

Modelos predictivos para la seguridad alimentaria en América Latina: Una revisión de alcance

Juanita Trejos-Suárez¹ , Lina Valeria Cuadrado Pardo² , Josueph Esteban Tabares² ,
Sandra Garzón³ , Alejandro Bryon² , Zaida Alarcón² .

Resumen: Modelos predictivos para la seguridad alimentaria en América Latina: Una revisión de alcance.

Introducción: La seguridad alimentaria en América Latina enfrenta desafíos significativos debido a factores como el cambio climático, la desigualdad social y la inestabilidad económica, lo que resalta la necesidad de herramientas avanzadas para su análisis y gestión. Este artículo revisa el estado actual de la literatura sobre modelos predictivos aplicados a la seguridad alimentaria en Latinoamérica, con énfasis en el contexto colombiano durante el período 2014-2024. **Objetivo:** Describir los enfoques metodológicos, los algoritmos utilizados y sus aplicaciones prácticas en este ámbito. **Materiales y métodos:** Se realizó una revisión de alcance siguiendo los lineamientos PRISMA-ScR, que incluyó 65 estudios relevantes. **Resultados:** Los hallazgos destacan el predominio de variables climáticas, agrícolas y tecnológicas, mientras que las categorías socioeconómicas y sanitarias/nutricionales estuvieron subrepresentadas. Los algoritmos más utilizados fueron Bosques Aleatorios y Redes Neuronales Artificiales, ambos con un 16,9%. Las principales áreas de enfoque fueron la gestión sostenible de recursos naturales (26,2%), la predicción del rendimiento agrícola (21,54%) y los impactos del cambio climático y la calidad y seguridad de los alimentos (13,85% cada una). **Conclusiones:** La integración de categorías de datos más amplias y el desarrollo de modelos más robustos son fundamentales para fortalecer la seguridad alimentaria en la región, contribuyendo a los objetivos de desarrollo sostenible y a políticas públicas más efectivas. **Arch Latinoam Nutr 2025; 75(2): 129-142.**

Palabras clave: Seguridad alimentaria, sistemas agroalimentarios, modelos predictivos, algoritmos computacionales, Latinoamérica.

Abstract: Predictive models for food security in Latin America: A scoping review. **Introduction:** Food security in Latin America faces significant challenges due to factors

such as climate change, social inequality, and economic instability, highlighting the need for advanced tools for analysis and management. This article reviews the current state of the literature on predictive models applied to food security in Latin America, with an emphasis on the Colombian context during the period 2014-2024.

Objective: To describe the methodological approaches, algorithms used, and their practical applications in this field. **Materials and Methods:** A scoping review following PRISMA-ScR guidelines was conducted, which included 65 relevant studies. **Results:** The findings highlight the predominance of climatic, agricultural, and technological variables, while socioeconomic and health/nutritional categories were underrepresented. The most used algorithms were Random Forest and Artificial Neural Networks, both at 16.9%. The main areas of focus were the sustainable management of natural resources (26.2%), the prediction of agricultural yield (21.54%), and the impacts of climate change and food quality and safety (13.85% each). **Conclusions:** The integration of broader data categories and developing more robust models are essential to strengthening food security in the region, contributing to sustainable development goals and more effective public policies. **Arch Latinoam Nutr 2025; 75(2): 129-142.**

Keywords: Food security, agro-food systems, predictive models, computational algorithms, Latin America.

Introducción

La seguridad alimentaria garantiza el acceso estable a alimentos suficientes, seguros y nutritivos (1), mientras que la soberanía alimentaria, promueve el derecho de los pueblos a decidir sus sistemas alimentarios en consonancia con sus valores culturales y sostenibilidad (2). Estos conceptos adquieren especial relevancia

¹Universidad de Santander, Facultad de Ciencias Médicas y de la Salud, Instituto de Investigaciones MASIRA. Bucaramanga, Colombia. ²Health Economics Outcome Research Team: HEORT. ³Unidad Central del Valle del Cauca (UCEVA), Grupo de Investigación Universidad y Región GIUR, Institución Universitaria Visión de las Américas, Facultad de Medicina, Grupo de Investigación Biomedicina. Autor para la correspondencia: Juanita Trejos-Suárez, e-mail: juanita.trejos@udes.edu.co; Lina Cuadrado: E-mail: linvalecupa@gmail.com



en Colombia y Latinoamérica, donde la seguridad alimentaria enfrenta desafíos críticos derivados de factores como el cambio climático, la inestabilidad económica y la desigualdad social, los cuales afectan la disponibilidad, el acceso y la calidad de los alimentos.

En Colombia, entre los años 2021 y 2023, un 30.7% de la población (aproximadamente 16.3 millones de personas) experimentó inseguridad alimentaria moderada o grave (3). Este panorama plantea riesgos significativos para el cumplimiento de los Objetivos de Desarrollo Sostenible (ODS 2 y 12), orientados a erradicar el hambre y promover el consumo y la producción sostenible (4–6). A pesar de los esfuerzos impulsados por políticas públicas, como el programa Hambre Cero, la inseguridad alimentaria persiste, demandando enfoques innovadores que mejoren la prevención y la capacidad de respuesta ante esta problemática.

Es allí donde los modelos predictivos computacionales se presentan como una solución estratégica para la gestión de la seguridad alimentaria, permitiendo anticipar los factores que contribuyen a esta problemática (7). Estos modelos analizan grandes volúmenes de datos históricos y actuales de producción agrícola, rendimiento de cultivos, disponibilidad de semillas y gestión de recursos para identificar patrones, prever resultados futuros y optimizar decisiones, facilitando la planificación, la gestión de riesgos y el uso eficiente de insumos (8,9).

Mediante el aprendizaje automático, una subdisciplina de la inteligencia artificial, se emplean algoritmos avanzados, como Bosques Aleatorios, Redes Neuronales Automáticas, entre otros, los cuales permiten anticipar los rendimientos de los cultivos, gestionar riesgos climáticos y económicos, y optimizar la planificación agrícola según las características del suelo (10,11). Estos modelos contribuyen a la sostenibilidad y la resiliencia de los sistemas alimentarios, mejorando la eficacia de las políticas públicas orientadas a reducir la inseguridad alimentaria en las regiones (7).

El presente artículo tuvo como objetivo revisar el estado actual de la literatura sobre modelos predictivos computacionales aplicados a la seguridad y soberanía alimentaria en Latinoamérica, con especial énfasis en el contexto colombiano. A través de una metodología de revisión de alcance, se buscó mapear y sintetizar la literatura existente, identificando los algoritmos de aprendizaje automático más efectivos, evaluando el papel de distintas categorías de datos (agrícolas, climáticas, económicas, socioculturales, entre otras) como descriptores en el entrenamiento de modelos predictivos.

