitiendo su transformación hacia modelos más sostenibles. En este sentido autores como Ali et al. (2025) logra demostrar que al usar Machine Learning aplicado en el análisis de series de tiempo permite mejorar los procesos fundamentales dentro de la

agricultura, como serían lograr predecir rendimientos futuros, la selección adecuada de los cultivos, la detección temprana de enfermedades y una gestión, control mucho más eficaz de los recursos naturales. Con todas estas herramientas juntas contribuye significativamente al aumento de la productividad y de igual forma fortalece la toma de decisiones basada en los distintos datos, con lo que se reduce la incertidumbre y mejora la capacidad de reacción en diferentes escenarios productivos. Asimismo, el estudio persiste en que la integración de todas estas tecnologías, con sistemas, sensores, vistas satelitales y manejo de big data, permite que la agricultura avance en la sostenibilidad económica y ambiental.

Sin dejar de lado lo anterior, estas investigaciones también evidencia que existen una gran cantidad de enfoques metodológicos y aplicaciones tecnológicas que, en muchos casos se desarrollan de manera aislada. Esta situación dificulta la identificación clara de tendencias y distintas oportunidades reales de aplicaciones dentro del sector agrícola, por esta razón se hace necesario la revisión sistemática de literatura, las cuales permiten organizar y analizar todo este conocimiento existente, facilitando su comprensión y promoviendo usos más efectivos.

Está revisión sistemática es de gran importancia porque permite identificar tendencias temáticas y principales desafíos encontrados por investigaciones científicas. De esta manera la revisión ayuda a consolidar este conocimiento y logra proporcionar una base útil para investigadores.

6.1 Delimitación del estudio

Este estudio se delimita a un análisis de literatura e investigaciones sobre el Machine Learning en los agronegocios, enfocada en una agricultura que sea sostenible con artículos científicos publicados a partir del 2020 hasta el año 2026 en las bases de datos reconocidas y de confianza como podrían ser Web of Science y Scopus, esto para lograr garantizar una investigación de calidad e información analizada cuidadosamente.

La delimitación geográfica que presenta esta investigación es una delimitación internacional, ya que se basa en investigaciones desarrolladas en diferentes regiones del mundo. Esto se debe a que el desarrollo del Machine Learning aplicado en agricultura no se limita a un único territorio, sino que se logra completar y construir con los múltiples aportes e investigaciones de distintos contextos geográficos. De esta manera la inclusión de estudios internacionales permite que se obtenga una visión más amplia y completa sobre los avances tecnológicos .

Sin dejar de lado que el Machine Learning puede tener un gran alcance a nivel global, es importante reconocer la relevancia que este tiene en el sector local, específicamente en países en desarrollo donde pueden existir distintos desafíos en relación con su infraestructura y desarrollo tecnológico, por esta razón se analizan investigaciones similares en Latinoamérica.

Desde una perspectiva temporal, esta investigación se centra en artículos públicos entre el año 2020 y el año 2026, como objetivo lograr identificar las más importantes y recientes tendencias del Machine Learning para usar sus datos dentro del sector de la agricultura.

En el alcance temático, esta investigación se centra en analizar las aplicaciones del Machine Learning para lograr optimizar procesos dentro de agricultura, como lograr predecir los rendimientos, tener una mejor gestión de los recursos, monitorear de manera óptima los cultivos y tener una mayor sostenibilidad. Revisando tecnologías que complementan el sector, como son los sensores y más herramientas que funcionen en la evolución del sector.

7. Marcos de referencia

7.1 Estado del arte

El punto de inicio de la literatura actual reconoce la urgencia de una transformación tecnológica hacia el futuro de los agronegocios. Para Aijaz et al. (2025) y otros autores como Waqas et al. (2025) la población mundial aumentará hasta los 10 mil millones de personas para el año 2050 y también se proyecta un deterioro de hasta al menos 20% de tierras cultivables para el año 2030, teniendo en cuenta esta estimación herramientas digitales como el machine learning y la inteligencia artificial tendrán un papel importante en dicha transformación tecnológica dirigida hacia los agronegocios. Ben Ayed y Hanana (2021) respaldan la necesidad de implementar la tecnología en la agricultura, además se menciona que la solución para gestionar la compleja y cambiante situación climática es la agricultura basada en datos, el desafío radica en la efectividad de la transformación en América Latina, la CEPAL (Sotomayor et al., 2023) resalta que la digitalización deberá ser un instrumento para una transición en la agricultura y que la tecnología no debe buscar solamente beneficios económicos, sino la sostenibilidad en los campos, que es el centro de empleabilidad de dichas regiones.

Ya establecida las necesidades, la literatura encontrada propone soluciones con herramientas de monitoreo preventivo; Sudha y Shajilin Loret (2026) y Singh et al. (2025) explican como la incorporación del machine learning y otras herramientas permiten realizar una administración de los agronegocios más predictiva y preventiva, donde mediante un pronóstico de cosechas se

puede disminuir los riesgos financieros de los campesinos. Una versión ampliada más allá de la cosecha la propone Rejeb et al. (2025), este autor muestra una visión de la aplicación del Machine learning hacia la cadena de suministro, ya que la optimización logística de los productos apoyada por algoritmos y datos permite una reducción en los desperdicios. Esto en gran medida aporta a la producción, distribución y la agricultura sostenible, para generar un sistema integral donde cada dato generado en el campo sirva para tomar una decisión administrativa Botero-Valencia et al. (2025).

Existe una brecha en la implementación de las herramientas tecnológicas como el machine learning, Doda et al. (2025) revela que el acierto de estas herramientas depende de aminorar barreras financieras y la resistencia de prácticas tradicionales en los agronegocios. Además, existe demasiada información y ciencia en la literatura en herramientas digitales, pero poca claridad sobre cómo es su aplicación para que sea rentable, lo que lleva a confundirse o perderse en la teoría. Por lo tanto, se menciona el protocolo PRISMA 2020 (González-Teruel et al., 2021), que funciona como un filtro de precisión para eliminar literatura o información que no sirve y garantizar que el conocimiento encontrado esté basado en altos estándares de calidad académica. Por lo tanto, la revisión sistemática de la literatura 2020 al 2026 del presente documento busca un puente entre la producción científica encontrada y la realidad de los productores, al sistematizar la información se pretende identificar qué herramientas de machine learning son verdaderamente útiles y viables para la gestión de los agronegocios en la actualidad y en el futuro.

7.2 Marco conceptual

El marco conceptual define los términos esenciales para la efectiva comprensión de la unión entre el machine learning y los agronegocios, lo cual permite un análisis unificado de los procesos estudiados en la investigación.

- **Machine learning:** Es un subcampo de la Inteligencia Artificial que posibilita a los sistemas aprender a través de los datos e identificar patrones complejos con una mínima intervención humana. En los agronegocios, se utiliza para predecir variables como el clima, la demanda del mercado y la de los cultivos (Aijaz et al., 2025).
- **Deep Learning:** Rama de la inteligencia artificial que mediante una computadora imita el comportamiento humano, que utiliza redes neuronales para procesar grandes volúmenes de datos, como imágenes de drones o satélites, facilitando un monitoreo de precisión en los agronegocios (Waqas et al., 2025).
- **Agricultura 4.0 (Agricultura Inteligente):** Es la integración de tecnologías digitales en el sector agropecuario. Su principal objetivo es la optimización de la producción mediante decisiones basadas en datos en lugar de solo en la experiencia empírica o prácticas cotidianas en el sector agropecuario.
- **Big Data:** Conjunto de datos masivos de alta velocidad que requieren tecnologías avanzadas para su almacenamiento, procesamiento y análisis. En el sector agrícola, el Big Data permite integrar información climática, productiva y de mercado para alimentar modelos de machine learning (Aijaz et al., 2025).
- **Inteligencia Artificial (IA):** Se refiere a la capacidad de sistemas tecnológicos para representar procesos mentales o intelectuales, tales como el aprendizaje o la solución de problemas. En el sector agrícola, la IA actúa como un facilitador para la automatización y la optimización de recursos y por ende una mayor rentabilidad (Aijaz et al., 2025).
- **Agronegocios:** Comprende todas las actividades económicas derivadas de o

conectadas con los productos del campo, incluyendo la producción, el procesamiento, la distribución y la comercialización (Doda et al., 2025).

- **Transformación digital en agronegocios:** Proceso de integración de tecnologías digitales en los sistemas productivos y administrativos del sector agrícola, con el fin de mejorar la eficiencia, la competitividad y la toma de decisiones estratégicas (Sotomayor et al., 2023; Waqas et al., 2025).
- **Sostenibilidad Agrícola:** Modelo de producción agrícola que busca optimizar la eficiencia económica en el sector agrícola, la protección ambiental y el bienestar social, mediante el uso responsable de los recursos naturales y la adopción de tecnología que disminuyan impactos negativos (Sotomayor et al., 2023).
- **Cadena de Suministro Agrícola:** Es toda la línea de procesos que empieza desde la producción hasta la entrega final al consumidor. La aplicación del machine learning en la cadena de suministro busca mejorar la logística en los agronegocios y reducir desperdicios mediante datos (Rejeb et al., 2025).
- **Brechas Tecnológicas Rurales:** Disparidad socioeconómica entre comunidades que tienen acceso a la tecnología, estas brechas se ven mayormente en zonas rurales en Latinoamérica, CEPAL (Sotomayor et al., 2023) explica la desigualdad en el acceso a tecnologías entre el sector urbano y el rural.
- **Declaración PRISMA 2020:** Es un manual reciente para la elaboración y presentación de revisiones sistemáticas, mediante la elección de este método se garantiza que los artículos seleccionados entre 2020 y 2026 sean transparentes, reproducibles y de alta calidad (Page et al., 2021)
- **Clústeres de decisión:** Este término hace referencia a la agrupación de problemas usuales identificados en la literatura científica, los cuales orientan la toma de decisiones estratégicas en los niveles gerenciales en estos casos de los agronegocios.
- **Producción Académica Indexada:** Hace referencia a artículos o documentos científicos que previamente han sido evaluados y por ende se encuentran registrados en bases de datos como scopus, esto asegura la calidad y validez de la información.
- **EVA:** Evaluaciones agropecuarias municipales

7.3 Marco legal

Los agronegocios en desarrollo y el implementar tecnología como lo es el Machine Learning en la agricultura, se mantiene dentro de unas normativas que regulan la producción y la sostenibilidad. En Colombia son normas constitucionales, legales y políticas públicas, las cuales son fundamentales para la implementación de estas herramientas en el sector agrícola.

Según la constitución colombiana de (1991) se mencionan los lineamientos para el sector agrícola y protección del medio ambiente

Se menciona en la Constitución Política de Colombia (1991, el art. 65) se reconoce a la producción de alimentos como una actividad que requiere una protección especial por parte del estado, lo que indica una inclusión de tecnología que logre mejorar la productividad en el sector agrícola. En este mismo sentido la Constitución Política de Colombia (1991, el art. 79) establece que todas las personas deben gozar de un ambiente sano, mientras que la Constitución Política de Colombia (1991, el art. 80) menciona que el estado tiene como obligación el manejar y aprovechar los recursos naturales para lograr un desarrollo sostenible.

Implementar tecnologías como el Machine Learning en el sector agrícola va de la mano con estos principios constitucionales, en el sentido que esto permite optimizar el manejo de los recursos, que mejora su productividad, tomar mejores decisiones y minimizar los impactos negativos.

En Colombia en el sector ambiental la ley 99 de 1993 establece la creación del Sistema Nacional ambiental (SINA), en este se describen los principios de gestión ambiental en Colombia. Estos principios buscan el buen uso de los recursos naturales y el desarrollo sostenible (Ley 99, 1993).

De igual forma el decreto 1076 de 2015 regula el uso, manejo y conservación de los recursos naturales. Estas normas son muy importantes en relación con la tecnología como el Machine Learning ya que estás mejoran la eficiencia en el sector agrícola (Decreto 1076, 2015).

Al hacer uso de Machine Learning en el sector de la agricultura quiere decir que hacer un almacenamiento y procesamiento de datos siendo necesario que esto sea regulado. En este sentido entra la Ley 1581 de 2012 que regula la protección de datos personales. para garantizar el correcto tratamiento de la información. Esta norma controla aspectos como su recolección, almacenamiento y uso de datos personales, cumpliendo con derechos como el habeas data, la privacidad y confidencialidad de la información (Ley 1581, 2012).

Esta ley es de gran importancia debido a que los sistemas con Machine Learning utilizan los datos de distintas fuentes personales provenientes de productores o trabajadores del sector agrícola. Por esta razón se debe garantizar que el uso de estas tecnologías maneje la información bajo una legalidad y seguridad.

Pero también hay que tener presente que para muchas herramientas es necesario el acceso a información pública, acá entre la Ley 1712 de 2014 que regula el derecho de acceso a

información pública, que establece la transparencia y disponibilidad de información pública que genera el estado (Ley 1712, 2014).

En el sector agrícola acceder a información pública es de gran relevancia tener información como datos climáticos, estadísticas nacionales de producción y estudios

que realiza el gobierno, permite que tecnologías como el Machine Learning sean alimentadas con esta información, que permiten una mejor toma de decisiones y mejora la planificación. Según Botero-Valencia et al. (2025) resaltan que usar Machine Learning es necesario la integración de distintas fuentes de datos que mejoren la precisión de esta tecnología que ayuda a tomar decisiones, lo cual confirma la importancia de tener un marco legal que regule la disponibilidad de la información y la protección de datos.

