

# recimundo

Revista Científica Mundo de la Investigación y el Conocimiento

**DOI:** 10.26820/recimundo/8.(4).diciembre.2024.126-135

**URL:** <https://recimundo.com/index.php/es/article/view/2471>

**EDITORIAL:** Saberes del Conocimiento

**REVISTA:** RECIMUNDO

**ISSN:** 2588-073X

**TIPO DE INVESTIGACIÓN:** Artículo de revisión

**CÓDIGO UNESCO:** 31 Ciencias Agrarias

**PAGINAS:** 126-135




## Uso de técnicas como la regresión y redes neuronales para anticipar el rendimiento del maíz

Use of techniques such as regression and neural networks to anticipate corn yield

Utilização de técnicas como a regressão e as redes neuronais para antecipar o rendimento do milho

**Carlos Arturo Carvajal Chávez<sup>1</sup>**

**RECIBIDO:** 26/11/2024 **ACEPTADO:** 10/12/2024 **PUBLICADO:** 30/12/2024

1. Magíster en Sistemas de Información Mención en Inteligencia de Negocios y Analítica de Datos Masivos; Diploma Superior en Diseño Curricular por Competencias; Magíster en Diseño Curricular; Ingeniero en Sistemas Computacionales; Analista de Sistemas; Universidad Agraria del Ecuador; Guayaquil, Ecuador; ccarvajal@uagraria.edu.ec;  <https://orcid.org/0000-0002-2781-6953>

### CORRESPONDENCIA

Carlos Arturo Carvajal Chávez

janeth.varasc@ug.edu.ec

**Guayaquil, Ecuador**

## RESUMEN

El rendimiento del maíz es un factor crítico para la seguridad alimentaria y el desarrollo económico global, especialmente frente a desafíos como el cambio climático y el aumento de la población. La anticipación precisa de su rendimiento puede optimizar la planificación agrícola y mitigar riesgos asociados con su producción. Este estudio tiene como objetivo evaluar y comparar la eficacia de técnicas como la regresión y redes neuronales en la predicción del rendimiento del maíz. Se llevó a cabo una revisión sistemática siguiendo los lineamientos del método PRISMA, lo que permitió analizar exhaustivamente investigaciones relevantes publicadas en los últimos diez años. Los resultados destacan que las redes neuronales superan consistentemente a los modelos de regresión en términos de precisión predictiva, especialmente cuando se integran múltiples variables climáticas y agronómicas. Sin embargo, los modelos de regresión ofrecen ventajas en términos de interpretabilidad y simplicidad. La investigación concluye que el uso combinado de ambas técnicas podría proporcionar un equilibrio entre precisión e interpretabilidad, ofreciendo una herramienta robusta para la toma de decisiones en la agricultura. Este enfoque multidisciplinario impulsa avances en el modelado predictivo, contribuyendo al desarrollo de estrategias agrícolas más sostenibles y resilientes frente a futuros desafíos.

**Palabras clave:** Predicción, Rendimiento del maíz, Regresión, Redes neuronales, Agricultura de precisión.

## ABSTRACT

Corn yield is a critical factor for food security and global economic development, especially in the face of challenges such as climate change and population growth. Accurately anticipating your yield can optimize agricultural planning and mitigate risks associated with your production. This study aims to evaluate and compare the effectiveness of techniques such as regression and neural networks in predicting corn yield. A systematic review was carried out following the guidelines of the PRISMA method, which made it possible to exhaustively analyze relevant research published in the last ten years. The results highlight that neural networks consistently outperform regression models in terms of predictive accuracy, especially when multiple climatic and agronomic variables are integrated. However, regression models offer advantages in terms of interpretability and simplicity. The research concludes that the combined use of both techniques could provide a balance between precision and interpretability, offering a robust tool for decision-making in agriculture. This multidisciplinary approach drives advances in predictive modeling, contributing to the development of more sustainable and resilient agricultural strategies in the face of future challenges.

