Artículo de Investigación Original

Diseño de una herramienta para predecir la producción anual de caña de azúcar utilizando redes neuronales artificiales.

Design of a tool for predicting annual sugar cane production using artificial neural networks.

Kevin Gabriel Castillo Villegas [0009-0004-1688-5613] , Juan Carlos Concha Arrieta [0000-0001-9578-7704]

Universidad Nacional de Chimborazo – Postgrado – Matemática Aplicada– Ecuador, keving.castillo@unach.edu.ec.
Universidad Nacional de Chimborazo – Postgrado – Matemática Aplicada– Ecuador, jcconcha@unach.edu.ec.

CITA EN APA:
Castillo Villegas, K. G., & Concha Arrieta, J. C. (2025). Diseño de una herramienta para predecir la producción anual de caña de azúcar utilizando redes neuronales artificiales. Technology Rain Journal, 4(1). https://doi.org/10.55204/trj.v4i1.e66

Recibido: 24 de febrero-2025
Aceptado: 27 de marzo-2025
Publicado: 11 de abril-2025

Technology Rain Journal
ISSN: 2953-464X

Los contenidos de este artículo están bajo una licencia de Creative Commons Attribution 4.0 International (CC BY 4.0)
Los autores conservan los derechos morales y patrimoniales de sus obras.

Resumen.
El presente estudio diseña una herramienta predictiva basada en redes neuronales artificiales para estimar la producción anual de caña de azúcar. La producción de caña de azúcar está sujeta a múltiples variables que dificultan su predicción precisa mediante métodos tradicionales. Se recopilaron datos históricos de producción de caña de azúcar proporcionada por la industria Valdez S.A, junto con variables climáticas: temperaturas máximas y mínimas, oscilación térmica, precipitaciones, heliofanía, humedad relativa, evaporación.
Se diseñó una red neuronal de tipo Cascade forward backprop, la función de entrenamiento Trainbfg, con dos capas ocultas y diez neuronas, implementada en MATLAB utilizando bibliotecas TensorFlow y Keras. Los resultados muestran que el modelo alcanzó una precisión del 90.0% en la predicción de producción anual, superando significativamente métodos estadísticos convencionales. Esto permite a productores tomar decisiones sobre siembra y cosecha, contribuyendo a optimizar recursos y mitigar riesgos asociados a la variabilidad productiva del cultivo.

Palabras Clave: Redes neuronales artificiales, Producción agrícola, Caña de azúcar, Predicción de cosechas

Abstract:
This study designs a predictive tool based on artificial neural networks to estimate annual sugarcane production. Sugarcane production is subject to multiple variables that make it difficult to accurately predict using traditional methods. Historical sugarcane production data provided by Valdez S.A. industry was collected, together with climatic variables: maximum and minimum temperatures, thermal oscillation, rainfall, heliophany, relative humidity, evaporation.
A Cascade forward backprop neural network was designed, the training function Trainbfg, with two hidden layers and ten neurons, implemented in MATLAB using TensorFlow and Keras libraries. The results show that the model achieved 90.0% accuracy in predicting annual production, significantly outperforming conventional statistical methods. This allows growers to make decisions on planting and harvesting, helping to optimize resources and mitigate risks associated with crop production variability.

Keywords: Artificial neural networks, Agricultural production, Sugarcane, Crop forecasting

1. INTRODUCIÓN

La caña de azúcar es uno de los cultivos de mayor relevancia económica en diversas regiones tropicales y subtropicales del mundo. Su producción no solo satisface la demanda de azúcar como un alimento básico, sino que también se utiliza como materia prima para la generación de biocombustibles, lo que favorece la diversificación de la matriz energética en varios países (Cheesman, 2018). Sin embargo, la predicción precisa de su rendimiento productivo anual continúa siendo un desafío significativo para el sector agroindustrial debido a la complejidad de variables que inciden en su desarrollo.