Según Botero-Valencia et al. (2025) usar Machine Learning en la agricultura hace mucho más fácil en lograr analizar gran cantidad de datos, logrando generar predicciones para sacar un mejor provecho de los recursos, al tiempo que reduce un impacto negativo en el ambiente, esto siendo de gran importancia porque va en relación con la normativa.

En los agronegocios, se encuentra la Ley 101 de 1993 promueve la modernización, competitividad y mejorar la eficiencia del sector, esta ley promueve la adopción de las tecnologías para mejorar toda su productividad y rentabilidad (Ley 101, 1993).

El sistema nacional de innovación (SNIA) es creado por la Ley 1876 de 2017, el principal objetivo de este es mejorar la investigación y desarrollo tecnológico. Esta norma es de gran importancia en el Machine Learning, ya que promueve el uso de herramientas tecnológicas avanzadas en los procesos productivos (Ley 1876, 2017).

Con estudios más recientes demuestran que en el sector agrícola, apoyada con estas herramientas tecnológicas como machine Learning permiten mejorar la toma de decisiones, optimizar sus recursos y sostenibilidad (Botero - Valencia at al.,2025)

7.4 Marco teórico

Los grandes avances tecnológicos han logrado transformar el sector agrícola, desde maneras muy tradicionales aprendidas de manera empírica y trasladadas de generación en generación, hasta los sistemas con análisis de datos. En este proceso el Machine Learning se posiciona como una herramienta de gran ayuda para lograr optimizar la producción en el sector agrícola.

El Machine Learning con los datos históricos, permite generar una serie de predicciones sin la necesidad de tener programación por cada tarea. Estas predicciones en el área agrícola, permiten conocer los posibles rendimientos, lograr detectar alguna enfermedad, tener un uso óptimo de recursos. Según Rejeb et al. (2025), el incremento de las investigaciones de Machine Learning y sus funciones en agricultura, evidencia una integración de ciencia de datos, ingeniería y economía.

La predicción para los cultivos con Machine Learning es una de las herramientas más destacadas en la agricultura. De esta manera Singh et al. (2025) quien analiza los principales focos de autoaprendizaje que son utilizados para mejor los procesos

agrícolas, aumentando la confiabilidad. De igual manera enfocó su estudio en distintas técnicas que permitan grandes cantidades de datos ser procesados.

Involucrar el Machine Learning hace que una agricultura reactiva a una agricultura que se pueda predecir, basada en datos. Siempre buscando minimizar pérdidas, anticipar cambios y mejorar la toma de decisiones.

Esta incorporación del Machine Learning en el sector agrícola debe entenderse junto con la inteligencia artificial, de esta manera Ben Ayed y Hanana (2021) hicieron una revisión donde los usos de la inteligencia artificial en el sector de la agricultura, se destacó que el Machine Learning es un sistema fundamental. La inteligencia artificial hace parte de varias tecnologías como lo podría ser Big Data, sensores. Estas herramientas permiten la automatización de los procesos.

Que, por su gran potencial para transformar procesos, el Machine Learning dentro de la agricultura también presenta una serie de limitaciones. Como lo serían sus elevados costos en infraestructura, también la dificultad de capacitación de los agricultores.

Rejeb et al. (2025) menciona la importancia de que en investigaciones futuras sean orientadas en lograr fortalecer la adopción del Machine Learning y más prácticas tecnológicas que mejoren la toma de decisiones. Estas limitaciones demuestran que para lograr tener esta transformación no depende únicamente de factores sociales y económicos, sino también la disponibilidad de tecnología. Bajo este contexto de necesidad tecnológica y digitalización del campo, surge el concepto técnico que viabiliza dicha evolución. Por lo tanto, la presente investigación propone los subtemas a abordar (Machine Learning, Agronegocios y Brechas y desafíos en la implementación del Machine Learning en el sector agrícola).

7.4.1 Machine Learning

El Machine Learning es una herramienta tecnológica que hace parte de la inteligencia artificial que aprende a partir de datos, identifica patrones y toma decisiones sin ser programado como otras inteligencias artificiales. Esta herramienta tecnológica se ha vuelto de gran importancia en distintos sectores, como podría ser el sector agrícola y agronegocios mejorando su productividad, mejor manejo de recursos y tomando mejores decisiones.

Es definido como una herramienta que le permite a las máquinas aprender de experiencias, basado en datos para lograr generar predicciones, clasificar o identificar patrones y posibles escenarios (Lejos et al., 2018). El uso de datos conformados por distintas variables, que son procesados por algoritmos logra construir los modelos para tomar decisiones.

Para el sector agrícola el Machine Learning ha evolucionado con tecnologías como el Big Data, sensores y otros dispositivos, logrando el desarrollo de la agricultura de precisión. Según Liakos et al. (2018), esto ha ayudado poder analizar de grandes cantidades de datos, como condiciones climáticas, estados de cultivos y datos operativos, esto mejorando la capacidad de respuesta, adicionalmente el Machine

Learning es fácilmente aplicable a distintas áreas del sector. Donde según Liakos et al. (2018), sus principales aplicaciones se concentran en la capacidad para gestionar cultivos, ganado y gestionar agua.

Por otro lado, Botero-Valencia et al. (2025) resaltan que el Machine Learning ha cambiado la gestión de los agronegocios ya que este permite tener un mejor manejo de los recursos. Esta herramienta facilita procesos como estimar los rendimientos, detectar enfermedades, logrando mejorar la capacidad de reacción y lograr tomar decisiones más eficiente.

Por el mismo camino, Benos et al. (2021) destacan que el Machine Learning tiene un papel fundamental para la transformación digital del sector agrícola y los agronegocios, al permitir manejar grandes cantidades de datos y convertirlas en información útil para tomar decisiones. Para la agricultura inteligente el Machine Learning logra facilitar la construcción de sistemas basados en conocimiento, que son capaces de analizar datos provenientes de distintas fuentes, generando valor a nivel productivo como ambiental.

Donde también el estudio de Benos et al. (2021) menciona que el Machine Learning en el sector agrícola se ha impulsado por el crecimiento del Big Data y la necesidad de mejorar los sistemas productivos, para enfrentar los desafíos que se presentan a nivel global como el cambio climático, una mayor demanda en productos agrícolas y la escasez de recursos naturales. El usar programas de aprendizaje automático logra permitir que se mejore la eficiencia, mejorando el equilibrio entre productividad y sostenibilidad. Estos autores logran identificar que la gran parte de las aplicaciones del Machine Learning están enfocadas en la gestión de cultivos, enfocados en la predicción de rendimientos, detectar enfermedades y tener un mejor control.

Según Araujo et al. (2023) en su investigación Machine Learning Applications in Agriculture: Current Trends, Challenges, and Future Perspectives, una parte crucial para lograr implementar el Machine Learning es la gran dependencia que se tiene de los datos masivos y que sean de gran calidad, algo que lo vuelve una limitación muy significativa, siendo una gran diferencia con otros sectores que los datos ya están más estandarizados, ya que en el sector agrícola estos presentan una alta variabilidad. De esta forma no quiere decir que lo

único importante es contar con una gran cantidad de datos de distintas fuentes, sino la capacidad de garantizar su importancia a lo largo del tiempo y ciclos productivos.

En relación con lo anterior ya mencionado, este estudio permite evidenciar que uno de los desafíos es la brecha que hay en la adopción de esta tecnología, especialmente en zonas rurales o en lugares productivos de pequeña escala. La implementación del Machine Learning no requiere solo de tecnologías avanzadas, sino también tener capacidades para poder usarla e interpretarlas. Esto quiere decir que la digitalización del sector agrícola está aferrada a factores económicos y culturales, lo que evidencia una desigualdad dentro del sector, de esta manera el único reto no es lograr desarrollar modelos tecnológicos avanzados, sino diseñar modelos que sean de fácil acceso, y orientados al perfil del usuario final. La implementación de sensores o plataformas digitales pueden generar grandes cantidades de información que deben ser procesadas

de manera eficiente para que estas tengan algún valor. Esto a la vez exige una buena infraestructura avanzada capaz de manejar mayor datos en Big Data, que sigue siendo un desafío tanto la inversión como la implementación y el manejo de esta en el sector.

7.4.2 Agronegocios

El concepto de agronegocios se define como la producción en el campo; lo cual se determina como un proceso que integra la provisión de insumos, producción primaria, logística y comercialización de los productos agrícolas (Doda et al., 2025). Los agronegocios contemporáneos son de vital importancia para el desarrollo actual en América latina, para CEPAL (Sotomayor et al., 2023), este sector es uno de los más importantes económicamente de América latina y presenta múltiples desafíos, en este escenario, la gestión administrativa debe ir orientada a decisiones que tengan respaldo científico y evidencia técnica, donde mediante datos se mitigue riesgos no contemplados como la variabilidad climática del entorno rural.

Actualmente en Colombia como en América latina representan uno de los sectores más dinámicos de la economía nacional. Según proyecciones sectoriales nacionales, el sector agrícola del país alcanzó un valor de USD 10,43 mil millones en 2025, con una tasa de crecimiento anual que se estima en el 6,71% hacia el 2035 (Informes de Expertos, 2025), este crecimiento se ve drásticamente promovido por la diversificación de cultivos y un ligero aumento en las exportaciones de productos agrícolas insignia de la economía colombiana como los son el café, las flores etc., para la gestión de estos datos Colombia cuenta con las evaluaciones agropecuarias municipales (EVA), que es el sistema oficial del ministerio de agricultura y desarrollo rural (MADR, 2025) que evalúa datos sobre áreas sembradas, cantidad de producción y rendimientos por hectárea en todo el territorio nacional. Una de las

oportunidades que se presentan para los agricultores es transformar todos esos datos en decisiones estratégicas mediante herramientas digitales como el machine learning que permitan aumentar la utilidad y reducir la incertidumbre.

En el sector agrícola colombiano enfrenta barreras críticas como la brecha tecnológica en el campo y la adopción de prácticas tradicionales que disminuyen la eficiencia de los agronegocios (Sotomayor et., al 2023). La necesidad de una transición hacia una agricultura 4.0 precisa que datos estadísticos e información relevante sobre la agricultura de las EVA se combine con modelos de aprendizaje automático predictivos, lo cual ayudaría a factores como la reducción de incertidumbre y anticipar riesgos en las cosechas, la optimización de la cadena de suministro reduciendo desperdicios, impulsar la sostenibilidad en la aplicación de pesticidas o insumos en el suelo, entre otros beneficios.

Es imperativo analizar la dinámica de la producción agrícola nacional en 2025, para poder realizar una gestión eficiente de las superficies sembradas y su variabilidad. Según los resultados suministrados por las EVA, en 2025 el área cultivada a nivel nacional presentó una reducción de 66.899 hectáreas (-1,2 %) frente a 2024. Este comportamiento refleja un ajuste moderado en el sector agrícola, esto se da principalmente en la caída del grupo de los alimentos específicamente la categoría de

los cereales y frutales (UPRA, 2026). (Ver tabla 1).

Grupo de cultivos	Área cultivada (ha)		Variación 2025/2024	
	2024	2025	Absoluta (ha)	Relativa (%)
Alimentos	3.084.331	3.006.343	-77.988	-2,5 %
Cereales	1.234.954	1.219.062	-15.892	-1,3 %
Frutales	1.102.509	1.042.951	-59.558	-5,4 %
Hortalizas	129.280	132.770	3.490	2,7 %
Leguminosas	128.415	127.884	-531	-0,4 %
Raíces y tubérculos	489.172	483.676	-5.497	-1,1 %
Otros cultivos	2.424.384	2.435.473	11.089	0,5 %
Cultivos tropicales tradicionales	1.647.808	1.630.206	-17.601	-1,1 %
Oleaginosas	772.292	801.385	29.093	3,8 %
Condimentos, medicinales y aromáticas	4.285	3.882	-403	-9,4 %
Total	5.508.715	5.441.816	-66.899	-1,2 %

Nota. Adaptado de las Evaluaciones Agropecuarias Municipales (EVA) por la Unidad de Planificación Rural Agropecuaria [UPRA] (2025).

Como se puede observar en la tabla 1, que compara el área cultivada y su variación entre el año 2024-2025, el grupo de alimentos que más tuvo disminuciones en cuanto a áreas cultivadas son los cereales con una caída del 1.3% y los frutales con una reducción del 5.4%, en otros cultivos que sugieren menos participación en áreas sembradas se encuentran los condimentos, medicinales y aromáticas con un decrecimiento del 9.4%, sin embargo esta última variación representa el menor cultivo de áreas sembradas (ha). Aunque otros grupos de cultivos

muestran aumentos, existe un decrecimiento total de las áreas cultivadas en el 2025 lo que subraya la fragilidad de los cultivos frente a escenarios no tan favorables como factores climáticos. Esto señala áreas de oportunidad para inversión tecnológica.

La labor de la unidad de planificación rural (UPRA, 2025) resulta fundamental, aun así, la integración de modelos tecnológicos como el machine learning permitirá que la planificación del territorio sea eficaz mediante el procesamiento de todos estos datos estadísticos. La integración de algoritmos predictivos posibilita tomar decisiones para identificar patrones ocultos tras la disminución de la siembra de cultivos, transformando dicha incertidumbre en ventajas competitivas para los agronegocios en Colombia.

