
Impacto transformador de la inteligencia artificial y aprendizaje autónomo en la producción agropecuaria: un enfoque en la sostenibilidad y eficiencia.

Transformative impact of artificial intelligence and autonomous learning in agricultural production: a focus on sustainability and efficiency

Johann Fernando Hoyos Patiño¹, Blanca Liliana Velásquez Carrascal², Dewar Rico Bautista³, Noel García Díaz⁴

REVISTA FORMACIÓN ESTRATÉGICA ISSN 2805-9832

Postulado en diciembre 2022-Aceptao febrero del 2023

Correspondencia: Johann Fernando Hoyos Patiño, Ocaña, Colombia. Teléfono móvil: +57- 3014435662. ORCID: <https://orcid.org/0000-0002-0377-4664> Email: jfhoyosp@ufpso.edu.co , Lugar donde se realizó la investigación: Ocaña, Norte de Santander

1: Docente e Investigador de la Universidad Francisco de Paula Santander Seccional Ocaña, Colombia, Departamento de Ciencias pecuarias. Correo: jfhoyosp@ufpso.edu.co; ORCID: <https://orcid.org/0000-0002-0377-4664>

2: Docente e Investigador de la Fundación de Estudios Superiores Comfanorte FESC Ocaña y Universidad Francisco de Paula Santander Seccional Ocaña, Colombia. Correo: bl_velasquez@fesc.edu.co ; ORCID: <https://orcid.org/0000-0001-7718-853X>

3: Docente e Investigador de la Universidad Francisco de Paula Santander Seccional Ocaña, Colombia, Departamento de Sistemas e informática. Correo: dwracob@ufpso.edu.co; ORCID: <https://orcid.org/0000-0002-1808-3874>

4: Docente e Investigador del Tecnológico Nacional de México / Instituto Tecnológico de Colima, México, Departamento de Ingeniería Eléctrica y Electrónica. Correo: ngarcia@colima.tecnm.mx; ORCID: <https://orcid.org/0000-0002-7078-0941>

Resumen

La aplicación de herramientas 4.0 en el sector agropecuario se muestra como una estrategia prometedora para mejorar los procesos productivos. En este estudio, se llevó a cabo un mapeo sistemático de literatura con el propósito de explorar la viabilidad de la Inteligencia Artificial (IA) y el Aprendizaje Automático (ML) en el ámbito agropecuario. Para ello, se seleccionaron cuatro palabras clave: "Inteligencia artificial", "Aprendizaje Automático", "Sector agropecuario" y "Sostenibilidad", realizando búsqueda en cuatro bases de datos, obteniendo un total de 99 documentos. Después de aplicar criterios de inclusión (I) y exclusión (E), se identificó que solo 66 de ellos cumplían con los parámetros establecidos. Posteriormente, los estudios se clasificaron en cuatro categorías según sus objetivos de investigación: General, Producción animal, Producción Vegetal y Sostenibilidad. Los resultados muestran que la aplicación de estas herramientas conlleva beneficios económicos, ambientales y sociales, lo que permite optimizar recursos y reducir el impacto de la producción agropecuaria. En conclusión, la incorporación de la Inteligencia Artificial y el Aprendizaje Automático en el sector agropecuario tiene un gran potencial para impulsar la sostenibilidad y eficiencia en el campo.

Palabras Clave: Agricultura de precisión, Desarrollo sostenible, E-agricultura, Inteligencia artificial, Toma de decisiones, Zootecnia de precisión.

Abstract

The application of 4.0 tools in the agricultural sector is shown as a promising strategy to improve production processes. In this study, a systematic literature mapping was carried out with the purpose of exploring the feasibility of Artificial Intelligence (AI) and Machine Learning (ML) in the agricultural sector. For this purpose, four key words were selected: "Artificial Intelligence", "Machine Learning", "Agricultural sector" and

"Sustainability", searching in four databases, obtaining a total of 99 documents. After applying inclusion (I) and exclusion (E) criteria, it was identified that only 66 of them met the established parameters. Subsequently, the studies were classified into four categories according to their research objectives: General, Animal Production, Plant Production and Sustainability. The results show that the application of these tools leads to economic, environmental, and social benefits, allowing the optimization of resources and reducing the impact of agricultural production. In conclusion, the incorporation of Artificial Intelligence and Machine Learning in the agricultural sector has great potential to boost sustainability and efficiency in the field.

Key words: Precision agriculture, Precision animal husbandry, Sustainable development, E-agriculture, Artificial intelligence, Decision making,

Introducción

El crecimiento demográfico proyectado por la Organización de las Naciones Unidas, que indica una población mundial cercana a los diez mil millones de habitantes para el año 2050 (Velásquez Carrascal, B. L., et al, 2020a), plantea desafíos significativos en términos de la producción y provisión de alimentos para cumplir con el segundo objetivo de desarrollo sostenible "hambre cero". En este contexto, el sector agropecuario es preponderante en la satisfacción de las necesidades alimenticias y suministro de materias primas (Velásquez Carrascal et al., 2020).

En la actualidad, el sector agropecuario presenta una amplia diversidad, abarcando desde grandes producciones intensivas hasta pequeñas fincas familiares. En ambos casos, se generan grandes cantidades de datos que, en muchos casos, se analizan utilizando técnicas básicas de procesamiento de información (Ramírez Morales, 2018a). No obstante, para tomar decisiones adecuadas y aprovechar la riqueza de estos datos, es esencial contar con técnicas adecuadas de tratamiento y análisis de la información (Walker, 2002).

En la búsqueda de soluciones para mejorar la gestión de la información agropecuaria, la inteligencia artificial (IA) emerge como una herramienta prometedora. En la actualidad, la IA se ha extendido más allá de su asociación con la ciencia ficción y ha encontrado aplicaciones prácticas en diversas áreas, incluidas las recomendaciones de asistentes digitales, la traducción instantánea, los vehículos de conducción autónoma, el reconocimiento facial y la predicción de condiciones de mercado (Mariano et al., 2014).

La IA es una disciplina informática que ha ganado relevancia en diversos entornos, gracias a su capacidad para crear sistemas que emulan un comportamiento inteligente. Esto permite la creación de modelos de decisión en entornos complejos y no lineales, como es el caso de la producción agropecuaria. Los algoritmos de aprendizaje automático (Machine Learning) son especialmente valiosos en este contexto, ya que pueden ser entrenados para analizar los datos agropecuarios y generar resultados similares a los de un experto, extrayendo relaciones a partir de ejemplos (Mucherino et al., 2009).

Aunque el uso de técnicas de IA en sistemas agropecuarios no es una novedad, ha surgido un creciente interés tanto por parte de investigadores como de la industria (Barrientos-Avendaño et al., 2020). Estos algoritmos han sido empleados en tareas de clasificación, diagnóstico, detección temprana, identificación de riesgos epidemiológicos, detección de preñez, control de calidad, entre otros (Hempstalk et al., 2015).

Metodología

La metodología utilizada en este artículo de revisión consistió en realizar una búsqueda exhaustiva de literatura científica y técnica relacionada con la aplicación de la IA en la producción agropecuaria. Se utilizaron bases de datos académicas, revistas científicas y libros especializados para recopilar la información relevante (Barrientos Monsalve et al., 2021).

El mapeo sistemático es una técnica investigativa que establece las pautas para realizar revisiones de bibliografía (Petersen et al., 2008). Esta metodología, consiste en seguir un conjunto de pasos metódicos destinados a localizar, interpretar, resumir y analizar información de artículos publicados relacionados con el tema objeto de estudio. El propósito de la técnica es proporcionar una visión general exhaustiva del área de

interés y reducir al mínimo la posibilidad de cometer errores durante el proceso de revisión (Revelo Sánchez et al., 2018).