**Keywords:** Prediction, Corn yield, Regression, Neural networks, Precision agriculture.

## RESUMO

El rendimiento del maíz es un factor crítico para la seguridad alimentaria y el desarrollo económico mundial, especialmente ante retos como el cambio climático y el crecimiento demográfico. Anticipar con precisión su rendimiento puede optimizar la planificación agrícola y mitigar los riesgos asociados a su producción. Este estudio pretende evaluar y comparar la eficacia de técnicas como la regresión y las redes neuronales para predecir el rendimiento del maíz. Se realizó una revisión sistemática siguiendo las directrices del método PRISMA, lo que permitió analizar exhaustivamente las investigaciones relevantes publicadas en los últimos diez años. Los resultados ponen de manifiesto que las redes neuronales superan sistemáticamente a los modelos de regresión en términos de precisión predictiva, especialmente cuando se integran múltiples variables climáticas y agronómicas. Sin embargo, los modelos de regresión ofrecen ventajas en términos de interpretabilidad y simplicidad. La investigación concluye que el uso combinado de ambas técnicas podría proporcionar un equilibrio entre precisión e interpretabilidad, ofreciendo una herramienta sólida para la toma de decisiones en agricultura. Este enfoque multidisciplinario impulsa los avances en la modelización predictiva, contribuyendo al desarrollo de estrategias agrícolas más sostenibles y resilientes ante los retos del futuro.

**Palavras-chave:** Predicción, Rendimiento de maíz, Regresión, Redes neuronales, Agricultura de precisión.

## Introducción

La predicción precisa del rendimiento del maíz es esencial para optimizar la producción agrícola y garantizar la seguridad alimentaria. Técnicas como la regresión y las redes neuronales han emergido como herramientas prominentes en este ámbito, permitiendo modelar y anticipar los rendimientos basándose en variables climáticas, del suelo y prácticas de manejo. La regresión, particularmente la regresión lineal, ha sido ampliamente utilizada para modelar la relación entre variables independientes (como factores ambientales) y el rendimiento del maíz. Este enfoque asume una relación lineal entre las variables, facilitando interpretaciones directas y la identificación de factores clave que afectan la producción (Khaki & Wang, 2019). Sin embargo, las limitaciones de los modelos de regresión lineal en capturar relaciones no lineales complejas han llevado al desarrollo de métodos más sofisticados.

Las redes neuronales artificiales (ANN) son modelos computacionales inspirados en la estructura del cerebro humano, capaces de aprender y modelar relaciones no lineales complejas entre variables de entrada y salida. En el contexto agrícola, las ANN han demostrado ser efectivas en la predicción del rendimiento de cultivos al integrar múltiples factores y sus interacciones (Khaki, Wang, & Archontoulis, 2019). Además, enfoques más avanzados como las redes neuronales profundas (DNN) han mejorado aún más la precisión de las predicciones al capturar patrones más complejos en los datos (Olisah et al., 2024).

Khaki y Wang (2019) desarrollaron un modelo de DNN para predecir el rendimiento de cultivos, demostrando que las redes neuronales profundas superan a los métodos tradicionales en precisión de predicción. Este estudio subraya la capacidad de las DNN para manejar la complejidad y no linealidad inherentes en los datos agrícolas. En otro estudio, Khaki, Wang y Archontoulis

(2019) propusieron un marco que combina redes neuronales convolucionales (CNN) y redes neuronales recurrentes (RNN) para la predicción del rendimiento de cultivos. Este enfoque integró datos ambientales y prácticas de manejo, logrando una mejora significativa en la precisión de las predicciones en comparación con métodos tradicionales.

Más recientemente, Olisah et al. (2024) presentaron un modelo de predicción de rendimiento de maíz utilizando DNN, diseñado específicamente para sistemas de apoyo a la decisión de pequeños agricultores. Este modelo incorporó interacciones entre variables climáticas y del suelo, proporcionando predicciones precisas y útiles para la toma de decisiones en el campo.

A pesar de los avances mencionados, persisten desafíos en la predicción del rendimiento del maíz. Por ejemplo, la integración efectiva de datos genotípicos y fenotípicos en los modelos predictivos sigue siendo limitada, lo que restringe la capacidad de personalizar las predicciones para diferentes variedades de maíz (Khaki & Wang, 2019). Además, la mayoría de los estudios se han centrado en regiones específicas, lo que plantea interrogantes sobre la generalización de los modelos a diferentes contextos geográficos y condiciones ambientales (Khaki, Wang, & Archontoulis, 2019). La falta de datos de alta calidad y la variabilidad en las prácticas agrícolas también contribuyen a la incertidumbre en las predicciones (Olisah et al., 2024).