7.4.3 Brechas y desafíos en la implementación del Machine Learning en el sector agrícola

El sector agrícola puede presentar una serie de desafíos y brechas al momento de querer implementar el Machine Learning, Según Araújo et al. (2023) él reconoce que el verdadero desafío para adoptar el Machine Learning en la agricultura no es solo tener un buen desarrollo tecnológico, sino en un buen sistema para tomar las mejores

decisiones. Esto quiere decir que el buen funcionamiento de estos modelos tiene una fuerte dependencia de la capacidad para transformarlas en acciones que mejore su productividad, logre reducir sus costos y mejore todos sus procesos. En ese sentido el futuro del Machine Learning en el sector agrícola estará determinado por la capacidad que se tenga para lograr transformarla de una herramienta analítica a una de gestión de los sistemas productivos.

Teniendo en cuenta que el Machine Learning puede tener múltiples beneficios, presenta otros desafíos importantes, como podría ser la disponibilidad de información pública o privada, calidad de esta información, tener una buena infraestructura tecnológica y lograr adoptar estos modelos a unas condiciones locales específicas. En este caso, la CEPAL (2025) afirma que la digitalización de la agroindustria en América Latina se enfrenta a limitaciones estructurales directamente relacionadas con la baja conectividad en zonas rurales y el difícil acceso a tecnologías digitales, lo que dificulta la transición e implementación a herramientas avanzadas como el Machine Learning. Como la falta de una adopción tecnológica en las zonas rurales de Colombia donde según Botero-Valencia et al. (2025) mencionan que aún existen una gran cantidad de vacíos para lograr comprender y aplicar sistemas tecnológicos como el Machine Learning, mencionando que sigue siendo necesario la continuación de investigaciones y fortalecer su desarrollo para que estos sistemas sean de mayor alcance a cualquier zona rural.

Por otro lado, hay otros autores que en sus investigaciones confirman lo que otros autores continúan destacando, como la investigación de Benos et al. (2021) que reconoce que el

Machine Learning ha tenido unos avances significativos en el sector agrícola a través de los años, siendo para el 2021 representativos los mismos retos que hoy en día siguen siendo un reto en la implementación de esta tecnología, como podrían ser la dificultad para lograr la recolección de datos que sean significativos a condiciones reales, los elevados costos de implementar esta tecnología y la necesidad de que el desarrollo de estos sistemas sean de fácil acceso, uso y que sean comprensibles para los agricultores que en su mayoría toda la vida han vivido en zonas rurales. De igual manera, la CEPAL (2025) señala que uno de los principales obstáculos para llegar a una transformación digital en el agro es asegurar que las tecnologías sean inclusivas, adaptables y escalables para los productores, evitando de esta manera que se profundicen aún más las brechas tecnológicas existentes en el sector. Estos desafíos continúan demostrando la importancia de continuar investigando y desarrollando enfocados en los usuarios de estos sistemas, para lograr una implementación más efectiva del Machine Learning en el sector agrícola.

El Machine Learning con el pasar de los años se sigue posicionando como una herramienta fundamental para lograr la transformación digital del sector agrícola, permitiendo que estos logren desarrollar un sistema que sea más productivo y más eficiente, que al tiempo sea mucho más sostenible y todo esto basado en datos, que van de la mano con las nuevas herramientas que están apoyando el sector agrícola y sus agronegocios.

En este contexto, la transición hacia la digitalización agrícola en América latina y el caribe no solo representa una oportunidad para mejorar en múltiples aspectos la productividad del campo, sino también significa un reto que requiere la superación de barreras tecnológicas, económicas y sociales para la sostenibilidad del sector agrícola. Según la CEPAL (2025), es primordial mejorar la conectividad rural e impulsar el acceso equitativo en zonas rurales para lograr una adopción eficaz de herramientas digitales como el Machine Learning. Así mismo, la transición a una transformación digital en el campo no solo dependerá del avance tecnológico, sino también de la capacidad de crear entornos inclusivos y participativos que permitan a los agricultores integrar herramientas digitales en sus procesos productivos y la mejora en la toma de decisiones, para que de esta manera se pase de procesos tradicionales que de cierta manera son poco eficientes a una verdadera transformación del sector agrícola.

7.4.4 Clústeres de decisión y tipos de problemas gerenciales

El análisis de los artículos permitió identificar los distintos clústeres de decisión relacionados con el Machine Learning en el sector agrícola y los agronegocios. Entre los principales clústeres identificados corresponde a la predicción de rendimientos, en el cual los estudios se enfocan en modelos de Machine Learning para poder estimar la producción con distintas condiciones, este clúster responde a problemas gerenciales relacionado con la planificación, estimación y toma de decisiones estratégicas.

La detección de enfermedades y plagas, donde el Machine Learning es utilizado con imágenes tomadas por drones o cámaras digitales, para poder identificar de forma temprana las posibles afectaciones en los cultivos, este clúster aborda problemas gerenciales con la reducción de pérdidas.

Otro clúster identificado corresponde a gestionar de manera eficiente la materia prima, especialmente como el uso del agua, fertilizantes y energía. Este clúster busca solucionar problemas gerenciales como la optimización de costos operativos y el uso sostenible de los recursos, permitiendo tener una eficiencia productiva en el sector agrícola y los agronegocios.

8. Diseño metodológico

8.1 Tipo de investigación

Esta investigación se clasifica como una descriptiva, ya que identifica y analiza las principales características del objeto de estudio, que es el Machine Learning en el sector agrícola. Según Hernández Sampieri (2014), los estudios descriptivos tienen como finalidad especificar las propiedades, características, grupos y objetos que estén en análisis, permitiendo ser comprendidos con mayor precisión.

Asimismo, la investigación descriptiva permite que se establezca una base sólida para lograr comprender fenómenos tecnológicos emergentes, que facilita identificar

tendencias para su implementación. Donde Hernández Sampieri et al. (20214) resalta que la investigación descriptiva no solo está limitada a recolectar datos, también esta requiere un análisis y organización, para poder tener una visión más detallada.

De esta forma la investigación descriptiva permite detallar particularidades del estudio, sin tener que intervenir directamente, únicamente enfocados en poder observar, recopilar y organizar toda la información disponible. Esto siendo muy relevante para este estudio ya que esto facilita el análisis de las aplicaciones, beneficios, limitaciones y desafíos del Machine Learning en el sector agrícola.

Seleccionar la investigación descriptiva para esta investigación se fundamenta en la necesidad de analizar de una manera muy detallada las aplicaciones y limitaciones del Machine Learning en el sector agrícola, junto con el análisis de información existente de artículos científicos publicados del 2020 al presente año, permitiendo lograr identificar tendencias y características relacionadas con el uso del Machine Learning en el sector agrícola, ya que al ser descriptiva facilita organizar y comprender el estado actual del Machine Learning.

8.2 Paradigma

Esta es una investigación con un paradigma empírico-analítico ya que se fundamenta en la observación y análisis de artículos científicos que contengan información verificable y confiable. Según Tamayo y Tamayo (2004), este paradigma está orientado en estudiar los distintos fenómenos a partir de la experiencia, que buscan explicar mediante la recopilación y análisis de información que pueda ser comprobada. De esta forma el conocimiento científico se logra con hechos observables y verificables, que permitan analizar y comprender los distintos fenómenos.

En este mismo sentido Tamayo y Tamayo (2004) resaltan que el paradigma empirico-analitico se reconoce por el uso de procedimientos muy rigurosos que permiten identificar las relaciones entre las distintas variables y lograr comprender con base a las evidencias, esto enfocado en la recopilación de información ordenada con el propósito de lograr transmitir esta información para generar conocimiento válido y confiable, siendo el paradigma empirico-analitico con gran relevancia para investigaciones que buscan describir y analizar objetos de estudio con la información verificable.

Esta investigación busca analizar de manera objetiva las aplicaciones del Machine Learning en el sector agrícola, con la revisión y organización de toda la información que se encuentre en fuentes como Scopus y Web of science, fuentes científicas y académicas. Esto permite que el objeto de estudio sea desde la evidencia, utilizando datos y resultados en investigaciones previas ya documentadas. El paradigma empírico-analítico en esta investigación permite comprender el Machine Learning en el sector agrícola y agronegocios, con el análisis de información verificable de estudios científicos. Buscando las principales características, aplicaciones, beneficios y

limitaciones de esta tecnología dentro del sector agrícola, permitiendo que se haga con datos verídicos y no interpretaciones subjetivas.

De igual manera este paradigma permite que el objeto de estudio se haga de una manera lógica y estructurada, donde se facilita la organización y el análisis de la información recolectada de las investigaciones científicas para permitir que el análisis del Machine Learning se haga de la manera correcta, con los artículos en fuentes científicas, facilitando que la construcción sea una buena base teórica sólida que logre permitir comprender las aplicaciones tecnológicas y productivas en el sector agrícola, que logran contribuir al desarrollo del conocimiento tecnológico en el campo.

8.3 Enfoque

La presente investigación se desarrolla bajo un enfoque cualitativo. Según Hernández-Sampieri et al. (2014) el enfoque cualitativo en una investigación “utiliza la recolección y análisis de los datos para afinar las preguntas de investigación o revelar nuevas interrogantes en el proceso de interpretación” (p. 7). Por lo tanto, el enfoque cualitativo comprende el conjunto de prácticas interpretativas para lograr comprender un problema con mayor profundidad abordando la recolección, análisis y evaluación de datos buscando principalmente el incremento o dispersión de la información recolectada en las bases de datos. Se diferencia del enfoque cuantitativo, ya que no se busca la conceptualización estadística, en cambio se prioriza la calidad interpretativa y la comprensión de los datos recopilados finalmente.

Por consiguiente, la adopción de este enfoque de tipo cualitativo es el más adecuado para el desarrollo y cumplimiento de objetivos de la investigación. El actual objeto de estudio no está orientado a la ejecución de algoritmos o a la disciplina cuantitativa, que evidentemente está intrínsecamente relacionada con los componentes del Machine Learning, sino a la interpretación, análisis y categorización de la producción académica existente, realizando una búsqueda sistemática en las bases de datos tales como Scopus y Web of Science, con el objetivo fundamental de analizar la producción académica indexada. Lo que permite identificar las principales tendencias temáticas, enfoques metodológicos, desafíos y clústeres de decisión que requieren una comprensión conceptual que enfoques cuantitativos con cifras por sí solos no pueden proporcionar. Además, el enfoque cualitativo es el más adecuado para procesar y sintetizar el gran volumen de información científica, ya que permite la recolección, análisis y evaluación de los artículos científicos caracterizando el estado actual del sector y proponer una ruta estratégica clara de la producción académica encontrada para el panorama nacional.

Concluyendo, la investigación busca establecer una relación entre la tecnología del machine learning y los agronegocios, mediante la sistematización de la producción académica indexada de los temas mencionados en el periodo del 2020-2026. El enfoque cualitativo permite examinar preguntas incluyendo el “porqué” y “cómo” de la adopción tecnológica en los agronegocios. Por lo tanto, se podrá clasificar la información encontrada facilitando la comprensión de cómo estas transiciones

tecnológicas modifican la toma de decisiones en el agro.

8.4 Diseño de la Investigación.

La presente investigación se fundamenta en un diseño de revisión sistemática de la literatura, dicho enfoque se distingue de las revisiones bibliográficas habituales por su tipo minucioso, estructurado y verificable. Según Page et al., 2021, la revisión sistemática de la literatura es un proceso que emplea protocolos para minimizar el sesgo de la selección de la producción académica, posibilitando una valoración analítica de los artículos disponibles sobre una problemática en particular. En el marco agrícola y de Machine Learning, esta estructura permite sintetizar un alto volumen de hallazgos en materia de literatura académica para los temas del actual estudio. Por consiguiente, se utilizará la declaración PRISMA 2020 (Preferred Reporting Items for Systematic Reviews and Meta-Analyses). Esta es una guía internacional que más allá de solo ser una lista de verificación, es un marco lógico que permite que la búsqueda de la información sea reproducible y verificable; lo cual quiere decir, que en temas investigativos cualquier otra persona interesada en el tema puede llegar a las mismas conclusiones o similares, siguiendo los mismos criterios y fases, de este modo se garantiza la validez interna del estudio. (Page et al., 2021). El actual estudio tiene un enfoque de tipo cualitativo, mediante la revisión sistemática de la literatura de temas de machine learning y agronegocios. Bajo las directrices de la declaración PRISMA 2020 se permiten la filtración técnica y transparente de los artículos, asegurando que la recopilación final de documentos sobre Machine Learning y Agronegocios posea la validez científica necesaria. Para la revisión que explica (Page et al., 2021), la declaración PRISMA 2020 consta de un diagrama de flujo de 3 etapas. Para la presente investigación funcionará como un instrumento de control de sesgos, lo cual garantiza que la clasificación de los artículos cumpla con los objetivos de estudio

La declaración PRISMA 2020 exige el procedimiento de 3 fases críticas, cada una con un propósito técnico específico para el éxito de la sistematización:

8.4.1 Fase de Identificación

La primera fase constituye el ingreso de la información de la producción académica indexada, en este punto el objetivo es captar el mayor número posible de artículos de gran relevancia. Por lo tanto, se realizará una búsqueda exhaustiva en las bases de datos de mayor prestigio científico y académico (Scopus y Web of Science WoS). Dichas bases de datos se seleccionaron debido a su riguroso proceso de indexación, que plenamente asegura que la producción académica sobre Machine Learning y Agronegocios posean una base metodológica comprobada.

