








Artículo de Revisión/ Review Article

## Aplicación del aprendizaje automático en la garantía de la seguridad alimentaria nutricional: una revisión sistemática del período 2015- 2025

*Application of machine learning in guaranteeing nutritional food security: a systematic review of the period 2015-2025*

\***Lourdes Oriana Chavarría**<sup>1,2</sup>  **María Sol Moreno**<sup>1,2</sup>  **María Guadalupe Teixeira**<sup>1,2,6</sup>   
**Micaela Natalia Campero**<sup>1,2,3,4,5</sup>  **Fernando Roda**<sup>1,4,5</sup>  **Sandra L. Restrepo-Mesa**<sup>1,7</sup>   
**Carlos Matías Scavuzzo**<sup>1,2,3,4,5</sup> 

<sup>1</sup>Fundación InnovaComunidad. Córdoba, Argentina.

<sup>2</sup>Universidad Nacional de Córdoba, Escuela de Nutrición, Facultad de Ciencias Médicas. Córdoba, Argentina.

<sup>3</sup>Universidad Nacional de Córdoba, Centro de Investigaciones en Nutrición Humana (CenINH), Escuela de Nutrición, Facultad de Ciencias Médicas. Córdoba, Argentina.

<sup>4</sup>Universidad Nacional de Córdoba, Instituto de Altos Estudios Espaciales Mario Gulich, Comisión Nacional de Actividades Espaciales. Córdoba, Argentina.

<sup>5</sup>Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET). Buenos Aires, Argentina.

<sup>6</sup>Universidad Nacional de Córdoba, Secretaría de Ciencia y Tecnología (SECyT). Córdoba, Argentina.

<sup>7</sup>Universidad de Antioquia. Medellín, Colombia

Correspondencia\*: [guada.teixeira@gmail.com](mailto:guada.teixeira@gmail.com)

### Para citar este artículo:

Chavarría, L. O., Moreno, M. S., Teixeira, M. G., Campero, M. N., Roda, F., Restrepo-Mesa, S. L. y Scavuzzo, C. M. (2026). Aplicación del aprendizaje automático en la garantía de la seguridad alimentaria nutricional: una revisión sistemática del periodo 2015 -2025. *UCOM Scientia*,4(1), 156-179.

Fecha de recepción: 15/02/2026

Fecha de aceptación: 03/03/2026

### Resumen

Durante las últimas décadas se ha tratado de erradicar la inseguridad alimentaria con programas y políticas públicas que resultan insuficientes para lograr el Hambre Cero. En este marco, surge el aprendizaje automático como herramienta para fortalecer el análisis, la toma de decisiones y la anticipación de riesgos en sistemas alimentarios. Analizar sistemáticamente la evidencia científica disponible sobre los aportes del aprendizaje automático en el ámbito de la seguridad alimentaria nutricional a nivel mundial durante el período 2015-2025. Se realizó una revisión sistemática, usando diferentes bases científicas online (Pubmed/Medline, Google Scholar, Lilacs, BVS, Scielo). Se incluyeron aquellos artículos que contenían las palabras clave o una combinación de ellas durante el año 2015-2025, que aplicaran herramientas de aprendizaje automático en al menos una

dimensión de la seguridad alimentaria nutricional. La calidad de los estudios incluidos se verificó mediante la guía STROBE y la guía Downs and Black. Se analizaron 17 artículos que reportan el uso de modelos de aprendizaje automático para abordar la seguridad alimentaria nutricional. En algunos casos, estos modelos incorporaron técnicas de aprendizaje profundo. La disponibilidad fue la dimensión más estudiada. Los modelos de aprendizaje automático son herramientas eficaces en el abordaje de la seguridad alimentaria nutricional para analizar y predecir aspectos vinculados con la misma. Se destaca la necesidad de promover investigaciones que integren dimensiones sociales y contextuales, con el fin de fortalecer un enfoque sostenible de la seguridad alimentaria nutricional.

**Palabras clave:** Inteligencia artificial; aprendizaje automático; aprendizaje profundo; seguridad alimentaria.

## Abstract

During the last decades, attempts have been made to eradicate food insecurity with public programs and policies that are insufficient to achieve Zero Hunger. In this framework, machine learning emerges as a tool to strengthen analysis, decision-making and risk anticipation in food systems. Systematically analyze the available scientific evidence on the contributions of machine learning in the field of nutritional food security worldwide during the period 2015-2025. A systematic review was carried out, using different online scientific bases (Pubmed/Medline, Google Scholar, Lilacs, BVS, Scielo). Those articles that contained the keywords or a combination of them during the year 2015-2025, that applied machine learning tools in at least one dimension of nutritional food security were included. The quality of the included studies was verified using the STROBE guideline and the Downs and Black guideline. Seventeen articles reporting the use of machine learning models to address nutritional food security were analyzed. In some cases, these models incorporated deep learning techniques. Availability was the most studied dimension. Machine learning models are effective tools in addressing nutritional food security to analyze and predict aspects related to it. The need to promote research that integrates social and contextual dimensions is highlighted, in order to strengthen a sustainable approach to nutritional food security.

**Keywords:** Artificial intelligence; machine learning; deep learning, food security.

## 1. Introducción

Aunque se registraron avances tras la pandemia de COVID-19, la Seguridad Alimentaria y Nutricional (SAN) sigue siendo un desafío global: en 2024, se estima que entre 7,8 % y 8,8 % de la población mundial (638–720 millones de personas) padeció hambre (FAO et al., 2025). La SAN no se limita solo a la disponibilidad de alimentos; es un fenómeno multidimensional que integra el acceso físico y económico, el consumo adecuado, la utilización biológica de los nutrientes y la estabilidad de estas condiciones en el tiempo (CFS, 2021; World Food Programme, 2025). Si bien esta concepción ha sido incorporada progresivamente en los marcos analíticos internacionales y retomada en iniciativas como los Objetivos de Desarrollo Sostenible, su traducción en políticas y estrategias efectivas continúa siendo limitada, especialmente en países de ingresos medios y bajos y en contextos atravesados por múltiples crisis (FAO et al., 2025; United Nations 2023).



Diversos estudios señalan que los enfoques tradicionales orientados a garantizar la SAN han mostrado resultados insuficientes para revertir las desigualdades estructurales que condicionan el acceso a una alimentación adecuada, o que refuerza la necesidad de enfoques intersectoriales y centrados en equidad (High Level Panel of Experts on Food Security and Nutrition [HLPE], 2023; FAO et al., 2025). En este sentido, los sistemas alimentarios actuales se caracterizan por una elevada complejidad, atravesada por dinámicas productivas, ambientales, socioeconómicas y sanitarias que interactúan de manera no lineal, generando escenarios de alta incertidumbre para la planificación y evaluación de intervenciones (CFS, 2021).

En este contexto, el desarrollo de diversas técnicas de Inteligencia Artificial (IA) ha abierto nuevas oportunidades para el análisis de sistemas complejos. Particularmente, el aprendizaje automático (machine learning - ML) es una rama de la inteligencia artificial en la que los modelos ajustan parámetros internos a partir de datos, incorporando la “experiencia” contenida en ellos para mejorar su desempeño y habilitar predicciones o apoyar decisiones. Dentro de este campo, el aprendizaje profundo (deep learning - DL) constituye una técnica más especializada que emplea redes neuronales con múltiples capas para procesar información y tomar decisiones con representaciones más complejas (Digital.govt.nz, 2025). La aplicación de estas técnicas en el campo de la SAN ha crecido en los últimos años, principalmente en el ámbito de la producción agrícola, la estimación de rendimientos y el monitoreo de variables ambientales, ámbitos en los que el ML se ha utilizado como herramienta de apoyo a la gestión y optimización productiva, con efectos potenciales sobre la disponibilidad de alimentos (Ding et al., 2023; Sarku et al., 2023).

No obstante, la literatura indica que estas aplicaciones se concentran mayormente en fases productivas de los sistemas alimentarios, con una atención limitada a las dimensiones sociales y nutricionales de la SAN (Li et al., 2024). Desde una perspectiva de salud pública, resulta necesario analizar el potencial del ML para integrar información ambiental, productiva y sanitaria, y apoyar procesos de toma de decisiones orientados a mejorar el acceso, el consumo y la utilización biológica de los alimentos, especialmente en poblaciones vulnerables.