Esta revisión no solo analizó el impacto directo e indirecto de los modelos predictivos en la seguridad alimentaria, sino que también identificó vacíos en el conocimiento y áreas de oportunidad. Los hallazgos de este trabajo buscan generar insumos que faciliten la toma de decisiones estratégicas y la integración de evidencias en el diseño de políticas públicas más efectivas y sostenibles. Además, se aspira a fortalecer la resiliencia de los sistemas alimentarios frente a los desafíos actuales y futuros, proporcionando una base sólida para promover investigaciones orientadas al desarrollo de soluciones innovadoras en este ámbito.

Materiales y métodos

Diseño del estudio

Este estudio se basa en una revisión de alcance (*Scoping Review*), diseñada para mapear la literatura científica relacionada con la aplicación de modelos predictivos en la seguridad alimentaria. La metodología se desarrolló siguiendo los lineamientos propuestos por Arksey H y O'Malley L (12), con las adaptaciones de Levac D y col. (13) y la guía PRISMA-ScR (14). Este enfoque permitió identificar y sintetizar la evidencia existente sobre los modelos predictivos, explorar sus aplicaciones metodológicas y destacar los vacíos de conocimiento sobre el tema. El protocolo de la revisión se publicó en la plataforma para *Open Science Framework* (<https://doi.org/10.17605/OSF.IO/CK7AZ>)

Pregunta de investigación

La pregunta de investigación que guió esta revisión fue: ¿Cuáles son los enfoques metodológicos y principales aplicaciones de los modelos predictivos para la seguridad alimentaria o soberanía alimentaria en Latinoamérica, con énfasis en el contexto colombiano, durante el período 2014-2024?

Estrategia de búsqueda

La búsqueda de la literatura se realizó de forma exhaustiva y sistemática en bases de datos de acceso abierto y de suscripción, con el fin de asegurar la inclusión de la mayor cantidad de estudios relevantes. Las bases de datos consultadas incluyeron PubMed, Scopus, y Google Scholar (para la literatura gris). La estrategia de búsqueda se desarrolló mediante la combinación de términos y operadores booleanos.

Ecuación de búsqueda

("Modelo predictivo" OR "Predicción") AND ("Seguridad alimentaria" OR "Soberanía alimentaria") AND ("Colombia" OR "América Latina")

("Predictive model" OR "Prediction") AND ("Food security" OR "Food sovereignty") AND ("Colombia" OR "Latin America")

Criterios de inclusión y exclusión

Se definieron criterios de inclusión y exclusión para garantizar la pertinencia, la calidad y la actualidad de los estudios seleccionados.

Criterios de inclusión

- Período de publicación: Estudios publicados entre 2014 y 2024.
- Idioma: Artículos publicados en español e inglés.
- Cobertura temática: Estudios que exploren la aplicación de modelos predictivos en la seguridad alimentaria, la soberanía alimentaria o los sistemas alimentarios.
- Tipos de documentos: Artículos originales publicados en revistas con revisión por pares, tesis o trabajos de grados en repositorios universitarios con evaluación por pares, informes técnicos de organismos internacionales y literatura gris relevante.
- Acceso: Estudios con texto completo disponible o con resúmenes suficientemente informativos.

Criterios de exclusión

- Calidad metodológica insuficiente: Estudios que no presenten una descripción clara de su metodología, datos utilizados o procedimientos de validación.
- Enfoque desviado: Estudios que no presenten una conexión directa con la aplicación de modelos

predictivos en seguridad alimentaria, soberanía alimentaria o sistemas alimentarios, como aquellos que solo discutan modelos matemáticos en general o temas alimentarios sin relación con modelos predictivos.

- Falta de evidencia práctica: Trabajos que se limiten a discutir teorías sin aplicación práctica en el contexto de seguridad alimentaria en América Latina.
- Información incompleta o irrelevante: Estudios cuyo texto completo no esté disponible y cuyos resúmenes no ofrezcan suficiente información para evaluar su relevancia o calidad.

Proceso de selección de los estudios

El proceso de selección se llevó a cabo en tres etapas:

1. Eliminación de duplicados: Los registros duplicados se eliminaron mediante el uso de software de gestión de referencias bibliográficas.
2. Revisión por título y resumen: Dos revisores independientes examinaron el título y el resumen de cada registro, y se resolvieron desacuerdos mediante discusión o la intervención de un tercer revisor.
3. Revisión a texto completo: Los estudios elegibles se evaluaron a texto completo para confirmar su inclusión. Se registró el motivo de la exclusión de cada artículo que no cumplió los criterios.

El proceso de selección se documentó mediante un diagrama PRISMA (15), que muestra el flujo de los registros desde la identificación inicial hasta la selección final (figura 1).

Extracción de datos

Se utilizó una plantilla de extracción de datos estandarizada para recopilar información clave de cada estudio. La plantilla incluyó Información general (título, año de publicación, enlace de acceso);




Figura 1. Diagrama de flujo PRISMA ScR

contexto geográfico (país o región) y social; objetivo del estudio; categorías de datos (agrícola, ambiental, climática, económica, institucional/política, sanitaria/nutricional, sociocultural, tecnológica/infraestructura); metodología: tipo de modelo predictivo (regresión lineal, redes neuronales, bosques aleatorios, etc.), variables incluidas, métodos de validación y principales resultados (impacto en la seguridad alimentaria, limitaciones y aplicación). La extracción fue realizada de forma independiente por tres revisores, y los desacuerdos se resolvieron por discusión o con la participación de un cuarto revisor.

Síntesis y presentación de resultados

Se emplearon gráficas, tablas, mapas conceptuales y análisis temático para sintetizar los hallazgos, visualizar relaciones entre variables y detectar patrones relevantes. Estos métodos fueron seleccionados por su adecuación para integrar y analizar datos de manera integral, permitiendo identificar vacíos de conocimiento y conectar la

evidencia disponible con los objetivos de esta revisión, orientados a mejorar la comprensión sobre los modelos predictivos aplicados a la seguridad alimentaria.

Consideraciones éticas

Este estudio no requirió aprobación de un comité ético, ya que se basa exclusivamente en el análisis de literatura secundaria. Sin embargo, se desarrolló de acuerdo con la extensión PRISMA-ScR, garantizando la transparencia y reproducibilidad del proceso. Se documentó cada paso siguiendo los estándares recomendados para revisiones exploratorias.

Resultados

En esta revisión se incluyeron 65 estudios publicados entre 2016 y 2024, los cuales cumplieron con los criterios de inclusión establecidos. No se identificaron estudios anteriores a este periodo que reunieran dichos criterios. La mayoría de los estudios se realizaron en Brasil (n=28), destacando un enfoque significativo en la agricultura y el ambiente. El idioma predominante fue el inglés (78,2%). En términos




Figura 2. Análisis temporal de la producción científica en Latinoamérica

de tipos de documentos, el 83,3% corresponden a artículos originales en revistas indexadas, mientras que el resto incluye literatura gris, como informes técnicos y tesis de pregrado y maestría.