Para asegurar la precisión en la indagación sobre principales temas de investigación, se emplearon ecuaciones o patrones de búsqueda avanzados que integren operadores booleanos (“AND”, “OR”, “NOT”) y palabras claves para especificar la recolección de artículos tales como: “Machine Learning” and “Agribusiness” or “Agriculture”. Los

descriptores serán escritos en inglés debido a que es el idioma predominante en la producción de tecnología de última generación. (Page et al., 2021)

8.4.2 Fase de Cribado o Screening

En esta fase se realiza el primer filtro de relevancia, una vez recolectados los registros se realizará un proceso de filtrado minucioso para la eliminación de duplicados, asegurando la efectividad en el manejo de las bases de datos. En este punto también se efectuarán los criterios de inclusión y exclusión detallados de la siguiente manera:

Criterio	Criterios de Inclusión	Criterios de Exclusión
Temporalidad	Artículos publicados entre 2020 y 2026.	Documentos anteriores a 2020.
Tipo de Fuente	Artículos de revistas científicas indexadas (Scopus y Web of Science)	Blogs, opiniones, literatura gris.
Idioma	Inglés (por ser el idioma de mayor impacto).	Otros idiomas que dificulten la interpretación técnica.
Temática Principal	Aplicación de ML con relación a factores agrícolas.	Estudios de ML aplicados a medicina, finanzas puras o áreas no agrícolas.
Enfoque Geográfico	Estudios globales con modelos de ML aplicables a cultivos y climas similares del entorno colombiano.	Contextos agroecológicos incompatibles con el entorno colombiano.

Bajo los criterios de inclusión y exclusión propuestos, se realiza el filtrado manual enfocado en la lectura crítica de títulos y resúmenes, descartando artículos que, aunque mencionen palabras clave no abordan la aplicación del machine learning a la gestión de los agronegocios. La ejecución de esta etapa debe ser de bastante rigurosidad, ya que este paso reduce significativamente el volumen de información, filtrando solamente los documentos que tengan un potencial con real aporte.

Los artículos preseleccionados previamente se someterán a una lectura más profunda e integral, el propósito es verificar si el documento cumple estrictamente con los criterios de inclusión y exclusión detallados en el punto anterior, además evaluar la calidad y pertinencia de los mismos. Por lo tanto, detallar que el artículo no solamente desarrolle temas tecnológicos y de machine learning, sino que bajo un criterio riguroso se evalúa si el artículo está vinculado con la gestión agrícola y modelos algorítmicos de machine learning. En consecuencia, este paso filtra por última vez los artículos anteriormente preseleccionados para que de esta manera se evidencie la calidad del trabajo interno y se obtengan los resultados esperados. (Page et al., 2021)

8.4.3 Fase de inclusión

Esta es la fase final de la declaración prisma donde se define el cuerpo del documento final, los artículos incluidos para esta etapa son aquellos que superaron todos los filtros anteriormente detallados y que poseen la robustez necesaria para ser sometidos a la extracción de datos y conclusiones sobre la investigación. En esta etapa se garantiza que los artículos seleccionados sean pertinentes y coherentes con el fin de la investigación, asegurando la validez de los resultados obtenidos. Para esta fase final no solo se enlistan los documentos, sino se prepara la recolección para un análisis de los hallazgos encontrados para posteriormente ser clasificados en una matriz de análisis literario. Por consiguiente, se ordenarán variables clave como: Autores, año de publicación, aportes al campo de estudio etc. Lo que permite una comparación estructurada de la recolección entre los artículos seleccionados. Además, esta fase facilita la identificación de patrones o tendencias en la literatura seleccionada, lo cual permite una interpretación más profunda sobre los resultados, y por ende un análisis crítico y la generación de conclusiones fundamentadas. (Page et al., 2021)

8.5 Línea investigativa

8.5.1 Área y Línea de Investigación

La línea de investigación del presente estudio corresponde a las siglas CESEIC, la cual significa centro de estudios sobre emprendimientos de innovación y creatividad.

8.6 Técnicas e instrumentos de recolección

Para la recolección, clasificación y análisis de la información, se utilizaron distintos tipos de instrumentos esenciales que garantizan la trazabilidad del estudio, los cuales son: Bases de datos (Scopus y Web of Science), Diagrama de flujo PRISMA 2020, Matriz de Análisis Literario y Gestores bibliográficos para la organización de la literatura (Mendeley)

El diagrama de flujo propuesto por la declaración PRISMA 2020 permite visualizar el filtro realizado por los investigadores de la producción académica indexada en temas de machine learning y agronegocios en el periodo del 2020-2026. En el cual se notifica el número de registros identificados en Scopus y Web of Science, los documentos descartados por duplicados o baja relevancia (para evaluar el número de duplicados es esencial el uso de gestores bibliográficos como Mendeley) y finalmente los artículos incluidos en el análisis cualitativo. El diagrama de flujo PRISMA 2020 es fundamental para evidenciar la transparencia y efectividad de la búsqueda realizada.

Una vez definido y finalizado el corpus final de los documentos, se procede a analizar el contenido encontrado mediante una Matriz de Análisis Literario diseñada en Microsoft Excel y adecuada al documento, para la realización de dicha matriz se tendrán en cuenta criterios relevantes e indagación por parte de los investigadores. Este instrumento es la base de datos primaria de la investigación, la cual permite dividir los artículos encontrados para su mayor comprensión y análisis.

9. Resultados

9.1 Análisis de Resultados

9.1.1 Matriz de Análisis Documental

Nº	Fuente/ Referencia	Nombre del artículo	Año	País	Palabras clave	Resumen	Hallazgos
1	Scopus (Mirmazloumi et al., 2026)	Monitoreo de alta resolución de la sequía agrícola intraestacional utilizando Sentinel-2 y ML en temporadas de cultivo bimodales en Kenia.	2026	Kenia	Sequía agrícola, Monitoreo del estado de los cultivos, Kenia, Machine Learning, Sentinel-2	La investigación propone un modelo de funcionamiento para el monitoreo de sequías agrícolas a nivel nacional en Kenia utilizando datos de alta precisión suministrados por satélites (Sentinel-2) y algoritmos de ML (Random Forest). El estudio integra datos fenológicos con el objetivo de analizar cultivos afectados por condiciones climáticas en el periodo comprendido entre 2016 y 2022.	El estudio verifica la funcionalidad del algoritmo Random Forest, ratificando una correlación con estadísticas gubernamentales en Kenia. La investigación determinó en el periodo analizado una constante afectación climática en zonas agrícolas, teniendo su punto más álgido durante el año 2022, considerando una afectación alrededor del 90% en áreas de cultivo. El estudio demuestra la ventaja estratégica del uso del Sentinel-2 fortaleciendo los sistemas de alerta temprana ante riesgos climáticos, en compañía del Random Forest.

2	Scopus (Mi et al., 2026)	Impacto del cambio climático en la productividad primaria neta de las tierras agrícolas: evidencia de proyecciones multiescenario en Japón.	2026	Japón	Cambio climático, Tierras agrícolas, Machine Learning, PPN, SSP.	El estudio desarrolla la implementación de Machine Learning de alta precisión y resolución el cual lo llaman cuadrícula 500 m, para tener una proyección del impacto climático sobre la productividad primaria neta (PPN) de la agricultura en Japón. La investigación realiza un análisis de Trayectorias Socioeconómicas Compartidas (SSP) a corto, mediano y largo plazo, todo esto en conjunto para entender la vulnerabilidad agrícola ante el calentamiento global.	La investigación valida el uso del instrumento de ML utilizado, asegurando su funcionamiento en la predicción de las PPN. Teniendo un leve margen de error en el empleo del algoritmo, sin embargo el estudio propone una herramienta de confianza para la planeación de cultivos y usos agrícolas en Japón.
3	Scopus (Carbajal et al., 2026)	Pronóstico del rendimiento durante la temporada de cultivo mediante observaciones ambientales multitemporales de teledetección y	2026	Estados Unidos	Toma de decisiones agrícolas, Algoritmos de aprendizaje conjunto, Compuestos derivados de satélites, EE. UU, Índice de vegetación,	La investigación integra algoritmos de machine learning como Random Forest para el pronóstico del rendimiento de la batata (Tubérculo). El estudio consiste en el análisis de variables como el suelo, la altitud, precipitaciones	Los rendimientos encontrados del algoritmo Random Forest fueron de gran relevancia para este estudio, encontrando que los datos analizados al comienzo y mediados de la temporada son suficientes para tener proyecciones claras sobre las cosechas de batatas, sin necesidad de evaluar las fases

		aprendizaje automático: Aplicaciones para la batata en Carolina del Norte, EE. UU.			Predicción de rendimiento	y temperatura en un periodo de 16 días, con el objetivo de predecir el rendimiento de los cultivos días o semanas antes.	finales. Logrando así, una ventaja para los productores optimizando la planificación y estrategias de venta para sus cultivos.
4	WOS (Karbassi Yazdi et al.,2026)	Pronóstico del rendimiento de cultivos en la India de secano: una evaluación comparativa de modelos base de aprendizaje automático y sus implicaciones para el agronegocio de precisión	2026	India	Ensemble learning, Agricultura de secano, Pronóstico del rendimiento de los cultivos	Analiza el uso de modelos de aprendizaje automático para lograr predecir el rendimiento que pueden tener en sus cultivos en el sector agrícola con las lluvias de India. Usaron 3 distintos modelos donde se comprobó que el Random Forest logró el mayor rendimiento	Se encontró que el modelo llamado Random Forest fue el que obtuvo mayor desempeño para predecir el rendimiento de los cultivos, comprobando que la temperatura y factores climáticos son los más influyentes en la productividad agrícola.
5	WOS (Motta et al.,2025)	Técnicas de aprendizaje automático para la clasificación del café: una revisión integral de la investigación científica	2025	Brasil	Inteligencia artificial, Machine Learning, Visión por computadora, Clasificación de los granos y hojas de café	En el artículo se habla de una investigación sobre el Machine Learning para poder clasificar características del café, defectos, niveles de tostado, madurez y calidad, los resultados demostraron que esta tecnología permite mejorar la precisión para clasificar	El estudio comprobó que el Machine Learning como redes neuronales son los más utilizados para clasificar café en sus distintas etapas de producción.

						café.	
6	WOS (Quadras et al. ,2023)	Aprendizaje automático aplicado a la toma de decisiones logísticas: mejoras en el proceso de clasificación de semillas de soja	2023	Brasil	Machine Learning, agronegocios 4.0, discrete event simulation	En una cooperativa agrícola de Brasil se hizo un estudio con Machine Learning para tomar decisiones en el proceso de clasificación de semillas de soja, se usó la hora de llegada de los camiones, tiempos de espera para simular distintos escenarios con distintas cantidades de trabajadores y máquinas.	El estudio comprobó que el número de trabajadores influye directamente en la reducción de tiempos de espera que en el número de máquinas, mientras que en los tiempos de proceso depende de la capacidad de las máquinas.
7	WOS (Aggarwal et al., 2022)	Detección de enfermedades del arroz utilizando inteligencia artificial y técnicas de aprendizaje automático para mejorar el agronegocio	2022	India	Procesamiento de imágenes, Agricultura de precisión, cultivos inteligentes	Analiza el uso de inteligencia artificial y Machine Learning para detectar enfermedades en los cultivos de arroz con el procesamiento de imágenes, mejorando la productividad agrícola.	Se encontró que con el Machine Learning se pueden tener precisiones hasta del 95% para la detección temprana de enfermedades en cultivos de arroz.
8	WOS (Tathego & D'Odoric	¿Los proyectos africanos de represas de riego están destinados a la	2022	África	Represas de riego, uso del suelo	El estudio analiza el impacto de represas de riego con imágenes satelitales y Machine Learning, los resultados	Con el Machine Learning se logró detectar cambios en el uso del suelo, se identificó que en varios casos hay un cambio de ser pequeños agricultores a

	o, 2022)	agroindustria a gran escala o a los pequeños agricultores?				mostraron que las áreas irrigadas alrededor de las represas fueron explotadas por grandes empresas.	medianos o grandes, con ayuda del Machine Learning.
9	WOS (Bakas et al., 2025)	Segmentación, conteo y estimación del rendimiento de árboles cítricos mediante drones utilizando enfoques ligeros de aprendizaje profundo	2025	Marruecos	Imágenes de UAV, Estimación de rendimiento, segmentación, cálculo	El estudio maneja un estudio con drones UAV para detectar, contar y estimar el rendimiento de los árboles, los resultados demuestran que hay una alta precisión en el conteo y segmentación.	Con el sistema de UAV se logra una precisión del 99% donde el uso de drones permite generar mapas detallados para mejorar la toma de decisiones.
10	WOS (Manjun et al., 2024)	Selección de características basada en el algoritmo de colonia de abejas artificiales y marco híbrido de aprendizaje automático para una predicción eficiente del rendimiento del arroz	2024	India	Algoritmo de colonia de abejas artificiales, selección de características, memoria a corto y largo plazo	El estudio propone un modelo combinado con el Artificial Bee Colony y Machine Learning para seleccionar variables y mejorar las predicciones de los posibles rendimientos del arroz, demostrando una alta precisión.	Con el Artificial Bee Colony un modelo matemático donde se busca la mejor respuesta entre miles de opciones mejora la selección de variables.