Asimismo, la incorporación del ML en el abordaje de la SAN plantea desafíos conceptuales y metodológicos vinculados a la calidad y disponibilidad de los datos, la presencia de sesgos algorítmicos y la escasa contextualización territorial de muchas aplicaciones (Namkhah et al., 2023; Sarku et al., 2023). En este sentido, el presente estudio tuvo como objetivo analizar sistemáticamente la evidencia científica disponible sobre los aportes del ML en el ámbito de la SAN a nivel mundial durante el período 2015-2025.

## 2. Materiales y métodos

El presente estudio se desarrolló a partir de una revisión sistemática de la literatura científica con enfoque exploratorio y descriptivo, orientada a identificar y analizar las aplicaciones de del ML en el abordaje de la SAN. El diseño metodológico se estructuró conforme a los lineamientos establecidos por la declaración PRISMA 2020 (Page et al., 2021), con el objetivo de garantizar transparencia, reproducibilidad y rigor en el proceso de búsqueda, selección y análisis de los estudios incluidos. El proceso de identificación, cribado, elegibilidad e inclusión de los artículos se documentó mediante un diagrama de flujo acorde a dicha declaración.

La estrategia de búsqueda bibliográfica se llevó a cabo en las bases de datos PubMed/Medline, Scielo, LILACS y la Biblioteca Virtual en Salud (BVS). Asimismo, Google Scholar fue utilizado como metabuscador para identificar literatura potencialmente relevante. Se seleccionaron estas fuentes por su trascendencia en los campos de la salud pública, la nutrición, las ciencias sociales y las tecnologías aplicadas. La búsqueda se realizó utilizando combinaciones de palabras claves como Seguridad Alimentaria y Nutricional, Inteligencia Artificial, Alimentación, Nutrición, Aprendizaje Automático, Aprendizaje Profundo en inglés y español y en todas sus posibles combinaciones utilizando entre ellas el operador booleano “AND” u “OR” adaptados a las particularidades de cada base de datos (Anexo 1).

Se incluyeron artículos científicos de acceso abierto y gratuito, publicados entre los años 2015 y 2025, en idioma español, inglés o portugués. Como criterio de inclusión, los estudios debían aplicar técnicas de ML en al menos una de las dimensiones de la SAN: disponibilidad, acceso, consumo, utilización biológica o estabilidad. Se excluyeron trabajos duplicados, documentos de opinión, editoriales, resúmenes de congresos, tesis, revisiones sistemáticas y aquellos estudios que no abordaran de manera explícita la relación entre ML y SAN.

El proceso de selección de los estudios se realizó en etapas sucesivas. En una primera instancia se efectuó la lectura de títulos y resúmenes para evaluar la pertinencia temática, revisando un total de 2544 artículos (PubMed n = 942; Google Scholar n = 1240; LILACS n = 2; SciELO n = 21; BVS n = 339). Posteriormente, se procedió a la lectura completa de los artículos preseleccionados, aplicando los criterios de inclusión y exclusión definidos previamente. Los desacuerdos en la selección fueron resueltos mediante revisión y consenso.

La evaluación de la calidad metodológica de los estudios incluidos se llevó a cabo utilizando herramientas validadas según el tipo de diseño, contando con la participación de revisores externos con los cuales se llevó a cabo la evaluación de la pertinencia y calidad metodológica esperada. Los estudios observacionales fueron analizados mediante la guía STROBE (Von Elm et al., 2008), una lista de verificación de veintidós puntos esenciales para la comunicación adecuada de dichos estudios, que guardan relación con el título, resumen, introducción, secciones de

métodos, resultados y discusión. Por otro lado, el estudio experimental se evaluó utilizando la herramienta de Downs and Black (Downs & Black, 1998), una lista de verificación que permite aprovisionar una puntuación global no sólo por la calidad de los artículos, su validez interna y poder, sino también por su validez externa. Los autores proponen la siguiente escala de puntuación: 20-31 puntos calidad alta; 10 a 19 puntos calidad intermedia; menos de 10 puntos calidad baja. La utilización de ambas herramientas, permitió valorar aspectos relacionados con la validez interna, la claridad en la presentación de resultados y la adecuación de los métodos utilizados de cada estudio.

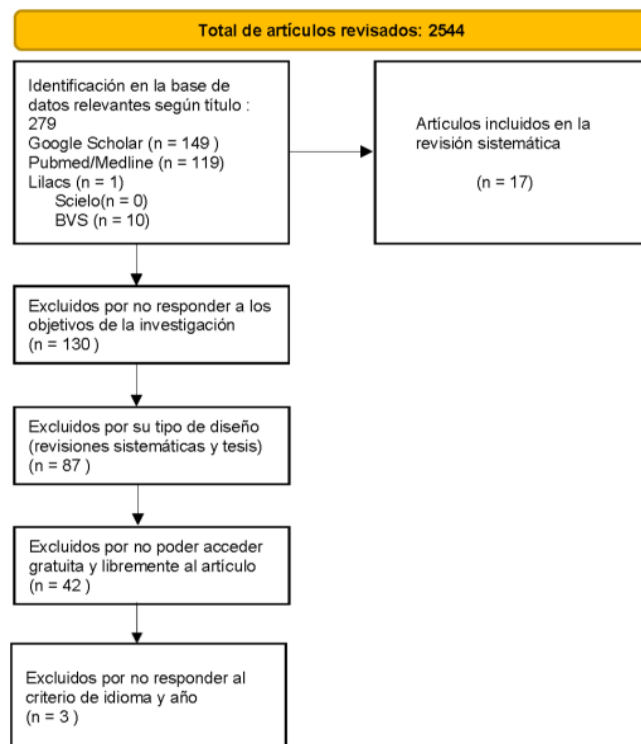
Finalmente, se realizó un análisis descriptivo de los estudios incluidos, considerando variables como el país de realización, el tipo de técnica de IA empleada, el ámbito de aplicación y la dimensión de la SAN abordada. Los resultados se organizaron de manera sistemática con el fin de identificar tendencias generales, áreas de concentración temática y vacíos en la literatura existente.

### 3. Resultados

Se identificaron un total de 2544 estudios en las bases de datos de Pubmed/Medline, Google Scholar, Scielo, BVS Y Lilacs. Tras la aplicación de los filtros por año de publicación y la evaluación de pertinencia mediante lectura de títulos y resúmenes, se distinguieron 279 artículos potencialmente relevantes (Google Scholar n = 149; PubMed/Medline n = 119; LILACS n = 1; BVS n = 10). Posteriormente, se excluyeron 87 artículos por no cumplir con el diseño metodológico requerido (estudios observacionales y experimentales, exceptuando revisiones sistemáticas, tesis de grado, documentos de opinión, editoriales y resúmenes de congresos), no alinearse con los objetivos de la investigación o que no disponían de acceso libre al texto completo. Así mismo, se descartaron algunos artículos por criterios de idioma y año de publicación. Finalmente, la muestra quedó conformada por 17 artículos (Google scholar n = 2, Pubmed/Medline n = 13, Scielo n = 0, BVS n = 2).

El proceso completo de selección se presenta en la Figura 1 mediante el diagrama de flujo PRISMA 2020. Así mismo, la descripción detallada de los 17 artículos incluidos (diseño, muestra, país, técnicas de IA empleadas y principales hallazgos) se presenta en el Anexo 2.

**Figura 1.** Diagrama de flujo del proceso de búsqueda y selección de estudios.



### Calidad metodológica

La evaluación metodológica evidenció que el 100% de los artículos cumplieron con los ítems contexto/fundamentos, definición de variables, fuentes de datos/mediciones y presentación de resultados principales. El 87,5% de los artículos describió adecuadamente los objetivos y las variables cuantitativas. Solo dos estudios (Bitew et al., 2021 y Vela Antón et al., 2023) abordaron explícitamente el ítem "participantes". Por el contrario, los ítems "generabilidad y "datos de las variables de resultado" no pudieron ser aplicados al análisis de los artículos. El estudio de Aqeel et al. (2024), único de diseño experimental en esta revisión, obtuvo una puntuación de 9/31 en la escala Downs & Black (calidad baja), lo que refleja limitaciones metodológicas como la ausencia de validación externa robusta, la adquisición de muestras en un único mercado local, y la falta de cálculo de tamaño muestral a priori. Estos aspectos deben considerarse al interpretar los resultados derivados de dicho estudio. En la Tabla 1 se presenta un resumen con el score de cada artículo. La matriz completa de evaluación de calidad metodológica (STROBE y Downs & Black) se presenta en el Anexo 3 y 4.