En el presente artículo, se aplicó la metodología propuesta por (Petersen et al., 2008), para mapeo sistemático. Esta se compone de cinco pasos secuenciales y bien definidos: (a) Definición de las preguntas de investigación para la revisión; (b) Elección de los criterios para la búsqueda de los estudios relevantes; (c) Establecer criterios de inclusión y excluidos de documentos para la revisión; (d) Definición del esquema de clasificación para organizar y categorizar los estudios recopilados; (e) Extracción de datos y realización del mapeo de los estudios de manera sistemática. A continuación, se describen en detalle cada uno de estos pasos realizados.

Definición de las preguntas de investigación para la revisión

El propósito de este mapeo sistemático radica en la identificación y categorización de las investigaciones actuales que abordan la aplicación de la Inteligencia Artificial (IA) y el Aprendizaje Automático (ML) o Machine Learning (ML) en el ámbito del sector agropecuario. Con el fin de localizar estudios primarios pertinentes, se han formulado las siguientes interrogantes de investigación:

P1: ¿Cuál es la aplicabilidad de Inteligencia artificial (IA) y Machine Learning (ML) aplicado al sector agropecuario?

P2: ¿En qué procesos productivos agropecuarios se ha empleado Inteligencia artificial (IA) y Machine Learning (ML)?

P3: ¿Qué aporte tiene el uso de Inteligencia artificial (IA) y Machine Learning (ML) para la sostenibilidad del sector agropecuario?

Elección de los criterios para la búsqueda de los estudios relevantes

La búsqueda de estudios primarios se estructura en dos etapas. En la primera, se elabora la cadena de búsqueda considerando los términos relacionados con el tema de investigación. En la segunda, se seleccionan las bases de datos electrónicas; la cadena de búsqueda se conformó: (a) mediante la incorporación de las palabras clave presentes en las preguntas planteadas, (b) obtenidas de documentos relevantes, y (c) adquiridas a través de una breve entrevista realizada a expertos y productores sobre información encontrada por ellos en la WEB. En la tabla 1 se muestra el resultado, donde se definieron cuatro palabras clave principales: “Inteligencia artificial/ Artificial intelligence”, “Aprendizaje Automático/Machine Learning”, “Sector agropecuario/ Agricultural sector” y “Sostenibilidad/ Sustainability”.

Tabla1. Palabras clave y términos relacionados

Referencia	Categoría	Termino relacionado
PC1	Inteligencia artificial/ Artificial intelligence	Toma de decisiones/Decision making Predicciones/ Predictions
PC2	Aprendizaje Automático/Machine Learning	Algoritmos/ Algorithms Redes de neuronas/ Neuron networks
PC3	Sector agropecuario/ Agricultural sector	Producción animal/ Animal production Producción vegetal/ Plant production
PC4	Sostenibilidad/ Sustainability	Eficiencia productiva/ Production efficiency Reducción de costos/ Cost reduction

Fuente: Elaboración Propia

La búsqueda de información se realizó partiendo de los sitios WEB recomendados por los productores (paginas corporativas y técnicas) las cuales dan el punto de inicio para el enfoque de las inquietudes presentadas sobre la temática y las siguientes bases de datos: Scopus, Dialnet y Google Académico. Para la creación de la cadena final de búsqueda, cada categoría PC1, PC2, PC3 y PC4 se combinó con el operador booleano "AND", y estas a su vez con los términos relacionados de cada categoría con el operador booleano "OR", de la siguiente forma para Scopus:

TAK (Artificial intelligence OR Decision making OR Predictions) AND (Machine Learning OR Algorithms OR Neuron networks) AND (Agricultural sector OR Animal production OR Plant production) AND (Sustainability OR Production efficiency OR Cost reduction).

Los resultados se muestran en la tabla2.

Tabla2: Estudios primarios obtenidos

Base de datos	Cantidad
WEB	12
Scopus	30
Dialnet	8
Google Académico	50
Total	99

Fuente: Elaboración Propia

Establecer criterios de inclusión y excluidos de documentos para la revisión

Se establecieron los criterios de inclusión (CI) y exclusión (CE), con el fin de descartar o incluir documentos al análisis.

CI1: Documentos publicados en los últimos cinco (5) años (2019-2023), incluyendo documento por fuera de este rango, considerados básicos para la implementación del uso de (IA) y (ML) en el sector agropecuario.

CI2: Si varios documentos se relacionen con el mismo estudio, se seleccionará el más reciente.

CI3: Reportes técnicos y documentos disponibles en WEB paginas corporativas y técnicas (literatura gris) recomendada por los productores.

CI4: Solo se incluyen versiones completas de los estudios.

CE1: Reportes publicitarios sobre el uso de (IA) y (ML) y estudios secundarios.

CE2: Documentos en idioma diferente a inglés o español.

CE3: Documentos que no presentan relación al sector agropecuario.

Definidos los criterios de (CI) y (CE), se analizan títulos y resúmenes de cada artículo (dependiendo el documento la introducción y conclusiones), descartando los irrelevantes para el estudio.

Definición del esquema de clasificación para organizar y categorizar los estudios recopilados

Con el propósito de obtener una comprensión profunda de las contribuciones de cada documento examinado, se empleó la categorización propuestas por (Wieringa et al., 2006), para analizar y clasificar los diferentes tipos de estudios planteados en los documentos, de la siguiente forma:

- Investigación de validación: Se refiere a técnicas nuevas que aún no se han implementado en la práctica, utilizadas comúnmente en laboratorio.
- Investigación de evaluación: Engloba técnicas implementadas en la práctica son el objeto de evaluarlas incluyendo análisis, pros y contras.
- Propuesta de solución: Implica la presentación de soluciones para problemáticas específicas, consideradas innovación o ajuste a técnicas ya existentes, basadas en estudios de casos y otro tipo de análisis.
- Artículos filosóficos: Incluye estudios que presentan nuevas perspectivas o enfoques del área de estudio, empleando marcos taxonómicos y conceptuales.
- Artículos de opinión: Comprende estudios que expresan opiniones personales acerca de la idoneidad de las técnicas, su utilidad o implementación.
- Artículos de experiencias: Experiencias personal del autor, exponiendo lo realizado en la práctica.

Extracción de datos y realización del mapeo de los estudios de manera sistemática

Se analizó y clasificó los documentos de acuerdo con los pasos anteriormente presentados, evidenciando material para responder a las preguntas de investigación, los datos se procesaron utilizando una hoja de cálculo, facilitando el análisis estadístico, determinación del número de publicaciones por año, lugar y tipo.