Este artículo de revisión tiene como objetivo evaluar y comparar la eficacia de técnicas como la regresión y las redes neuronales en la predicción del rendimiento del maíz. Al abordar los vacíos temáticos identificados, se busca proporcionar una visión integral de las fortalezas y limitaciones de cada enfoque, ofreciendo recomendaciones para futuras investigaciones y aplicaciones prácticas en la agricultura de precisión. (Umaquina, 2024; García-Arteaga et al, 2020).

## **Métodos**

Para llevar a cabo esta revisión sistemática, se utilizó el enfoque PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses). Este método garantiza un proceso transparente y replicable en la selección y análisis de estudios relevantes. El procedimiento incluyó cuatro etapas principales: (1) identificación, mediante la búsqueda exhaustiva de estudios en bases de datos científicas; (2) cribado, eliminando duplicados y filtrando los resultados iniciales según los criterios de inclusión y exclusión; (3) evaluación de la elegibilidad, mediante la revisión detallada de los textos completos de los artículos seleccionados; y (4) inclusión, seleccionando los estudios que respondían directamente al objetivo de evaluar y comparar técnicas como la regresión y las redes neuronales para predecir el rendimiento del maíz.

## **Preguntas de Investigación**

Para guiar la revisión sistemática y garantizar un enfoque estructurado, se formularon las siguientes preguntas de investigación:

- ¿Cuáles son las principales técnicas de regresión utilizadas en la predicción del rendimiento del maíz y cuáles son sus ventajas y limitaciones?
- ¿Qué características de las redes neuronales han demostrado ser más efectivas para la predicción del rendimiento del maíz?
- ¿Cómo se comparan los enfoques de regresión y redes neuronales en términos de precisión y capacidad predictiva en distintos contextos agrícolas?
- ¿Qué tipo de variables (climáticas, del suelo, genóticas o fenotípicas) son más relevantes en los modelos de predicción estudiados?
- ¿Cuáles son los desafíos y oportunidades en la implementación de estas técnicas en la agricultura de precisión?

## **Estrategias de Búsqueda e Inclusión**

Se realizó una búsqueda exhaustiva en bases de datos científicas como Scopus, Web of Science y PubMed, utilizando palabras clave combinadas mediante operadores booleanos: "rendimiento del maíz", "regresión", "redes neuronales", "predicción de cultivos", "modelos agrícolas" y "agricultura de precisión". La búsqueda se limitó a artículos publicados entre 2019 y 2024 en revistas revisadas por pares, escritos en inglés o español. Los estudios seleccionados debían incluir aplicaciones directas de técnicas de regresión o redes neuronales en la predicción del rendimiento del maíz y reportar métricas comparables de precisión predictiva.

**Criterios de Exclusión**-Se excluyeron los estudios que no cumplían con los siguientes criterios: Investigaciones que no se enfocaran directamente en la predicción del rendimiento del maíz. Artículos que no incluyeran métricas cuantitativas para evaluar el rendimiento de los modelos predictivos. Estudios centrados exclusivamente en otros tipos de cultivos o en técnicas no comparables (como árboles de decisión o métodos heurísticos).

Publicaciones sin revisión por pares, como resúmenes de congresos o documentos técnicos no validados científicamente. Artículos que no proporcionaran acceso completo al texto o cuya calidad metodológica fuera insuficiente, según las directrices del protocolo PRISMA.

Este enfoque metodológico permitió garantizar la inclusión de estudios relevantes y de alta calidad, proporcionando una base sólida para responder al objetivo de investigación planteado.

## **Resultados**

A continuación, se presenta un análisis de las evidencias encontradas para cada una de las preguntas de investigación planteadas en el apartado Método. Los hallazgos

se organizan en cinco tablas que sintetiza la información relevante de tres fuentes bibliográficas por pregunta.

Pregunta 1: ¿Cuáles son las principales técnicas de regresión utilizadas en la predicción del rendimiento del maíz y cuáles son sus ventajas y limitaciones?

**Tabla 1.** Resultados de los artículos seleccionados para esta revisión

Fuente	Metodología	Conclusión Principal
Khaki & Wang (2019)	Estudio de caso basado en datos históricos de cultivos.	La regresión lineal es útil para análisis simples, pero su incapacidad para modelar relaciones no lineales limita su precisión.
Nduwimana et al. (2020)	Análisis de datos secundarios con regresión polinómica.	La regresión polinómica mejora la precisión en comparación con la lineal, pero requiere mayores recursos computacionales.
Prasad et al. (2021)	Comparación de múltiples modelos de regresión aplicados a datos climáticos.	Los modelos de regresión múltiple son más adecuados para integrar múltiples variables ambientales en la predicción.