**Tabla 1.** Evaluación de la calidad metodológica de los estudios incluidos según escala STROBE y Downs & Black

<b>STROBE</b>		
Autor y año	N° de ítems cumplidos / total (22)	
Gavai et al., 2023	13	
Kanna et al., 2023	16	
Al-Adhaileh & Aldhyani, 202	15	
Mohammed et al., 2024	15	
Wang, et al., 2024	19	
Li et al., 2024	14	
Wang et al., 2017	13	
Espinosa-Herrera et al., 202	16	
Bitew et al., 2021	20	
Ramyaa et al., 2019	15	
Zenteno et al., 2024	14	
Vela Antón et al., 2023	15	
Han et al., 2023	15	
Asamoah et al, 2024	13	
Qasrawi et al, 2024	10	
Gyamerah et al, 2024	22	
<b>Downs and Black</b>		
	Puntuación	Nivel de calidad
Aqeel et al., 2024	9	Baja

#### Caracterización general de los estudios

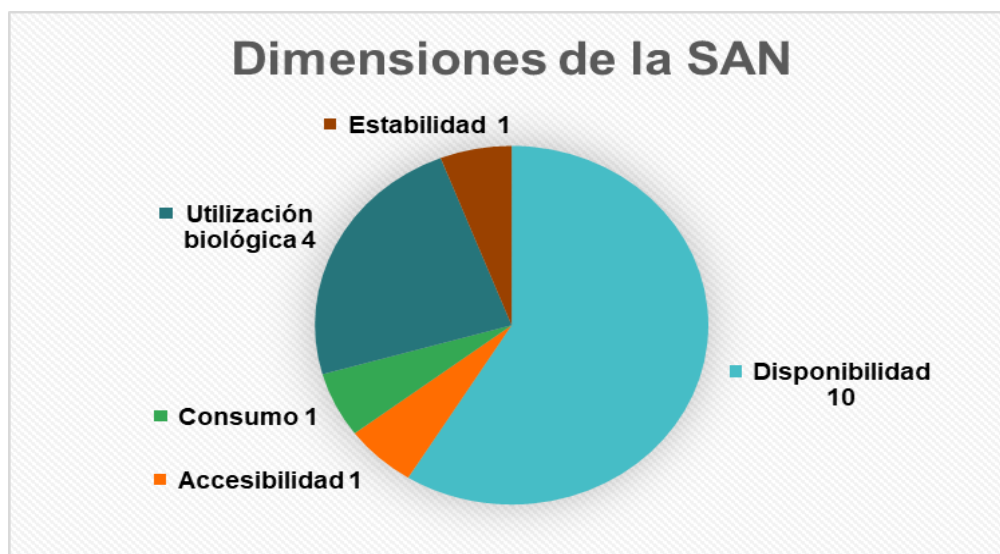
De los estudios seleccionados, el 82,3% provienen de países en desarrollo (India (n = 1), Etiopía (n = 1), Ghana (n = 2), Palestina (n = 1), Perú (n = 1), Siria (n = 1), México (n = 2), China (n = 4) y Arabia Saudita (n = 1)), mientras que el 17,7% correspondió a países desarrollados (Estados Unidos (n = 1), Países Bajos (n = 1) e Irlanda (n = 1)). China fue el país con mayor frecuencia (23,5%), seguido por Ghana y México (11,8% cada uno) (Figura 2).

**Figura 2.** Distribución de los artículos seleccionados según país de origen.



A partir del proceso de búsqueda y selección documentado previamente, se incluyeron 17 estudios que aplicaron técnicas de Machine Learning (ML) y Deep Learning (DL) en problemáticas vinculadas con la SAN. Los estudios analizados reportaron diversos indicadores de desempeño para evaluar los modelos de ML. Las métricas más utilizadas fueron Accuracy, RMSE, AUC-ROC y F1-score, dependiendo del tipo de tarea (clasificación o regresión). En general, los algoritmos basados en ensamblado, como Random Forest y XGBoost, mostraron los niveles de desempeño más elevados en tareas de predicción agrícola y análisis de seguridad alimentaria. Asimismo, el análisis permitió identificar una marcada concentración temática en la dimensión de disponibilidad de alimentos ( $n = 10$ ), seguida por utilización biológica ( $n = 4$ ). En defecto, las dimensiones de acceso ( $n = 1$ ), consumo ( $n = 1$ ) y estabilidad ( $n = 1$ ) mostraron una representación considerablemente menor (Figura 3)

**Figura 3.** Cantidad de artículos incluidos según las dimensiones de la SAN que tratan



Así mismo, los estudios presentan una gran diversidad metodológica en cuanto a fuentes de datos, escalas de análisis y tipos de algoritmos empleados. En términos generales, los trabajos pueden organizarse analíticamente según: (a) dimensión de la SAN abordada, (b) funcionalidad del modelo (predicción, clasificación, monitoreo o diagnóstico), y (c) tipo de arquitectura algorítmica utilizada.

Ámbito de aplicación del ML: Disponibilidad de alimentos La dimensión de disponibilidad concentra el 58,8% de los estudios analizados. En este grupo predominan aplicaciones orientadas a la predicción del rendimiento agrícola, monitoreo de cultivos, detección temprana de enfermedades vegetales y evaluación de variables climáticas y edáficas.

Predicción del rendimiento agrícola: Wang et al. (2024), Gyamerah et al. (2024), Asamoah et al. (2024), Espinosa-Herrera et al. (2022) y Al-Adhaileh & Aldhyani (2022) desarrollaron modelos predictivos basados en variables climáticas (temperatura, precipitación, humedad), edáficas (propiedades del suelo y salinidad), de manejo agronómico (uso de fertilizantes e insecticidas) y, en algunos casos, información genética y fenotípica. Estos trabajos comparten la premisa de que el rendimiento agrícola es el resultado de interacciones multivariadas complejas, difícilmente capturables mediante enfoques lineales tradicionales.

Al-Adhaileh & Aldhyani (2022) implementaron redes neuronales para predecir rendimientos de trigo, papa, arroz y sorgo, evidenciando que las condiciones climáticas y las prácticas agrícolas influyen de manera directa en la productividad. En contextos como Arabia Saudita,

caracterizados por limitaciones agroclimáticas, la aplicación de ML se presenta como una herramienta estratégica para optimizar recursos hídricos y productivos.

Wang et al. (2024) utilizaron redes neuronales de grafos bipartitos (BGNN) capaces de procesar información incompleta, consolidando un enfoque robusto para escenarios donde existen datos ausentes. Este aspecto resulta particularmente relevante en sistemas agrícolas de países de ingresos medios y bajos, donde la disponibilidad de datos puede ser irregular.

Asamoah et al. (2024) entrenaron modelos de Random Forest (RF) para estimar el rendimiento del maíz y la eficiencia agronómica en Ghana, con el objetivo explícito de apoyar decisiones hacia una intensificación más sostenible, en lugar de expandir la superficie cultivada. Demostrando que, el algoritmo logra capturar interacciones complejas entre variables climáticas y prácticas de manejo. Gyamerah et al. (2024), también en Ghana, analizaron la variabilidad climática regional y su impacto diferencial en la producción, evidenciando que la eficacia predictiva depende del contexto agroecológico específico.

Espinosa-Herrera et al. (2022) propusieron modelos para reconocer maíz, frijol y alfalfa antes de que termine el ciclo de cultivo, acelerando la disponibilidad de información útil para la toma de decisiones agrícolas. Entrenaron clasificadores SVM y árboles embolsados con datos de campo de una temporada previa y usaron bandas espectrales de Sentinel-2. Este estudio permitió generar mapas de cultivos oportunos, sin relevamientos de campo nuevos cada año.