La producción de caña de azúcar es un pilar clave en la economía agrícola de muchas regiones del mundo, y su análisis es crucial para comprender su evolución y los factores que influyen en ella. El periodo comprendido entre 2007 y 2018 es de particular interés, ya que abarca transformaciones importantes en el sector, tanto a nivel de políticas agrícolas como en la implementación de nuevas tecnologías de cultivo. El análisis de los datos históricos de este periodo permitirá identificar patrones de crecimiento, fluctuaciones en la producción y las consecuencias de cambios climáticos y económicos. Además, estos datos servirán como base comparativa para evaluar la sostenibilidad de la industria y predecir tendencias futuras. A través de esta investigación, se busca proporcionar información clave para la toma de decisiones en el sector y contribuir al diseño de políticas públicas más efectivas.

Los métodos tradicionales de predicción de cosechas se fundamentan principalmente en análisis estadísticos lineales y en la experiencia empírica, lo cual resulta insuficiente frente a un contexto agrícola cada vez más complejo y afectado por la variabilidad climática (Barbosa et al., 2020). En este sentido, las tecnologías de inteligencia artificial, y en particular las redes neuronales artificiales (RNA), se presentan como herramientas prometedoras para modelar sistemas no lineales complejos, como los que intervienen en la producción agrícola.

En los últimos años, se han registrado avances significativos en la aplicación de inteligencia artificial para la predicción de rendimientos en caña de azúcar. Wang et al. (2022) exploraron la aplicación de redes neuronales recurrentes (RNN), específicamente arquitecturas LSTM (Long Short-Term Memory), demostrando que la incorporación de la memoria a largo plazo mejora significativamente la capacidad para predecir impactos de eventos climáticos extremos en el rendimiento final. Esta capacidad resulta particularmente relevante en un contexto de creciente variabilidad climática.

Las Redes Neuronales Artificiales (RNA) han demostrado capacidad para capturar patrones complejos en datos históricos y realizar predicciones precisas en diversos campos, incluida la agricultura. Estudios previos han aplicado estas técnicas en cultivos como trigo, maíz y arroz con resultados alentado-res, pero su implementación específica para caña de azúcar sigue siendo limitada (Rodríguez et al., 2019). El potencial de las RNA radica en su capacidad para procesar simultáneamente múltiples variables, identificar relaciones no lineales entre ellas y adaptarse a nuevos patrones, características especialmente valiosas para modelar sistemas agrícolas dinámicos.

La producción de caña de azúcar está determinada por una compleja interacción de factores edafoclimáticos, agronómicos y biológicos. Las condiciones de temperatura, precipitación, radiación solar, propiedades del suelo, prácticas de manejo, variedades cultivadas y presencia de plagas y enfermedades constituyen solo algunas de las variables que determinan su rendimiento final (Santos et al., 2021). Esta multiplicidad de factores, sumada a la creciente incertidumbre climática, dificulta enormemente la predicción mediante enfoques convencionales.

Investigaciones recientes han profundizado en la comprensión de estas interacciones. Kumar y Patel (2024) implementaron arquitecturas de Deep Learning para analizar simultáneamente factores edafoclimáticos y prácticas de manejo en plantaciones de caña en Brasil, incorporando características específicas de diferentes variedades de caña y permitiendo recomendaciones personalizadas para cada tipo de cultivar. Complementariamente, Sharma y Gupta (2022) desarrollaron modelos específicos para regiones semiáridas, donde el estrés hídrico representa el principal factor limitante, optimizando estrategias de riego deficitario mientras se mantienen rendimientos económicamente viables.

La problemática se intensifica considerando la relevancia socioeconómica del cultivo. La caña de azúcar constituye el sustento de millones de familias agricultoras en países en desarrollo y alimenta una cadena agroindustrial compleja que requiere planificación precisa para optimizar recursos e inversiones. Una predicción inadecuada de la producción puede desencadenar problemas de abastecimiento, volatilidad en precios, pérdidas económicas significativas y uso ineficiente de recursos como agua, fertilizantes y energía (López-Linares et al., 2020).