11	Scopus (Colmillo et al., 2026)	Mapeo del estrés hídrico por sequía basado en aprendizaje automático utilizando imágenes Landsat y Sentinel-2: un enfoque de teledetección	2026	China	Resiliencia climática, transformación del uso de la tierra, temporada de cultivo del arroz, dinámica espacio temporal de la sequía, índice de salud de la vegetación.	La investigación desarrolla el monitoreo de estrés hídrico en cultivos de arroz durante temporadas pico (2022-2024) en la provincia de Hunan (China), mediante el uso de instrumentos de teledetección multiespectral (Landsat-8 y Sentinel-2). Además, como uso complementario se implementan indicadores avanzados como el índice de salud de la vegetación en los cultivos.	La investigación identificó una reducción de alrededor del 8% en zonas de cultivo y una respuesta tardía en la vegetación entre 2022 y 2024 debido a tiempos con sequías extremas. Por lo tanto, el estudio ratifica el uso de satélites para protocolos de alerta temprana con el fin de una gestión más eficiente del agua en los cultivos de arroz.
12	WOS (Hernandez-Salazar et al., 2024)	Integración de la inteligencia artificial y la agricultura de precisión en cultivos de café	2024	Colombia	Café, redes neuronales, agricultura de precisión	El estudio revisó las aplicaciones de la IA en el sector cafetero, donde buscan la detección temprana de plagas y enfermedades, optimización del uso de agua y modelos predictivos, destacando las tecnologías para mejorar la productividad, reducir costos y minimizar impactos ambientales	El estudio logró evidenciar que con ayuda de la inteligencia artificial se puede detectar tempranamente enfermedades y plagas en los cultivos de café.

13	Scopus (Haghighi et al., 2025)	Sistema integrado de pronóstico y simulación para el apoyo a la toma de decisiones en la agricultura inteligente durante la pretemporada.	2025	Irán	Machine Learning, Redes Neuronales, Planificación de pretemporada, Predicción de rendimiento de cultivos, Análisis de Incertidumbre, Gestión Agrícola.	La investigación desarrolla un sistema integrado para el pronóstico y soporte mejorando la toma de decisiones en la gestión agrícola, combinando redes neuronales artificiales y modelos de evapotranspiración para la predicción climática y el crecimiento de los cultivos.	Los hallazgos encontrados en el estudio afirman que el trasplante (técnica de siembra), ofrece un mayor rendimiento en los cultivos que la siembra directa ante condiciones adversas como el estrés hídrico. Las redes neuronales artificiales demostraron una efectividad antes la predicción de cambios climáticos y valida que la implementación de sistemas inteligentes de soporte optimiza la eficiencia de recursos y la sostenibilidad en los agronegocios.
14	Scopus (Mkondwa et al., 2025)	Respuestas de los agricultores al manejo agronómico de la sequía extrema y rendimientos del arroz en Bihar, India.	2025	India	Abandono de cultivos, Inicio tardío del monzón, Machine Learning, Riego con pozos tubulares.	El estudio recopiló datos de una de las sequías más prolongadas en Bihar (India) en 2022. Con lo que se elaboró un modelo de ML casual, para cuantificar los impactos de la sequía en la producción de cultivos de arroz. Además, la investigación realiza un análisis contrafactual para evaluar cómo el acceso a infraestructura de riego eléctrico actúa	El estudio presentó la pérdida de rendimiento de hasta un 23% en los cultivos de arroz en temporadas de sequía extrema, donde el acceso al riego solo pudo mitigar una mínima parte de toda la producción. Además, concluyó que una estrategia preventiva es la gestión del trasplante temprano (técnica de siembra) con el acompañamiento de sistemas de soporte de decisión y asesoramiento a los productores.

						como mecanismos de mitigación.	
15	Scopus (Chang et al., 2025)	Estimación de la eficiencia del uso del agua en el maíz: un enfoque basado en UAV que integra datos multisensoriales con el modelo de evapotranspiración SEBAL.	2025	China	Crecimiento de cultivos, Fenotipado, Agricultura inteligente, Vehículos aéreos no tripulados (UAV), Balance hídrico.	La investigación emplea un método fenotipado para estimar el uso del agua en cultivos de maíz mediante vehículos aéreos no tripulados (UAV). Se combinan datos multiespectrales, térmicos y de radar con ML y el modelo SEBAL. Lo que permite el monitoreo diario de los cultivos.	Los hallazgos encontrados en la investigación demuestran que la integración de sensores en UAV permite optimizar los sistemas de riego y seleccionar variedades más productivas con menor consumo de agua, en compañía del uso del machine learning automatizado como una herramienta eficaz para temporadas de sequía.
16	Scopus (Ma et al., 2025)	Estimación del índice de crecimiento integral para el maíz de primavera irrigado por goteo en la cuenca de Junggar mediante imágenes satelitales y aprendizaje automático.	2025	China	Índice de Crecimiento Integral, Riego por Goteo, Machine Learning, Sentinel-2, Variación espacio-temporal, Maíz de primavera.	El estudio emplea un índice de crecimiento integral para monitorear los cultivos de maíz en primavera bajo el método de riego gota a gota. El estudio implementa el uso de datos satelitales de Sentinel-2 y la utilización de algoritmos de ML (Bosques Aleatorios). La metodología identifica predictores óptimos para cada etapa fenológica de los	Los modelos de ML utilizados en la investigación lograron una precisión excepcional, demostrando que el uso de estos instrumentos es influyente para la producción de los cultivos de maíz, lo que permite una agricultura basada en datos que optimizan el monitoreo en cada etapa de crecimiento de los cultivos de maíz en este caso.

						cultivos.	
17	WOS (Sable et al., 2024)	Sistemas de recomendación de rentabilidad agrícola basados en Machine Learning: un cambio de paradigma en el cultivo de cosechas	2024	India	Agricultura, cultivo, análisis de datos, Machine Learning	El estudio menciona que usar técnicas de Machine Learning para analizar los datos históricos de precios agrícolas y predecir futuros precios de frutas y verduras, ayudando a la agricultura sobre qué cultivar.	El Machine Learning logra predecir los precios agrícolas con precisión, este modelo permite tomar decisiones sobre qué es mejor cultivar para tener mayor rendimiento.
18	WOS (Scarton et al., 2025)	Factores de manejo y edafoclimáticos que determinan a los agricultores con mayor rendimiento de soja en Brasil	2025	Brasil	Rendimiento de la soja, gestión de cultivos, fecha de siembra, madurez del cultivar	El estudio analiza factores climáticos, del suelo y uso agrícola, con el modelo Machine Learning para poder revisar cómo los agricultores de soja pueden alcanzar mayores niveles de productividad.	Con Machine Learning es el modelo más preciso para determinar la productividad, donde factores como temperaturas cercanas a los 30 grados centígrados, y suelos con materia orgánica ayudan a tener mayores rendimientos.
19	Scopus (Sabut et al., 2025)	Evaluación del impacto de los índices climáticos en el rendimiento del maíz en los Estados Unidos continentales mediante un enfoque de	2025	Estados Unidos	Variabilidad climática, Rendimiento de los cultivos, Machine Learning.	La investigación analiza modelos de ML para evaluar el impacto de índices climáticos en los cultivos de maíz de secano en condados de EE.UU. Los algoritmos evalúan variables como estrés térmico, variabilidad de la	Los hallazgos de esta investigación demuestran que el modelo de ML más confiable es el XG Boost, superando a modelos como Random Forest y SMV, particularmente en sequías extremas.

		aprendizaje automático.				temperatura y rango extremo, usando el algoritmo K-means para clasificar las áreas de cultivo.	
20	WOS (Ordoñez et al., 2024)	Blockchain y sostenibilidad agrícola en América del Sur: una revisión sistemática	2024	Colombia	Blockchain, agricultura sostenible, contratos inteligentes, agronegocios	El estudio revisa el uso del Blockchain en la agricultura sostenible, donde identifica sus ventajas y desventajas, como también sus aplicaciones y gestión en toda la cadena de suministros.	Se logró evidenciar que el Blockchain mejora la transparencia en la cadena de suministros, se evidencia que los contratos inteligentes y tecnologías que ayudan al sector agrícola son prometedora para la sostenibilidad agrícola.
21	WOS (Quintero Rincon et al., 2022)	Base de datos Raspberries-LITRP: base de imágenes RGB para aplicaciones industriales en la estimación automática de la calidad de frambuesas rojas	2022	Chile	Detección de calidad, Machine Learning, Base de datos	El estudio desarrolló una base de datos industrial que su principal objetivo era entrenar un modelo de visión y aprendizaje automático, que sean capaces de detectar enfermedades, con mejor precisión que modelos tradicionales.	Con una red neuronal se logró evidenciar que tienen una precisión del 91%, al automatizar el control de calidad reduce la subjetividad humana.
22	Scopus (Selvida et al., 2025)	Optimización de la selección de terrenos para el cultivo de ajo mediante el método PCA	2025	Indonesia	cultivo de ajo, k-means, Machine Learning, análisis de componentes	La investigación hace uso de algoritmos de ML para la zonificación de tierras agrícolas con potencial para el cultivo de ajo, se emplea	El estudio logra optimizar la selección de terrenos en áreas extensas y mejorar significativamente los rendimientos de los cultivos de ajo y mejorar la seguridad

		y el algoritmo K-means en un sistema inteligente espacial.			principales, terreno espacial	principalmente el algoritmo K-means para clasificar la aptitud del suelo.	alimentaria, asegurando que esta metodología facilita la planeación agrícola eficiente de ese país.
23	WOS (Bran et al., 2024)	Inteligencia artificial para el agronegocio sostenible: innovaciones y desafíos	2024	Rumani a	Inteligencia artificial, sostenibilidad, eficiencia, agronegocios, resiliencia.	Se examina la integración de inteligencia artificial, robótica y el internet, en el sector agrícola, demostrando que analizar datos permite tener un mejor uso de los recursos, anticipar posibles riesgos,	La inteligencia artificial permite que algunas decisiones sean automáticas, mientras que la robótica ayuda a los trabajos intensivos mejorando su precisión, que la sostenibilidad no solo depende de la tecnología también de las capacidades humanas
24	WOS (Joshi et al., 2023)	Predicción del rendimiento del trigo de invierno en los Estados Unidos continentales utilizando fluorescencia de clorofila inducida por el sol y algoritmos XGBoost y Random Forest	2023	Estados Unidos	Predicción de rendimiento de cultivos, Machine Learning, importancia de las variables, datos climáticos.	El estudio hizo uso de satélites, variables climáticas y propiedades del suelo con algoritmos de aprendizaje automático para simular el rendimiento de cultivos de trigo a gran escala, ayudando a tener una mayor precisión.	La integración de datos satelitales, climáticos son determinantes para el rendimiento agrícola, el índice SIF (métrica avanzada de teledetección que aísla la señal de vegetación del infrarrojo cercano para estimar la salud de las plantas) son variables claves capaces de explicar el 69% de la variabilidad del rendimiento agrícola.
25	Scopus (Abouza hir et al.,	Control de malezas terrestre en	2024	Emirato s Árabes	Deep Learning, Vehículos terrestres,	El estudio analiza la precisión y la visión artificial para el control	Los hallazgos de la investigación demuestran que para el control de malezas es

	2024)	línea mediante visión artificial: Análisis del dilema entre tiempo de inferencia y precisión.		Unidos	Machine Learning, Control de malezas en línea, Tiempo real.	de malezas mediante vehículos terrestres. El estudio propone que para garantizar un deshierbe eficaz se debe implementar el uso de redes neuronales profundas para operaciones agrícolas.	mejor optimizar la precisión del software al operar a velocidades de 4 km/hr, ahorrando al productor en la adquisición de computadoras costosas, mejorando otros ítems en los cultivos.
26	WOS (Ghandar et al., 2021)	Sistema de apoyo a la toma de decisiones para la agricultura urbana utilizando gemelo digital: un estudio de caso con acuaponía	2021	China y Pakistán	Producción, agricultura, áreas urbanas, sistemas de apoyo a la toma de decisiones, modelos predictivos.	El estudio propone un sistema de inteligencia artificial basado en gemelos digitales para maximizar la producción del sector agrícola, con el uso de modelos virtuales y datos en tiempo real, reduciendo desperdicios.	Los sistemas gemelos permiten simular y optimizar sistemas agrícolas con mayor precisión, la combinación con Machine Learning mejora la predicción productiva.
27	Scopus (Hayat et al., 2024)	FruitVision: Un sistema automático de clasificación de frutas basado en aprendizaje profundo	2024	Estados Unidos	Agricultura, visión artificial, Deep Learning, clasificación de frutas, Machine Learning.	La investigación presenta un modelo de IA y ML, para clasificar la calidad de algunas frutas como: manzana, banano, mango etc. Mediante la inteligencia artificial el estudio propone reemplazar la clasificación manual por modelos de algoritmos de alta precisión para detectar	El estudio encontró que el modelo propuesto tiene una efectividad de alrededor del 99% en la mayoría de las frutas, permitiendo así automatizar mejor el control de calidad de las frutas, ya que el modelo demostró un mayor nivel de eficiencia que la clasificación manual.