En conjunto, estos estudios coinciden en que los modelos basados en ML superan a los enfoques estadísticos tradicionales en precisión predictiva y capacidad de adaptación a sistemas dinámicos. Esta superioridad se explica, en parte, por la capacidad de los algoritmos para modelar relaciones no lineales, incorporar grandes volúmenes de datos multivariados y actualizarse ante nuevos patrones, lo que resulta particularmente relevante en escenarios de variabilidad climática creciente y cambios estructurales en los sistemas productivos. Así mismo, los autores destacan que la integración de datos provenientes de sensores remotos, estaciones meteorológicas y registros agronómicos permite construir modelos más robustos y contextualizados territorialmente.

Monitoreo automatizado y detección de enfermedades: Kanna et al. (2023), Wang et al. (2017) y Zenteno et al. (2024) aplicaron técnicas de DL, principalmente Redes Neuronales Convolucionales (CNN), para el diagnóstico automatizado de enfermedades vegetales y estimación de parámetros de crecimiento.

Kanna et al. (2023) emplearon EfficientNet para la detección temprana de enfermedades en coliflor, reduciendo la dependencia de inspecciones manuales y mejorando la velocidad de diagnóstico. Wang et al. (2017) desarrollaron modelos de DL para estimar la severidad de las

enfermedades en plantas mediante análisis de imágenes, alcanzando altos niveles de precisión. Por su parte, Zenteno et al. (2024) propusieron un sistema de predicción del peso y crecimiento de la lechuga hidropónica a partir de imágenes, permitiendo estimaciones no invasivas como el área foliar, altura y diámetro.

Estos desarrollos evidencian la transición hacia sistemas de agricultura de precisión, donde la automatización y el procesamiento masivo de datos visuales contribuyen a optimizar la producción y reducir las pérdidas.

Gestión ecológica y territorial: Mohammed et al. (2024) abordaron la problemática de la salinización del suelo mediante ML, destacando su potencial para mejorar la gestión agrícola regional. Por su lado, Li et al. (2024) integraron arquitecturas avanzadas de DL para clasificar espacios ecológicos, agrícolas y urbanos, mejorando la comprensión de su interacción.

Estos estudios amplían la noción de disponibilidad más allá del rendimiento puntual, incorporando variables asociadas a sostenibilidad territorial.

#### Ámbito de aplicación del ML: Utilización biológica

La dimensión de utilización biológica representa el 23,5% de los estudios. Aquí predominan investigaciones orientadas a la predicción de la desnutrición, sobrepeso y obesidad y factores de riesgo asociados.

Qasrawi et al. (2024) identificaron determinantes sociodemográficos vinculados a la inseguridad alimentaria y malnutrición infantil, destacando que más del 70% de los hogares con inseguridad alimentaria presentan niveles educativos por debajo de la secundaria. El modelo predictivo permitió jerarquizar variables críticas como educación del hogar, ingreso y localidad.

Bitew et al. (2021) utilizaron datos de la Encuesta Demográfica y de Salud de Etiopía (2016), encontrando que XGBTree mostró mayor precisión en la predicción del retraso del crecimiento, aunque con limitaciones en especificidad.

Vela Antón et al. (2023) desarrollaron modelos basados en historias clínicas electrónicas para predecir sobrepeso y obesidad infantil, evidenciando la adaptabilidad de ML a contextos clínicos reales.

Ramyaa et al. (2019) analizaron patrones dietéticos y actividad física en mujeres posmenopáusicas, señalando la capacidad de ML para modelar relaciones no lineales entre ingesta energética y peso corporal, aunque identificando sesgos derivados de autoinformes.

En conjunto, estos estudios muestran que ML permite integrar variables antropométricas, socioeconómicas y conductuales para estimar riesgos nutricionales de manera anticipada. La posibilidad de combinar datos clínicos, encuestas poblacionales y registros administrativos

amplía el horizonte analítico en salud pública, favoreciendo la identificación temprana de grupos vulnerables y la priorización de intervenciones focalizadas. No obstante, algunos estudios advierten que la calidad de los modelos depende de la consistencia y representatividad de los datos de entrada, especialmente cuando se utilizan autoinformes o encuestas transversales.

Ámbito de aplicación del ML: Consumo, acceso y estabilidad

Estas dimensiones presentan una menor representación individual en los estudios.

Consumo y calidad alimentaria: Aqeel et al. (2024) analizaron adulteración de aceites mediante imágenes hiperespectrales procesadas con SVM, regresión logística, árboles de decisión, Random Forest, K-NN, Naïve Bayes y análisis discriminante lineal (LDA), resultando este último el más eficaz.

Gavai et al. (2023) abordaron el fraude alimentario<sup>1</sup> mediante aprendizaje federado basado en Redes Bayesianas, priorizando la privacidad de datos en cadenas de suministro complejas. Ambos estudios destacan el rol del ML en la protección del consumidor y la garantía de calidad. Además, ponen de relieve que la incorporación de tecnologías avanzadas en la cadena alimentaria no solo mejora la capacidad de detección de irregularidades, sino que también contribuye a fortalecer la trazabilidad y transparencia del sistema, elementos clave para consolidar la confianza en los mercados alimentarios.

En este sentido, el fraude alimentario no solo constituye una práctica económica ilícita, sino que representa una amenaza directa a la SAN, al afectar la inocuidad, la calidad nutricional y la confiabilidad de los productos disponibles. La aplicación de modelos de ML para la detección temprana de adulteraciones, inconsistencias en cadenas de suministro y patrones anómalos de comercialización contribuye a mitigar riesgos sanitarios y económicos, fortaleciendo los mecanismos de vigilancia y gobernanza alimentaria sin alterar la estructura general del sistema analizado.

Acceso económico: Han et al. (2023) aplicaron modelos de ML e interpretabilidad SHAP para analizar el aumento global de precios de alimentos, identificando como variables más influyentes el precio del petróleo, la demanda de granos y la oferta monetaria. El estudio evidencia que el acceso económico, entendido como la capacidad de los hogares para adquirir alimentos suficientes y adecuados a partir de su ingreso disponible, puede analizarse mediante modelos

---

<sup>1</sup> El fraude alimentario ocurre cuando se omite, elimina, sustituye o diluye un componente valioso de un alimento con el fin de obtener una ganancia económica. Incluye la adición de sustancias para que el producto parezca de mayor calidad o valor, así como el etiquetado o la declaración de origen incorrectos. Este tipo de prácticas genera pérdidas económicas, erosiona la confianza del consumidor y, en algunos casos, puede implicar riesgos para la salud (U.S. Food and Drug Administration, 2025).

predictivos que integren variables macroeconómicas y de mercado. A través de técnicas de aprendizaje automático, los autores lograron cuantificar la contribución relativa de distintos determinantes estructurales en la dinámica de precios, permitiendo una lectura más precisa de los factores que condicionan la asequibilidad alimentaria a escala global.

La incorporación de herramientas de interpretabilidad como SHAP resulta particularmente relevante en esta dimensión, ya que no solo mejora la capacidad predictiva del modelo, sino que también facilita la comprensión de los mecanismos subyacentes. En comparación con enfoques econométricos tradicionales centrados en relaciones lineales entre oferta y demanda, el ML permite capturar interacciones no lineales entre variables energéticas, financieras y agrícolas, evidenciando la complejidad sistémica que incide en el acceso económico a los alimentos. Así mismo, este tipo de aproximación ofrece potencial para desarrollar sistemas de alerta temprana frente a incrementos abruptos de precios, contribuyendo a anticipar escenarios de vulnerabilidad alimentaria sin alterar la estructura analítica general del estudio.

Estabilidad: No se identificaron estudios que analicen la estabilidad como dimensión aislada de la SAN, lo que evidencia una brecha temática relevante dentro del corpus analizado. Sin embargo, Gyamerah et al. (2024) incorporan elementos asociados a la estabilidad al examinar la variabilidad climática interanual y su impacto en el rendimiento agrícola en Ghana. En este sentido, la estabilidad aparece integrada a la disponibilidad, particularmente en lo que refiere a la persistencia temporal de la producción frente a fluctuaciones ambientales.