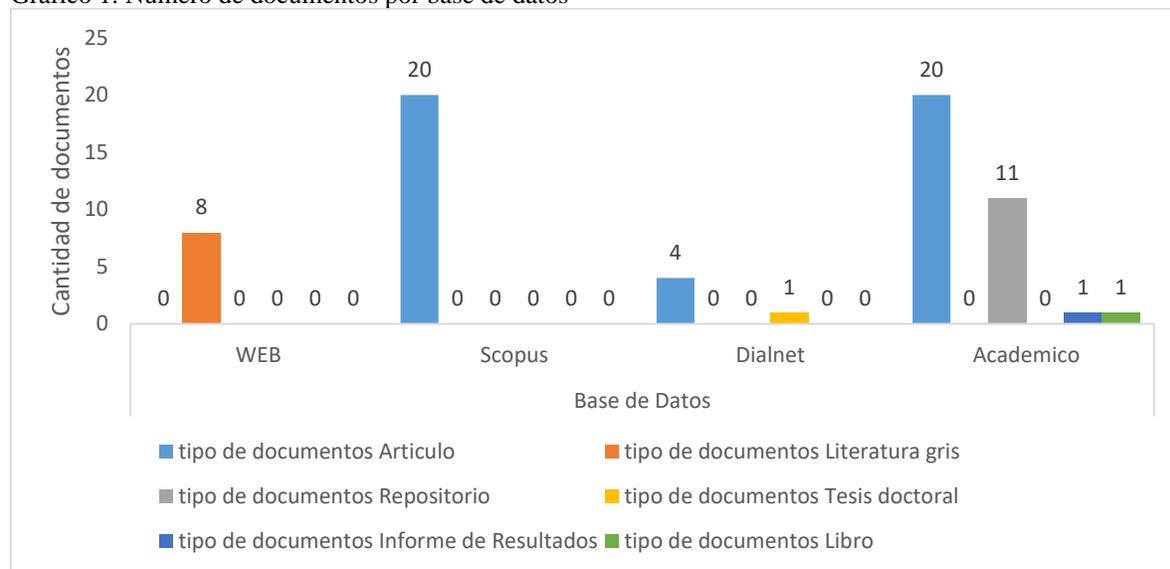
Resultados

Se relacionaban los hallazgos del mapeo sistemático, sobre la aplicabilidad de Inteligencia artificial (IA) y Machine Learning (ML) aplicado en el sector agropecuario. Inicialmente, al realizar la búsqueda en las bases de datos seleccionadas, se obtuvieron 99 documentos. A continuación, se aplican los criterios de inclusión y exclusión (CI1+ CE1+CE2), se incluyen documentos publicados entre (2019-2023), se tienen en cuenta algunos documentos por fuera de este rango, considerados básicos para la implementación del uso de (IA) y (ML) en el sector agropecuario, excluyendo Reportes publicitarios sobre el uso de (IA) y (ML) y estudios secundarios (revisiones y mapeos sistemáticos), y Documentos en idioma diferente a inglés o español, quedando 86 documentos.

A estos 86 documentos se aplican los criterios (CI2+CI3+CI4+CE3), analizando título y resumen (si es el caso), identificando 75 trabajos pertinentes con la temática; se aplican nuevamente los criterios, eliminaron 9 trabajos. Dejando 66 documentos, para responder a las preguntas planteadas. El listado final de los documentos se relaciona en la bibliografía del artículo.

Antes de responder a las preguntas planteadas, se dará una relación el año y base de datos donde se publicaron los 66 documentos. En la gráfica 1 presenta en el eje X la base de datos donde se encontró el documento y en el eje Y la cantidad de trabajos por tipo de publicación.

Gráfico 1. Numero de documentos por base de datos

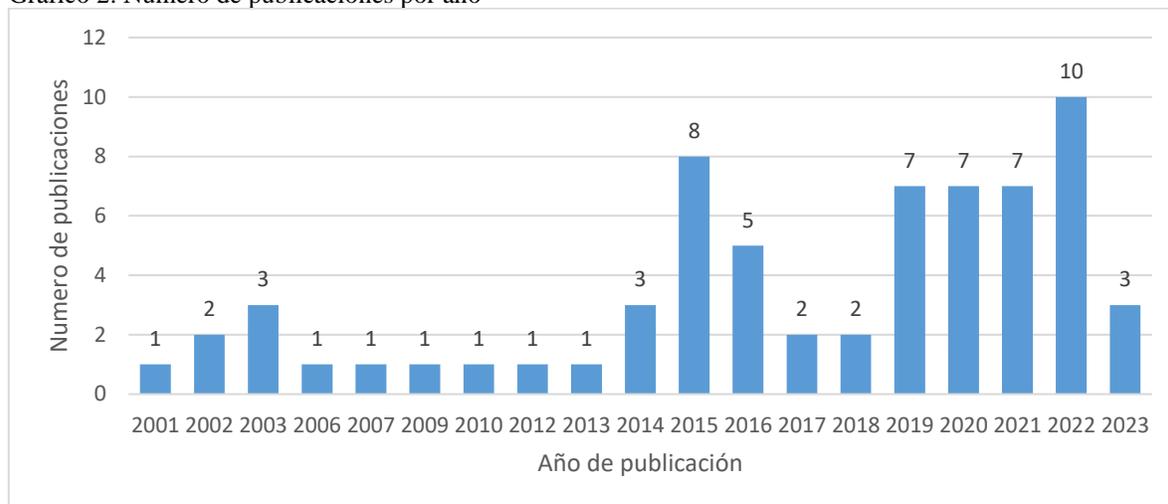


Fuente: Elaboración Propia

De acuerdo con la figura 1. el número de artículos analizados es 44, seguido por 11 documentos encontrados en repositorios institucionales, 8 artículos técnicos tomados de la WEB, 1 informe y 1 libro. Destacando la importancia que tiene los artículos para la divulgación del uso de Inteligencia artificial (IA) y Machine Learning (ML) aplicado al sector agropecuario.

Observando la fecha de publicación, se evidencia que el 51.5% de los documentos sobre el tema se publicaron en los últimos 5 años, como se evidencia en la figura 2. Este aumento indica el creciente interés investigativo del tema. Presentando un pico aislado en el año 2015 con documentos.

Gráfico 2. Numero de publicaciones por año



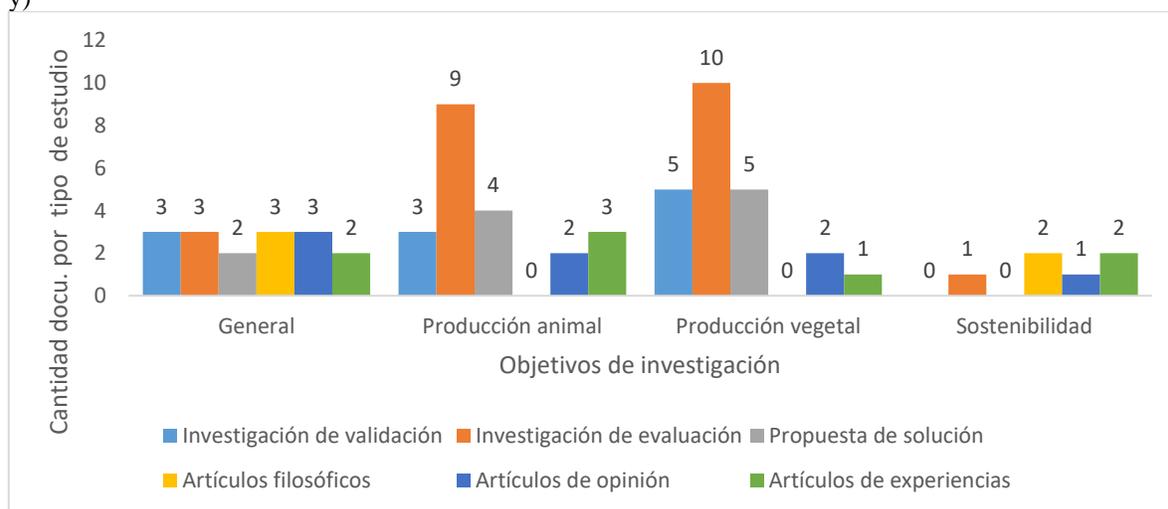
Fuente: Elaboración Propia

Como se menciona en el numera 2.4 la categorización propuesta por (Wieringa et al., 2006) para reunir los documentos por “tipo de estudio”, se hace necesario para contestar la pregunta P1: ¿Cuál es la aplicabilidad de Inteligencia artificial (IA) y Machine Learning (ML) aplicado al sector agropecuario?, generar una nueva categorización de los documentos “por objetivo de investigación”; proponiendo las siguientes tres categorías:

- General: Documentos o estudios sobre la aplicación de Inteligencia artificial (IA) y Machine Learning (ML) como alternativa para el desarrollo del sector agropecuario.
- Producción animal: Documentos o estudios sobre la aplicación de Inteligencia artificial (IA) y Machine Learning (ML) en el sector pecuario.
- Producción vegetal: Documentos o estudios sobre la aplicación de Inteligencia artificial (IA) y Machine Learning (ML) en el sector agrícola.
- Sostenibilidad: Documentos o estudios sobre el efecto o incidencia de la Inteligencia artificial (IA) y Machine Learning (ML) en la sostenibilidad de los sistemas de producción.

Utilizando estas categorías por objetivo de investigación y las presentadas en el numeral 2.4 se crea el grafico 3.