						defectos y mejorar la calidad.	
28	WOS (Cruz et al., 2024)	RosenPy: Un marco de trabajo de código abierto en Python para redes neuronales de valores complejos	2024	Brasil	Machine Learning, red neuronal, pitón, Agronegocios	El estudio habla de RosenPy , un código abierto de Python que está diseñado para ser usado en redes neuronales, que permite procesar señales complejas con una mayor precisión y eficiencia, esto amplía la capacidad de aprendizaje en áreas tecnológicas mejorando los procesos productivos y la toma de decisiones.	RosenPy demostró que las redes neuronales son mucho más eficaces en precisión y velocidad al momento de tomar una decisión, facilitando el desarrollo de soluciones mucho más eficientes, reducción de desperdicios y análisis de datos.
29	WOS (Jin et al., 2022)	Mejorando los pronósticos tempranos del rendimiento del trigo mediante pronósticos climáticos estacionales probabilísticos	2022	Australia	Previsión del rendimiento de trigo, pronósticos climáticos, pronóstico de rendimiento.	El estudio logró demostrar que la combinación de pronósticos climáticos y modelos biofísicos, permiten predecir el rendimiento de los cultivos de trigo con varios meses de anticipación.	Esta técnica mejora significativamente la precisión y confiabilidad de las predicciones de rendimientos de cultivos de trigo, esto permite una mejor planificación para gestionar riesgos climáticos y optimizar las decisiones.
30	Scopus (Jararweh et al., 2023)	Agricultura inteligente y sostenible: fundamentos,	2023	Jordania	Inteligencia artificial, Seguridad alimentaria,	El artículo propone la integración de la agricultura inteligente y sostenible mediante la	El artículo define la agricultura inteligente y sostenible como una agricultura más optimizada,

		tecnologías facilitadoras y perspectivas de futuro			Internet de las cosas, Machine Learning, Agricultura de precisión, Agricultura segura, Agricultura inteligente.	integración de IA, ML e internet de las cosas, todo esto con la necesidad de implementar estas tecnologías debido al desafío de una seguridad alimentaria para las proyecciones del aumento poblacional en 2050.	ya que mejora la rentabilidad mediante la reducción de costos operativos y una mejor gestión de la mano de obra.
31	WOS (Afaq & Manocha., 2022)	Enfoque de aprendizaje profundo basado en multirresolución para el monitoreo de campos de arroz	2022	India	Aprendizaje, redes neuronales, monitoreo de cultivos de arroz, imágenes satelitales	El estudio desarrolla un modelo de aprendizaje que es capaz de integrar imágenes satelitales, donde identifica con precisión las áreas cultivadas con arroz.	La integración de redes mejora la capacidad de monitoreo agrícola con las imágenes satelitales, siendo también una gran alternativa para vigilancia agrícola y apoyo en la seguridad.
32	WOS (Borba et al., 2021)	Selección de tomates industriales mediante datos de resonancia magnética nuclear TD-NMR y métodos computacionales de clasificación	2021	Brasil	Procesamiento del tomate, Machine Learning, Parámetros de calidad., Resonancia magnética	El estudio hace modelos de clasificación basado en resonancia magnética y algoritmos de aprendizaje, para revisar la madurez y defectos en tomates industriales.	Se evidencia que este sistema logró clasificar los tomates con una precisión del 97% en su madurez y un 90% en la detección de defectos, demostrando que este sistema puede automatizar la selección de materia prima y mejorando la eficiencia productiva.

33	Scopus (Aggarwal et al., 2023)	Selección de características basada en redes neuronales profundas pre entrenadas para la clasificación de enfermedades de las hojas de arroz mediante aprendizaje automático.	2023	India	Deep Learning, aprendizaje de conjuntos, Machine Learning, modelos pre entrenados, enfermedad de la hoja de arroz, segmentación	El estudio analiza redes neuronales artificiales pre entrenadas para identificar automáticamente enfermedades en las hojas del arroz, de esta manera compara múltiples modelos de IA y modelos de procesamiento de imágenes, con el fin de proporcionar una herramienta eficaz que identifique las enfermedades y optimice las tareas de los agricultores.	El estudio logró demostrar que el uso de redes neuronales artificiales pre entrenadas logra hasta un 94% de precisión para reconocer enfermedades en las hojas del arroz, validando modelos de IA como Efficient Net.
34	WOS (Flores junior et al., 20229)	Algoritmo híbrido semi-analítico para estimar la concentración de clorofila-a en aguas de llanuras inundables del Bajo Amazonas	2022	Brasil	calidad y claridad del agua, agua turbia, Machine Learning	El estudio desarrolla y valida modelos para estimar con una mayor precisión la concentración de clorofila en aguas turbias del Amazonas, fortaleciendo el monitoreo ambiental.	El modelo propuesto redujo significativamente los errores en el cálculo de clorofila en comparación con modelos convencionales, demostrando que el uso de una buena herramienta tecnológica permite un monitoreo confiable de aguas turbias.
35	Scopus (Kamyshova et al., 2022)	Redes neuronales artificiales y sistemas de fitoindicación	2022	Rusia	Agricultura, Cultivos, Índices, Riego, Machine Learning,	El estudio propone un sistema de visión artificial en sistemas de riego para crear mapas de riego en tiempo real	El sistema destaca por su gran capacidad de procesamiento de plantas en poco tiempo, logrando hasta un 92% de efectividad del estado de los


		basados en visión artificial para la mejora del riego de tasa variable			Suelo, Recursos hídricos.	para el maíz. Además, usa redes neuronales artificiales para analizar la fitoindicación de las plantas (estado de las plantas de maíz).	cultivos, permitiendo un riego diferenciado dependiendo la planta y reduciendo el desperdicio de agua significativamente.
36	WOS (Hayat et al., 2024)	FruitVision: Sistema automático de clasificación de frutas basado en aprendizaje profundo	2024	Portugal	Machine Learning, Visión por computadora, clasificación, agricultura, textura, color	El estudio propone un sistema basado en aprendizaje capaz de clasificar las frutas dependiendo de su calidad, con altos niveles de precisión demostrando que la inteligencia artificial puede ayudar a los procesos en el sector agrícola, como reducir costos y desperdicios y garantizar estándares de calidad.	El modelo FruitVision tiene una precisión del 97% con la mayoría de las frutas analizadas, demostrando que el sistema tiene gran capacidad de clasificación de distintos tipos de frutas, reduciendo errores humanos y aumentando la productividad.
37	Scopus (Sundaramoorthi & Dong, 2024)	Herramienta de apoyo a la toma de decisiones basada en aprendizaje automático y optimización para la selección de variedades de semillas.	2024	Estados Unidos	Ciencia de datos, Escasez de alimentos, Machine Learning, Optimización de cartera, Simulación y optimización, Soja	El estudio implementa algoritmos de ML (Árboles de Regresión) para la selección óptima de semillas de soja. El modelo está basado en datos tales como clima y suelo para la simulación de escenarios con el objetivo de recomendar	El estudio logró demostrar que el uso de instrumentos de machine learning pueden aumentar la rentabilidad de los agricultores en hasta un 9% anualmente, lo que permite realizar estrategias de inversión basadas en datos.

						una mezcla de semillas óptima que aumente la rentabilidad y disminuya la incertidumbre en variaciones climáticas.	
38	WOS (Kutyaur ipo et al., 2023)	Aplicaciones de la inteligencia artificial en los sectores agroalimentarios	2023		Redes neuronales, inteligencia artificial, procesamiento de alimentos, sistemas alimentarios, agricultura	El estudio analiza cómo la inteligencia artificial se utiliza en todas del sistema alimentario, desde la producción del sector agrícola hasta el consumo, demostrando que estas tecnologías hacen los procesos más eficientes, y aumentan la productividad.	La inteligencia artificial utilizada en todas las etapas del sector alimentario permite que las enfermedades sean detectadas a tiempo, optimizando el uso del agua y teniendo predicciones más exactas de la producción, y el uso de drones, sistemas o alguna otra herramienta tecnológica aumentan la productividad.
39	Scopus (Xian et al., 2024)	Un marco de trabajo integral para la evaluación de la calidad de las tierras agrícolas basado en aprendizaje automático y modelos físicos.	2024	China	Calidad de las tierras de cultivo, Machine Learning, Verificación de la exportación de nitrógeno.	El estudio propone la integración de un modelo híbrido que combina algoritmos de Ml (Bosque Aleatorio) y un modelo físico (InVEST) para analizar la calidad de las tierras agrícolas. Los cuales evalúan emisiones de nitrógeno, mapeando la calidad de las tierras asegurando la producción de los cultivos.	Los hallazgos determinan que el modelo híbrido alcanza una precisión determinante en la calidad de los suelos, asegurando que los factores más fundamentales en la calidad de la tierra son los factores ambientales (Nitrógeno) y la capacidad de riego.

40	Scopus (Hachem e et al., 2025)	La expansión del riego a pequeña escala en el centro de Kenia demuestra la importancia de proteger los paisajes de pastizales.	2025	Kenia	Pastizales, cartografía de riego, conversión de uso del suelo, machine learning, teledetección, sábanas.	La investigación analiza la expansión agrícola y el riego en los pastizales mediante un monitoreo satelital de alta resolución en Kenia. El estudio mediante el uso de estos mecanismos establece la probabilidad de riego basándose en índices de vegetación, altitud y proximidad a fuentes de agua.	El sistema logró un 86% de precisión al identificar fincas con riego sin necesidad de visitas de campo constantes, además se identificó que en el transcurso de solo 4 años se aumentó el número de tierras irrigadas en un 27%.
41	Scopus (Grant et al., 2025)	Tendencias históricas de las sequías estacionales en Australia	2025	Australia	Sistemas de aprendizaje, Machine Learning, Sequía agrícola, Agroindustria, Maquinaria agrícola.	La investigación analiza las sequías históricas en Australia utilizando métricas hidrológicas. Además, emplea técnicas de IA para desglosar los factores que impulsan las sequías agrícolas.	Se determina en el estudio que la precipitación no es factor principal común que determina las tendencias de sequías en Australia,

Nota: Matriz de análisis documental, elaboración propia.

9.1.2 Diagrama de Flujo PRISMA 2020



Nota. Elaboración propia basada en la guía PRISMA 2020 (Page et al., 2021).

9.1.3 Proceso de Selección de Información (Diagrama PRISMA)

Como se puede observar en el diagrama de flujo (PRISMA 2020), este protocolo permite documentar el proceso del filtro de artículos académicos indexados en temas de Machine Learning y agronegocios que se ha generado entre 2020 y 2026. Desde la identificación inicial de los registros, hasta la consolidación de la fase final, asegurando que los artículos seleccionados cumplan con los requisitos y estándares establecidos para el éxito de la investigación.

Interpretación del proceso de filtrado

Como se mencionó en el diseño de la investigación definitivo, el proceso de filtración de los artículos se estructuró en 3 fases, las cuales permitieron refinar la búsqueda global hacia el enfoque especializado:

- 1. Identificación:** En esta fase se inició con la extracción de 435 registros de artículos de las dos bases de datos analizadas Scopus (358 artículos) y Web of Science (77 artículos). De los cuales, se detectaron y eliminaron 50 registros duplicados, resultando un total de 385 artículos para el proceso de evaluación inicial.
- 2. Cribado:** Los 385 artículos fueron sometidos a un primer filtro de inclusión el cual consiste en publicaciones producidas entre los años 2020-2026, redactadas en el idioma inglés y clasificadas como artículos de investigación. El resultado de este primer filtro reflejó la exclusión de 298 artículos, quedando una base de 87 informes (54 Scopus y 33 de WOS), los cuales se determinaron para una potencial revisión a mayor profundidad. Por consiguiente, se realizó una evaluación cualitativa de los 87 artículos restantes. Posteriormente se ejecutaron los criterios de exclusión relacionados con la pertinencia climática/geográfica y la aplicación directa de modelos de Machine Learning en los agronegocios. Como resultado, se excluyeron 46 artículos (35 de Scopus y 11 de WOS) que no cumplieran con el enfoque solicitado por la investigación.
- 3. Inclusión:** A modo de conclusión, el proceso determinó la selección de 41 artículos científicos de alto impacto para la investigación, los cuales constituyen la matriz documental que sustenta el análisis de los resultados, describiendo los artículos más recientes y relevantes sobre la transformación y tecnológica en modelos algoritmos de Machine Learning del sector agrícola global.