El análisis de la variabilidad climática realizado por estos autores demuestra que los modelos de ML permiten capturar patrones estacionales y anomalías que inciden directamente en la regularidad de los rendimientos. Si bien el objetivo principal del estudio no fue modelar estabilidad en términos de seguridad alimentaria a nivel macro, los resultados evidencian que la incorporación de series temporales climáticas y productivas constituye una aproximación indirecta pero sustantiva a dicha dimensión.

La estabilidad, entendida como la capacidad del sistema alimentario de sostener en el tiempo la disponibilidad, el acceso y la utilización de alimentos frente a shocks externos (climáticos, económicos o sanitarios), requiere modelos capaces de integrar datos longitudinales y multiescalares. En este marco, el uso de algoritmos como Random Forest o XGBoost, entrenados con datos históricos de rendimiento y clima, ofrece ventajas en la detección de umbrales críticos y variaciones abruptas.

Asimismo, la posibilidad de actualizar los modelos con nuevos datos permite fortalecer la capacidad adaptativa del sistema analítico frente a escenarios de cambio climático. En comparación con enfoques estáticos, los modelos basados en ML facilitan la incorporación progresiva de información, reduciendo la obsolescencia de las predicciones. No obstante, la

ausencia de estudios que aborden explícitamente la estabilidad como variable dependiente revela la necesidad de profundizar investigaciones que integren dimensiones temporales más extensas y eventos disruptivos específicos.

#### Técnicas de ML utilizadas

El 82,5% de los estudios empleó técnicas de ML convencional: principalmente Random Forest (RF), XGBoost, Support Vector Machines (SVM) y regresión logística; mientras que el 17,5% utilizó arquitecturas de Deep Learning (DL), tales como Redes Neuronales Convolucionales (CNN), EfficientNet y modelos específicos como SAREs-NET.

RF y XGBoost se destacaron por su robustez frente a datos heterogéneos y multivariados. Estos algoritmos permiten modelar relaciones no lineales complejas y manejar interacciones entre variables sin requerir supuestos paramétricos estrictos. En estudios de rendimiento agrícola (Asamoah et al., 2024; Gyamerah et al., 2024), RF demostró capacidad para capturar la interacción entre variables climáticas y prácticas agronómicas, mientras que en estudios de salud nutricional (Bitew et al., 2021) XGBTree alcanzó mayores niveles de precisión en comparación con otros clasificadores.

Las SVM mostraron alta precisión en tareas de clasificación con conjuntos de datos moderados, particularmente en análisis de imágenes hiperespectrales (Aqeel et al., 2024). Su capacidad para maximizar márgenes de separación entre clases resultó adecuada en contextos donde la dimensionalidad de los datos es elevada pero el tamaño muestral es relativamente acotado.

En el ámbito del DL, las CNN evidenciaron superioridad en tareas basadas en imágenes, como detección de enfermedades vegetales (Kanna et al., 2023; Wang et al., 2017) y estimación de parámetros de crecimiento (Zenteno et al., 2024). Estas arquitecturas permiten la extracción automática de características espaciales relevantes, reduciendo la necesidad de ingeniería manual de variables. EfficientNet, por ejemplo, optimiza la relación entre profundidad, ancho y resolución de la red, mejorando la eficiencia computacional sin sacrificar precisión.

Li et al. (2024) evidenciaron que modelos de DL como SAREs-NET superan a arquitecturas convencionales en la modelización de relaciones no lineales complejas en clasificación espacial. Este tipo de modelos resulta particularmente pertinente cuando las variables presentan dependencia espacial o jerárquica.

En términos generales, la elección de la técnica estuvo condicionada por la naturaleza de los datos disponibles (tabulares, imágenes, series temporales) y por la funcionalidad buscada (predicción, clasificación o monitoreo). Los estudios muestran una tendencia hacia la combinación de múltiples fuentes de datos (climáticos, edáficos, sociodemográficos, clínicos e imágenes) lo que exige algoritmos capaces de integrar información heterogénea.

## Funcionalidades predominantes

La predicción y el modelado representaron el 58,8% de las aplicaciones identificadas, constituyéndose como la funcionalidad predominante. En agricultura, esta orientación se traduce en la estimación anticipada de rendimientos, evaluación de impactos climáticos y proyección de escenarios productivos (Wang et al., 2024; Asamoah et al., 2024). La capacidad predictiva permite reducir la incertidumbre en la planificación agrícola y optimizar decisiones de manejo.

La detección y clasificación automatizada ocuparon el segundo lugar en frecuencia. En este grupo se incluyen diagnósticos fitosanitarios basados en imágenes (Kanna et al., 2023; Wang et al., 2017), clasificación de espacios ecológicos (Li et al., 2024) y detección de adulteraciones en productos alimentarios (Aqeel et al., 2024). Estas aplicaciones se caracterizan por operar en tiempo casi real y reducir la dependencia de evaluaciones manuales.

El monitoreo continuo constituye otra funcionalidad relevante, particularmente en sistemas de agricultura de precisión y en análisis de precios de alimentos (Han et al., 2023). El uso de ML en monitoreo permite identificar tendencias emergentes y patrones anómalos, favoreciendo intervenciones tempranas.

En el ámbito nutricional, los modelos se orientan a la predicción de riesgos individuales o poblacionales de malnutrición (Qasrawi et al., 2024; Bitew et al., 2021; Vela Antón et al., 2023). Aquí la funcionalidad se vincula con la estratificación de riesgo y la priorización de intervenciones sanitarias.

En conjunto, las funcionalidades predominantes muestran una orientación prospectiva más que descriptiva. A diferencia de enfoques tradicionales centrados en análisis retrospectivos, los modelos de ML permiten anticipar eventos, clasificar automáticamente grandes volúmenes de información y sostener sistemas de vigilancia continuos.

## Comparación con métodos tradicionales

Diversos estudios compararon explícitamente el desempeño de modelos de ML con enfoques estadísticos convencionales, evidenciando limitaciones de estos últimos en términos de escalabilidad, capacidad de generalización y manejo de relaciones no lineales (Kanna et al., 2023; Wang et al., 2017). Los métodos tradicionales, basados en regresiones lineales o modelos paramétricos, suelen requerir supuestos estrictos sobre la distribución de los datos y la independencia entre variables.

Al-Adhaileh & Aldhyani (2022) subrayan que los modelos estadísticos tradicionales presentan mayor incertidumbre frente a sistemas dinámicos y variables altamente interdependientes, como ocurre en contextos agrícolas con múltiples determinantes climáticos y de manejo. En contraste, las redes neuronales permiten capturar interacciones complejas sin necesidad de especificar previamente la forma funcional de la relación.

En estudios de nutrición y salud pública, los algoritmos de boosting (Bitew et al., 2021) mostraron mayor precisión que modelos logísticos convencionales, particularmente cuando se incorporan múltiples variables sociodemográficas y antropométricas. Esta mejora se vincula con la capacidad del ML para manejar colinealidad y detectar patrones no evidentes mediante análisis lineales.

En aplicaciones basadas en imágenes, la superioridad del DL frente a métodos manuales o semi-automatizados es aún más marcada. Mientras que los enfoques tradicionales requieren extracción manual de características, las CNN aprenden representaciones jerárquicas directamente a partir de los datos visuales (Wang et al., 2017; Kanna et al., 2023), lo que incrementa precisión y reduce sesgos del observador.

No obstante, algunos estudios señalan que el desempeño superior del ML depende de la calidad y volumen de datos disponibles. En contextos con bases de datos limitadas o sesgadas, los modelos pueden sobreajustarse o perder capacidad de generalización. Por ello, si bien el ML ofrece ventajas claras en sistemas complejos y dinámicos, su implementación requiere criterios rigurosos de validación, selección de variables y evaluación comparativa.

En síntesis, la comparación evidencia que los métodos tradicionales mantienen utilidad descriptiva y explicativa en contextos simples o con datos limitados, pero los modelos de ML presentan ventajas sustantivas cuando se abordan sistemas alimentarios caracterizados por multicausalidad, heterogeneidad territorial y alta variabilidad temporal.