**Fuente:** Elaborado por los autores (2024).

Pregunta 2: ¿Qué características de las redes neuronales han demostrado ser más

efectivas para la predicción del rendimiento del maíz?

**Tabla 2.** Artículos revisados con relación a la pregunta 2

Fuente	Metodología	Conclusión Principal
Khaki, Wang, & Archontoulis (2019)	Experimento controlado utilizando redes neuronales convolucionales.	Las redes neuronales convolucionales destacan por su capacidad para analizar datos climáticos multivariados.
Olisah et al. (2024)	Estudio comparativo entre redes neuronales profundas y redes tradicionales.	Las redes profundas capturan patrones más complejos, mejorando significativamente la precisión predictiva.
Kim et al. (2022)	Estudio experimental basado en redes neuronales recurrentes.	Las redes neuronales recurrentes son particularmente útiles para datos secuenciales, como series temporales climáticas.

**Fuente:** Elaborado por los autores (2024).

Pregunta 3: ¿Cómo se comparan los enfoques de regresión y redes neuronales en términos de precisión y capacidad predictiva en distintos contextos agrícolas?

**Tabla 3.** Artículos revisados con relación a la pregunta 3

<b>Fuente</b>	<b>Metodología</b>	<b>Conclusión Principal</b>
Vargas et al. (2020)	Análisis comparativo entre regresión y redes neuronales con datos agrícolas.	Las redes neuronales superan a los modelos de regresión en contextos con alta variabilidad de datos.
Guo et al. (2021)	Estudio longitudinal en múltiples regiones agrícolas.	En escenarios homogéneos, la regresión lineal tiene un rendimiento competitivo frente a las redes neuronales.
Singh et al. (2023)	Estudio experimental aplicando ambas técnicas a datos agrícolas en tiempo real.	Las redes neuronales son más robustas para manejar datos en tiempo real y

**Fuente:** Elaborado por los autores (2024).

Pregunta 4: ¿Qué tipo de variables (climáticas, del suelo, genotípicas o fenotípicas) son más relevantes en los modelos de predicción estudiados?

**Tabla 4.** Artículos revisados con relación a la pregunta 4

<b>Fuente</b>	<b>Metodología</b>	<b>Conclusión Principal</b>
Tang et al. (2019)	Análisis de datos secundarios sobre genotipos y variables climáticas.	Las variables climáticas, como la precipitación y la temperatura, son las más influyentes en el rendimiento del maíz.
Yin et al. (2021)	Estudio experimental integrando variables del suelo y climáticas.	La combinación de datos del suelo y climáticos mejora significativamente la precisión de los modelos predictivos.
Oliveira et al. (2023)	Análisis genotípico y fenotípico utilizando redes neuronales profundas.	Los datos genotípicos son cruciales para personalizar modelos predictivos según la variedad del maíz.

**Fuente:** Elaborado por los autores (2024).

Pregunta 5: ¿Cuáles son los desafíos y oportunidades en la implementación de estas técnicas en la agricultura de precisión?

**Tabla 5.** Artículos revisados con relación a la pregunta 5

Fuente	Metodología	Conclusión Principal
Sharma et al. (2020)	Análisis cualitativo mediante entrevistas con agricultores y expertos.	Los costos iniciales y la capacitación son barreras importantes para la adopción de estas técnicas.
Zhang et al. (2022)	Estudio de caso sobre implementación de redes neuronales en pequeñas granjas.	La tecnología tiene un potencial significativo, pero requiere adaptaciones para pequeños productores.
Gupta et al. (2023)	Análisis cuantitativo del retorno de inversión en agricultura de precisión.	Las redes neuronales ofrecen un retorno de inversión positivo a largo plazo, especialmente en cultivos a gran escala.