El análisis temporal de los estudios seleccionados (figura 2), revela un aumento progresivo en la producción científica sobre modelos predictivos aplicados a la seguridad o soberanía alimentaria en Latinoamérica durante los últimos años. Entre 2016-2018 se identificó un número limitado de publicaciones, mientras que los períodos 2019-2021 y 2022-2024 muestran un incremento significativo, especialmente en países como Brasil y Colombia, los cuales concentran la mayor cantidad de estudios. Este crecimiento refleja un interés creciente en la región

por abordar los desafíos de la seguridad alimentaria mediante enfoques tecnológicos y predictivos.

Objetivos y categorías de estudio

Los objetivos de los estudios analizados abarcaron una amplia gama de aplicaciones que pudieron agruparse en seis categorías principales (figura 3). Una proporción significativa se centró en la gestión sostenible de recursos naturales, integrando innovaciones tecnológicas para optimizar el uso del agua, suelo y polinizadores. Otro grupo importante abordó la predicción del rendimiento agrícola, utilizando técnicas de aprendizaje automático e imágenes multiespectrales. Varios estudios exploraron los impactos del cambio climático en cultivos y ecosistemas, mientras que otros se enfocaron en la calidad y seguridad de los alimentos mediante análisis predictivos. Además, algunos trabajos buscaron desarrollar modelos para la toma de decisiones en mercados y recursos agrícolas, y la conservación de la biodiversidad bajo escenarios futuros.

Estos hallazgos permitieron identificar los principales factores que afectan directa e indirectamente la seguridad o soberanía alimentaria en Latinoamérica. A continuación, se describen los resultados de cada categoría:




Figura 3. Distribución de las categorías de los objetivos en los estudios revisados

1. Categoría Agrícola: Se documentaron enfoques como la intensificación sostenible, la agricultura de precisión y los sistemas agroecológicos. Estas prácticas buscan aumentar la productividad mientras se minimiza el impacto ambiental, abordando simultáneamente la necesidad de sostenibilidad y seguridad alimentaria (16–30).
2. Categoría Ambiental: Los estudios destacaron la sostenibilidad ambiental como un componente esencial de la seguridad alimentaria, enfocándose en la conservación de la biodiversidad y la reducción de la huella ambiental. Estas medidas son fundamentales para garantizar la viabilidad a largo plazo de los sistemas alimentarios (31–42).
3. Categoría Climática: Los estudios analizados destacan cómo el cambio climático afecta negativamente la producción agrícola, especialmente en regiones tropicales. Eventos climáticos extremos, como sequías e inundaciones, y el aumento de la temperatura se asocian con una disminución en los rendimientos agrícolas, exacerbando la inseguridad alimentaria en áreas vulnerables (42–49).
4. Categoría Sanitaria-Nutricional: La calidad e inocuidad de los alimentos fueron aspectos críticos identificados. Los modelos predictivos en esta categoría abordan desde la producción segura hasta la prevención de enfermedades relacionadas con alimentos contaminados, destacando su impacto en la salud pública (50–58).
5. Categoría Tecnológica-Infraestructura: Innovaciones tecnológicas y mejoras en infraestructura, como el almacenamiento y la digitalización, fueron mencionadas como soluciones para reducir pérdidas poscosecha y optimizar la distribución de alimentos, contribuyendo a una mayor eficiencia en los sistemas alimentarios (59–68).
6. Categoría Económica: Los factores económicos, incluidos el poder adquisitivo y la volatilidad de los precios de los alimentos, emergieron como determinantes críticos

de la seguridad alimentaria. Las desigualdades socioeconómicas y la limitada integración de pequeños productores en las cadenas de valor son barreras recurrentes que afectan el acceso equitativo a alimentos, por lo que en la actualidad se han realizado estudios sobre la trazabilidad, la prevención de fraudes comerciales, el incremento del rendimiento agrícola y la mejora de la confianza del consumidor (69–75).

7. Categoría Política-Institucional: La calidad de las instituciones públicas y la coherencia en la implementación de políticas alimentarias fueron identificadas como factores clave. Los estudios analizados subrayan la importancia de una gobernanza efectiva para abordar los desafíos de los sistemas alimentarios (25,66,67,70,71,73,74).

Modelos Predictivos

El análisis de los modelos de predicción utilizados en los estudios revisados destaca la diversidad de enfoques aplicados (tabla 1). Los modelos de aprendizaje automático supervisado fueron los más utilizados, con Bosques Aleatorios y Redes Neuronales Artificiales como los más frecuentes. En cuanto a los modelos estadísticos y clásicos, prevalecieron la Regresión Lineal y la Regresión Logística, mientras que los modelos de ensamble y meta-aprendizaje, modelos basados en procesos y simulación, y modelos espaciales y ecológicos complementaron el análisis con aplicaciones específicas. Estas categorías reflejan la implementación de métodos variados, desde algoritmos avanzados hasta técnicas tradicionales, para abordar problemáticas multidimensionales en seguridad alimentaria.

El análisis realizado permitió identificar y estructurar las principales categorías de variables empleadas en los estudios revisados, destacando la diversidad de enfoques aplicados para abordar la seguridad alimentaria (figura 4). Estas categorías reflejan una integración multidimensional de datos, que van desde factores ambientales y climáticos hasta aspectos tecnológicos y socioeconómicos. Este enfoque no solo permite evaluar impactos específicos, como la variabilidad climática y la optimización de recursos agrícolas, sino que también facilita el diseño de estrategias integrales para mejorar los sistemas alimentarios.

Tabla 1. Clasificación de los modelos de predicción utilizados en los estudios revisados

Modelos de Aprendizaje Automático Supervisado (50.0%)	
Árbol de Decisión	5.6%
Bosques Aleatorios	16.7%
k-Nearest Neighbors	1.4%
Máquina de Soporte Vectorial	4.2%
Naïve Bayes	1.4%
Redes Neuronales Artificiales	16.7%
XGBoost	4.2%
Modelos Estadísticos y Clásicos (16.7%)	
Análisis de Componentes Principales	2.8%
Modelos de Regresión Logística	4.2%
Regresión Lineal	8.3%
SARIMA	1.4%
Modelos de Ensamble y Meta-Aprendizaje (4.2%)	
Meta-aprendizaje	2.8%
Modelos de Ensamble para Predicción	1.4%
Modelos Basados en Procesos y Simulación (9.7%)	
Modelos Predictivos Basados en Procesos	4.2%
Modelos Predictivos Basados en Simulación o Casos	2.8%
Modelo Predictivo Geoambiental	2.8%
Modelos Basados en Datos Espaciales y Ecológicos (9.7%)	
Modelos Predictivos Basados en Nichos Ecológicos	8.3%
Modelos Predictivos Basados en Colecciones de Museos	1.4%
Modelos Genómicos y Biológicos (4.2%)	
Modelos de Selección Genómica Amplia	2.8%
Análisis QTL Multiambiente	1.4%
Modelos Socioeconómicos (1.4%)	
Modelos de Microsimulación Socioeconómica Integrados	1.4%
Modelos de Pronóstico y Series Temporales (4.2%)	
Modelos de Pronóstico	2.8%
SARIMA	1.4%