#### **4. Discusión**

Los resultados evidencian una tensión entre el enfoque multidimensional de la SAN adoptado en los marcos internacionales y la orientación principalmente productivista de las aplicaciones actuales de ML. El análisis revela que el ML se aplica predominantemente en la dimensión de disponibilidad de la SAN, priorizando la oferta cuantitativa sobre las disparidades en el acceso. Sarku et al. (2023) confirman este énfasis, aunque instan a integrar las demás dimensiones para una comprensión completa del problema. De modo convergente, Alvarez Di Fino et al. (2022) señalan que las herramientas geoespaciales y de teledetección se han centrado históricamente en variables ambientales y productivas, postergando factores críticos como el acceso y la utilización biológica. El énfasis en la predicción productiva, si bien relevante, resulta insuficiente ante un escenario donde los principales determinantes de la inseguridad alimentaria se vinculan

crecientemente con la inflación, el cambio climático, los desastres naturales, y desigualdades socioeconómicas estructurales (FAO et al., 2025; Calvin et al., 2023).

Los estudios incluidos reportan que el ML es una herramienta valiosa para fortalecer la disponibilidad de alimentos, con aplicaciones que abarcan desde la predicción precisa del rendimiento de cultivos (Wang et al., 2024) hasta enfoques innovadores para la detección de adulteraciones motivadas económicamente (Aqeel et al., 2024) y la estimación automatizada de fitopatologías (Wang et al., 2017). En sintonía con esto, Alamu (2024) sostiene que la adopción de modelos de ML permite reducir amenazas y costos de producción, proveyendo sistemas más asequibles y eficientes para gestionar plagas y predecir cosechas. Estas aplicaciones demuestran el potencial del ML para optimizar procesos productivos clave en un contexto de creciente presión climática y demográfica. Asimismo, la literatura analizada sugiere que estas tecnologías presentan un desempeño favorable frente a métodos tradicionales en tareas de inspección visual y precisión predictiva. A modo de ejemplo, Afzal et al. (2025) ilustran la dificultad de los agricultores para seleccionar cultivos óptimos ante la alta variabilidad climática y edáfica y proponen un enfoque de ML que recomienda el cultivo más adecuado según las propiedades específicas del suelo, facilitando la toma de decisiones para una agricultura inteligente y sostenible con impacto directo en la rentabilidad y el rendimiento productivo. (Afzal et al., 2025).

En cuanto a las técnicas de ML utilizadas en los estudios analizados, la predominancia de ciertos algoritmos puede explicarse por la naturaleza de los datos empleados. Los modelos más utilizados, como Random Forest y XGBoost, resultan adecuados para contextos agrícolas debido a su capacidad para manejar conjuntos de datos heterogéneos y multivariados, integrando variables climáticas, edáficas y agronómicas sin requerir supuestos paramétricos estrictos. Esto se relaciona con la mayor cantidad de estudios centrados en la dimensión de disponibilidad de la SAN, donde predominan datos tabulares vinculados con la producción agrícola. Por su parte, las arquitecturas de DL, especialmente las CNN, han demostrado ventajas en tareas basadas en imágenes, como la detección de enfermedades vegetales o el análisis de imágenes satelitales, lo que también las vincula con dicha dimensión al permitir monitorear el estado de los cultivos y estimar rendimientos. En conjunto, la elección de los algoritmos refleja tanto las características de los datos disponibles como los objetivos analíticos de cada estudio.

A pesar del valor del ML en la SAN, su interpretación crítica exige reconocer diversas limitaciones técnicas. La más recurrente es la dependencia de datos incompletos, desactualizados o sesgados por autoinformes (Ramya et al., 2019). Por otro lado, el aprendizaje federado aún enfrenta barreras por la necesidad de datos estructurados (Gavai et al., 2023), mientras que el procesamiento de imágenes sufre ante condiciones climáticas como la nubosidad o errores en la detección de contornos (Espinosa-Herrera et al., 2022). Adicionalmente, la falta de transferibilidad

de los modelos entre regiones con contextos agroecológicos distintos es un desafío mayor (Mohammed et al., 2024). Muchos estudios omiten variables ambientales críticas como el estado de los suelos o el agua (Li et al., 2024), y otros se limitan a factores macroeconómicos que restringen la comprensión de la causalidad (Han et al., 2023).

Más allá de estas restricciones técnicas, resulta pertinente preguntarse si la concentración de aplicaciones en la dimensión productiva responde únicamente a la disponibilidad de datos y factibilidad técnica, o si refleja una orientación estructural del campo hacia prioridades económicas y de eficiencia productiva. En este sentido, Clapp & Moseley (2020) han señalado que, ante crisis alimentarias, las respuestas políticas dominantes han tendido a privilegiar el aumento de la producción y la expansión de la agricultura industrial, junto con la especialización y el comercio internacional, como estrategia estándar para sostener la SAN. Sin embargo, la abundancia global de alimentos (disponibilidad) no necesariamente evita el hambre, dado que garantizar la SAN depende de interacciones dinámicas entre acceso económico, estabilidad, nutrición y gobernanza (High Level Panel of Experts on Food Security and Nutrition [HLPE], 2020; HLPE, 2023). Este énfasis histórico en la expansión productiva ha sido conceptualizado como un “paradigma productivista”, centrado en volúmenes agregados y eficiencia, que tiende a subestimar dimensiones distributivas y sociales de la seguridad alimentaria (Lähde et al., 2023; Ingram, 2011).

Un hallazgo relevante de esta revisión es la escasa presencia de estudios que modelen explícitamente la estabilidad como variable central dentro del marco de la SAN. El análisis de esta dimensión exige datos longitudinales y multiescalares capaces de capturar variaciones temporales y la interacción entre factores climáticos, productivos y socioeconómicos. En este contexto, el ML ofrece un alto potencial analítico al permitir la integración de grandes volúmenes de datos heterogéneos y la detección de patrones complejos. Esta promesa, sin embargo, choca con la disponibilidad limitada de series de datos continuas y comparables en muchas regiones, restricción que se agudiza en contextos vulnerables donde la información sobre sistemas alimentarios suele ser incompleta, fragmentada o poco comparable, dificultando el análisis de la estabilidad alimentaria en el largo plazo (Deconinck, 2022; HLPE, 2020; FAO et al., 2025).

Para futuras investigaciones, es imperativo superar el sesgo hacia la dimensión de disponibilidad, la cual concentra la mayoría de los estudios actuales (Sarku et al., 2023). Existe una necesidad crítica de expandir estas tecnologías hacia América Latina, donde los determinantes de la SAN difieren y la IA podría transformar la planificación de políticas públicas (Alvarez Di Fino et al., 2022). Finalmente, los modelos deben evolucionar hacia la resiliencia, incorporando escenarios de crisis climática y pandemias para garantizar sistemas alimentarios sostenibles (Sarku et al., 2023; Alamu, 2024). El potencial transformador del ML en la SAN dependerá, en última instancia, de su

capacidad para trascender la eficiencia productiva y abordar la complejidad social, distributiva y política que subyace al problema del hambre.

## 5. Conclusiones

La evidencia analizada muestra que el Machine Learning (ML) y el Deep Learning (DL) se han consolidado como herramientas relevantes para el procesamiento de grandes volúmenes de datos en el campo de la SAN, particularmente en la optimización productiva, la inocuidad y la detección de riesgos. Sin embargo, el predominio de aplicaciones orientadas a la disponibilidad pone de relieve una oportunidad significativa para ampliar el alcance de estas tecnologías hacia otras dimensiones de la SAN.

En este sentido, el desafío de la SAN no puede resolverse únicamente desde la dimensión de disponibilidad. El potencial transformador del ML reside en su capacidad para integrarse con las demás dimensiones—acceso, utilización biológica y estabilidad—y apoyar un abordaje integral. Resulta fundamental que las futuras aplicaciones del ML trasciendan el enfoque productivista y contribuyan a mitigar las disparidades socioeconómicas y nutricionales que aún persisten.