Gráfico 3. Distribución de documentos por objetivo de investigación (eje x) y cantidad por tipo de estudio (eje y)



Fuente: Elaboración Propia

Al observar la gráfica 3, se evidencia que la mayoría de los documentos 23 pertenecen a la categoría de producción vegetal, destacándose el tipo de evaluación de investigación con 10 documentos. La segunda categoría con mayor número de documentos es producción animal con 21, igualmente con 10 documentos en el parámetro de investigación de evaluación.

De donde se destacan las siguientes apreciaciones: En la actualidad, el uso (IA) en el campo agropecuario ha adquirido una importancia significativa debido a sus diversos beneficios para mejorar la productividad, eficiencia y sostenibilidad. La (IA) hace referencia a sistemas informáticos con capacidad para percibir el entorno, aprender de la experiencia, procesar grandes volúmenes de datos y tomar decisiones basadas en la información recibida. Esta tecnología se clasifica en cuatro categorías principales: inteligencia automatizada e inteligencia autónoma, inteligencia asistida e inteligencia aumentada.

Inteligencia automatizada en la agricultura promete cambiar la forma de producir alimentos, utilizando menos recursos y mano de obra, esto se logra mediante la implementación de tecnologías avanzadas que permiten optimizar el proceso de producción y reducir el impacto ambiental (EDS Robotics, 2021; Figueroa Jaimés, 2022). Por otro lado, la inteligencia autónoma en la agricultura se refiere al uso de máquinas agrícolas que pueden tomar decisiones por sí mismas, reduciendo así la intervención humana en el proceso. Estas máquinas utilizan fuentes de energía renovable y contribuyen a la reducción de emisiones de gases de efecto invernadero, al tiempo que aumentan la eficiencia y productividad en el campo (Quiroz & Msg, 2021).

La inteligencia asistida en la agricultura combina el conocimiento humano y la tecnología para facilitar tareas cotidianas y aumentar la eficiencia en los procesos agrícolas. Los sistemas de inteligencia aumentada, por su parte, han demostrado ser herramientas potenciales para la agricultura de precisión, permitiendo a los productores observar condiciones en tiempo real para detectar a tiempo posibles problemas (Lopez, 2020).

La implementación de la (IA) en el sector agropecuario se evidencia debido a los desafíos para aumentar la producción y garantizar la seguridad alimentaria; el uso inadecuado del suelo, el impacto del cambio climático y la aparición de enfermedades y plagas son solo algunos de los obstáculos a los que se enfrenta la industria agropecuaria (Segovia et al., 2021)(Herrera Carvajal et al., 2022).

En la búsqueda de soluciones a estos desafíos, las tecnologías de (IA) han demostrado su capacidad para optimizar la gestión de cultivos, mejorar la eficiencia en el uso de recursos, prevenir y controlar enfermedades y plagas, y proporcionar datos precisos y en tiempo real para la toma de decisiones (FIA, 2021). Una aplicación relevante de la (IA) es la “Agricultura de Precisión”; esta disciplina se basa en el uso de tecnologías avanzadas como sensores, drones, GPS y sistemas de información geográfica (SIG) para recopilar datos sobre los cultivos y el entorno. Estos datos se analizan mediante algoritmos de aprendizaje automático, que optimizan la gestión de los cultivos, aplicación de tratamientos específicos y uso de recursos como agua y fertilizantes (Johanna et al., 2020).

Aprendizaje Automático (Machine Learning - ML) en el Sector Agropecuario

El aprendizaje automático (ML) o aprendizaje máquina es una técnica de inteligencia artificial que abarca un conjunto de algoritmos capaces de realizar tareas complejas sin requerir programación explícita (Ramírez-Morales et al., 2016). En la actualidad, el uso de técnicas de ML en el sector agropecuario ha ganado relevancia. Si bien existen numerosas publicaciones que hacen referencia a su aplicación en diversos ámbitos, aún hay áreas por explorar, convirtiéndolo en un tema de interés para los investigadores especializados en el área.

En el campo del modelado, se han publicado trabajos sobre el uso de redes de neuronas artificiales para modelar el secado de granos (Farkas et al., 2000). También se ha utilizado ML para simular el daño en duraznos (*Prunus persica*) durante el transporte (Bielza et al., 2003). Algunos sistemas emplean espectrómetros y sensores junto con algoritmos de ML para autenticar uvas (*Vitis vinifera*) previo a la fermentación (Roussel et al., 2003). Los sistemas de clasificación son ampliamente utilizados en el sector agropecuario; entre ellos, destaca un sistema basado en redes neuronales y lógica difusa para clasificar y graduar manzanas (*Malus domestica*) según su tamaño (Shahin et al., 2001). Otro sistema de interés se enfoca en la clasificación de carnes, empleando tres algoritmos de ML (Díez et al., 2003).

En cuanto a los sistemas expertos para el soporte en la toma de decisiones, se han realizado trabajos para mejorar y optimizar la productividad agropecuaria (Rico-Bautista et al., 2019). Recientemente, se ha observado un creciente interés en el diagnóstico de enfermedades. Además, a nivel comercial, se menciona un sistema de pronóstico de precios futuros para alimentos utilizando técnicas de (ML) (Doganis et al., 2006).

Para responder a la pregunta P2: ¿En qué procesos productivos agropecuarios se ha empleado Inteligencia artificial (IA) y Machine Learning (ML)?, se evidencia la aplicabilidad de las herramientas tecnológicas en el sector agrícola con aplicaciones en la Industria de la Caña de Azúcar (*Saccharum officinarum*).

El flujo de producción en la industria azucarera implica diversos procesos y subprocesos que requieren un análisis detallado para mantener altos estándares de calidad (Polanco et al., 2014). Las plantas agroindustriales necesitan sistemas costo-eficientes y no destructivos para controlar la calidad de sus procesos de producción, la seguridad alimentaria y el cumplimiento de especificaciones técnicas (Kumaravelu & Gopal, 2015); (Ramírez-Morales et al., 2016).

En el análisis de materias primas orgánicas, la espectroscopía de Reflectancia del Infrarrojo Cercano (NIR spectroscopy) asociada a la quimiometría es una técnica comúnmente utilizada; sin embargo, la relación entre la absorción en la región del infrarrojo cercano y lo analizado suele ser de tipo no lineal (Ramírez-Morales et al., 2016). Actualmente, hay una creciente literatura que aplica técnicas de Machine Learning en quimiometría, destacando el uso de Artificial Neural Networks y Support Vector Machines, que se basan en el reconocimiento de patrones (Brereton, 2015). En la industria de los alimentos, la espectroscopía NIR se ha empleado ampliamente para analizar la calidad nutricional de lácteos, aceites, cárnicos, peces, cereales y frutas (Wang et al., 2017) (Tajammal Munir et al., 2015).

En el contexto de la industria de la caña de azúcar, se han realizado varios estudios que evidencian la correlación entre los espectros NIR y los indicadores de calidad de la caña de azúcar (Valderrama et al., 2007). Se han investigado técnicas de pre-procesamiento de espectros NIR en caña de azúcar, así como la selección de características y algoritmos de quimiometría para mejorar la predicción de analitos objetivos (Zayas Ruiz et al., 2015).

(Rasmussen et al., 2015) demostraron que el uso de modelos de calibración con Máquinas de Soporte Vectorial (SVM) para regresión resulta eficiente para estimar los valores de °Brix y Sacarosa, parámetros de calidad del proceso industrial del azúcar. Aunque el modelo propuesto utiliza todo el espectro NIR, se sugiere que aún es posible optimizarlo mediante una adecuada técnica de pre-procesamiento, selección de características y optimización de los parámetros de la máquina de soporte de vectores.