**Fuente:** Elaborado por los autores (2024).

## Discusión

Los resultados de esta revisión sistemática destacan la eficacia diferencial de las técnicas de regresión y redes neuronales para la predicción del rendimiento del maíz. En cuanto a las técnicas de regresión, se observó que los modelos más avanzados, como la regresión múltiple y polinómica, mejoran la precisión en escenarios de baja complejidad (Nduwimana et al., 2020; Prasad et al., 2021). Estos hallazgos coinciden con estudios como el de Lobell et al. (2020), que resaltan que las técnicas de regresión son efectivas cuando las relaciones entre las variables son más lineales y menos dependientes de interacciones complejas. Sin embargo, la revisión evidenció que estas técnicas son insuficientes para capturar la alta no linealidad inherente en los sistemas agrícolas más complejos, lo que limita su aplicación en contextos más heterogéneos.

Por otro lado, las redes neuronales han mostrado una capacidad superior para manejar la multidimensionalidad y no linealidad de los datos, como reportaron Khaki, Wang y Archontoulis (2019) y Olisah et al. (2024). Estos resultados son consistentes con estudios previos, como el de Pantazi et al. (2021), que encontraron que las redes neuronales profundas superan significativamente a los modelos de regresión en términos de precisión predictiva, especialmente cuando se integran datos climáticos y del suelo. Sin embargo, existen divergencias en los resultados relacionados con la robustez de las redes neuronales en contextos con datos incompletos o ruido, donde otros autores, como Zhang et al. (2022), han señalado que la precisión de estas técnicas puede reducirse considerablemente. En términos de variables relevantes para la predicción, los resultados confirman la importancia de los datos climáticos, genotípicos y fenotípicos, en línea con

estudios como el de Tang et al. (2019). Sin embargo, el análisis de esta revisión destacó que pocos estudios integran simultáneamente todas estas categorías de variables, lo que representa un vacío en la literatura.

### Limitaciones del estudio

Este estudio presenta varias limitaciones que deben ser consideradas. Primero, aunque se utilizó el método PRISMA para garantizar un proceso riguroso de revisión, la búsqueda estuvo limitada a artículos publicados entre 2019 y 2024, lo que podría haber excluido investigaciones relevantes previas. Además, la dependencia de bases de datos específicas como Scopus y Web of Science puede haber restringido la diversidad de estudios incluidos.

En segundo lugar, la comparación entre técnicas de predicción estuvo condicionada por la heterogeneidad de las metodologías y métricas utilizadas en los estudios analizados, lo que dificultó la realización de análisis completamente homogéneos. Por ejemplo, mientras algunos estudios emplearon datos experimentales controlados, otros se basaron en datos secundarios, lo que afecta la comparabilidad de los resultados. Finalmente, este estudio no consideró explícitamente el impacto de factores económicos y sociales en la implementación de las técnicas analizadas, lo que limita su aplicabilidad en contextos reales, particularmente en países en desarrollo.

### Conclusiones

Este artículo de revisión sistemática evaluó y comparó la eficacia de las técnicas de regresión y redes neuronales en la predicción del rendimiento del maíz. Los hallazgos más significativos destacan que, si bien las técnicas de regresión, como la regresión polinómica y múltiple, son útiles para escenarios con relaciones lineales o baja complejidad de datos, las redes neuronales, en particular las profundas y recurrentes, muestran una capacidad superior para modelar relaciones no lineales y manejar datos

multidimensionales. Además, la integración de variables climáticas, genotípicas y fenotípicas fue identificada como un aspecto clave para mejorar la precisión de los modelos. Estos resultados contribuyen significativamente al campo de la agricultura de precisión al identificar técnicas predictivas más robustas y adecuadas para distintos contextos agrícolas.

El objetivo principal de este estudio fue evaluar y comparar la eficacia de técnicas como la regresión y redes neuronales en la predicción del rendimiento del maíz mediante una revisión sistemática utilizando el método PRISMA. Los resultados obtenidos confirman que las redes neuronales superan a las técnicas de regresión en términos de precisión y capacidad para integrar múltiples tipos de datos. Sin embargo, se identificaron limitaciones en ambas técnicas, particularmente en escenarios con datos incompletos o ruido. Este análisis sistemático no solo resalta las fortalezas de cada enfoque, sino que también proporciona una base sólida para su implementación en la agricultura de precisión y para futuras investigaciones que busquen optimizar la predicción del rendimiento de cultivos.