9.1.4 Análisis de Resultados (Matriz de Análisis Documental)

La Matriz de Análisis Documental proyectó datos relevantes sobre la actualidad en temas relacionados a la integración de algoritmos de Machine Learning en los agronegocios, el análisis demuestra los siguientes puntos:

- Las investigaciones previamente desarrolladas durante el periodo 2020-2026 muestran una mayor concentración de investigaciones en métodos mediante machine learning y otros instrumentos como satélites en anticipar el futuro productivo en los cultivos. El constante uso en varias investigaciones de algoritmos como Random Forest y XGBoost (algoritmos de Machine Learning enfocados en conjuntos de árboles de decisión, utilizados para clasificación y regresión), que a su vez se alimentaban de satélites como Sentinel-2 permite con eficacia predecir las cosechas semanas antes. Además, el uso de tecnologías como los satélites, permite a los productores anticipar factores climáticos devastadores como lluvias torrenciales devastadoras para establecer mejores condiciones de cultivo. Esta integración de datos geoespaciales con modelos predictivos de machine learning permite que la planificación logística se ajuste a la realidad del campo en tiempo real, por lo cual se minimizan las pérdidas en la cosecha.
- Las investigaciones arrojaron que el uso de la tecnología reduce significativamente costos elevados en la agricultura, disminuyendo el consumo de agua, selección de insumos y de semillas. Esto debido a la utilización de Drones UAV y sensores térmicos, reducen disminuir el desperdicio de agua mediante tasas de riego variables definiendo automáticamente que tipo de plantas necesitan agua. La selección estratégica de insumos mejora la rentabilidad de los productores mediante la correcta selección de mezclas de semillas, apoyado por algoritmos de Machine Learning. La estandarización automática de modelos como FruitVision alcanzan precisiones de casi un 100%, con un mínimo margen de error en la clasificación de frutas como la naranja, el mango y el banano, mejorando la calidad de la selección y eliminando casi que por completo el error humano.
- Para el contexto de Colombia y América del Sur, el uso de algoritmos como Blockchain (cadena de bloques, funciona como una base de datos descentralizada) permite mejorar la cadena de suministros y la trazabilidad de los productos, por su parte la sanidad vegetal mediante procesamiento de imágenes podría ser un factor relevante para la detección temprana de enfermedades en el café, evitando la pérdida completa de lotes y evitando el uso excesivo de químicos. Además, La transición hacia una agricultura 4.0 mediante gemelos digitales e internet de las cosas (en conjunto su funcionamiento se basa en la recolección de datos históricos para simular escenarios), permite reducir incertidumbre en la toma de decisiones debido al análisis de posibles escenarios agrícolas.
- A partir del riguroso análisis de la matriz de análisis documental procedente de la producción académica en Scopus y WOS, se identificaron los siguientes clústeres de decisión que vinculan la tecnología con problemas gerenciales reales: El primer clúster es la predicción del rendimiento de los cultivos, el cual aborda la incertidumbre de diversos factores externos como el clima; mediante modelos de Machine Learning, los productores pueden proyectar cosechas fiables mediante el uso de datos climáticos que

son generados por satélites, permitiendo generar una mejor planeación estratégica de los cultivos. El segundo cluster identificado es la gestión de la materia prima y recursos operativos, los cuales son orientados a la mitigación del desperdicio de recursos en el campo, para este ámbito las investigaciones apuntan a la mejora de la agricultura mediante el uso de mecanismos de precisión como drones y sensores optimizando el uso del agua, semillas y fertilizantes. Finalmente, el último clúster de decisión es la detección temprana de enfermedades, la cual resuelve la vulnerabilidad biológica y la sanidad vegetal en los cultivos, con el uso de modelos de machine learning y visión artificial los productores pueden realizar intervenciones preventivas que protegen las cosechas, evitando gran pérdida de la producción. Estos clústeres demuestran que la integración del Machine Learning en los agronegocios fortalece la toma de decisiones, al proporcionar información precisa y oportuna.

9.2 Conclusiones

La investigación realizada sobre los artículos encontrados en temas de Machine Learning y Agronegocios en las bases de datos Scopus y Web of Science en el periodo comprendido entre el 2020 y 2026 permite determinar que dicha producción académica indexada ha tenido una expansión global y refinamiento técnico entre los años seleccionados. Las investigaciones realizadas han tenido una distribución geográfica global, ya que se evidencia un interés científico distribuido en varios países como: India, Brasil, Estados Unidos, Australia, Kenia dentro de los que más destacan por su producción literaria en temas de aplicación de algoritmos de Machine Learning y herramientas tecnológicas en la agricultura, esto con la posibilidad de enfrentar retos para la mejora de la seguridad alimentaria, la sostenibilidad a futuro y el cambio climático que afecta a los cultivos. Se analizó que la producción literaria ha evolucionado en el desarrollo de sistemas integrados de decisión que optimizan la gestión de los productores, donde los modelos de machine learning son suministrados en varios casos por satélites como el Sentinel-2, que se ha convertido en sistema de vigilancia y recopilación de datos, que detectan sequías y estrés hídrico en las temporadas de cultivo, permitiendo que los productores tomen decisiones logísticas evitando las pérdidas de las cosechas. Lo que también evidencia una mejora sustancial en las rentabilidades de los agronegocios debido a la integración de estas tecnologías.

La producción académica en temas de machine learning y agronegocios describe una gestión autónoma de precisión en la agricultura, debido a tendencias temáticas como el monitoreo de sequías extremas mediante instrumentos con un bajo margen de error. En conjunto, la combinación de múltiples fuentes de datos y modelos de alta complejidad como los algoritmos de machine learning Random Forest y XGBoost, se consolida como uno de los modelos más usados por su alta precisión en la predicción, en acompañamiento con los datos obtenidos de la teledetección multiespectral (Satélites Sentinel-2 y Landsat). Esta robusta infraestructura de datos geoespaciales ha permitido que los dominios de aplicación en las investigaciones se hayan extendido al diagnóstico técnico de los cultivos con una alta precisión del cultivo y la adaptabilidad climática, lo cual se ve reflejado en la rentabilidad de los agronegocios. Además, se pudo evidenciar el complemento de metodologías que integran tecnologías de punta como el uso de drones (UAV) y maquinaria que perfeccionan la

implementación de estas herramientas tecnológicas en conjunto.

El análisis de los artículos indexados entre los años 2020 y 2026 en fuentes científicas como SCOPUS Y WOS, permitió lograr identificar diferentes clústeres de decisión asociados con el Machine Learning en el sector agrícola y los agronegocios. Particularmente se evidencio que la gran mayoría de los estudios se enfocan en la predicción del rendimiento de los cultivos, la gestión de la materia prima y detección temprana de enfermedades, aspectos que representan problemas clave en la productividad. En este contexto estos clústeres evidencian la necesidad de fortalecer la toma de decisiones estratégicas, con información precisa y confiable, lo que refleja una mejora en la eficiencia productiva y reduce la incertidumbre.

La toma de decisiones gerenciales en el sector agrícola y los agronegocios se han fortalecido con el Machine Learning con datos de satélites, sensores, drones y registros históricos. permitiendo resolver problemas relacionados con la productividad y predicción de rendimientos, reduciendo la incertidumbre en el sector. Estos clústeres identificados se aplican en áreas tecnológicas y campos estratégicos donde los datos son una parte fundamental en la rentabilidad.

Muchos de estos problemas gerenciales están relacionados con la necesidad de una optimización de la toma de decisiones en diferentes climas, evidenciando que el uso del Machine Learning es una herramienta de apoyo para decisiones estratégicas, permitiendo que se optimicen los recursos. Desde la cadena de suministros agrícola, con un enfoque en el Machine Learning Rejeb et al. (2025), identifican clústeres de investigación enfocados en una optimización de su logística, llevar un buen control de inventarios en toda su cadena de valor, Estas investigaciones logran evidenciar el gran impacto del Machine Learning desde la producción de un inicio, que logra llegar hasta las decisiones estratégicas.

Permitiendo identificar diferentes desafíos en la implementación y adopción del Machine Learning en los agronegocios, los cuales evidencian que dependen de factores como infraestructura, económicos y operativos para el manejo de esta tecnología, siendo un desafío la disponibilidad y calidad de los datos, teniendo en cuenta que son fundamentales para el buen funcionamiento de esta tecnología.

Los altos costos de esta tecnología siguen siendo un desafío importante para la implementación, siendo necesarios drones, sensores o sistemas que permitan el funcionamiento del Machine Learning, creando una brecha entre los grandes productores y los pequeños, limitándose en regiones con menor acceso a tecnología y falta de capacitación tecnológica, facilidad para interpretar resultados, demostrando la necesidad de que estas herramientas presentan resultados claros y fáciles de interpretar.

9.3 Recomendaciones

Resulta pertinente desarrollar investigaciones en contextos locales específicos como en países en desarrollo, los artículos revisados evidencian los beneficios de usar herramientas tecnológicas como Machine Learning en el sector agrícola y los agronegocios, muchos de estos estudios son realizados en lugares con una gran tecnología, por eso se sugiere que se realice en condiciones climáticas y económicas de países en desarrollo.

Así mismo es importante promover estudios al uso de herramientas tecnológicas con menor complejidad y más bajo costo que sean accesibles para las personas del campo, evidenciando que en los artículos muchas de estas herramientas dependen de tecnología costosa como drones, sensores o sistemas, siendo importante que el Machine Learning pueda ser fácilmente aplicada en el campo.

Profundizar el impacto económico del uso del Machine Learning en el sector agrícola y los agronegocios, muchos estudios resaltan los beneficios en productividad, pero aún quedan muchas dudas con los costos de implementación y su retorno de inversión, y si esto va afectar que más personas pierdan sus empleos con la adopción de estas herramientas.

Analicen cómo la adopción del Machine Learning por parte de grande agricultores o productores puede llegar afectar a los pequeños agricultores especialmente en la competitividad, los artículos evidencian que para la implementación de esta tecnología se quiere de un gran capital y buena infraestructura tecnológica, lo que genera una gran brecha entre los distintos niveles de productores.

Finalmente se considera fundamental revisar a profundidad las capacidades de manejo de tecnología por parte de los agricultores, considerando que el uso de esta herramienta tecnológica como Machine Learning enfocada en el sector agrícola y los agronegocios se usará en zonas rurales que no pueden llegar a tener acceso fácil, ni capacitación para el uso de estas herramientas, dificultando la toma de decisiones y que no se logren tener los resultados esperados por falta de estos conocimientos.

10. Referencias

- Abouzahir, S., Sabir, E., Sadik, M., Abouzahir, M., & Agramelal, F. (2024). Ground-based on-line weed control using computer vision: Analyzing the inference time–accuracy dilemma. *Computers and Electronics in Agriculture*, 227(Part 1), 109577. <https://doi.org/10.1016/j.compag.2024.109577>
- Afaq, Y., & Manocha, A. (2022). Multi-resolution-based deep learning approach for rice field monitoring. *Canadian Journal of Remote Sensing*, 48(2), 278–298. <https://doi.org/10.1080/07038992.2021.2010036>
- Aggarwal, M., Khullar, V., Goyal, N., Singh, A., Tolba, A., Thompson, E. B., & Kumar, S. (2023). Pre-trained deep neural network-based feature selection for rice leaf disease classification. *Agriculture*, 13(5), 936. <https://doi.org/10.3390/agriculture13050936>
- Aggarwal, S., Suchithra, M., Chandramouli, N., Sarada, M., Verma, A., Vetrithangam, D., Pant, B., & Adugna, B. A. (2022). Rice disease detection using artificial intelligence and machine learning techniques to improvise agro-business. *Scientific Programming*, 2022, Article 1757888. <https://doi.org/10.1155/2022/1757888>
- Aijaz, N., Lan, H., Raza, T., Yaqub, M., Iqbal, R., & Pathan, M. S. (2025). Artificial intelligence in agriculture: Advancing crop productivity and sustainability. *Journal of Agriculture and Food Research*, 20, 101762. <https://www.sciencedirect.com/science/article/pii/S2666154325001334>
- Ali, Z., Muhammad, A., Lee, N., Waqar, M., & Lee, S. W. (2025). Artificial intelligence for sustainable agriculture: A comprehensive review of AI-driven technologies in crop production. *Sustainability*, 17(5), 2281. <https://doi.org/10.3390/su17052281>
- 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>
- Asamblea Nacional Constituyente. (1991). *Constitución Política de Colombia*.
- Bakas, K., Saddik, A., Dliou, A., Hssaisoune, M., El Hachemy, S., Ait-Ichou, H., El Hafyani, M., Labbaci, A., & Bouchaou, L. (2025). UAV-based citrus tree segmentation, counting and yield estimation using lightweight deep learning approaches. *Agricultural Technology*. <https://doi.org/10.1016/j.atech.2025.101618>

Ben Ayed, A., & Hanana, M. (2021). Artificial intelligence in agriculture: A review. *Sustainable Computing: Informatics and Systems*, 31, 100541. <https://onlinelibrary.wiley.com/doi/epdf/10.1155/2021/5584754>

Benos, L., Tagarakis, A. C., Dolias, G., Berruto, R., Kateris, D., & Bochtis, D. (2021). Machine learning in agriculture: A comprehensive updated review. *Sensors*, 21(11), 3758. <https://doi.org/10.3390/s21113758>

Borba, K. R., Oldoni, F. C. A., Monaretto, T., Colnago, L. A., & Ferreira, M. D. (2021). Selection of industrial tomatoes using TD-NMR data and computational classification methods. *Microchemical Journal*, 167, 106048. <https://doi.org/10.1016/j.microc.2021.106048>

Botero-Valencia, J., García-Pineda, V., Valencia-Arias, A., Valencia, J., Reyes-Vera, E., Mejía Herrera, M., & Hernández-García, R. (2025). Machine learning in sustainable agriculture: Systematic review and research perspectives. *Agriculture*, 15(4), 377. <https://doi.org/10.3390/agriculture15040377>

Bran, F., Bodislav, D. A., Gombos, S., & Angheluță, S. P. (2024). Artificial intelligence for sustainable agribusiness: Innovations and challenges. *European Journal of Sustainable Development*, 13(3), 233–239. <https://doi.org/10.14207/ejsd.2024.v13n3p233>

Carbajal, M., Jones, D., Williams, C., & Nelson, N. G. (2026). In-season yield forecasting using multitemporal remote sensing environmental observations and machine learning: Applications for sweetpotato in North Carolina, USA. *European Journal of Agronomy*, 172, 127818. <https://doi.org/10.1016/j.eja.2025.127818>

Chang, W., Gu, S., Wang, B., Hu, S., Li, R., & Guo, X. (2025). Estimating water use efficiency in maize: A UAV-based approach integrating multisensory data with SEBAL evapotranspiration modeling. *Computers and Electronics in Agriculture*, 237(Part C), 110695. <https://doi.org/10.1016/j.compag.2025.110695>

Comisión Económica para América Latina y el Caribe (CEPAL). (2025, mayo 22). *Digitalización de la agroindustria en América Latina y el Caribe: avances, desafíos y experiencias desde la CEPAL*.