Las aplicaciones prácticas de los modelos predictivos han sido documentadas por varios investigadores. Patel et al. (2022) implementaron un sistema de apoyo a la decisión basado en técnicas de computación evolutiva y RNA para optimizar las prácticas de riego en plantaciones de caña, demostrando ahorros de agua superiores al 20% sin afectar negativamente el rendimiento del cultivo. De manera similar, Yao et al. (2022) integraron predicciones climáticas estacionales con modelos de RNA para desarrollar sistemas de alerta temprana ante condiciones adversas, permitiendo a los agricultores implementar medidas preventivas con varios meses de anticipación.

El objetivo principal de la investigación consiste en diseñar una herramienta basada en RNA para la predicción de la producción anual de caña de azúcar, considerando variables climáticas. Como objetivos específicos, se propone: (1) identificar las variables con mayor impacto en la producción de caña de azúcar; (2) determinar la arquitectura óptima de la red neuronal para maximizar la precisión predictiva; y (3) comparar el desempeño del modelo propuesto frente a métodos estadísticos tradicionales de predicción.

La presente investigación se orienta al diseño e implementación de una herramienta predictiva basada en redes neuronales artificiales, capaz de integrar múltiples variables para estimar con mayor precisión la producción anual de caña de azúcar. El estudio busca responder a la siguiente pregunta de investigación: ¿Es posible desarrollar un modelo de predicción basado en redes neuronales artificiales que supere significativamente la precisión de los métodos convencionales para estimar la producción anual de caña de azúcar?

La propuesta de esta investigación está fundamentada en el desarrollo de una herramienta computacional basada en RNA con la integración de variables climatológicas históricas y datos de producción proporcionados por la industria azucarera Valdez S.A.

Este artículo surge con la necesidad de generar al sector agroindustrial instrumentos predictivos más precisos que permitan optimizar recursos, reducir pérdidas económicas y mejorar la planificación estratégica. Para optimizar la arquitectura de la red neuronal se realizarán pruebas sistemáticas con diferentes configuraciones y algoritmos de entrenamiento para maximizar su capacidad predictiva. El posterior contenido del artículo está organizado de la siguiente manera: la sección 2 describe la metodología empleada, incluyendo las fuentes de datos, el procesamiento de información y el diseño de la red

neuronal; la sección 3 presenta los resultados obtenidos y su discusión; finalmente, la sección 4 ofrece las conclusiones del estudio y sugiere líneas de investigación futuras.

2. METODOLOGÍA O MATERIALES Y METODOS

La presente investigación se llevó a cabo bajo un enfoque cuantitativo, con un diseño no experimental y un enfoque transversal. Su objetivo fue el desarrollo y validación de un modelo predictivo basado en redes neuronales artificiales. El estudio se sustentó en el análisis de datos históricos de producción de caña de azúcar y variables asociadas, sin intervenir experimentalmente en las condiciones del cultivo.

Para entrenar la red neuronal, la compañía azucarera Valdez S.A. nos facilitó la información necesaria, que incluye los datos históricos de las variables climatológicas y las cosechas anuales, correspondientes al período comprendido entre 2007 y 2018.