Aplicación de inteligencia artificial en otros cultivos

El uso de la (IA) en cultivos específicos ha mostrado resultados prometedores; en el caso del banano (*Musa paradisiaca*), se han desarrollado aplicaciones para detectar enfermedades, evitando pérdidas millonarias (CÁRDENAS VALDOVINOS et al., 2017), (Alianza, 2019) en la producción de cacao (*Theobroma cacao*), la (IA) ha permitido control preciso de factores ambientales y desarrollo de pronósticos agrícolas y de mercado (Ortega et al., 2019). En la producción de la palma de aceite (*Elaeis guineensis*), la (IA) ha contribuido al manejo de cultivos (Mohd Shafri et al., 2019). Por otro lado, en el cultivo del arroz (*Oryza sativa*), el aprendizaje automático y la robótica se utilizan para tareas repetitivas y el monitoreo de condiciones climáticas (Asencio Beltran, 2022).

Espectroscopía en el Infrarrojo Cercano (NIR)

La espectroscopía es una técnica que estudia la interacción entre la radiación electromagnética y las sustancias químicas, donde la naturaleza de esta interacción depende de las propiedades de la muestra. Cuando la radiación atraviesa una muestra, ciertas frecuencias son absorbidas por las moléculas, lo que genera vibraciones moleculares y crea un patrón único que caracteriza a la sustancia (Morales et al., 2016).

En el ámbito agroalimentario, la espectroscopía NIR ha sido adoptada como una técnica analítica para evaluar la calidad de alimentos de forma rápida y no destructiva. Sin embargo, para extraer información relevante de los datos espectrales, es necesario utilizar algoritmos de aproximación estadística conocidos como quimiometría (Kumaravelu & Gopal, 2015).

La espectroscopía NIR se basa en las transiciones vibratorias de enlaces químicos, como C-H, N-H, S-H y O-H, presentes en diversos compuestos orgánicos e inorgánicos. Los espectros NIR abarcan un rango de longitud de onda entre 780 nm y 2500 nm. A pesar de su utilidad, la espectroscopía NIR requiere calibración debido a que no existen modelos preestablecidos para medir la interacción entre la materia y la radiación (Kumaravelu & Gopal, 2015). Para obtener modelos de calibración precisos, es necesario contar con un número suficiente de muestras que representen las variaciones en las propiedades físicas o químicas a analizar, como las provenientes de distintos lugares, climas y sistemas de producción (Ramírez Morales, 2018b).

El análisis de espectros NIR puede contener información sobre diferentes variables, lo que complica el proceso de calibración (Blanco & Villarroya, 2002). Además, factores como temperatura, viscosidad, cristales y pH también pueden afectar el espectro NIR, al igual que las bandas de absorción de agua, el ruido del instrumento de medición y otros efectos ambientales, lo que requiere el uso de técnicas estadísticas multivariantes y preprocesamiento para obtener modelos robustos (Teixeira Dos Santos et al., 2013).

En el sector agroalimentario, la quimiometría es esencial para la espectroscopía NIR, utilizando métodos de análisis multivariante como el Análisis de Componentes Principales (PCA) para análisis cualitativo de los datos espectrales, y el Análisis de Regresión por Cuadrados Mínimos Parciales (PLS) para predicción cuantitativa de los parámetros de interés en las muestras (Kumaravelu & Gopal, 2015). En la literatura científica también se han reportado el uso de otros métodos como la regresión lineal, regresión multivariante, redes de neuronas artificiales y Support Vector Regression (SVR) (Rasmussen et al., 2015).

Igualmente, en sector de la producción animal el uso de la IA se convierte en un instrumento importante para la producción animal, una de estas aplicaciones es el monitoreo constante, lo que permite detectar enfermedades y lesiones de manera temprana, ayudando a prevenir problemas y garantizar el bienestar animal (Carrero Carrero, 2018); (Júlio Cesar et al., 2022). Además, la IA puede ayudar a optimizar la alimentación, mejorando la eficiencia y desperdicio (Cirión et al., 2022); también puede utilizarse para controlar la calidad de los productos, como huevos (Juárez & Pinzón, 2023). La automatización de tareas también es una aplicación de la IA en la producción animal, mejorando eficiencia y reduciendo carga de trabajo para los productores (Juárez & Pinzón, 2023).

El futuro del Machine Learning en la producción animal se vislumbra prometedor, ya que esta tecnología tiene el potencial de mejorar la gestión y el aprendizaje en las granjas de animales, algunas de las aplicaciones específicas incluyen:

- **Monitoreo de animales:** El (ML) puede utilizarse para analizar datos recopilados de sensores y dispositivos de monitoreo en las granjas, lo que permite identificar patrones y tendencias en el comportamiento y la salud de los animales (Hassán Vásquez, J. A., 2023). Por ejemplo, se pueden utilizar algoritmos de (ML) para detectar signos tempranos de enfermedades o estrés en los animales, lo que permite tomar medidas preventivas y mejorar su bienestar.
- **Optimización de la alimentación:** El (ML) puede ayudar a determinar la dieta óptima para los animales, teniendo en cuenta factores como su edad, peso, raza y necesidades nutricionales individuales (Trillos-Arenas, J., et al, 2019; Ordoñez Merino, J. I., 2023). Por ejemplo, se pueden utilizar algoritmos de (ML) para analizar grandes cantidades de datos sobre la composición de los alimentos y los requerimientos nutricionales de los animales, y así recomendar la dieta más adecuada para maximizar su crecimiento y salud.
- **Automatización de tareas:** El (ML) puede ser utilizado para automatizar ciertas tareas en la producción animal, como la alimentación, el control del ambiente y la limpieza de las instalaciones (Carrillo-Riofrío, F. M., Segovia-Cáceres, S. M., & Jijon-Paredes, E. M., 2021). Por ejemplo, se pueden utilizar algoritmos de (ML) para controlar sistemas de alimentación automatizados que ajusten la cantidad y el tipo de alimento

suministrado a los animales en función de sus necesidades individuales, mejorando la eficiencia y reducir los costos de mano de obra en las granjas.

Aplicación de Machine Learning (ML) en Producción Avícola

En la industria avícola, los avicultores han estado recopilando datos durante décadas para monitorear la salud y producción de sus lotes, estos datos incluyen información sobre consumo de alimentos y agua, crecimiento y mortalidad, con el objetivo de mejorar el rendimiento (Hepworth et al., 2012). Para analizar los datos de producción en sistemas agropecuarios, se han utilizado ampliamente métodos matemáticos, técnicas estadísticas y visualización de datos para identificar diferencias significativas en los indicadores productivos, como posibles anomalías (De Vries & Reneau, 2010).

El uso de gráficos estadísticos de control, comúnmente utilizado en control de procesos industriales, también ha sido aplicado en la cría de animales. Sin embargo, las propiedades estadísticas de los datos relacionados con los animales no siempre cumplen con los principios básicos de estas técnicas, a medida que las poblaciones de animales aumentan en tamaño, se hace necesario incorporar sistemas automáticos de monitoreo en la gestión de la producción ganadera para complementar la observación humana (Arda, 2016).

La producción de huevos en una explotación avícola puede verse afectada por diversos factores como la alimentación (calidad y cantidad), consumo de agua, luz recibida, presencia de parásitos, enfermedades y condiciones ambientales; varios estudios han desarrollado modelos matemáticos para describir la curva de producción y su persistencia en gallinas ponedoras (Juárez & Pinzón, 2023). Otros trabajos han investigado la curva de producción para determinar el mejor aprovechamiento de los lotes de gallinas ponedoras (Cirión et al., 2022).

La recopilación masiva de datos ha permitido diseñar sistemas expertos y prototipos de monitoreo de producción avícola, que utilizan análisis estadísticos para detectar problemas en la curva de producción (Morales et al., 2016). Sin embargo, la monitorización en tiempo real enfrenta desafíos debido a la variabilidad natural de los datos, como la hora de recogida, estado nutricional y fotoperiodo; en la actualidad, la implementación de alertas tempranas en sistemas de gestión de la producción animal ha ganado interés. Sin embargo, esto requiere recopilar suficiente información para establecer reglas de inferencia y detectar automáticamente las anomalías en la curva de producción, lo que resulta desafiante debido a la variabilidad natural y fluctuaciones aleatorias de los datos (Woudenberg et al., 2014).