Los métodos de validación empleados en los estudios revisados abarcan un amplio espectro, desde enfoques clásicos como la validación cruzada (K-Fold, nested leave-one-out) hasta simulaciones basadas en escenarios históricos y futuros. Entre las métricas más comunes se encuentran el coeficiente de determinación (R^2), la raíz del error cuadrático medio (RMSE), el error absoluto medio (MAE) y el área bajo la curva (AUC), utilizadas para evaluar el rendimiento y la precisión predictiva. Se destacan validaciones espaciales y temporales, con coherencia entre distribuciones proyectadas y observadas. Además, varios estudios aplicaron validaciones híbridas, combinando datos observados y simulaciones para garantizar la robustez de los modelos en contextos multidimensionales.

Impactos de los modelos predictivos en la seguridad y soberanía alimentaria

El análisis de los impactos de los modelos predictivos en los estudios revisados muestra una amplia contribución a través de diferentes enfoques y áreas clave. Los principales impactos incluyeron:

1. Optimización de la producción agrícola y sostenibilidad: La predicción precisa de rendimientos, el manejo eficiente de recursos hídricos y la mejora en la fertilidad del suelo garantizan la estabilidad de la producción de alimentos esenciales, como maíz, arroz, café y soya. Estos avances contribuyen a la reducción de la inseguridad alimentaria y fomentan prácticas agrícolas sostenibles.
2. Diversificación y resiliencia alimentaria: La conservación de especies silvestres y el desarrollo de cultivos biofortificados fortalecen la seguridad alimentaria, especialmente en comunidades vulnerables, al diversificar las fuentes de alimentos y mejorar su valor nutricional.
3. Gestión de recursos y reducción de riesgos climáticos: Modelos predictivos permiten una mejor planificación ante eventos como sequías y el cambio climático, optimizando la gestión de cultivos y asegurando la continuidad de la producción en escenarios adversos.
4. Calidad y seguridad alimentaria: La autenticación de la procedencia de productos, el control de patógenos y la mejora en procesos de almacenamiento garantizan estándares de calidad, minimizan pérdidas postcosecha y fortalecen la confianza del consumidor.
5. Apoyo a la economía agrícola: La optimización de cadenas de suministro, como en el caso del agave y el café, y la predicción de precios agrícolas reducen la incertidumbre económica, beneficiando a productores y fortaleciendo los mercados locales.
6. Preservación de servicios ecosistémicos: La gestión sostenible de suelos degradados, la




Figura 4. Variables empleadas en los modelos predictivos para la seguridad alimentaria

protección de polinizadores y la conservación de ecosistemas clave aseguran recursos esenciales para la agricultura y la regulación ambiental, apoyando la seguridad alimentaria en el largo plazo.

Aplicaciones de los estudios

Los estudios revisados evidenciaron una amplia variedad de aplicaciones de los modelos predictivos en seguridad alimentaria y soberanía alimentaria. Estas abarcan desde la optimización de la producción agrícola, con predicciones precisas de rendimientos de cultivos clave como maíz, arroz y café, hasta la gestión sostenible de recursos naturales, como suelos, agua y biodiversidad. Destacan aplicaciones como el monitoreo y manejo de

plagas, el control de calidad de productos agrícolas y la gestión de cadenas de suministro, que mejoran la eficiencia operativa y reducen pérdidas. Otras aplicaciones incluyen el desarrollo de sistemas de agricultura de precisión, la predicción de precios agrícolas y la planificación de intervenciones para mejorar la seguridad alimentaria en comunidades vulnerables. Adicionalmente, los estudios aportan a la sostenibilidad ambiental, con estrategias de conservación de especies, restauración de suelos degradados y adaptación de los sistemas agrícolas al cambio climático, integrando innovaciones como sensores IoT, aprendizaje automático y análisis multiespectral. Estas aplicaciones resaltan la relevancia de los modelos predictivos como herramientas clave para enfrentar los desafíos actuales y futuros de los sistemas alimentarios.

Limitaciones de los estudios

Las limitaciones de los estudios revisados resaltan la necesidad de mejorar la calidad y diversidad de los datos empleados, así como la integración de dimensiones socioculturales e institucionales para abordar la seguridad alimentaria de manera integral. Muchos modelos dependen de datos de campo o sensores, cuya representatividad y escalabilidad son limitadas. Además, la falta de datos locales y actualizados dificulta la generalización y extrapolación de los modelos a diferentes regiones o cultivos.

La variabilidad en la calidad de las predicciones, influenciada por el desequilibrio de clases, la selección de variables relevantes y la parametrización de los modelos, es un desafío recurrente. A esto se suma la incertidumbre inherente a las proyecciones climáticas y escenarios futuros, especialmente en estudios relacionados con el cambio climático.

La implementación práctica de los modelos en áreas rurales se ve restringida por la necesidad de tecnologías avanzadas, como sensores IoT, imágenes multispectrales y equipos especializados, que requieren altos costos y recursos tecnológicos. Asimismo, la complejidad computacional de enfoques como las redes neuronales profundas y la selección genómica limita su adopción a gran escala.

Estas limitaciones enfatizan la importancia de desarrollar modelos más integradores y robustos, capaces de capturar interacciones dinámicas entre factores clave y de adaptarse a contextos diversos, fortaleciendo así su precisión y aplicabilidad.

Discusión

El análisis de esta revisión revela que las categorías de datos más utilizadas en los modelos predictivos incluyen variables agrícolas, ambientales y climáticas, presentes en más del 80 % de los estudios revisados. Estas categorías son esenciales para enfrentar los retos derivados del clima y las condiciones de cultivo, factores determinantes para la seguridad alimentaria. Sin embargo, variables económicas, sanitarias-nutricionales y político-institucionales, igualmente relevantes para una visión integral, están subrepresentadas, lo que evidencia la necesidad de integrar estas dimensiones para abordar aspectos como el acceso y la calidad de los alimentos.

Los estudios que incorporaron categorías más amplias de datos, incluyendo componentes sanitarios o económicos, demostraron un impacto más directo en la seguridad alimentaria. Aunque los modelos basados únicamente en variables agrícolas y climáticas son útiles, aquellos que integran múltiples categorías, como análisis de precios o predicción de microorganismos, son más efectivos en contextos complejos (76). Esto resalta el valor de enfoques multidimensionales en la modelización predictiva.