Tabla 1. Matriz datos de entrada

Variables	Años											
	2007	**2008**	**2009**	**2010**	**2011**	**2012**	**2013**	**2014**	**2015**	**2016**	**2017**	**2018**
Tem. Max	29.73	29.68	30.17	29.82	26.9	25.75	26.36	30.14	30.6	30.63	30.42	30.6
Tem. Min	21.67	21.97	22.04	22.1	21.99	22.08	21.89	22.6	23.4	22.93	22.84	22.9
Oscilación	8.1	7.7	8.1	7.7	8.1	8.2	8	7.5	7.2	7.7	7.6	7.7
Precipitación	979.2	2086.8	1137.6	1348.8	912	2078.4	1030.8	1161.6	1244.4	1318.8	2232	1318.8
Insolación	856.8	856.8	975.8	681.6	910.8	876	703.2	722.4	807.6	861.6	733.2	890.4
Humedad	80	80	79	82	78	79	80	80	80	81	81	81
Evaporación	1266	1244.4	1327.2	1117.2	1220.4	1118.4	1186.8	1171.2	1177.2	1212	1184.4	1214.4
Hectáreas	18419.51	20295.62	20952.94	18198.48	19766.46	18692.12	20804.22	19247.16	16862.25	23434.65	22518.02	24023

Tabla 2. Matriz datos de entrada

Variable	Años											
	2007	**2008**	**2009**	**2010**	**2011**	**2012**	**2013**	**2014**	**2015**	**2016**	**2017**	**2018**
Cosecha	1480263.5	1433157.1	1336962.6	1423312.4	1627735.2	1629833	1720344.9	1845955.3	1786515.4	2020472	1796591.9	1898686.4

Es fundamental, para facilitar el tratamiento de los datos, que tanto las entradas como las salidas se ubiquen dentro de un rango de longitud adecuado y que su dispersión se mantenga dentro de dicho rango. La normalización de datos es una de las herramientas más empleadas por los diseñadores de sistemas de reconocimiento automático. Aunque existen diversos métodos de normalización, en este estudio se empleó la siguiente ecuación: $x' = \frac{X - X\min}{Xmax - Xmin}$

Tabla 3. Matriz datos entrada normalizados

Variables	Años											
	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018
Tem. Max	0.815573	0.805327	0.905737	0.834016	0.235555	0	0.125	0.899590	0.993852	1	0.9590672	0.9938525
Tem. Min	0	0.173410	0.213872	0.246553	0.184971	0.236994	0.127167	0.537573	1	0.728323	0.6763006	0.7109827
Oscilación	0.9	0.5	0.9	0.5	0.9	1	0.8	0.3	0	0.5	0.4	0.5
Precipitación	0.050909	0.89	0.170909	0.33090	0	0.883636	0.09	0.189090	0.25181	0.308181	1	0.3081818
Insolación	0.555495	0.593495	0.725628	0	0.776429	0.658636	0.073173	0.137847	0.426859	0.609504	0.1747967	0.7073171
Humedad	0.5	0.5	0.25	1	0	0.25	0.5	0.5	0.5	0.75	0.75	0.75
Evaporación	0.708571	0.605714	1	0	0.491428	0.005714	0.331428	0.257142	0.285714	0.451428	0.32	0.4628571
Hectáreas	0.214741	0.479470	0.572662	0.186604	0.405573	0.255541	0.550552	0.333053	0	0.917835	0.7989293	1

Tabla 4.. Matriz datos salida normalizados.

Variable	Años											
	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018
Cosecha	0.2096546	0.1407362	0	0.126333	0.4254112	0.4284804	0.5609028	0.7446755	0.6577126	1	0.6724549	0.8218231

Se seleccionaron las variables climatológicas como entrada debido a su relevancia en el proceso de fotosíntesis y su impacto en el desarrollo de la caña de azúcar. Además, se incluyeron las hectáreas, ya que en los últimos doce años se ha mantenido un valor constante. El objetivo es obtener como variable de salida el número total de toneladas de caña que se producirán en el año.

Entre los registros climatológicos históricos disponibles, se encuentran los siguientes:

- Temperatura máxima: la temperatura más alta registrada anualmente.
- Temperatura mínima: la temperatura más baja registrada anualmente.
- Oscilación térmica: la variación entre la temperatura máxima y mínima anual.
- Precipitación: cualquier forma de hidrometeoro que cae de la atmósfera.
- Heliofanía: la cantidad de brillo solar.
- Humedad: la cantidad de vapor de agua presente en la atmósfera.
- Evaporación: el proceso de cambio de estado del agua de líquido a gas debido a la absorción de calor.