La detección temprana de problemas en los animales es crucial para tomar acciones oportunas y reducir daños y contagios en caso de enfermedades, lo que impacta en la eficacia y reducción de costos del tratamiento (Júlio Cesar et al., 2022). En la avicultura, los algoritmos de (ML) han demostrado éxito al reemplazar a modelos matemáticos y estadísticos tradicionales para modelar la curva de producción de huevos. Son fáciles de usar, requieren menos variables y resultan más eficientes (Felipe et al., 2015).

Por último, para contestar la pregunta P3 ¿Qué aporte tiene el uso de Inteligencia artificial (IA) y Machine Learning (ML) para la sostenibilidad del sector agropecuario?, se puede mencionar que la implementación de la (IA) en el ámbito agropecuario conlleva diversos beneficios, destacando entre ellos una mayor eficiencia y reducción de costos. (Berrio & Alzate, 2018) afirman que, al adoptar innovaciones tecnológicas en el sector agropecuario, se mejora la productividad y disminuir los gastos de producción. En este sentido, la (IA) juega un papel crucial al proporcionar rápidamente información sobre el desarrollo de los cultivos, lo que mejora la toma de decisiones en este ámbito (Brenes et al., 2020); (Calvo, 2022).

No obstante, es importante tener en cuenta los desafíos asociados con la implementación de estas tecnologías avanzadas. Según Manchado (Quiroz & Msg, 2021); (Pelegri, 2022) la incorporación de la (IA) presenta un amplio potencial para mejorar la sostenibilidad y eficiencia, además de estimular la competitividad en el mercado. Se proponen soluciones tecnológicas como robots capaces de clasificar cosechas y drones para optimizar los cultivos, monitorizar el riego y las condiciones climáticas.

Según (Chakraborty et al., 2022), se han desarrollado robots terrestres para diversas aplicaciones agropecuarias, siendo el principal desafío lograr autónoma en la navegación. Este desafío cobra especial relevancia ante la

proyección de un aumento del 70% en la producción de alimentos para el año 2050, con el propósito de satisfacer las necesidades de la creciente población mundial. En este contexto, es crucial que las innovaciones científicas y tecnológicas sean utilizadas de forma responsable para garantizar una producción sostenible en el tiempo (Barrientos Monsalve et al., 2021).

También, la (IA) detectará patrones y señales tempranas de enfermedades y plagas en cultivos y animales, posibilitando respuestas rápidas y precisas para controlar y prevenir su propagación, minimizando pérdidas económicas y reduciendo el uso innecesario de pesticidas. Además, facilitará la gestión logística y la distribución eficiente de productos agrícolas, planificando rutas optimizadas para el transporte y minimizando el desperdicio. Asimismo, contribuirá al monitoreo y protección ambiental mediante la evaluación de la calidad del suelo, agua y aire, así como la identificación de prácticas sostenibles para conservar la biodiversidad y el equilibrio ecológico (Bonilla Segovia et al., 2021).

Conclusiones

La Inteligencia artificial (IA) y Machine Learning (ML) se convertirán en herramientas valiosas para el sector agropecuario, que ofrecerán soluciones innovadoras y sostenibles para abordar los desafíos que enfrenta la producción agropecuaria en la actualidad; el uso de robótica, aprendizaje automático, drones y sistemas de información geográfica demuestran su eficacia para mejorar la productividad.

Con la información recabada en 66 documentos, se pueda contextualizar la aplicabilidad de (IA) y (ML) en el sector agropecuario presentando beneficios económicos, ambientales y sociales, con la optimización de recursos y reducción en el impacto ambiental. Además, el acceso a información en tiempo real y el uso de tecnologías avanzadas permiten toma de decisiones contextualizadas y manejo eficiente de los cultivos, lo que se traduce en mayor rendimiento y rentabilidad para los productores.

El aprendizaje automático ha encontrado aplicaciones valiosas y diversas en el sector agropecuario, desde el modelado y la clasificación hasta el soporte en la toma de decisiones y el pronóstico de precios futuros, mostrando un potencial significativo para optimizar y mejorar la productividad y eficiencia en la agricultura y ganadería.

El Machine Learning (ML) tiene el potencial de revolucionar la producción animal al mejorar la gestión, el bienestar animal y la eficiencia en las granjas (Barrientos-Avedaño et al., 2019). A medida que esta tecnología avanza, se tendrá mayor uso de algoritmos y sistemas inteligentes en la producción animal, lo que podría conducir a mejoras significativas en la industria.

Agradecimientos

Nuestro agradecimiento al grupo de ingeniería en innovación tecnología y emprendimiento (GRIITEM); igualmente, al grupo de investigación en producción animal sostenible, biodiversidad y biotecnología (GIPAB) de la Universidad Francisco de Paula Santander Seccional Ocaña.

Fuentes de Financiación

Esta investigación fue autofinanciada.

Referencias Bibliográficas

1. Arencibia Pardo, F. R., Peña Rodríguez, B., & Pardo García, A. . (2020). El falso conteo de las revoluciones industriales: de la 1 a la 5. Productividad y mano de obra. Fin del paradigma, comienzo de la ética. *Aglala*, 11(1), 95–106. Recuperado a partir de <https://revistas.curn.edu.co/index.php/aglala/article/view/1562>

2. Alianza. (2019, August 12). *La inteligencia artificial ayuda a los productores de banano a proteger la fruta favorita del planeta | Alliance Bioversity International - CIAT*. <https://alliancebioversityciat.org/es/node/18015>
3. Arda, A. (2016). *Automated Monitoring Systems to Assess Gait Score and Feed Intake of Broilers - KU Leuven*.
4. Asencio Beltran, L. S. (2022). *DISEÑO DE UN MODELO PREDICTIVO DE APRENDIZAJE AUTOMÁTICO SUPERVISADO PARA DETERMINAR PRECIOS DINÁMICOS DE INSUMOS AGRÍCOLAS DE LA REGIÓN COSTA DEL ECUADOR*. Universidad de Guayaquil .
5. Barrientos Monsalve, E. J., Velásquez Carrasca, B. L., & Hoyos Patiño, J. F. (2021). Contemporaneidad de las corrientes del pensamiento en los paradigmas de investigación | Aglala. *Aglala*, 12(s1), 163–181.
6. Barrientos-Avendaño, E., Coronel-Rojas, L. A., Cuesta-Quintero, F., & Rico-Bautista, D. (2020). Store-to-store sales management system: Applying artificial intelligence techniques [Sistema de administración de ventas tienda a tienda: Aplicando técnicas de inteligencia artificial]. *RISTI - Revista Iberica de Sistemas e Tecnologias de Informacao*, 2020(E27), 677–689. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85080989924&partnerID=40&md5=af078c48936a0a6b415d8af335c9a80b>
7. Barrientos-Avendaño, E., Rico-Bautista, D., Coronel-Rojas, L. A., & Cuesta-Quintero, F. R. (2019). Smart farm: Defining of infrastructure based on internet of things, IPv6 and software defined networks [Granja inteligente: Definición de infraestructura basada en internet de las cosas, IPv6 y redes definidas por software]. *RISTI - Revista Iberica de Sistemas e Tecnologias de Informacao*, E17, 183–197. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85061174873&partnerID=40&md5=ac38dc2b5b0d67edae2c307fe67f26e3>
8. Berrio, V., & Alzate, D. A. (2018). *Sistema de optimización de las técnicas de planificación en agricultura de precisión por medio de drones*. 39.
9. Bielza, C., Barreiro, P., Rodríguez-Galiano, M. I., & Martín, J. (2003). Logistic regression for simulating damage occurrence on a fruit grading line. *Computers and Electronics in Agriculture*, 39(2), 95–113. [https://doi.org/10.1016/S0168-1699\(03\)00021-8](https://doi.org/10.1016/S0168-1699(03)00021-8)
10. Blanco, M., & Villarroya, I. (2002). NIR spectroscopy: a rapid-response analytical tool. *TrAC Trends in Analytical Chemistry*, 21(4), 240–250. [https://doi.org/10.1016/S0165-9936\(02\)00404-1](https://doi.org/10.1016/S0165-9936(02)00404-1)
11. Bonilla Segovia, J. S., Dávila Rojas, F. A., & Villa Quishpe, M. W. (2021). Estudio del uso de técnicas de inteligencia artificial aplicadas para análisis de suelos para el sector agrícola. *RECIMUNDO*, 5(1), 4–19. [https://doi.org/10.26820/RECIMUNDO/5.\(1\).ENERO.2021.4-19](https://doi.org/10.26820/RECIMUNDO/5.(1).ENERO.2021.4-19)
12. Brenes, J. A., Martínez, A., Quesada-López, C., & Jenkins, M. (2020). Sistemas de apoyo a la toma de decisiones que usan inteligencia artificial en la agricultura de precisión: un mapeo sistemático de literatura. *RISTI*, E28, 217–229.
13. Brereton, R. G. (2015). Pattern recognition in chemometrics. *Chemometrics and Intelligent Laboratory Systems*, 149, 90–96. <https://doi.org/10.1016/J.CHEMOLAB.2015.06.012>
14. Calvo, A. (2022, March 14). *Mejoras de la inteligencia artificial en la agricultura*. <https://www.agroptima.com/es/blog/mejoras-de-la-inteligencia-artificial-en-la-agricultura/>
15. CÁRDENAS VALDOVINOS, E., GARCÍA DÍAZ, N., GARCÍA VIRGEN, J., & FLORES GALLEGOS, E. (2017). Modelo difuso para predecir la proliferación de plaga “Sigatoka Negra” en el cultivo de plátano . *Revista de Ingeniería Eléctrica*, 1, 16–21.
16. Carrero Carrero, J. L. (2018). *SISTEMA DE VISIÓN ARTIFICIAL PARA EL MONITOREO DE POLLOS DE ENGORDE EN LA GRANJA AVICOLA MASCRIOLLO.SAS DE LA CIUDAD DE CUCUTA*. Universidad de Pamplona .
17. Chakraborty, S., Elangovan, D., Govindarajan, P. L., ELnaggar, M. F., Alrashed, M. M., & Kamel, S. (2022). A Comprehensive Review of Path Planning for Agricultural Ground Robots. *Sustainability*, 14(15), 9156. <https://doi.org/10.3390/SU14159156>
18. Cirión, L. E. C., Iglesias, A. M. C., & Viñoles, J. (2022). La avicultura de precisión: una herramienta clave para potenciar la eficiencia del sector avícola. *LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades*, 3(2), 67–83. <https://doi.org/10.56712/latam.v3i2.64>