Cabe señalar que la presente revisión no tuvo como objetivo profundizar en el análisis técnico de los algoritmos de ML, sino evaluar su implicancia e impacto en el abordaje de la SAN. La comparación cuantitativa de indicadores de rendimiento como Accuracy, F1-Score, RMSE o AUC-ROC entre los estudios incluidos excede el alcance metodológico de una revisión sistemática orientada a evaluar aplicaciones. Si bien su reporte constituye información valiosa, la heterogeneidad metodológica de la literatura analizada limita la comparabilidad directa de dichos indicadores entre sí. Asimismo, el dinamismo propio del desarrollo tecnológico implica que las conclusiones aquí presentadas podrían requerir actualizaciones en el corto o mediano plazo. En este sentido, futuras investigaciones deberían adoptar una búsqueda más exhaustiva que contemple el conjunto de técnicas de IA, ya que la utilización de palabras clave limitadas puede restringir el alcance y la sensibilidad de la evidencia recuperada. Como estrategia para mejorar la reproducibilidad y ampliar la cobertura de la búsqueda, se recomienda utilizar un vocabulario controlado de subdominios de IA, como el propuesto por Duran Silva et al. (2021).

Finalmente, los resultados sugieren que los modelos de ML y DL constituyen herramientas con alto potencial para el análisis, la predicción y el apoyo a la toma de decisiones en materia de SAN. Su incorporación resulta particularmente relevante en contextos caracterizados por inseguridad alimentaria, cambio climático y crecimiento poblacional, donde la articulación entre tecnología, salud pública y sistemas alimentarios sostenibles adquiere un carácter prioritario.

## 6. Declaración de financiamiento

La presente investigación se llevó a cabo con financiación propia.

## 7. Declaración de conflictos de intereses

Los autores declaran no tener conflictos de intereses.

## 8. Declaración de autores

Los autores aprueban la versión final del artículo.

## 9. Declaración de disponibilidad de datos

Los datos que responden al artículo pueden ser solicitados al autor de correspondencia.

## 10. Contribución de los autores

Autor	Contribución
Lourdes Oriana Chavarría	Conceptualización, metodología, búsqueda bibliográfica, selección de estudios, extracción de datos, redacción del borrador original, revisión y edición.
María Sol Moreno	Conceptualización, metodología, búsqueda bibliográfica, selección de estudios, extracción de datos, redacción del borrador original, revisión y edición.
María Guadalupe Teixeira	Conceptualización, metodología, validación, revisión y edición, supervisión.
Micaela Natalia Campero	Conceptualización, metodología, análisis/síntesis de evidencia, visualización, revisión y edición, supervisión.
Fernando Roda	Validación, revisión crítica del contenido, revisión y edición.
Sandra L. Restrepo-Mesa	Validación, revisión crítica del contenido, revisión y edición.
Carlos Matías Scavuzzo	Conceptualización, metodología, supervisión, administración del proyecto, revisión y edición.

## 11. Referencias Bibliográficas

Afzal, H., Amjad, M., Raza, A., Munir, K., Villar, S. G., López, L. A. D., & Ashraf, I. (2025). Incorporating soil information with machine learning for crop recommendation to improve agricultural output. *Scientific Reports*, 15(1), 8560. <https://doi.org/10.1038/s41598-025-88676-z>



- Al-Adhaileh, M. H., & Aldhyani, T. H. H. (2022). Artificial intelligence framework for modeling and predicting crop yield to enhance food security in Saudi Arabia. *PeerJ Computer Science*, 8, e1104. <https://doi.org/10.7717/peerj-cs.1104>
- Alamu, S. A. (2024). Systematic review of current trends in precision agricultural model to address food insecurity challenges. *Journal of Applied Sciences and Environmental Management*, 28(12), 4181–4192. <https://doi.org/10.4314/jasem.v28i12.30>
- Álvarez Di Fino, E. M., Scavuzzo, C. M., Campero, M. N., Scavuzzo, C. M., & Defagó, M. D. (2022). Exploring the use of remote sensing tools and geospatial technologies applied to the multidimensional food security problem. *Uniciencia*, 36(1), 746–760. <https://doi.org/10.15359/ru.36-1.48>
- Aqeel, M., Sohaib, A., Iqbal, M., Rehman, H. U., & Rustam, F. (2024). Hyperspectral identification of oil adulteration using machine learning techniques. *Current Research in Food Science*, 8, 100773. <https://doi.org/10.1016/j.crfs.2024.100773>
- Asamoah, E., Heuvelink, G. B. M., Chairi, I., Bindraban, P. S., & Logah, V. (2024). Random forest machine learning for maize yield and agronomic efficiency prediction in Ghana. *Heliyon*, 10(17), e37065. <https://doi.org/10.1016/j.heliyon.2024.e37065>
- Bitew, F. H., Sparks, C. S., & Nyarko, S. H. (2021). Machine learning algorithms for predicting undernutrition among under-five children in Ethiopia. *Public Health Nutrition*, 25(2), 269–280. <https://doi.org/10.1017/S1368980021004262>
- Clapp, J., & Moseley, W. G. (2020). This food crisis is different: COVID-19 and the fragility of the neoliberal food security order. *The Journal of Peasant Studies*, 47(7), 1393–1417. <https://doi.org/10.1080/03066150.2020.1823838>
- Committee on World Food Security. (2021). Global strategic framework for food security and nutrition (GSF). *Food and Agriculture Organization of the United Nations*. [https://www.fao.org/fileadmin/templates/cfs/Docs2021/GSF/NF445\\_CFS\\_GSF\\_2021\\_Clean\\_en.pdf](https://www.fao.org/fileadmin/templates/cfs/Docs2021/GSF/NF445_CFS_GSF_2021_Clean_en.pdf)
- Deconinck, K. (2022). Making better policies for food systems will require reducing evidence gaps. *Global Food Security*, 33, 100621. <https://doi.org/10.1016/j.gfs.2022.100621>
- Ding, H., Tian, J., Yu, W., Wilson, D. I., Young, B. R., Cui, X., Xin, X., Wang, Z., & Li, W. (2023). The application of artificial intelligence and big data in the food industry. *Foods*, 12(24), 4511. <https://doi.org/10.3390/foods12244511>
- Digital.govt.nz. (2025). *Glossary of AI terms (Machine learning)*. New Zealand Government. <https://www.digital.govt.nz/standards-and-guidance/technology-and-architecture/artificial-intelligence/responsible-ai-guidance-for-the-public-service-genai/glossary-of-ai-terms>
- Downs, S. H., & Black, N. (1998). The feasibility of creating a checklist for the assessment of the methodological quality both of randomised and non-randomised studies of health care interventions. *Journal of Epidemiology and Community Health*, 52(6), 377–384.
- Duran-Silva, N., Fuster, E., Massucci, F. A., Parra-Rojas, C., Quinquillà, A., Roda, F., Rondelli, B., Bovenzi, N., & Toietta, C. (2021). *A controlled vocabulary for research and innovation in the field of*

artificial intelligence (AI) (Version 2) [Data set]. Zenodo.  
<https://doi.org/10.5281/zenodo.5591987>