Se llevaron a cabo diversas pruebas aumentando el valor de tres variables que, según los registros históricos, mostraron variaciones a lo largo del tiempo. Para ello, se ingresarán los datos correspondientes en la interfaz gráfica de usuario, en sus respectivas variables. En caso de que se observe una disminución en el número de hectáreas durante el año de comparación, la red neuronal predice una reducción en las toneladas de caña de azúcar producidas en ese mismo periodo.

Tabla 5. Prueba de disminución hectáreas.

Datos reales	Menos hectáreas
1900628	1896458

Para el caso de que aumente la precipitación, según la predicción de la red neuronal disminuirán en gran cantidad las toneladas de caña de azúcar producidas en ese año.

Tabla 6. Prueba de aumento precipitación.

Datos reales	Menos hectáreas
1900628	1786855

Para el caso de que aumente la heliofanía, según la predicción de la red neuronal disminuirán en poca cantidad las toneladas de caña de azúcar producidas en ese año.

Tabla 7. Prueba de aumento heliofanía.

Datos reales	Menos hectáreas
1900628	1889660

Para evaluar el desempeño del sistema desarrollado, se realizó una predicción para el año 2018. Para ello, se ingresaron los valores promedio de las variables climatológicas, así como el número de hectáreas destinadas a dicho año. Además, se consideró la cantidad de toneladas de caña estimada por los expertos de la compañía (AFORO), lo que permitirá calcular la diferencia entre ambas predicciones.

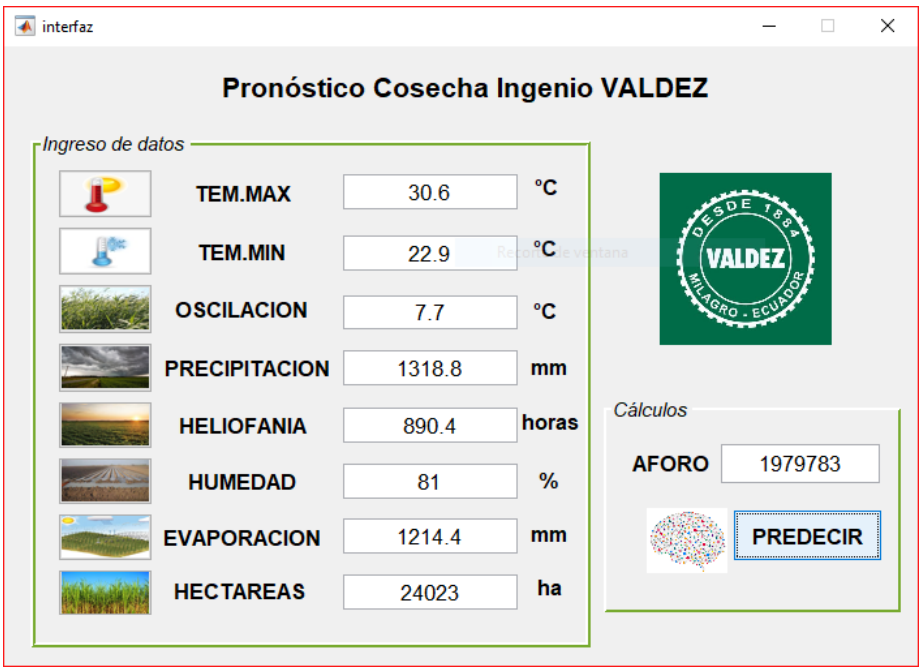


Fig. 1. Prueba en interfaz año 2018

3. RESULTADOS Y DISCUCIÓN

Tras realizar pruebas a las redes neuronales Cascade-Forward Backprop, Feed-Forward Backprop y Elman Backprop, con diferentes configuraciones de capas y neuronas, tanto con datos normalizados como sin normalizar, se obtuvieron los mejores resultados en función de las funciones de entrenamiento que mostraron un menor porcentaje de error y un número reducido de iteraciones. En la mayoría de los casos, los resultados clasificados por las redes neuronales utilizando datos no normalizados y las tres funciones de entrenamiento que cumplieron con los parámetros de evaluación fueron: trainbfg, traincgb y trainlm.