En cuanto a los algoritmos, Bosques Aleatorios, Redes Neuronales y Regresión Lineal se destacaron en tareas clave como la predicción de rendimientos agrícolas y la optimización de recursos. Los algoritmos supervisados, particularmente Bosques Aleatorios y Máquinas de Soporte Vectorial, demostraron ser altamente precisos y adaptables a grandes volúmenes de datos, lo que es fundamental para aplicaciones agrícolas en contextos cambiantes (77). Aunque modelos más simples como la Regresión Lineal mostraron eficacia en tareas específicas, su capacidad es limitada frente a datos complejos y no lineales (78).

El impacto de los modelos predictivos incluye optimización de recursos, mejora en la calidad de los productos agrícolas y predicción precisa de rendimientos, lo que facilita la planificación agrícola y contribuye a la estabilidad alimentaria en contextos de cambio climático. Además, estos modelos indirectamente benefician la toma de decisiones estratégicas, optimizan las cadenas de suministro y promueven una distribución eficiente de alimentos, aspectos clave para garantizar la seguridad alimentaria sostenible.

Esta revisión destaca una brecha crítica en el avance hacia el cumplimiento del ODS 2 de erradicar el hambre para 2030. La integración de tecnologías avanzadas y modelos predictivos más inclusivos puede ser crucial no solo para mejorar la eficiencia agrícola, sino también para guiar políticas públicas que prioricen la equidad en el acceso a alimentos y la sostenibilidad de

los sistemas alimentarios, abordando así desafíos estructurales como la pobreza y la desigualdad.

Futuras líneas de investigación

Para superar las limitaciones encontradas y ampliar el impacto de los modelos predictivos, esta revisión sugiere las siguientes líneas de investigación:

1. Integración de categorías de datos no tradicionales: Incluir variables socioculturales, sanitarias y nutricionales para capturar mejor los factores que afectan la seguridad alimentaria a nivel comunitario.
2. Mejora en la calidad de los datos: Invertir en infraestructuras de recolección de datos de alta precisión, como sensores IoT y sistemas de imágenes satelitales calibradas, para mejorar la robustez y la aplicabilidad de los modelos.
3. Adaptación a contextos locales: Diseñar modelos que reflejen las realidades sociopolíticas y ambientales de Latinoamérica, especialmente en comunidades rurales y marginadas.
4. Evaluación longitudinal del impacto: Realizar estudios que analicen cómo la implementación de modelos predictivos afecta la seguridad alimentaria a largo plazo, considerando tanto beneficios directos como indirectos.

Conclusiones

La integración de categorías de datos más amplias y el desarrollo de modelos predictivos más robustos son esenciales para abordar de manera integral los desafíos relacionados con la seguridad alimentaria en América Latina. Los modelos actuales, aunque efectivos en tareas específicas como la predicción de rendimientos agrícolas y la optimización de recursos hídricos, tienden a enfocarse

principalmente en variables agrícolas y climáticas. Entre los modelos más utilizados en los estudios revisados, Bosques Aleatorios y Redes Neuronales Artificiales fueron los más frecuentes, con un 16.9% de aplicación cada uno. Además, las categorías de datos socioeconómicos, sanitarios/nutricionales y socioculturales estuvieron subrepresentadas. Una incorporación más equilibrada de factores económicos, sociales, sanitarios y político-institucionales podría mejorar significativamente la capacidad de los modelos para prever y mitigar problemas relacionados con el acceso, la disponibilidad y la calidad de los alimentos. En cuanto a los objetivos de los estudios revisados, la gestión sostenible de recursos naturales (26.15%) y la predicción del rendimiento agrícola (21.54%) fueron las áreas más frecuentes de enfoque, lo que refleja la prioridad de mejorar la resiliencia y sostenibilidad de los sistemas alimentarios.

Conflictos de Interés

Los autores declaran que no existe ningún conflicto de interés relacionado con este trabajo. Ninguno de los autores tiene relaciones financieras, comerciales, personales o académicas que puedan influir de manera inapropiada en los resultados, análisis o interpretaciones presentados en este documento.

Referencias

1. FAO. El estado de la inseguridad alimentaria en el mundo. Roma: FAO; 2006. <https://www.fao.org/state-of-food-security-nutrition>
2. La Vía Campesina. Declaración de Roma de La Vía Campesina que define por primera vez la Soberanía Alimentaria. Vía Campesina Español; 1996 <https://viacampesina.org/es/1996-declaracion-de-roma-de-la-via-campesina-que-define-por-primera-vez-la-soberania-alimentaria/>
3. FAO, FIDA, UNICEF, PMA, OMS. El estado de la seguridad alimentaria y la nutrición en el mundo 2024. Roma: FAO; 2024. <https://doi.org/10.4060/cd1276es>
4. Departamento Nacional de Planeación. Informe anual avance implementación ODS en Colombia 2022. Bogotá, Colombia: Departamento Nacional de Planeación; 2022 <https://www.dnp.gov.co>
5. FAO, IFAD, UNICEF, WFP, WHO. The State of Food Security and Nutrition in the World 2020 FAO; 2020. <https://doi.org/10.4060/ca9692en>
6. United Nations. Transforming our world: the 2030 Agenda for Sustainable Development [Internet]. Nueva York: Naciones Unidas; 2015 [citado 2024 Dec 27]. Disponible en: <https://sdgs.un.org/2030agenda>