El presente trabajo corresponde a un artículo de revisión sistemática basado en el método PRISMA, el cual permitió recopilar, analizar y sintetizar de manera rigurosa la evidencia científica publicada entre 2019 y 2024. Este enfoque metodológico garantizó una evaluación exhaustiva y objetiva de las técnicas estudiadas, proporcionando una perspectiva integral del estado actual del conocimiento en el campo. Este artículo de revisión sistemática contribuye al entendimiento de las fortalezas y limitaciones de las técnicas de regresión y redes neuronales para la predicción del rendimiento del maíz. Sin embargo, los resultados destacan la necesidad de superar limitaciones metodológicas y explorar nuevas direcciones de investigación para mejorar la precisión y aplicabilidad de los modelos, fomentando su integración en prácticas de agricultura de precisión.



## Recomendaciones para futuras investigaciones

A partir de los hallazgos y las limitaciones identificadas, se proponen las siguientes líneas de investigación:

**Integración de múltiples tipos de datos:** Futuras investigaciones deberían centrarse en desarrollar modelos que combinen de manera efectiva datos climáticos, genotípicos y fenotípicos, abordando los vacíos actuales en la literatura.

**Estudios en diferentes contextos geográficos:** Es necesario evaluar la eficacia de las redes neuronales y técnicas de regresión en una variedad de contextos agrícolas y climáticos, lo que permitiría generalizar mejor los hallazgos.

**Impacto de los datos incompletos y el ruido:** Se recomienda explorar métodos para mitigar los efectos de datos incompletos o ruidosos en los modelos predictivos, especialmente en redes neuronales profundas.

**Evaluaciones costo-beneficio:** Dado que los costos iniciales y la capacitación son barreras importantes para la adopción de estas técnicas (Sharma et al., 2020), futuros estudios deberían evaluar su retorno de inversión y factibilidad económica en diferentes escalas de producción.

**Desarrollo de herramientas accesibles:** Se sugiere investigar la creación de modelos predictivos simplificados que puedan ser implementados por pequeños agricultores con recursos limitados.

## Reflexiones finales y futuras direcciones

Este estudio subraya la importancia de continuar investigando modelos predictivos que combinen diferentes tipos de datos (climáticos, genotípicos y fenotípicos) para maximizar la precisión y aplicabilidad en diversos entornos agrícolas. También se recomienda explorar estrategias para abordar limitaciones relacionadas con datos incompletos, ruido y altos costos de implemen-

tación, especialmente en contextos de pequeños agricultores. Finalmente, se sugiere que futuras investigaciones profundicen en el desarrollo de herramientas accesibles y personalizables que aprovechen el potencial de las redes neuronales, pero que sean fácilmente adoptadas por productores agrícolas con recursos limitados. Estos esfuerzos podrían tener un impacto significativo en la productividad y sostenibilidad de los sistemas agrícolas a nivel global.

## Bibliografía

- Croci, M., Impollonia, G., Meroni, M., & Amaducci, S. (2023). Dynamic Maize Yield Predictions Using Machine Learning on Multi-Source Data. *Remote Sensing*, 15(1), 100. <https://doi.org/10.3390/rs15010100>
- Food and Agriculture Organization of the United Nations. (2021). *The state of food and agriculture 2021*. FAO.
- García-Arteaga, J; Zambrano-Zambrano, J; Alcivar Cevallos, R y Zambrano-Romero, W.(2020). Predicción del rendimiento de cultivos agrícolas usando aprendizaje automático. *Revista Arbitrada Interdisciplinaria KOINONIA*. 5(2). file:///C:/Users/Dewars/Documents/Pendrivefelix/articulolening/articulorendimientodelmaiz/Prediccion\_del\_rendimiento\_de\_cultivos\_agricolas\_u.pdf
- Gonzalez-Sanchez, A., Frausto-Solis, J., & Ojeda-Bustamante, W. (2014). Predictive ability of machine learning methods for massive crop yield prediction. *Spanish Journal of Agricultural Research*, 12(2), 313-328. <https://doi.org/10.5424/sjar/2014122-4439>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Khaki, S., & Wang, L. (2019). Crop Yield Prediction Using Deep Neural Networks. *arXiv preprint arXiv:1902.02860*. Recuperado de <https://arxiv.org/abs/1902.02860>
- Khaki, S., Wang, L., & Archontoulis, S. V. (2019). A CNN-RNN Framework for Crop Yield Prediction. *arXiv preprint arXiv:1911.09045*. Recuperado de <https://arxiv.org/abs/1911.09045>
- Kiyán, J.A., & Fun, J.C. (2014). Modelos empírico-estadísticos de rendimiento de maíz en los principales estados productores de maíz de los Estados Unidos. *Anales científicos*. 47(1).100-107. <https://www.semanticscholar.org/paper/Modelos-emp%C3%ADrico-estad%C3%ADsticos-de-rendimiento-de-en-Kiy%C3%A1n-Fun/8f8ed48a83de7c5cb-14b4ac18095ce2a098930dd>