Congreso de la República de Colombia. (1993). *Ley 99 de 1993*. Por la cual se crea el Ministerio del Medio Ambiente...

Congreso de la República de Colombia. (1993). *Ley 101 de 1993*. Por la cual se desarrolla el artículo 64 de la Constitución Política...

Congreso de la República de Colombia. (2012). *Ley 1581 de 2012*. Por la cual se dictan disposiciones generales para la protección de datos personales.

Congreso de la República de Colombia. (2014). *Ley 1712 de 2014*. Por medio de la cual se crea la Ley de Transparencia y del Derecho de Acceso a la Información Pública Nacional.

Congreso de la República de Colombia. (2017). *Ley 1876 de 2017*. Por la cual se crea el Sistema Nacional de Innovación Agropecuaria (SNIA).

Conroy, H., Rondinone, G., De Salvo, C. P., & Muñoz, G. (2024). *Políticas agropecuarias en América Latina y el Caribe 2023*. <https://doi.org/10.18235/0013100>

Cruz, A. A., Mayer, K. S., & Arantes, D. S. (2024). RosenPy: An open source Python framework for complex-valued neural networks. *SoftwareX*. <https://doi.org/10.1016/j.softx.2024.101925>

Doda H, Sharma A and Thakur N (2025). A systematic review on sustainable practices transforming global agribusiness. *Front. Sustain. Food Syst.* 9:1566708. doi: 10.3389/fsufs.2025.1566708

Flores Júnior, R., Barbosa, C. C. F., Maciel, D. A., Novo, E. M. L. M., Martins, V. S., Lobo, F. L., ... & Carlos, F. M. (2022). Hybrid semi-analytical algorithm for estimating chlorophyll-a concentration in lower Amazon floodplain waters. *Frontiers in Remote Sensing*, 3, 834576. <https://doi.org/10.3389/frsen.2022.834576>

Ghandar, A., Ahmed, A., Zulfiqar, S., Hua, Z., Hanai, M., & Theodoropoulos, G. (2021). A decision support system for urban agriculture using digital twin: A case study with aquaponics. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2021.3061722>

Grant, M. O., Ukkola, A. M., Vogel, E., Hobeichi, S., Pitman, A. J., Borowiak, A. R., & Fowler, K. (2025). Historical trends of seasonal droughts in Australia. *Hydrology and Earth System Sciences*, 29(20), 5555–5573. <https://doi.org/10.5194/hess-29-5555-2025>

Hacheme, G. Q., et al. (2025). Small-scale irrigation expansion in central Kenya highlights the importance of protecting rangeland landscapes. *Environmental Research Letters*, 20, 074003. <https://doi.org/10.1088/1748-9326/addc82>

Haghighi, A., Parsinejad, M., & Bazrafshan, J. (2025). An integrated forecast-simulation system for intelligent preseason farming decision support. *Journal of Irrigation and Drainage Engineering*, 151(6), 04025037. <https://doi.org/10.1061/JIDEDH.IRENG-10538>

Hayat, A., Morgado-Dias, F., Choudhury, T., Singh, T. P., & Kotecha, K. (2024). FruitVision: Un sistema automático de clasificación de frutas basado en aprendizaje profundo. *Open Agriculture*, 9(1), 20220276. <https://doi.org/10.1515/opag-2022-0276>

Hernández-Salazar, C. A., González-Estrada, O. A., & González-Silva, G. (2024). Integración de la inteligencia artificial y la agricultura de precisión en cultivos de café. *Revista UIS Ingenierías*, 23(4). <https://doi.org/10.18273/revuin.v23n4-2024012>

Hernández Sampieri, R., Fernández Collado, C., & Baptista Lucio, P. (2014). *Metodología de la investigación* (6.^a ed.). México, D.F.: McGraw-Hill Education.

Informes de Expertos. (2025). *Mercado de Agricultura en Colombia: Análisis 2035*.

Jararweh, Y., Fatima, S., Jarrah, M., & AlZu'bi, S. (2023). Smart and sustainable agriculture: Fundamentals, enabling technologies, and future directions. *Computers and Electrical Engineering*, 110, 108799. <https://doi.org/10.1016/j.compeleceng.2023.108799>

Jin, H., Li, M., Hopwood, G., Hochman, Z., & Bakar, K. S. (2022). Improving early-season wheat yield forecasts driven by probabilistic seasonal climate forecasts. *Agricultural and Forest Meteorology*, 323, 108832. <https://doi.org/10.1016/j.agrformet.2022.108832>

Joshi, A., Pradhan, B., Chakraborty, S., & Behera, M. D. (2023). Winter wheat yield prediction in the conterminous United States using solar-induced chlorophyll fluorescence data and XGBoost and random forest algorithm. *Ecological Informatics*. <https://doi.org/10.1016/j.ecoinf.2023.102194>

Kamyshova, G., et al. (2022). Artificial neural networks and computer vision-based phytoindication systems for variable rate irrigation improving. *IEEE Access*, 10, 8577–8589. <https://doi.org/10.1109/ACCESS.2022.3143524>

Karbassi Yazdi, A., Durán, C., Derpich, I., & Valdés González, G. (2026). Forecasting crop yields in rainfed India: A comparative assessment of machine learning baselines and implications for precision agribusiness. *Agriculture*, 16(1), 65. <https://doi.org/10.3390/agriculture16010065>

Kutyaauripo, I., Rushambwa, M., & Chiwazi, L. (2023). Artificial intelligence applications in the agrifood sectors. *Journal of Agriculture and Food Research*, 13, 100502. <https://doi.org/10.1016/j.jafr.2023.100502>

Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674. <https://doi.org/10.3390/s18082674>

Ma, M., Zhao, J., Yang, T., Liu, F., Yuan, Y., Ma, S., & Chang, Z. (2025). Estimating comprehensive growth index for drip-irrigated spring maize in Junggar Basin via satellite imagery and machine learning. *Agricultural Water Management*, 318, 109651. <https://doi.org/10.1016/j.agwat.2025.109651>

Manjun, M. C. (2024). 10 Artificial bee colony algorithm-based feature selection and hybrid ML framework for efficient rice yield prediction. *Journal of Information and Organizational Sciences*, 15(3), 235.

Mi, J., Li, C., & Rahut, D. B. (2026). Impact of climate change on farmland NPP: Evidence from multi-scenario projections in Japan. *Journal of Environmental Management*, 398, 128452. <https://doi.org/10.1016/j.jenvman.2025.128452>

Ministerio de Agricultura y Desarrollo Rural [MADR]. (2025). *Evaluaciones Agropecuarias Municipales (EVA): Reporte de área, producción y rendimiento*. Gobierno de Colombia.

Mirmazloumi, S. M., Kipkulei, H., Waswa, R., Landmann, T., Dienya, T., Schwarz, M., Ramoino, F., Albergel, C., & Ghazaryan, G. (2026). High-resolution monitoring of intra-seasonal agricultural drought using Sentinel-2 and machine learning across bimodal growing seasons in Kenya. *Ecological Indicators*, 185, 114790. <https://doi.org/10.1016/j.ecolind.2026.114790>

Mkondiwa, M., Kishore, A., Veettil, P. C., Sherpa, S., Saxena, S., et al. (2025). Respuestas de los agricultores al manejo agronómico de la sequía extrema y rendimientos del arroz en Bihar, India. *Agricultural Water Management*. <https://doi.org/10.1016/j.agwat.2025.109830>

Motta, I. V. C., Vuillerme, N., & Figueiredo, F. A. P. (2025). Machine learning techniques for coffee classification: A comprehensive review of scientific research. *Artificial Intelligence Review*, 58, 15. <https://doi.org/10.1007/s10462-024-11004-w>

Olmillo, Z., Zhu, J., Liao, X., & Zhang, L. (2026). Mapeo del estrés por sequía basado en aprendizaje automático utilizando imágenes Landsat y Sentinel-2: Un enfoque de teledetección. *Land Degradation & Development*, 1–13. <https://doi.org/10.1002/ldr.70509>

Ordoñez, C. C., Ramírez Gonzales, G., & Corrales, J. C. (2024). Blockchain and agricultural sustainability in South America: A systematic review. *Frontiers in Sustainable Food Systems*, 8. <https://doi.org/10.3389/fsufs.2024.1347116>

Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., et al. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>

Page, M. J., Moher, D., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., et al. (2021). PRISMA 2020 explanation and elaboration: Updated guidance and exemplars for reporting systematic reviews. *BMJ*, 372, n160. <https://doi.org/10.1136/bmj.n160>

Presidencia de la República de Colombia. (2015). *Decreto 1076 de 2015*. Por medio del cual se expide el Decreto Único Reglamentario del Sector Ambiente...

PRISMA Statement. (2020). *PRISMA 2020 statement*. <https://www.prisma-statement.org/prisma-2020>

Quadras, D. L. de O., Cavalcante, I., Kück, M., Mendes, L. G., & Frazzon, E. M. (2023). Machine learning applied to logistics decision making: Improvements to the soybean seed classification process. *Applied Sciences*, 13(19), 10904. <https://doi.org/10.3390/app131910904>

Quintero Rincón, A., Mora, M., Naranjo-Torres, J., Fredes, C., & Valenzuela, A. (2022). Raspberries-LITRP database: RGB images database for the industrial applications of red raspberries' automatic quality estimation. *Applied Sciences*, 12(22), 11586. <https://doi.org/10.3390/app122211586>

Rejeb, A., Rejeb, K., & Hassoun, A. (2025). The impact of machine learning applications in agricultural supply chain: A topic modeling-based review. *Discover Food*, 5, Article 141. <https://doi.org/10.1007/s44187-025-00419-1>

Sable, N. P., Patil, R. V., Deore, M., Bhimanpallewar, R., & Mahalle, P. N. (2024). Machine learning based agricultural profitability recommendation systems: A paradigm shift in crop cultivation. *International Journal of Interactive Multimedia and Artificial Intelligence*. <https://doi.org/10.9781/ijimai.2024.10.005>

Sabut, A., Tripathy, K. P., Mishra, A., Anderson, M., Cosh, M., Kraatz, S., Gao, F., & Cirone, R. (2025). Assessing the impact of climate indices on corn yield in the continental USA using machine learning approach. *Agricultural and Forest Meteorology*, 371, 110632. <https://doi.org/10.1016/j.agrformet.2025.110632>

Scarton, V. D. B., Carvalho, I. R., Colet, C. F., Pradebon, L. C., Bandeira, W. J. A., Sangiovo, J. P., Loro, M. V., & Gonzalez da Silva, J. A. (2025). Management and edaphoclimatic factors that determine soybean top-performing farmers in Brazil. <https://doi.org/10.18406/2316-1817v17nunico20251956>

Selvada, D., Pulungan, A. F., & Huzaifah, A. S. (2025). Optimización de la selección de tierras para el cultivo de ajo mediante el enfoque PCA y K-means en un sistema de inteligencia espacial. *Eastern-European Journal of Enterprise Technologies*. <https://doi.org/10.15587/1729-4061.2025.325340>

Singh, K., Yadav, M., Barak, D., Bansal, S., & Moreira, F. (2025). Machine-learning-based frameworks for reliable and sustainable crop forecasting. *Sustainability*, 17, 4711. <https://doi.org/10.3390/su17104711>

Sotomayor, O., Nunes, S., & Rodrigues, M. (2023). *La digitalización al servicio de la transición agroecológica*. Comisión Económica para América Latina y el Caribe (CEPAL).

Sudha, S. P., & Shajilin Loret, J. B. (2026). A review on machine learning-based precision agriculture techniques for crop farming monitoring with IoT. *Discover Environment*, 4, Article 10. <https://doi.org/10.1007/s44274-025-00305-8>

Sundaramoorthi, D., & Dong, L. (2024). Machine learning and optimization-based decision support tool for seed variety selection. *Annals of Operations Research*, 341, 5–39. <https://doi.org/10.1007/s10479-022-04995-8>

Tamayo y Tamayo, M. (2004). *El proceso de la investigación científica* (4.^a ed.). Limusa.

Tatlhego, M., & D'Odorico, P. (2022). Are African irrigation dam projects for large-scale agribusiness or small-scale farmers? *Environmental Research Communications*, 4(1), 015005. <https://doi.org/10.1088/2515-7620/ac2263>

Unidad de Planificación Rural Agropecuaria (UPRA). (2026). *Resultados EVA*. https://upra.gov.co/sites/default/files/2026-02/03_RdosEVA_VF.pdf

Universidad Pedagógica de Durango (UPD). (s.f.). *Metodología de la investigación*. <https://upd.edu.mx/PDF/Libros/MetodologiaInvestigacion.pdf>

Waqas, M., Naseem, A., Wannasingha Humphries, U., Hlaing, P. T., Dechpichai, P., & Wangwongchai, A. (2025). Applications of machine learning and deep learning in agriculture: A comprehensive review. *Green Technologies and Sustainability*, 3, 100199. <https://doi.org/10.1016/j.grets.2025.100199>

Xian, W., Liu, H., Yang, X., Huang, X., Huang, H., Li, Y., Zeng, Q., & Tang, X. (2024). An ensemble framework for farmland quality evaluation based on machine learning and physical models. *Science of the Total Environment*, 912, 168914. <https://doi.org/10.1016/j.scitotenv.2023.168914>