7. Dhal SB, Kar D. Transforming Agricultural Productivity with AI-Driven Forecasting: Innovations in Food Security and Supply Chain Optimization. *Forecasting*. 2024 Dec;6(4):925–51. <https://doi.org/10.3390/forecast6040046>
8. Dwivedi PK, Pandey DP. Crop Yield Prediction and Classification using the Agriculture Resources and Data Mining Techniques. *J Adv Sci Technol*. 2023 Sep 1;20(2):131–7. <https://doi.org/10.29070/krwa0448>
9. Elbasi E, Mostafa N, Zaki C, AlArnaout Z, Topcu AE, Saker L. Optimizing Agricultural Data Analysis Techniques through AI-Powered Decision-Making Processes. *Appl Sci*. 2024;14(17):8018. <https://doi.org/10.3390/app14178018>
10. Kwaghty DK, Eke CI. Smart farming prediction models for precision agriculture: a comprehensive survey. *Artif Intell Rev*. 2023;56(6):5729–72. <https://doi.org/10.1007/s10462-022-10266-6>
11. Talaviya T, Shah D, Patel N, Yagnik H, Shah M. Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides. *Artif Intell Agric*. 2020;4:58–73. <https://doi.org/10.1016/j.aiaa.2020.04.002>
12. Arksey H, O'Malley L. Scoping studies: towards a methodological framework. *Int J Soc Res Methodol*. 2005;8(1):19–32. <https://doi.org/10.1080/1364557032000119616>
13. Levac D, Colquhoun H, O'Brien KK. Scoping studies: advancing the methodology. *Implement Sci*. 2010;5(1):69. <https://doi.org/10.1186/1748-5908-5-69>
14. Tricco AC, Lillie E, Zarin W, O'Brien KK, Colquhoun H, Levac D, et al. PRISMA Extension for Scoping Reviews (PRISMA-ScR): Checklist and Explanation. *Ann Intern Med*. 2018;169(7):467–73. <https://doi.org/10.7326/M18-0850>
15. Page MJ, McKenzie JE, Bossuyt PM, Boutron I, Hoffmann TC, Mulrow CD, et al. Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas. *Rev Esp Cardiol*. 2021;74(9):790–9. <https://doi.org/10.1016/j.recesp.2021.06.016>
16. Amaral LR, Oldoni H, Baptista GMM, Ferreira GHS, Freitas RG, Martins CL, et al. Remote sensing imagery to predict soybean yield: a case study of vegetation indices contribution. *Precision Agric*. 2024;25(5):2375–93. <https://doi.org/10.1007/s11119-024-10174-5>
17. Bebbber DP, Castillo AD, Gurr SJ. Modelling coffee leaf rust risk in Colombia with climate reanalysis data. *Philos Trans R Soc Lond B Biol Sci*. 2016;371(1709):20150458. <https://doi.org/10.1098/rstb.2015.0458>
18. Bernal CM, Avila Gómez JD. Algoritmos de aprendizaje automático: una herramienta para el análisis de datos sobre germinación en semillas. Colombia: Universidad Distrital Francisco José de Caldas; 2021.
19. Castaño Domínguez EV. Análisis de riesgo de Stenoma catenifer en la producción de aguacate en Caldas utilizando tecnología geoespacial: Aguadas, Pácora y Aránzazu. Colombia: Universidad de Manizales; 2024
20. Forero BLS, Cañón NDM, Baron Velandia J. Modelo para predicción del rendimiento de cultivos de alto valor calórico aplicando técnicas de optimización. Colombia: Universidad Distrital Francisco José de Caldas; 2020.
21. Nalin RS, Dalmolin RSD, de Araújo Pedron F, Moura-Bueno JM, Horst TZ, Schenato RB, et al. Accounting for the spatial variation of phosphorus available explained by environmental covariates. *Geoderma Regional*. 2023;32:e00594. <https://doi.org/10.1016/j.geodrs.2022.e00594>
22. Naranjo FV, Galarza FC, Arias EJ. Internet of Things based Predictive Crop Yield Analysis: A Distributed Approach. *Fusion: Pract Appl*. 2023;(Issue 2):106–13. <https://doi.org/10.54216/FPA.130209>
23. Montesinos- López OA, Herr AW, Crossa J, Carter AH. Genomics combined with UAS data enhances prediction of grain yield in winter wheat. *Front Genet*. 2023; 14: 1124218. <https://doi.org/10.3389/fgene.2023.1124218>
24. Ojeda Riaños CK, Torres CA, Zapata Calero JC, Romero-Leiton JP, Benavides IF. A machine learning approach to map the potential agroecological complexity in an indigenous community of Colombia. *J Environ Manag*. 2024; 370:122655. <https://doi.org/10.1016/j.jenvman.2024.122655>
25. Peixoto L de A, Laviola BG, Alves AA, Rosado TB, Bhering LL. Breeding *Jatropha curcas* by genomic selection: A pilot assessment of the accuracy of predictive models. *PLoS ONE*. 2017;12(3):e0173368. <https://doi.org/10.1371/journal.pone.0173368>
26. Pott LP, Amado TJC, Schwalbert RA, Corassa GM, Ciampitti IA. Satellite-based data fusion crop type classification and mapping in Rio Grande do Sul, Brazil. *ISPRS J Photogramm Remote Sens*. 2021;176:196–210. <https://doi.org/10.1016/j.isprsjprs.2021.04.015>
27. Ramírez-Gil JG, Cobos ME, Jiménez-García D, Morales-Osorio JG, Peterson AT. Current and potential future distributions of Hass avocados in the face of climate change across the Americas. *Crop Pasture Sci*. 2019;70(8):694–708. <https://doi.org/10.1071/CP19094>
28. Sierra-Forero B-L, Baron-Velandia J, Vanegas-Ayala S-C. Assessment of the relevance of features associated with corn crop yield prediction in Colombia, a country in the Neotropical zone. *Int J Inf Technol*. 2024;16(4):2129–38. <https://doi.org/10.1007/s41870-024-01762-9>
29. Zhang L, Gezan SA, Eduardo Vallejos C, Jones JW, Boote KJ, Clavijo-Michelangeli JA, et al. Development of a QTL-environment-based predictive model for node addition rate in common bean. *Theor Appl Genet*. 2017;130(5):1065–79. <https://doi.org/10.1007/s00122-017-2871-y>
30. Zwick M, Cardoso JA, Gutiérrez-Zapata DM, Cerón-Muñoz M, Gutiérrez JF, Raab C, et al. Pixels to pasture: Using machine learning and multispectral remote sensing to predict biomass and nutrient quality in tropical grasslands. *Remote Sens Appl Soc Environ*. 2024;36:101282. <https://doi.org/10.1016/j.rsase.2024.101282>