19. Corzo-Arévalo, D., & Cuadra, R. (2019). Crowdsourcing como herramienta de participación colectiva en la creación de modelos educativos. Estudio de caso del Centro Latinoamericano del Propósito. I+ D REVISTA DE INVESTIGACIONES, 13(1), 129-136.
20. De Vries, A., & Reneau, J. K. (2010). Application of statistical process control charts to monitor changes in animal production systems. *Journal of Animal Science*, 88(suppl_13), E11–E24. <https://doi.org/10.2527/JAS.2009-2622>
21. Díez, J., Bahamonde, A., Alonso, J., López, S., Del Coz, J. J., Quevedo, J. R., Ranilla, J., Luaces, O., Alvarez, I., Royo, L. J., & Goyache, F. (2003). Artificial intelligence techniques point out differences in classification performance between light and standard bovine carcasses. *Meat Science*, 64(3), 249–258. [https://doi.org/10.1016/S0309-1740\(02\)00185-7](https://doi.org/10.1016/S0309-1740(02)00185-7)
22. Doganis, P., Alexandridis, A., Patrinos, P., & Sarimveis, H. (2006). Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing. *Journal of Food Engineering*, 75(2), 196–204. <https://doi.org/10.1016/J.JFOODENG.2005.03.056>
23. Farkas, I., Reményi, P., & Biró, A. (2000). A neural network topology for modelling grain drying. *Computers and Electronics in Agriculture*, 26(2), 147–158. [https://doi.org/10.1016/S0168-1699\(00\)00068-5](https://doi.org/10.1016/S0168-1699(00)00068-5)
24. Grajales-Fonseca, Y. A. ., Gutiérrez-Salazar, C. A. ., & Gamboa-Suárez, A. A. . (2021). Importancia de la actividad experimental en la formación del docente de ciencias naturales. *Mundo FESC*, 11(S6), 187–196. Recuperado a partir de <https://www.fesc.edu.co/Revistas/OJS/index.php/mundofesc/article/view/1115>
25. Felipe, V. P. S., Silva, M. A., Valente, B. D., & Rosa, G. J. M. (2015). Using multiple regression, Bayesian networks and artificial neural networks for prediction of total egg production in European quails based on earlier expressed phenotypes. *Poultry Science*, 94(4), 772–780. <https://doi.org/10.3382/PS/PEV031>
26. Hempstalk, K., McParland, S., & Berry, D. P. (2015). Machine learning algorithms for the prediction of conception success to a given insemination in lactating dairy cows. *Journal of Dairy Science*, 98(8), 5262–5273. <https://doi.org/10.3168/JDS.2014-8984>
27. Hepworth, P. J., Nefedov, A. V., Muchnik, I. B., & Morgan, K. L. (2012). Broiler chickens can benefit from machine learning: support vector machine analysis of observational epidemiological data. *Journal of The Royal Society Interface*, 9(73), 1934–1942. <https://doi.org/10.1098/RSIF.2011.0852>
28. Herrera Carvajal, L. C., Hernandez Villamizar, D. A., Hoyos Patiño, J. F., & Balmelli, F. (2022). Efecto del dispositivo Kyminasi Crop Booster en cultivo maíz (*Zea mays*) granja experimental Universidad Francisco de Paula Santander Ocaña. *Mundo Fesc*, 12(s1), 100–112.
29. Johanna, L., Gonzalez, R., Ingeniería, P., Santiago, A., & Cali, D. (2020). *Agricultura de precisión en el mundo y en Colombia: revisión bibliográfica*.
30. Juárez, R., & Pinzón, C. (2023). Ganadería de precisión, una revisión a los avances dentro de la avicultura enfocados a la crianza de pollos de engorde. *Prisma Tecnológico*, 14(1), 38–48. <https://doi.org/10.33412/PRI.V14.1.3652>
31. Júlio Cesar, C. R., Miguel Angel, F. R., Angie Lilian, G. C., Ingrid Maritza, L. A., Dayli María, Q. S., & Esmeralda, T. F. (2022). Categorización de patas de pollo mediante visión artificial. *INGnosis*, 8, 23–31.
32. Juan David Ardila Suárez: Rueda Galvis, J. F., & Portilla Castellanos, S. A. (2020). Formación en competencias laborales generales, desafío para la educación superior. I+ D revista de investigaciones, 15(1), 37-44
33. Kumaravelu, C., & Gopal, A. (2015). A review on the applications of Near-Infrared spectrometer and Chemometrics for the agro-food processing industries. *Proceedings - 2015 IEEE International Conference on Technological Innovations in ICT for Agriculture and Rural Development, TIAR 2015*, 8–12. <https://doi.org/10.1109/TIAR.2015.7358523>
34. Lopez, J. (2020, August 4). *Realidad Aumentada en Agricultura de Precisión* | by Jmlopezcorrea / Medium. <https://medium.com/@jmlopezcorrea08/realidad-aumentada-en-agricultura-de-precisión-37fdf6be4f17>
35. Mariano, F. C. M. Q., Lima, R. R., Alvarenga, R. R., Rodrigues, P. B., & Lacerda, W. S. (2014). Neural network committee to predict the AMEn of poultry feedstuffs. *Neural Computing and Applications*, 25(7), 1903–1911. <https://doi.org/10.1007/S00521-014-1680-3/METRICS>