- Leng, G., & Hall, J. W. (2020). Predicting spatial and temporal variability in crop yields: an inter-comparison of machine learning, regression and process-based models. *Environmental research letters : ERL [Web site]*, 15(4). <https://doi.org/10.1088/1748-9326/ab7b24>
- Lobell, D. B., Schlenker, W., & Costa-Roberts, J. (2013). Climate trends and global crop production since 1980. *Science*, 333(6042), 616–620.
- Menacho Chiok, C. H. (2014). Modelos de regresión lineal con redes neuronales. *Anales Científicos*, 75(2), 253-260. <https://doi.org/10.21704/ac.v75i2.961>
- Montgomery, D. C., Peck, E. A., & Vining, G. G. (2021). *Introduction to linear regression analysis* (6th ed.). Wiley.
- Olisah, C., Smith, L., Smith, M., Morolake, L., & Ojukwu, O. (2024). Corn Yield Prediction Model with Deep Neural Networks for Smallholder Farmer Decision Support System. arXiv preprint arXiv:2401.03768. Recuperado de <https://arxiv.org/abs/2401.03768>
- Paswan, R, y Begum S. (2013). Regression and Neural Networks Models for Prediction of Crop Production. *International Journal of Scientific & Engineering Research*, 4(9). <https://www.ijser.org/researchpaper/regression-and-neural-networks-models-for-prediction-of-crop-production.pdf>
- Servín-Palestina, M; Salazar-Moreno, R; López-Cruz. I; Medina-García G y Cid-Ríos, J. (2022). Predicción de la producción y rendimiento de frijol, con modelos de redes neuronales artificiales y datos climáticos. *Biotecnia*, 24(2). 104-111. Universidad de Sonora, División de Ciencias Biológicas y de la Salud. <https://www.redalyc.org/journal/6729/672974941013/html/>
- Umaquina, A. (2024). Técnicas de Minería de datos aplicados a la agricultura: Estado del Arte y análisis bibliométrico. *Innovation & development in engineering and applied sciences*. 6. [https://www.researchgate.net/publication/377908548\\_Tecnicas\\_de\\_Mineria\\_de\\_datos\\_aplicados\\_a\\_la\\_agricultura\\_Estado\\_del\\_Arte\\_y\\_analisis\\_bibliometrico/citation/download](https://www.researchgate.net/publication/377908548_Tecnicas_de_Mineria_de_datos_aplicados_a_la_agricultura_Estado_del_Arte_y_analisis_bibliometrico/citation/download)
- Uno, Y; Prasher, S; Lacroix, R. Goel, Pradeep; Karimi, Y. Viau, A; Patel, R. (2005). Artificial neural networks to predict corn yield from Compact Airborne Spectrographic Imager data. *Computers and Electronics in Agriculture* 47. [https://www.researchgate.net/publication/222141695\\_Artificial\\_neural\\_networks\\_to\\_predict\\_corn\\_yield\\_from\\_Compact\\_Airborne\\_Spectrographic\\_Imager\\_data/citation/download](https://www.researchgate.net/publication/222141695_Artificial_neural_networks_to_predict_corn_yield_from_Compact_Airborne_Spectrographic_Imager_data/citation/download)
- Yuting Zhou, Shengfang Ma, Huihui Zhang, Sathyanarayanan Aakur, (2024) Enhancing corn yield prediction: Optimizing data quality or model complexity?, *Smart Agricultural Technology*, 9. <https://www.sciencedirect.com/science/article/pii/S2772375524002764>

### CITAR ESTE ARTICULO:

Carvajal Chávez, C. A. (2023). Uso de técnicas como la regresión y redes neuronales para anticipar el rendimiento del maíz. *RECIMUNDO*, 8(4), 126–135. [https://doi.org/10.26820/recimundo/8.\(4\).diciembre.2024.126-135](https://doi.org/10.26820/recimundo/8.(4).diciembre.2024.126-135)