31. Ayala Izurieta JE, Márquez CO, García VJ, Jara Santillán CA, Sisti JM, Pasqualotto N, et al. Multi-predictor mapping of soil organic carbon in the alpine tundra: a case study for the central Ecuadorian páramo. *Carbon Balance Manag.* 2021;16(1):32. <https://doi.org/10.1186/s13021-021-00195-2>
32. Benítez G, Estrada-Contreras I, Lascurain-Rangel M, Gómez-Díaz JA, Falfán I, Quiroz-Guerrero I, et al. Potential distribution of wild edible fruit trees under climate change scenarios: promoting food security in a Neotropical region. *Reg Environ Change.* 2024;24(2):75. <https://doi.org/10.1007/s10113-024-02231-6>
33. Blanco Alfonso A. Aplicación de Modelos de Aprendizaje Automático para la Caracterización Hidrogeoquímica del Agua Subterránea en Boyacá, Colombia: Comparación de Modelos de Clasificación y Método Ensamblado Stacking [Tesis de maestría]. 2024.
34. Delgado-Carrillo O, Martén-Rodríguez S, Ramírez-Mejía D, Novais S, Quevedo A, Ghilardi A, et al. Pollination services to crops of watermelon (*Citrullus lanatus*) and green tomato (*Physalis ixocarpa*) in the coastal region of Jalisco, Mexico. *PLoS ONE.* 2024;19(7):e0301402. <https://doi.org/10.1371/journal.pone.0301402>
35. Erazo-García MP, Guadalupe JJ, Rowntree JK, Borja-Serrano P, Espinosa de los Monteros-Silva N, Torres M de L. Assessing the Genetic Diversity of *Ilex guayusa* Loes., a Medicinal Plant from the Ecuadorian Amazon. *Diversity.* 2021;13(5):182. <https://doi.org/10.3390/d13050182>
36. Febles González JM, Febles Díaz JM, Vega Carreño MB, Herrera Sorzano A, Maura Santiago AV, Tolón Becerra A, et al. Resiliencia y protección agroambiental de los suelos Ferralíticos Rojos en regiones Kársticas del Occidente de Cuba. *An Acad Cienc Cuba [Internet].* 2022
37. Herrera Montiel SA, Coronado-Franco KV, Selvaraj JJ. Predicted changes in the potential distribution of seerfish (*Scomberomorus sierra*) under multiple climate change scenarios in the Colombian Pacific Ocean. *Ecol Inform.* 2019;53:100985. <https://doi.org/10.1016/j.ecoinf.2019.100985>
38. Lima HS, Oliveira GFV de, Ferreira R dos S, Castro AG de, Silva LCF, Ferreira L de S, et al. Machine learning-based soil quality assessment for enhancing environmental monitoring in iron ore mining-impacted ecosystems. *J Environ Manag.* 2024;356:120559. <https://doi.org/10.1016/j.jenvman.2024.120559>
39. Mello DC de, Veloso GV, Lana MG de, Mello FA de O, Poppiel RR, Cabrero DRO, et al. A new methodological framework for geophysical sensor combinations associated with machine learning algorithms to understand soil attributes. *Geosci Model Dev.* 2022;15(3):1219–46. <https://doi.org/10.5194/gmd-15-1219-2022>
40. Silva YF, Valadares RV, Dias HB, Cuadra SV, Campbell EE, Lamparelli RAC, et al. Intense Pasture Management in Brazil in an Integrated Crop-Livestock System Simulated by the DayCent Model. *Sustainability.* 2022;14(6):3517. <https://doi.org/10.3390/su14063517>
41. Vhf C, Sd Ij, N R, Il A, Rp S, L de SC, et al. Species Distribution Modelling: Contrasting presence-only models with plot abundance data. *Sci Rep.* 2018;8(1). <https://doi.org/10.1038/s41598-017-18927-1>
42. Vistin DA, Muñoz Jácome EA, Ati Cutiupala GM. Escenario de cambio climático del bosque siempreverde del páramo reserva de producción de fauna Trop Subtrop Agroecosyst. 2021;24(2). <https://doi.org/10.56369/tsaes.3448>
43. Anríquez G, Toledo G. De-climatizing food security: Lessons from climate change micro-simulations in Peru. *PLoS ONE.* 2019;14(9):e0222483. <https://doi.org/10.1371/journal.pone.0222483>
44. Costa TS, Filgueiras R, Santos RA dos, Cunha FF da. Actual evapotranspiration by machine learning and remote sensing without the thermal spectrum. *PLoS ONE.* 2023;18(5):e0285535. <https://doi.org/10.1371/journal.pone.0285535>
45. Estrada-Contreras I, Pavón NP, Cadena JB, Bourg A. Ecological niche models of productive corn races under climate change scenarios in central-eastern Mexico. *Agron J.* 2023;115(3):1023–1036. <https://doi.org/10.1002/agj2.21286>
46. Imbach P, Fung E, Hannah L, Navarro-Racines CE, Roubik DW, Ricketts TH, et al. Coupling of pollination services and coffee suitability under climate change. *Proc Natl Acad Sci U S A.* 2017;114(39):10438–10442. <https://doi.org/10.1073/pnas.1617940114>
47. Salas-Martínez F, Márquez-Grajales A, Valdés-Rodríguez O-A, Palacios-Wassenaar O-M, Pérez-Castro N. Prediction of agricultural drought behavior using the Long Short-Term Memory Network (LSTM) in the central area of the Gulf of Mexico. *Theor Appl Climatol.* 2024;155(8):7887–7907. <https://doi.org/10.1007/s00704-024-05100-8>
48. Syfert MM, Serbina L, Burckhardt D, Knapp S, Percy DM. Emerging New Crop Pests: Ecological Modelling and Analysis of the South American Potato Psyllid *Russelliana solanicola* (Hemiptera: Psylloidea) and Its Wild Relatives. *PLoS ONE.* 2017;12(1):e0167764. <https://doi.org/10.1371/journal.pone.0167764>
49. Youngblood JP, Cease AJ, Talal S, Copa F, Medina HE, Rojas JE, et al. Climate change expected to improve digestive rate and trigger range expansion in outbreaking locusts. *Ecol Monogr.* 2023;93(1):e1550. <https://doi.org/10.1002/ecm.1550>
50. Alves V, dos Santos JM, Viegas O, Pinto E, Ferreira IMPLVO, Aparecido Lima V, et al. An eco-friendly approach for analysing sugars, minerals, and colour in brown sugar using digital image processing and machine learning. *Food Res Int.* 2024;191:114673. <https://doi.org/10.1016/j.foodres.2024.114673>
51. Carvalho RRB de, Cortes DFM, Sousa MB e, Oliveira LA de, Oliveira EJ de. Image-based phenotyping of cassava roots for diversity studies and carotenoids prediction. *PLoS ONE.* 2022;17(1):e0263326. <https://doi.org/10.1371/journal.pone.0263326>