36. Mohd Shafri, H. Z., Al-Habshi, M. M., & Nisa Shaharum, N. S. (2019). Métodos de inteligencia artificial (IA) para aplicaciones de teledetección de palma de aceite. *Palmas*, 40, 185–193.
37. Morales, I. R., Cebrián, D. R., Fernandez-Blanco, E., & Sierra, A. P. (2016). Early warning in egg production curves from commercial hens: A SVM approach. *Computers and Electronics in Agriculture*, 121, 169–179. <https://doi.org/10.1016/J.COMPAG.2015.12.009>
38. Mucherino, A., Papajorgji, P., & Pardalos, P. (2009). *Data Mining in Agriculture*. Springer.
39. Pelegri, J. (2022, May 16). *Robots para agricultura: Hacia un mayor aprovechamiento de los recursos*. <https://www.universal-robots.com/es/blog/robots-para-agricultura/>
40. Pardo-Padilla, J. R. . (2022). El aula invertida una estrategia para potencializar el aprendizaje a distancia. *Formación Estratégica*, 4(01), 47–61. Recuperado a partir de <https://www.formacionestrategica.com/index.php/foes/article/view/51>
41. Petersen, K., Feldt, R., Mujtaba, S., & Mattsson, M. (2008). Systematic Mapping Studies in Software Engineering. *12th International Conference on Evaluation and Assessment in Software Engineering, EASE 2008*. <https://doi.org/10.14236/EWIC/EASE2008.8>
42. Polanco, L. S., Kochergin, V., & Carline, G. (2014). [PDF] *Improvements of raw sugar quality using double purge of C-magma* | Semantic Scholar. <https://www.semanticscholar.org/paper/Improvements-of-raw-sugar-quality-using-double-of-Polanco-Kochergin/101c625d1f510781e5fedeb839af320d81bfd0a0>
43. Páez, J (2019). Herramientas Pedagógicas para intervención de dificultades relacionadas con los dispositivos básicos de aprendizaje. *Conocimiento Global* 4(1), 12-25. Recuperado a partir de <https://conocimientoglobal.org/revista/index.php/cglobal/article/view/31>
44. Plata-Gómez, K. R., & Caballero-Márquez, J. A. (2020). Influencia de los programas de educación financiera sobre el comportamiento de los jóvenes: una revisión de literatura. *I+ D Revista De Investigaciones*, 15(2), 18-27.
45. Quiroz, M. Á., & Msg, M. (2021). *Estudio comparativo de las técnicas de inteligencia artificial para el diagnóstico de enfermedades en la agricultura*.
46. Ramírez Morales, I. (2018a). *Estudio de aplicabilidad de técnicas de inteligencia artificial en el sector agropecuario*.
47. Ramírez Morales, I. (2018b). Estudio de aplicabilidad de técnicas de inteligencia artificial en el sector agropecuario. *Dialnet* .
48. Ramírez-Morales, I., Rivero, D., Fernández-Blanco, E., & Pazos, A. (2016). Optimization of NIR calibration models for multiple processes in the sugar industry. *Chemometrics and Intelligent Laboratory Systems*, 159, 45–57. <https://doi.org/10.1016/J.CHEMOLAB.2016.10.003>
49. Rasmussen, M. A., Taira, E., Bro, R., & Tange, R. (2015). Application of Support Vector Regression for Simultaneous Modelling of near Infrared Spectra from Multiple Process Steps. *Journal of Near Infrared Spectroscopy*, Vol. 23, Issue 2, Pp. 75-84, 23(2), 75–84. <https://doi.org/10.1364/JNIRS.23.000075>
50. Revelo Sánchez, O., Collazos Ordoñez, C. A., Alejandro, J., & Toledo, J. (2018). La Gamificación como estrategia didáctica para la enseñanza/aprendizaje de la programación: un mapeo sistemático de literatura. *Lámpsakos (Revista Descontinuada)*, 19(19), 31–46. <https://doi.org/10.21501/21454086.2347>
51. Roussel, S., Bellon-Maurel, V. E., Roger, J. M., & Grenier, P. (2003). Authenticating white grape must variety with classification models based on aroma sensors, FT-IR and UV spectrometry. *Journal of Food Engineering*, 60(4), 407–419. [https://doi.org/10.1016/S0260-8774\(03\)00064-5](https://doi.org/10.1016/S0260-8774(03)00064-5)
52. Segovia, J. S. B., Rojas, F. A. D., & Quishpe, M. W. V. (2021). Estudio del uso de técnicas de inteligencia artificial aplicadas para análisis de suelos para el sector agrícola. *RECIMUNDO*, 5(1), 4–19. [https://doi.org/10.26820/RECIMUNDO/5.\(1\).ENERO.2021.4-19](https://doi.org/10.26820/RECIMUNDO/5.(1).ENERO.2021.4-19)
53. Shahin, M. A., Tollner, E. W., & McClendon, R. W. (2001). AE—Automation and Emerging Technologies: Artificial Intelligence Classifiers for sorting Apples based on Watercore. *Journal of Agricultural Engineering Research*, 79(3), 265–274. <https://doi.org/10.1006/JAER.2001.0705>
54. Tajammal Munir, M., Yu, W., Young, B. R., & Wilson, D. I. (2015). The current status of process analytical technologies in the dairy industry. *Trends in Food Science & Technology*, 43(2), 205–218. <https://doi.org/10.1016/J.TIFS.2015.02.010>

55. Teixeira Dos Santos, C. A., Lopo, M., Páscoa, R. N. M. J., & Lopes, J. A. (2013). A Review on the Applications of Portable Near-Infrared Spectrometers in the Agro-Food Industry. *Sage Journals*, 67(11), 1215–1233. <https://doi.org/10.1366/13-07228>
56. Valderrama, P., Braga, J. W. B., & Poppi, R. J. (2007). Validation of multivariate calibration models in the determination of sugar cane quality parameters by near infrared spectroscopy. *Journal of the Brazilian Chemical Society*, 18(2), 259–266. <https://doi.org/10.1590/S0103-50532007000200003>
57. Velásquez Carrascal, B. L., Hoyos Patiño, J. F., Hernández Villamizar, D. A., Sayado Velasquez, L. N., Sayago Velásquez, J. E., & Vargas Yuncosa, J. A. (2020). (DIE) - MODELO PARA EL DISEÑO DE IDEAS DE EMPRENDIMIENTO. *Revista Facultad de Ciencias Agropecuarias -FAGROPEC*, 12(1), 52–64. <https://doi.org/10.47847/fagropec.v12n1a5>
58. Walker, D. H. (2002). Decision support, learning and rural resource management. *Agricultural Systems*, 73(1), 113–127. [https://doi.org/10.1016/S0308-521X\(01\)00103-2](https://doi.org/10.1016/S0308-521X(01)00103-2)
59. Wang, L., Sun, D. W., Pu, H., & Cheng, J. H. (2017). Quality analysis, classification, and authentication of liquid foods by near-infrared spectroscopy: A review of recent research developments. *Https://Doi.Org/10.1080/10408398.2015.1115954*, 57(7), 1524–1538. <https://doi.org/10.1080/10408398.2015.1115954>
60. Wieringa, R., Maiden, N., Mead, N., & Rolland, C. (2006). Requirements engineering paper classification and evaluation criteria: A proposal and a discussion. *Requirements Engineering*, 11(1), 102–107. <https://doi.org/10.1007/S00766-005-0021-6/METRICS>
61. Woudenberg, S. P. D., Van Der Gaag, L. C., Feelders, A., & Elbers, A. R. W. (2014). Real-time Adaptive Problem Detection in Poultry. *Frontiers in Artificial Intelligence and Applications*, 263, 1217–1218. <https://doi.org/10.3233/978-1-61499-419-0-1217>
62. Zayas Ruiz, E., Lorenzo Izquierdo, M., & Fragoso Concepción, F. (2015). La quimiometría y la industria del azúcar y sus derivados. *ICIDCA*, 49(3).