- Espinosa-Herrera, J. M., Macedo-Cruz, A., Fernández-Reynoso, D. S., Flores-Magdaleno, H., Fernández-Ordoñez, Y. M., & Soria-Ruiz, J. (2022). Monitoring and identification of agricultural crops through multitemporal analysis of optical images and machine learning algorithms. *Sensors*, 22(16), 6106. <https://doi.org/10.3390/s22166106>
- FAO, FIDA, OMS, PMA, y UNICEF. (2025). El estado de la seguridad alimentaria y la nutrición en el mundo 2025: Hacer frente a la inflación alta de los precios de los alimentos en aras de la seguridad alimentaria y la nutrición. *Organización de las Naciones Unidas para la Alimentación y la Agricultura*. <https://doi.org/10.4060/cd6008es>
- Gavai, A., Bouzembrak, Y., Mu, W., Martin, F., Kaliyaperumal, R., van Soest, J., Choudhury, A., Heringa, J., Dekker, A., & Marvin, H. J. P. (2023). Applying federated learning to combat food fraud in food supply chains. *Science of Food*, 7(1). <https://doi.org/10.1038/s41538-023-00220-3>
- Gyamerah, S. A., Asare, C., Agbi-Kaeser, H. O., & Baffour-Ata, F. (2024). Assessing the impact of climate variability on maize yields in the different regions of Ghana: A machine learning perspective. *PLOS ONE*, 19(6), e0305762. <https://doi.org/10.1371/journal.pone.0305762>
- Han, X., Yuan, T., Wang, D., Zhao, Z., & Gong, B. (2023). How to understand high global food price? Using SHAP to interpret machine learning algorithm. *PLOS ONE*, 18(8), e0290120. <https://doi.org/10.1371/journal.pone.0290120>
- High Level Panel of Experts on Food Security and Nutrition (HLPE). (2020). *COVID-19 and the world's food security and nutrition: Developing effective policy responses (Policy Report No. 16)*. Committee on World Food Security. <https://www.fao.org/3/ca9731en/CA9731EN.pdf>
- High Level Panel of Experts on Food Security and Nutrition (HLPE-FSN). (2023). *Reducing inequalities for food security and nutrition (Policy Report No. 18)*. Committee on World Food Security. <https://www.fao.org/3/cc1451en/cc1451en.pdf>
- Ingram, J. (2011). A food systems approach to researching food security and its interactions with global environmental change. *Food Security*, 3(4), 417–431. <https://doi.org/10.1007/s12571-011-0149-9>
- Calvin, K., Dasgupta, D., Krinner, G., Mukherji, A., Thorne, P. W., Trisos, C., Romero, J., Aldunce, P., Barrett, K., Blanco, G., Cheung, W. W. L., Connors, S., Denton, F., Diongue-Niang, A., Dodman, D., Garschagen, M., Geden, O., Hayward, B., Jones, C., ... Ha, M. (with Lee, H.). (2023). *Ipcc, 2023: Climate change 2023: synthesis report. Contribution of working groups i, ii and iii to the sixth assessment report of the intergovernmental panel on climate change [core writing team, h. Lee and j. Romero (Eds.)]. Ipcc, geneva, switzerland*. (P. Arias, M. Bustamante, I. Elgizouli, G. Flato, M. Howden, C. Méndez-Vallejo, J. J. Pereira, R. Pichs-Madruga, S. K. Rose, Y. Saheb, R. Sánchez Rodríguez, D. Ürge-Vorsatz, C. Xiao, N. Yassaa, J. Romero, J. Kim, E. F. Haites, Y. Jung, R. Stavins, ... C. Péan, Eds.). Intergovernmental Panel on Climate Change (IPCC). <https://doi.org/10.59327/IPCC/AR6-9789291691647>



- Kanna, G. P., Kumar, S. J., Kumar, Y., Changela, A., Woźniak, M., Shafi, J., & Ijaz, M. F. (2023). Advanced deep learning techniques for early disease prediction in cauliflower plants. *Scientific Reports*, *13*(1), 18475. <https://doi.org/10.1038/s41598-023-45403-w>
- Lähde, V., Vadén, T., Toivanen, T., Järvensivu, P., & Eronen, J. T. (2023). The crises inherent in the success of the global food system. *Ecology and Society*, *28*(4). <https://doi.org/10.5751/ES-14624-280416>
- Li, A., Zhang, Z., Hong, Z., Liu, L., & Liu, Y. (2024). Evaluation method for ecology-agriculture-urban spaces based on deep learning. *Scientific Reports*, *14*(1), 11353. <https://doi.org/10.1038/s41598-024-61919-1>
- Mohammed, S., Arshad, S., Bashir, B., Ata, B., Al-Dalahmeh, M., Alsalman, A., Ali, H., Alhennawi, S., Kiwan, S., & Harsanyi, E. (2024). Evaluating machine learning performance in predicting sodium adsorption ratio for sustainable soil-water management in the eastern Mediterranean. *Journal of Environmental Management*, *370*, 122640. <https://doi.org/10.1016/j.jenvman.2024.122640>
- Namkhah, Z., Fatemi, S. F., Mansoori, A., Nosratabadi, S., Ghayour-Mobarhan, M., & Sobhani, S. R. (2023). Advancing sustainability in the food and nutrition system: A review of artificial intelligence applications. *Frontiers in Nutrition*, *10*, 1295241. <https://doi.org/10.3389/fnut.2023.1295241>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Alonso-Fernández, S. (2021). Declaración PRISMA 2020: Una guía actualizada para la publicación de revisiones sistemáticas. *Revista Española de Cardiología*, *74*(9), 790–799. <https://doi.org/10.1016/j.recesp.2021.06.016>
- Qasrawi, R., Sgahir, S., Nemer, M., Halaikah, M., Badrasawi, M., Amro, M., Vicuna Polo, S., Abu Al-Halawa, D., Mujahed, D., Nasreddine, L., Elmadfa, I., Atari, S., & Al-Jawaldeh, A. (2024). Machine learning approach for predicting the impact of food insecurity on nutrient consumption and malnutrition in children aged 6 months to 5 years. *Children*, *11*(7), 810. <https://doi.org/10.3390/children11070810>
- Ramyaa, R., Hosseini, O., Krishnan, G. P., & Krishnan, S. (2019). Phenotyping women based on dietary macronutrients, physical activity, and body weight using machine learning tools. *Nutrients*, *11*(7), 1681. <https://doi.org/10.3390/nu11071681>
- Sarku, R., Clemen, U., y Clemen, T. (2023). La aplicación de modelos de inteligencia artificial para la seguridad alimentaria: una revisión. *Agriculture*, *13*(10), 2037. <https://doi.org/10.3390/agriculture13102037>
- U.S. Food and Drug Administration. (2025). *Economically motivated adulteration (food fraud)*. <https://www.fda.gov/food/compliance-enforcement-food/economically-motivated-adulteration-food-fraud>
- United Nations, Department of Economic and Social Affairs. (2023). *The Sustainable Development Goals Report 2023: Special edition*. United Nations.



<https://unstats.un.org/sdgs/report/2023/The-Sustainable-Development-Goals-Report-2023.pdf>

- Vela Antón, P., Soto Becerra, P., Bonilla-Aguilar, K., Guillermo Roman, M., & Apolaya-Segura, M. (2023). *Machine learning para la predicción de sobrepeso y obesidad en pacientes atendidos por el programa de control de crecimiento y desarrollo de la red asistencial Sabogal del Seguro Social de Salud del Perú (Reporte de Resultados de Investigación No. 05-2023)*. Seguro Social de Salud (EsSalud), Instituto de Evaluación de Tecnologías en Salud e Investigación (IETSI). <https://hdl.handle.net/20.500.12959/5017>
- Von Elm, E., Altman, D. G., Egger, M., Pocock, S. J., Gøtzsche, P. C., Vandenbroucke, J. P., & Iniciativa STROBE. (2008). Declaración de la Iniciativa STROBE (Strengthening the Reporting of Observational studies in Epidemiology): directrices para la comunicación de estudios observacionales. *Gac Sanit*, 22(2), 144-150.
- Wang, G., Sun, Y., & Wang, J. (2017). Automatic image-based plant disease severity estimation using deep learning. *Computational Intelligence and Neuroscience*, 2017, 1-8. <https://doi.org/10.1155/2017/2917536>
- Wang, K., Han, Y., Zhang, Y., Zhang, Y., Wang, S., Yang, F., Liu, C., Zhang, D., Lu, T., Zhang, L., & Liu, Z. (2024). Maize yield prediction with trait-missing data via bipartite graph neural network. *Frontiers in Plant Science*, 15, 1433552. <https://doi.org/10.3389/fpls.2024.1433552>
- World Food Programme. (2025). *WFP 2026 Global Outlook: Hunger and hope—Innovative solutions to address food insecurity*. <https://docs.wfp.org/api/documents/WFP-0000170274/download/>
- Zenteno, N. A. R., Zebadúa Martínez, C. C., Morales Navarro, N. A., Pérez Patricio, M., Cossío Martínez, A. G., y Nango Solís, G. B. (2025). Estimación del índice de crecimiento de la lechuga mediante el aprendizaje profundo. *Revista Tecnología Digital*, 15. [http://www.revistatecnologiadigital.com/pdf/15\\_ael\\_estimacion\\_indice\\_crecimiento\\_lechuga\\_aprendizaje\\_profundo.pdf](http://www.revistatecnologiadigital.com/pdf/15_ael_estimacion_indice_crecimiento_lechuga_aprendizaje_profundo.pdf)