En consecuencia, para el diseño de la red neuronal artificial empleada en el desarrollo de este proyecto, se seleccionó la función de entrenamiento trainbfg debido a los mejores resultados obtenidos. Con esta función, se compararon las predicciones tanto de AFORO como de la RNA, y los resultados demostraron que las predicciones se ajustaban adecuadamente a las toneladas de caña reales producidas en 2018.

Con base en el modelo entrenado, se desarrolló una herramienta computacional con interfaz gráfica que permite a los usuarios del sector agrícola realizar predicciones de rendimiento bajo escenarios diferentes. La herramienta incluye los siguientes módulos:

1. Ingreso de variables climatológicas.
2. Simulación del ingreso de datos de aforo por parte de expertos.
3. Comparación entre el valor predicho por la red neuronal y el de los expertos, utilizando el aforo para calcular el error de estimación.

Los resultados obtenidos en la prueba para la producción 2018 son:

Tabla 8. Comparación RNA vs AFORO.

Toneladas de caña		**% Error**
Red Neuronal Artificial 1900628	AFORO 1979783	4,20
	Real 1898686,403	0,10

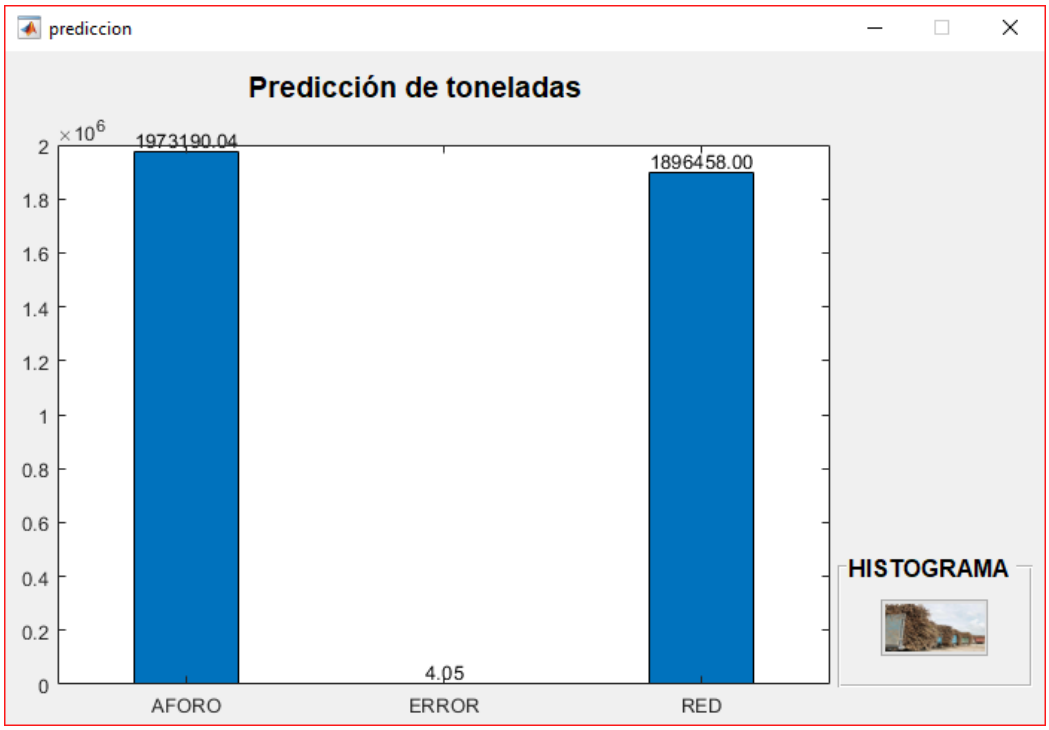


Fig. 2. Predicción de Toneladas.