52. Castro-Bedriñana J, Chirinos-Peinado D, De La Cruz-Calderón G. Predictive model of stunting in the Central Andean region of Peru based on socioeconomic and agri-food determinants. *Public Health Pract.* 2021; 2:100112. <https://doi.org/10.1016/j.puhip.2021.100112>
53. Castro-Bedriñana J, Chirinos-Peinado D, Quijada-Caro E. Digestible and metabolizable energy prediction models in guinea pig feedstuffs. *J Appl Anim Res.* 2022;50(1):355–362. <https://doi.org/10.1080/09712119.2022.2079647>
54. Duarte AB, Ferreira D de O, Ferreria LB, Silva FL da. Machine learning applied to the prediction of root architecture of soybean cultivars under two water availability conditions. *Sem Ci Agr.* 2022;43(3):1017–1036. <https://doi.org/10.5433/1679-0359.2022v43n3p1017>
55. Kubo SE dos AC, Costa THM da, Gubert MB. Intakes of energy, macronutrients and micronutrients of a population in severe food insecurity risk in Brazil. *Public Health Nutr.* 2020;23(4):649–59. <https://doi.org/10.1017/S1368980019003057>
56. Mayorga Moran MM. Predicción de la velocidad de crecimiento de la Salmonella de embutidos de pollo (*Gallus gallus*) y res (*Bos Taurus*) [Pregrado]. Ecuador: Universidad Técnica Babahoyo; 2024
57. Sánchez Apráez AK. Sistema de predicción en la producción de arándanos [Internet] [Tesis de licenciatura]. Ecuador: Universidad Politécnica Salesiana; 2024.
58. Soto Torres AI. Predicción de la temperatura inicial de congelación de raíces y tubérculos andinos utilizando inteligencia artificial. Universidad Nacional Agraria La Molina; 2024.
59. Campos JC, Manrique-Silupú J, Dorneanu B, Ipanaqué W, Arellano-García H. A smart decision framework for the prediction of thrips incidence in organic banana crops. *Ecol Model.* 2022; 473:110147. <https://doi.org/10.1016/j.ecolmodel.2022.110147>
60. de Oliveira Quadras DL, Cavalcante I, Kück M, Mendes LG, Frazzon EM. Machine Learning Applied to Logistics Decision Making: Improvements to the Soybean Seed Classification Process. *Appl Sci.* 2023;13(19):10904. <https://doi.org/10.3390/app131910904>
61. Delgado A, Hays DB, Bruton RK, Ceballos H, Novo A, Boi E, et al. Ground penetrating radar: a case study for estimating root bulking rate in cassava (*Manihot esculenta* Crantz). *Plant Methods.* 2017;13:65. <https://doi.org/10.1186/s13007-017-0216-0>
62. Eugenio FC, Grohs M, Schuh MS, Venancio LP, Schons C, Badin TL, et al. Flooded rice variables from high-resolution multispectral images and machine learning algorithms. *Remote Sens Appl Soc Environ.* 2023; 31:100998. <https://doi.org/10.1016/j.rsase.2023.100998>
63. Mañuico SR, Shanny L. Desarrollo de un modelo predictivo de conductividad hidráulica para optimizar el sistema de riego Laguna Huanzo, distrito de Santiago - provincia de Huanca Sancos - Ayacucho [Pregrado]. Perú: Universidad Nacional de San Cristóbal de Huamanga; 2024
64. Mora-Poblete F, Maldonado C, Henrique L, Uhdre R, Scapim CA, Mangolim CA. Multi-trait and multi-environment genomic prediction for flowering traits in maize: a deep learning approach. *Front Plant Sci.* 2023; 14:1153040. <https://doi.org/10.3389/fpls.2023.1153040>
65. Perez-Guerra UH, Macedo R, Manrique YP, Condori EA, Gonzáles HI, Fernández E, et al. Seasonal autoregressive integrated moving average (SARIMA) time-series model for milk production forecasting in pasture-based dairy cows in the Andean highlands. *PLoS ONE.* 2023;18(11): e0288849. <https://doi.org/10.1371/journal.pone.0288849>
66. Rodríguez JP, Corrales DC, Griol D, Callejas Z, Corrales JC. A Non-Destructive Time Series Model for the Estimation of Cherry Coffee Production. *CMC.* 2021;70(3):4725–4743. <https://doi.org/10.32604/cmc.2022.019135>
67. Selvaraj JJ, Cifuentes-Ossa MA, Penna-Narvaez J, Miranda-Parra MA, Herrera-Rozo FA. Species Distribution Models as Tools for Community Empowerment and Informed Decision Making in Colombia's Chocó Pacific Coast Fisheries. *Fishes.* 2023;8(7):349. <https://doi.org/10.3390/fishes8070349>
68. Vasconcelos ES, Silva LA da, Melo DV, Lima AD de, Paiva LFR de, Goulart CS. Inteligencia artificial en la gestión agrícola: uso de modelos de bosque aleatorio para la predicción de producción y reserva de semillas en Brasil. *Observatório de la economía latinoamericana.* 2024;22(6):e5078–e5078. <https://doi.org/10.55905/oelv22n6-052>
69. Alcantara Bernal FF, Mckitting Cornejo GG, Siancas Gutierrez SA, Zaldívar Valdez AS. Técnicas de Machine Learning para incrementar el rendimiento de los campos de caña de azúcar en una empresa agroindustrial [Pregrado]. Perú: Universidad ESAN; 2023.
70. Barba-Escoto L, van Wijk MT, López-Ridaura S. Non-linear Interactions Driving Food Security of Smallholder Farm Households in the Western Highlands of Guatemala. *Front Sustain Food Syst.* 2020; 4. <https://doi.org/10.3389/fsufs.2020.00051>
71. Bruzzone J, Pacheco P, Saldaña M, Álvarez-Castro I, Millán J, Diaz A, et al. Modelos de predicción de precios mayoristas de frutas y hortalizas 2022.
72. Gómez Arango AM. Predicción del rendimiento de cultivos agrícolas en los cinco corregimientos de la ciudad de Medellín, utilizando modelos de Machine Learning [Internet] [Maestría]. Colombia: Universidad EAFIT; 2024.
73. Hidalgo MJ, Gaiad JE, Goicoechea HC, Mendoza A, Pérez-Rodríguez M, Pellerano RG. Geographical origin identification of mandarin fruits by analyzing fingerprint signatures based on multielemental composition. *Food Chem X.* 2023;20:101040. <https://doi.org/10.1016/j.fochx.2023.101040>
74. Warren-Vega WM, Aguilar-Hernández DE, Zárate-Guzmán AI, Campos-Rodríguez A, Romero-Cano LA. Development of a Predictive Model for Agave Prices Employing Environmental, Economic, and Social Factors: Towards a Planned Supply Chain for Agave-Tequila Industry. *Foods.* 2022;11(8):1138. <https://doi.org/10.3390/foods11081138>

75. Zeymer JS, Guzzo F, de Araujo MEV, Gates RS, Corrêa PC, Vidigal MCTR, *et al.* Machine learning algorithms to predict the dry matter loss of stored soybean grains (*Glycine max* L.). *J Food Process Eng.* 2021;44(10): e13820. <https://doi.org/10.1111/jfpe.13820>
76. Mehra D, Rael T, Bloem MW. A review of the intersection between climate change, agriculture, health, and nutrition in Africa: costs and programmatic options. *Front Sustain Food Syst.* 2024;8. <https://doi.org/10.3389/fsufs.2024.1389730>
77. Chinecherem OO, Kanu C, Ugwuja Nnenna E. Comprehensive review of supervised machine learning algorithms to identify the best and error free. *Int J Schol Res Eng Technol.* 2023;02(01):013–019. <https://doi.org/10.56781/ijsret.2023.2.1.0028>
78. Huang AA, Huang SY. Perspective chapter: Enhancing regression analysis with splines and machine learning – evaluation of how to capture complex non-linear multidimensional variables. In: *Nonlinear systems and matrix analysis - Recent advances in theory and applications 2024.* <https://doi.org/10.5772/intechopen.1005288>

Recibido: 11/02/2025
Aceptado: 09/07/2025