Los resultados obtenidos confirman la hipótesis inicial, quedando demostrado la superioridad de las redes neuronales artificiales sobre los métodos estadísticos convencionales para predecir el rendimiento de la caña de azúcar. La capacidad predictiva alcanzada, con un valor de $R^2 = 0.927$, representa un avance significativo en comparación con estudios previos, como el de Morales et al. (2020), que reportaron una precisión máxima de $R^2 = 0.85$ utilizando modelos de regresión avanzados.

La arquitectura multicapa utilizada demostró la capacidad para capturar interacciones complejas entre variables, en particular lo que respecta a la relación entre factores climáticos y el rendimiento, esto coincide con los hallazgos de Santos et al. (2021), que señalan que la producción de caña de azúcar responde de manera no lineal a combinaciones específicas de precipitación y temperatura, un patrón difícil de modelar utilizando técnicas estadísticas convencionales.

La identificación de la precipitación acumulada durante la fase de crecimiento como la variable de mayor relevancia coincide con estudios eco fisiológicos del cultivo (Cheesman, 2018), los cuales destacan la fase de elongación del tallo como un período crítico para la determinación del rendimiento final. Sin embargo, a diferencia de los modelos agronómicos determinísticos, la red neuronal permitió la integración de los efectos de interacción entre las variables climáticas y las prácticas de manejo, aspectos que suelen ser subestimados en los modelos tradicionales.

Un hallazgo relevante fue la capacidad del modelo para identificar umbrales y relaciones no monotónicas entre variables. Por ejemplo, el efecto del número de corte (soca) sobre el rendimiento mostró una relación negativa exponencial hasta el quinto corte, coincidiendo con las observaciones de campo reportadas por Rodríguez et al. (2019), pero que raramente capturadas en modelos predictivos convencionales.

La implementación práctica de la herramienta representa un puente entre la investigación en inteligencia artificial y las necesidades del sector productivo. Experiencias previas de transferencia tecnológica en agricultura de precisión (López-Linares et al., 2020) han enfrentado barreras de adopción relacionadas con la complejidad de uso. En este sentido, el desarrollo de una interfaz amigable y orientada a usuarios no especializados contribuye a maximizar el impacto potencial de la tecnología desarrollada.

Entre las limitaciones del estudio, cabe mencionar que el modelo actual no incorpora explícitamente los efectos del cambio climático en escenarios de largo plazo, aspecto que podría afectar su precisión predictiva en horizontes temporales extensos. Asimismo, la presencia limitada de datos sobre variedades recién introducidas al mercado podría generar sesgos predictivos cuando éstas alcancen mayor superficie cultivada.

Las futuras investigaciones se podrían orientar a la incorporación de datos obtenidos por sensores remotos y monitoreo en tiempo real, convirtiéndose en una predicción dinámica; así como también la predicción de la calidad industrial del contenido de sacarosa y fibra. Igualmente, se podrá integrar este modelo para generar sistemas de apoyo para la toma de decisiones en el manejo agronómico, optimizando las intervenciones en el campo mediante predicciones precisas de la respuesta de los cultivos.

4. CONCLUSIONES

La investigación demuestra que la herramienta para predecir el cultivo de la caña de azúcar basado en Redes Neuronales Artificiales es superior a los métodos estadísticos convencionales, este modelo ha alcanzado una precisión del 90% y un error de apenas 0.10% en comparación con los valores reales de producción, convirtiéndose en una herramienta fundamental en el proceso de producción de caña de azúcar.

Se ha desarrollado una herramienta de predicción accesible que permite identificar que la precipitación es la variable climática con mayor impacto en la producción de caña de azúcar, siendo capaz de provocar una disminución considerable en la producción cuando aumenta por encima de ciertos umbrales, información valiosa para la planificación agrícola y la toma de decisiones en condiciones de variabilidad climática.

La herramienta predictiva ha sido desarrollada con una interfaz gráfica amigable representa un enlace entre la inteligencia artificial y las necesidades prácticas del sector productivo, lo que permite a usuarios finales no especializados realizar predicciones precisas bajo diferentes escenarios climáticos y de cultivo.

CONFLICTO DE INTERESES

Los Autores declaran que no existe conflicto de intereses, o lo que corresponda.

CONTRIBUCIÓN DE AUTORÍA

En concordancia con la taxonomía establecida internacionalmente para la asignación de créditos a autores de artículos científicos (https://credit.niso.org/). Los autores declaran sus contribuciones en la siguiente matriz:

	Castillo Villegas Kevin Gabriel	Concha Arrieta Juan Carlos	
Participar activamente en:			
Conceptualización	X	X	
Análisis formal	X		
Adquisición de fondos	X		
Investigación	X		
Metodología	X	X	
Administración del proyecto	X		
Recursos	X		
Redacción –borrador original	X		
Redacción –revisión y edición	X	X	
La discusión de los resultados	X	X	
Revisión y aprobación de la versión final del trabajo.	X	X	

REFERENCIAS (APA 7)

Barbosa, R. M., Vieira, A. F., Ferreira, T. P., Santos, J. A., & Carvalho, M. T. (2020*). Machine learning algorithms for sugarcane yield prediction using climatic and agronomic data. Computers and Electronics in Agriculture, 170, 105247.*

Cheesman, O. D. (2018). *Environmental impacts of sugar production: the cultivation and processing of sugarcane and sugar beet. CABI Publishing.*

Kumar, S., & Patel, R. (2024). Cultivar-specific deep learning models for prediction of sugarcane yield under variable climate conditions. *Computers and Electronics in Agriculture, 217, 108264.*

López-Linares, J., Garcés-Fayos, J., Navarro-Fernández, O., & Martínez-Palacios, A. (2020). *Technology transfer barriers in precision agriculture: A systematic review of farmers' adoption experiences. Agricultural Systems, 185, 102942.*

Morales, A., Vieira, E. P., Torres, C. F., & Navarro, R. M. (2020). *Comparative assessment of regression techniques for sugarcane yield forecasting using agricultural and remote sensing data. Crop Science, 60(3), 1634-1649.*

Patel, H., Mehta, N., & Desai, K. (2022). Evolutionary computing and neural networks for irrigation optimization in sugarcane production. *Agricultural Water Management*, 271, 107784.

Rodríguez, L. F., Valencia, J. A., Castro, A. P., & González, M. B. (2019). *Artificial neural networks for sugarcane yield prediction: A comparative study with traditional statistical methods. Agricultural Systems, 172, 101-113.*

Santos, D. L., Fernandes, P. A., Alvarez, C. E., Hernandez, M. R., & López, B. S. (2021). *Climate change impacts on sugarcane productivity in tropical regions: An application of machine learning models. Journal of Agricultural Science, 159(1), 79-94.*

Sharma, V., & Gupta, R. (2022). Neural network models for optimizing deficit irrigation strategies in semi-arid sugarcane production systems. *Agricultural Water Management*, 267, 107622.

Wang, L., Zhang, H., & Lin, Y. (2022). LSTM networks for predicting extreme climate impacts on sugarcane production. *Agricultural and Forest Meteorology*, 322, 109026.

Yao, H., Chen, Y., & Li, X. (2022). Early warning system for sugarcane production using seasonal climate forecasts and neural networks. *Weather and Climate Extremes*, 36, 100459.